



Apprentissage automatique pour l'estimation de l'état de charge des batteries

Mémoire présenté

dans le cadre du programme de maîtrise en ingénierie

en vue de l'obtention du grade de maître ès sciences appliquées (M. Sc. A.)

PAR

© **Abderrahim Zilali**

Mai 2025

Composition du jury :

Yacine Benahmed, président du jury, Université du Québec à Rimouski

Mehdi Adda, directeur de recherche, Université du Québec à Rimouski

Maxime Berger, codirecteur de recherche, Université du Québec à Rimouski

Martin Otis, examinateur externe, Université du Québec à Chicoutimi

Dépôt initial le 08 Novembre 2024

Dépôt final le 06 Mai 2025

UNIVERSITÉ DU QUÉBEC À RIMOUSKI
Service de la bibliothèque

Avertissement

La diffusion de ce mémoire se fait dans le respect des droits de son auteur, qui a signé le formulaire « *Autorisation de reproduire et de diffuser un rapport, un mémoire ou une thèse* ». En signant ce formulaire, l'auteur concède à l'Université du Québec à Rimouski une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de son travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, l'auteur autorise l'Université du Québec à Rimouski à reproduire, diffuser, prêter, distribuer ou vendre des copies de son travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de la part de l'auteur à ses droits moraux ni à ses droits de propriété intellectuelle. Sauf entente contraire, l'auteur conserve la liberté de diffuser et de commercialiser ou non ce travail dont il possède un exemplaire.

A ma mère et mon père, à Yahya, Moha, Amine et Youssef, à 3mi, l3wich et Sofia, votre soutien constant a été ma force tout au long de ce chemin. Ce travail est le résultat de votre amour et de vos encouragements. Merci du fond du cœur...

REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude à toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce projet.

Mes premiers remerciements vont à Mehdi Adda et Maxime Berger, mes directeurs de recherche, pour leur encadrement rigoureux et leur engagement sans faille. Leurs commentaires constructifs, leur disponibilité et leurs conseils avisés ont été déterminants dans l'aboutissement de ce travail.

Je souhaite également témoigner toute ma reconnaissance à Khaled Ziane, dont le rôle a dépassé celui d'un simple encadrant. Il en a assumé toutes les responsabilités avec une implication remarquable. Son appui constant, tant sur le plan scientifique que logistique, a été essentiel dès le choix du sujet jusqu'à la finalisation du projet.

Une mention spéciale à Hussein Ibrahim pour son aide précieuse lors des phases critiques. Son soutien m'a permis de surmonter des défis majeurs et d'avancer avec sérénité.

À tous, je suis infiniment reconnaissant pour votre collaboration et votre contribution à la réussite de ce mémoire.

RÉSUMÉ

Ce mémoire se concentre sur l'implémentation des techniques d'apprentissage automatique pour l'estimation de l'état de charge (SOC) des batteries, en particulier pour les batteries lithium-ion. L'estimation de l'état de charge est difficile, car il s'agit d'un paramètre qui ne peut pas être mesurée directement, mais qui doit être déduite à partir d'autres quantités comme la tension de la batterie, le courant débité et la température de surface.

Ce travail vise à investiguer l'implémentation des méthodes d'apprentissage automatique pour estimer l'état de charge des batteries lithium-ion dans des conditions de charge dynamiques à différentes températures ambiantes. En particulier, il envisage l'estimation à basse température connues par ses défis majeurs en raison de l'altération des comportement électrochimique et dynamique de la batterie sous l'effet du froid.

Deux modèles d'apprentissage automatique sont proposés pour l'estimation, C-BLSTM-AE et CatBoost. Le premier, C-BLSTM-AE, repose sur une architecture hybride d'apprentissage profond. Il prend en entrée une séquence de mesures et prédit la valeur du SOC à la fin de cette séquence. Cette architecture est conçue pour capturer les dépendances spatio-temporelles, permettant ainsi de révéler les motifs complexes présents dans les séquences d'entrée. Le second modèle, CatBoost, utilise une approche basée sur les arbres de décision. Il prédit le SOC correspondant à un vecteur de mesures en s'appuyant sur une technique d'apprentissage par ensemble. Cette méthode consiste à corriger de manière séquentielle les erreurs commises par les arbres de décision, améliorant ainsi la précision des prédictions.

Afin d'optimiser le choix des hyperparamètres des algorithmes proposés, des expériences détaillées ont été menées qui prennent en compte la température ambiante lors des tests ainsi que la taille des données. Pour déterminer les valeurs optimales des hyperparamètres pour

chaque modèle, la stratégie de Grid Search a été suivie. Grid Search consiste à explorer de manière exhaustive la grille de combinaisons d'hyperparamètres. Chaque combinaison est évaluée lors de l'étape de test. Les résultats de ce mémoire mettent en évidence le potentiel de l'apprentissage automatique à estimer avec précision le SOC sans recourir à la modélisation physique de la batterie ni à la prise en compte de sa chimie. Le modèle C-BLSTM-AE atteint une erreur absolue moyenne (MAE) de 0,52 % dans des conditions de température ambiante fixe et une MAE de 1,03 % pour des températures variables. Le modèle **CatBoost**, quant à lui, atteint une MAE de **0,69 %** dans les températures fixes et une MAE de **1,09 %** dans les températures variables. De plus, il souligne l'influence de la température ambiante sur la qualité de l'estimation, montrant que la précision se dégrade à mesure que l'on se rapproche de conditions climatiques froides.

Le bilan sur la performance est établi, concluant que le modèle C-BLSTM-AE surpasse le modèle CatBoost en termes de précision, les estimations produites par le modèle CatBoost présentent davantage de fluctuations et de volatilité, tandis que celles du modèle C-BLSTM-AE sont plus stables et suivent de manière cohérente l'évolution réelle de l'état de charge. Un autre aspect à considérer est la rapidité de calcul. Le modèle C-BLSTM-AE demande un temps de rétro-propagation significatif, ce qui prolonge le temps de calcul sur CPU. Ainsi, l'entraînement du modèle C-BLSTM-AE a pris plusieurs milliers de secondes en CPU. En revanche, l'entraînement du modèle CatBoost a été bien plus rapide, nécessitant seulement quelques dizaines de secondes.

Mots clés : batteries Li-ion, état de charge, SOC, intelligence artificielle, apprentissage automatique

ABSTRACT

This thesis focuses on the implementation of machine learning algorithms for estimating the state of charge (SOC) of batteries, particularly lithium-ion batteries. Estimating the SOC is challenging because it cannot be measured directly; it must be inferred from other quantities such as battery voltage, current, and battery temperature.

The aim of research is to implement machine learning methods to estimate the state of charge of lithium-ion batteries under dynamic driving conditions at different ambient temperatures. Particularly, it focuses on the estimation at low temperatures which is known to pose major challenges due to the alteration of the electrochemical and dynamic behavior of the battery under the effect of cold.

We propose two machine learning models for SOC estimation C-BLSTM-AE and CatBoost. The first model, C-BLSTM-AE utilizes deep learning through a hybrid architecture. It takes a sequence of measurements as input to predict the SOC value at the end of the sequence. This architecture is designed to capture spatiotemporal dependencies thereby revealing complex patterns present in the input sequences. The second model is CatBoost uses a decision tree-based approach. It predicts the SOC corresponding to a vector of measurements by leveraging an ensemble technique. This method sequentially corrects errors made by the decision trees, thereby improving the global prediction accuracy.

Detailed experiments were conducted to optimize the hyperparameters of the algorithms, considering the ambient temperature during testing and the size of the dataset. To determine the optimal hyperparameters for each model, the Grid Search strategy was used. Grid Search consists of exhaustively exploring the set of hyperparameter combinations, with each combination evaluated during the testing phase.

The results of this thesis highlight the potential of machine learning to accurately estimate SOC without relying on battery physics-based modeling or considering its chemistry. The C-BLSTM-AE model achieved a mean absolute error (MAE) of

0.52% under fixed ambient temperatures and 1.03% MAE under variable temperatures. Whereas the CatBoost model reached 0.69% MAE at fixed temperatures and 1.09% MAE under varying temperature conditions. Additionally, it underscores the influence of ambient temperature on the quality of the estimation, showing that accuracy deteriorates as colder climatic conditions are approached. Finally, the thesis addresses the trade-off between estimation accuracy and the required computational resources.

The performance assessment concluded that the C-BLSTM-AE model outperforms CatBoost in terms of regression accuracy. The estimation produced by the CatBoost shows greater fluctuations and volatility whereas those by C-BLSTM-AE are more stable and consistently track the true state of charge evolution. Another consideration is the computational speed. The C-BLSTM-AE model required significant backpropagation time, leading to prolonged CPU computation. As a result, training the C-BLSTM-AE model took several thousand CPU seconds. In contrast the CatBoost model trained much faster requiring only a few tens of seconds.

Keywords: Li-ion batteries, State of charge, SOC, artificial intelligence, machine learning,

TABLE DES MATIÈRES

REMERCIEMENTS.....	vi
RÉSUMÉ	vii
ABSTRACT.....	ix
TABLE DES MATIÈRES	xi
LISTE DES FIGURES.....	xiii
LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES	xiv
INTRODUCTION GÉNÉRALE	14
1. MISE EN CONTEXTE	14
2. ESTIMATION DE L'ÉTAT DE CHARGE	15
3. PROBLÉMATIQUE	27
4. OBJECTIF DE RECHERCHE	28
5. MÉTHODOLOGIE.....	29
6. CONTRIBUTION DU TRAVAIL DE RECHERCHE.....	35
7. ORGANISATION DU MÉMOIRE	36
CHAPITRE 1 Notions de base sur l'intelligence artificielle	37
APPRENTISSAGE AUTOMATIQUE	38
1.1.1 Arbre de décision.....	39
1.1.2 Apprentissage par ensemble	40
1.1.3 <i>Boosting</i> du gradient.....	40
APPRENTISSAGE PROFOND.....	41
1.1.4 Réseau de neurones simple.....	42
1.1.5 Réseau de neurones convolutif.....	43
1.1.6 Réseau de neurones récurrent.....	44
1.1.7 Auto-encodeur	45

1.1.8 C-BLSTM-AE	46
APPRENTISSAGE PAR TRANSFERT DE CONNAISSANCE.....	47
CHAPITRE 2 Estimation de l'état de charge à base d'apprentissage automatique : comparaison entre le modèle CatBoost et le modèle C-BLSTM-AE	49
RESUME EN FRANÇAIS DU PREMIER ARTICLE.....	49
ABSTRACT	50
1. INTRODUCTION.....	50
2. BACKGROUND AND LITERATURE REVIEW	52
3. METHODOLOGY.....	56
4. EXPERIMENTAL SETUP AND TRAINING	62
5. MODEL EVALUATION	63
6. CONCLUSION	69
CONCLUSION GÉNÉRALE	75
RÉFÉRENCES BIBLIOGRAPHIQUES	79

LISTE DES FIGURES

Figure 1: Illustration de l'état de charge pour une batterie.....	15
Figure 2: Taxonomie des méthodes d'estimation de l'état de charge.....	16
Figure 3: Exemple de courbe de tension en circuit ouvert vs l'état de charge.....	19
Figure 4: Schéma de base pour l'estimation du SOC en utilisant le filtre de Kalman	20
Figure 5: Processus d'estimation du SOC en utilisant l'apprentissage automatique.....	22
Figure 6: Le diagramme montrant les étapes suivies dans la méthodologie	30
Figure 7: Anomalies présentes dans le jeu de données.....	31
Figure 8: Erreurs d'estimation du modèle C-BLSTM-AE pour différentes valeur de TW à chaque condition de température ambiante.....	34
Figure 9: Erreurs d'estimation du modèle CatBoost pour différentes valeurs Lavg à chaque condition de température ambiante	34
Figure 10: Programmation classique vs apprentissage automatique	38
Figure 11: Relation entre l'IA et l'apprentissage automatique.....	39
Figure 12: La logique d'un arbre de décision	40
Figure 13: Fonctionnement d'un neurone artificiel	43
Figure 14: L'image est décomposée en motifs locaux tels que les contours et les textures.....	44
Figure 15: Cellule LSTM.....	45
Figure 16: Principe de fonctionnement d'un auto-encodeur.....	45
Figure 17: Architecture du C-BLSTM-AE.....	46
Figure 18: Illustration de la technique Transfer Learning	48

LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES

SOC	<i>State of Charge</i>
AI	<i>Artificial Intelligence</i>
ML	<i>Machine Learning</i>
DT	<i>Decision Tree</i>
DL	<i>Deep Learning</i>
ANN	<i>Artificial Neural Network</i>
DNN	<i>Deep Neural Network</i>
FNN	<i>Feed Forward Neural Network</i>
CNN	<i>Convolutional Neural Network</i>
LSTM	<i>Long–Short Term Memory</i>
TCN	<i>Temporal Convolutional Neural Network</i>
OCV	<i>Open Circuit Voltage</i>
KF	<i>Kalman Filter</i>
MAE	<i>Mean Absolute Error</i>
RMSE	<i>Root Mean Squared Error</i>
MAX	<i>Mean Absolute Maximal Error</i>
CPU	<i>Central Process</i>

INTRODUCTION GÉNÉRALE

1. MISE EN CONTEXTE

Les *batteries lithium-ion* sont parmi les dispositifs de stockage d'énergie les plus prometteurs qui ont émergé au cours des dernières années. Elles sont composées de cellules individuelles qui sont les unités de base de stockage d'énergie. Chaque cellule est un dispositif électrochimique qui convertit l'énergie chimique en énergie électrique grâce à des réactions d'oxydoréduction (Saisset, R.2004). Une batterie est constituée de plusieurs cellules connectées entre elles, soit en série afin d'augmenter la tension globale, soit en parallèle pour accroître la capacité. Ces cellules sont ensuite regroupées en modules adaptés aux besoins spécifiques de l'application visée (Eddahech, 2013). Les batteries lithium-ion ont gagné en popularité et en application dans plusieurs gammes de produits électriques. Leur popularité résulte de plusieurs avantages (Placke et al., 2017) : les batteries lithium-ion sont très appréciées pour leur légèreté, offrant une densité énergétique élevée, ce qui les rend idéales notamment pour les véhicules électriques où le poids est un élément important. Elles possèdent aussi une longue durée d'utilisation, ce qui leur permet de supporter de nombreux cycles de charge et de décharge avant leur fin de vie, améliorant ainsi leur rentabilité économique. L'industrie automobile, en particulier celle des véhicules électriques, a largement adopté les batteries lithium-ion en raison de ces avantages. Cette adoption croissante impose que les systèmes de gestion d'énergie dans ces véhicules garantissent une utilisation fiable, sécuritaire et optimale de la batterie. L'état de charge, en anglais *State of Charge* (SOC) est paramètre clé dans la gestion d'énergie dans un véhicule électrique, sa connaissance permet une planification optimale des recharges et déplacements. Cependant, l'estimation précise de l'état de charge, reste un défi majeur, en raison de sa dépendance de nombreuses variables, comme les conditions de température, les cycles de charge/décharge

et les caractéristiques de vieillissement des cellules, ce qui compliquent le processus et nécessitent des modèles physiques sophistiqués pour une estimation fiable.

Ce chapitre est consacré à la définition de l'état de charge (SOC) des batteries, en présentant les différentes méthodes utilisées pour son estimation, ainsi que les spécificités propres à chacune.

2. ESTIMATION DE L'ÉTAT DE CHARGE

2.1 Définition de l'état de charge

L'état de charge (SOC) est un paramètre critique dans les systèmes de gestion des batteries, fournissant des informations sur l'autonomie restante de la batterie et aidant à assurer des performances optimales et une longue durée de vie. L'état de charge réfère au niveau de charge actuel d'une batterie, exprimé en pourcentage de sa capacité totale. Il indique la capacité disponible par rapport à la capacité totale de la batterie.

$$SOC_t = C_t / C_n \quad (1)$$

où SOC_t indique la valeur de l'état de charge à l'instant, C_t est la capacité instantanée, et C_n est la capacité nominale totale de la batterie. La Figure 1 illustre différents états de charge pour une cellule avec la valeur de SOC correspondante.




Figure 1: Illustration de l'état de charge pour une batterie

2.2 État de l'art sur les méthodes d'estimation de l'état de charge

L'estimation de l'état de charge est intrinsèquement difficile puisqu'il ne peut pas être mesuré directement (Lipu et al., 2018). Par conséquent, son estimation utilise des paramètres mesurables comme la tension et le courant de la batterie, la température de surface (How et al., 2019). En pratique, plusieurs méthodes sont utilisées pour l'estimation de l'état de charge.

De nombreuses méthodes ont été développées pour estimer avec précision l'état de charge des batteries lithium-ion, comme illustré dans la Figure 2, les méthodes d'estimation peuvent être subdivisées en deux catégories : les méthodes expérimentales, comme la méthode à base de comptage de Coulomb et la méthode de tension en circuit ouvert ainsi que les méthodes à base de données comme les méthodes à base du filtre de Kalman et les méthodes utilisant l'apprentissage automatique. Cette section présente un résumé de ces techniques.




Figure 2: Taxonomie des méthodes d'estimation de l'état de charge

2.2.1 Méthodes d'estimation classiques

2.2.1.1 Méthode de comptage de coulomb

La méthode de comptage de coulomb, également appelée méthode de comptage des ampères–heures, est une approche traditionnelle pour estimer l'état de charge des batteries (Zhang et al., 2020). Elle consiste à intégrer le courant de la batterie pour déterminer la charge stockée, qui est ensuite divisée par la capacité de charge totale de la batterie pour déterminer le SOC, comme illustré dans (2).

$$SOC_t = SOC_0 - \int_0^t \eta I(t) dt / C_n \quad (2)$$

où η est l'efficacité coulombique, SOC_0 représente la valeur initiale de l'état de charge, C_n est la capacité nominale et $I(t)$ est le courant électrique à l'instant t . Le η décrit le rapport entre les électrons consommés et les électrons disponibles pendant la charge et la décharge, supposé être de 0,9 pendant la charge et de 1,0 pendant la décharge.

L'avantage de cette méthode réside dans sa simplicité et sa stabilité (Zheng et al., 2018). Cette méthode est reconnue comme étant assez précise si l'état de charge initial de la batterie est connu (Xiong et al., 2017), les capteurs de courant sont précisément calibrés (Hannan et al., 2017), et la capacité maximale disponible de la batterie est correctement recalibrée sous diverses conditions de fonctionnement et niveaux de vieillissement de la batterie (Waag et al., 2014).

Malgré que la mise en œuvre de la méthode de comptage de coulomb dans l'estimation dynamique du SOC soit relativement simple, elle présente des limitations en termes de précision dues aux variations des conditions de fonctionnement de la batterie et à l'intégration du courant (Sepasi et al., 2014). Pour obtenir des estimations précises, il faut prolonger les périodes de surveillance et disposer de ressources de mémoire importantes. Néanmoins, cette méthode sert souvent de référence pour valider l'exactitude d'autres méthodes, en particulier dans les scénarios de tests de charge en continu de la batterie (Zhang et al., 2020).

2.2.1.2 Méthode de tension en circuit ouvert

Une autre méthode couramment employée dans l'estimation du SOC est la méthode de tension en circuit ouvert (OCV). Le succès de cette méthode est justifié par sa simplicité et sa grande précision (Shen et al., 2017). La méthode consiste à mesurer la tension en circuit ouvert et à définir son état de charge correspondant en utilisant un Tableau de correspondance, comme celui présenté à la Figure 3.

Cette méthode prend en compte que la résistance interne influe sur la tension en circuit fermé et impose un temps de repos suffisamment long de la cellule en circuit ouvert avant de pouvoir en mesurer l'OCV. La méthode utilise la force électromotrice stable de la batterie en état de circuit ouvert et sa relation avec son SOC pour estimer la valeur du SOC (Zheng et al., 2018).

Cette méthode d'estimation repose sur une approximation linéaire entre le SOC et l'OCV, mais cette corrélation n'est pas cohérente entre différentes batteries en raison de limitations telles que les variations de capacité et de matériau de l'électrode (Hannan et al., 2017).

Bien que cette méthode soit précise, elle présente un inconvénient majeur. Pour mesurer avec précision la tension en circuit ouvert des batteries lithium-ion, il est impératif que la chimie de la batterie soit au repos pour atteindre une condition d'équilibre, ce qui n'est pas possible lorsque la batterie est en fonctionnement (charge ou décharge); mesurer l'OCV pendant que la batterie est en fonctionnement entraîne une faible précision (Hannan et al., 2017). Finalement, les mesures de l'OCV sont également influencées par d'autres facteurs comme la température ambiante et le vieillissement de la batterie (He et al., 2012).




Figure 3: Exemple de courbe de tension en circuit ouvert vs l'état de charge

2.2.1.3 Méthodes à base du filtre de Kalman

L'estimation du SOC avec la méthode du filtre de Kalman, en anglais *Kalman Filter* (KF), est la méthode la plus utilisée dans les applications courantes, surtout pour l'estimation en temps réel. La méthode utilise des mesures en temps réel et un modèle de batterie pour affiner continuellement son estimation du SOC, améliorant la précision au fil du temps et dans diverses conditions de fonctionnement. Le principe de base de l'estimation est de relier les signaux mesurés de la batterie (tension, courant et température) avec un circuit électrique de la batterie. La première étape consiste à estimer une valeur du SOC en utilisant la méthode de comptage de coulomb discutée à la section 2.2.1. Ce calcul nécessite une valeur initiale du SOC qui peut être obtenue à partir de la relation entre le SOC et la tension en circuit ouvert (OCV) comme discuté à la section 2.2.2.

Ensuite, la deuxième étape consiste à estimer la tension du modèle à l'aide du circuit électrique équivalent choisi pour modéliser la batterie. Les paramètres de ce modèle sont déterminés en fonction de la tension mesurée, du courant et de la température en utilisant diverses méthodes d'estimation des variables d'états (Wang et al., 2016).

L'étape finale consiste à actualiser le gain de Kalman en comparant tensions modélisée et mesurée, puis utiliser leur écart pour corriger ce gain. Le SOC estimé est alors déterminé via ce gain actualisé suivant l'algorithme KF (Shrivastava et al., 2019). Les étapes du processus sont illustrées dans le schéma de la Figure 4.

En raison de sa grande précision et de ses caractéristiques d'auto-corrrection, l'estimation du SOC basée sur le filtre de Kalman est l'une des méthodes les plus célèbres pour l'estimation en ligne du SOC. Cependant, la performance de l'estimation du SOC basée sur le filtre de Kalman dépend fortement de la précision du modèle de circuit équivalent de la batterie et des informations de covariance de mesure (Xia et al., 2015).




Figure 4: Schéma de base pour l'estimation du SOC en utilisant le filtre de Kalman

Ces limitations dans les méthodes d'estimation actuelles incitent à investiguer des techniques d'estimation du SOC plus efficaces et plus précises. L'avènement de l'intelligence artificielle a accéléré la popularité de l'estimation du SOC basée sur l'apprentissage automatique et les données (Ng et al., 2020). Selon (Sesidhar et al., 2023), dans la dernière décennie, l'estimation de l'état de charge est devenue un sujet de grand intérêt pour la communauté d'apprentissage automatique.

2.2.2 Méthodes d'estimation basée sur l'apprentissage automatique

Au cours de la dernière décennie, la recherche sur les batteries s'est de plus en plus tournée vers l'utilisation d'algorithmes d'apprentissage automatique pour l'estimation de l'état de

charge. Plusieurs méthodes ont ainsi été proposées, démontrant le potentiel de ces techniques à offrir des estimations précises. Le processus d'estimation peut être synthétisé en cinq étapes successives :

- **Collecte des données** : Les premières étapes consistent à recueillir des données brutes durant les cycles de décharge, provenant de la batterie elle-même. Ces données incluent principalement la tension, le courant, la température de surface et la capacité nominale de la batterie.
- **Prétraitement des données** : Les données collectées sont ensuite soumises à un traitement n tenant compte des anomalies, les valeurs aberrantes et les valeurs manquantes, tout en normalisant les variables. Ce processus permet de constituer une base de données fiable pour l'entraînement du modèle. Ensuite, une étape de création de nouvelles caractéristiques est envisagée pour affiner l'estimation du SOC.
- **Sélection de technique et entraînement du modèle** : Après avoir choisi une méthode de régression adaptée, l'entraînement débute avec un sous-ensemble de données, appelé données d'entraînement, comprenant les variables caractéristiques ainsi que le SOC comme valeur cible.
- **Validation** : Une validation croisée est effectuée en subdivisant le jeu de données en trois sous-ensembles – entraînement, validation et test – afin d'évaluer la performance du modèle, d'ajuster ses hyperparamètres.
- **Test** : L'estimation du SOC est ensuite réalisée en utilisant de nouvelles données et caractéristiques, à partir de la base de données d'évaluation, pour tester la robustesse du modèle.

Ce processus, tel que représenté à la Figure 5, permet une estimation directe à partir des données (*data-driven*), sans nécessiter de modèle physique de batterie ni de tables de correspondance et indépendamment de leurs chimies et de leurs propriétés physiques.




Figure 5: Processus d'estimation du SOC en utilisant l'apprentissage automatique

De nombreuses recherches ont exploré l'application de l'apprentissage automatique pour l'estimation du SOC, en s'appuyant sur une variété d'algorithmes d'apprentissage. Ces travaux se concentrent sur l'amélioration de la précision et de la robustesse des estimations du SOC, tout en éliminant la dépendance à des modèles physiques complexes ou à des méthodes traditionnelles. Afin d'évaluer la précision des algorithmes proposés, l'erreur absolue moyenne (MAE) est fréquemment utilisée comme métrique. Elle présente l'avantage d'être simple à interpréter en exprimant l'erreur moyenne entre les prédictions du modèle et les valeurs réelles sans amplifier les grandes erreurs comme donnée par :

$$MAE = \frac{1}{N} \sum_{n=1}^N (|\widehat{SOC}_n - SOC_n|) \quad (2)$$

Parmi les algorithmes utilisés, on retrouve les réseaux de neurones dense (Dense NN). Par exemple, dans (Chemali et al., 2018) et dans (Vidal et al., 2020), les auteurs ont proposé un réseau de neurones dense de type à action directe (*feedforward* ou FFN) pour estimer l'état de charge.

Dans le travail (Chemali et al., 2018), vecteur d'entrées fourni au réseau est donné par $[V_t, T_t, Vavg_t, Iavg_t]$ où V_t est la tension, T_t est la température, $Vavg_t$ est la tension

moyenne et I_{avg_t} est le courant moyen sur une période de 400 s d'enregistrement de la batterie à l'instant t . La sortie du réseau correspond à l'état de charge estimé à l'instant t . Ces estimations ont été réalisées sous différentes températures extérieures, à savoir $-20\text{ }^{\circ}\text{C}$, $-10\text{ }^{\circ}\text{C}$, $0\text{ }^{\circ}\text{C}$ et $25\text{ }^{\circ}\text{C}$, en utilisant des cycles de décharge dynamiques pour évaluer la robustesse du modèle. Le modèle démontre particulièrement une grande fiabilité à $25\text{ }^{\circ}\text{C}$ où il a atteint sa meilleure performance avec une MAE de seulement 0,61 %. Une dégradation progressive des performances est observée aux températures plus basses en constatant que la MAE s'élève à 1,4 % à $-10\text{ }^{\circ}\text{C}$, puis atteint 3,4 % à $-20\text{ }^{\circ}\text{C}$.

Le réseau dans (Vidal et al., 2020) reçoit en entrée un vecteur de données composé des variables suivantes à l'instant t : la tension V_t , le courant I_t , la température de surface T_t , ainsi que les valeurs moyennes de la tension V_{avg_t} et du courant I_{avg_t} . L'inclusion de ces valeurs moyennes dans le vecteur d'entrée joue un rôle clé en permettant au modèle de capturer la tendance sous-jacente dans la séquence de données. Ces valeurs moyennes ont été calculées sur la base de 500 observations pour chacune des quantités représentant ainsi les variations moyennes de tension et de courant sur une période donnée d'une durée de 500 secondes. Cette approche aide à réduire les erreurs de l'estimation du SOC, contribuant ainsi à améliorer la précision de l'algorithme (Vidal et al., 2020). L'estimation a été réalisée à la fois pendant les phases de charge et de décharge de la batterie et pour plusieurs températures, soit $-10\text{ }^{\circ}\text{C}$, $0\text{ }^{\circ}\text{C}$, $10\text{ }^{\circ}\text{C}$, et $25\text{ }^{\circ}\text{C}$, permettant ainsi d'évaluer la précision du modèle dans des conditions thermiques variées, atteignant une MAE inférieure à 0.66 % à $25\text{ }^{\circ}\text{C}$ et une MAE de 0.84 % à $-10\text{ }^{\circ}\text{C}$.

D'autres travaux se sont concentrés sur l'utilisation des réseaux de neurones convolutifs (CNN) pour estimer l'état de charge. (Bhattacharjee et al., 2021) ont proposé un modèle basé sur un CNN à une dimension couplée à un mécanisme d'apprentissage par transfert. L'estimation repose sur l'inférence d'une séquence de données d'entrée comportant les trois mesures $[V_t, I_t, T_t]$ pour estimer le SOC à la fin de la séquence. Cette approche d'apprentissage par transfert exploite les connaissances acquises à partir de batteries de types différents pour améliorer la précision de l'estimation du SOC, même avec un jeu de données

réduit. Cette combinaison a permis à l'algorithme proposé de mieux généraliser les prédictions, en réussissant à estimer le SOC de batteries ayant des caractéristiques chimiques différentes de celles utilisées pour l'entraînement initial du modèle, ce qui a permis de démontrer la robustesse du modèle et sa capacité à s'adapter à des environnements variés et d'atteindre une MAE de 0.58 % à 25 °C.

Les auteurs de (Fan et al., 2022) ont proposé une architecture avancée de type CNN entièrement convolutionnelle, appelée U-Net, qui se distingue par sa capacité à estimer l'état de charge en utilisant uniquement des séquences temporelles de tension V_t et de courant I_t . Cette architecture, connue pour son efficacité en segmentation d'images, a été adaptée pour capturer les caractéristiques des données de tension et de courant, permettant ainsi une estimation précise du SOC dans des conditions de température dynamique. La méthode proposée permet d'estimer le SOC avec une MAE minimal de 1,0 % à 10 °C et une MAE minimal de 1,1 % à -20 °C.

(Hannan et al., 2020) ont proposé un réseau de convolution qui met en œuvre une stratégie d'apprentissage basée sur un pas d'apprentissage variable pour créer un modèle d'estimation du SOC à 25 °C et dans des températures variables (25 °C et -20 °C). Le modèle estime le SOC à partir de la séquence d'entrée $[V_t, I_t, T_t]$. Le modèle a atteint une MAE de 0,7 % à 25 °C aux températures d'entraînement fixes et une MAE de 1.55% aux températures d'entraînement variables (de -20 °C à 25 °C).

L'utilisation des modèles à base des cellules à mémoire longue et courte (LSTM) a également retenu l'attention pour l'estimation du SOC. Dans (Wong et al., 2021) les auteurs ont développé un modèle pour estimer l'état de charge des batteries lithium-ion à partir de séquences de données de tension, de courant et de température à 0 °C, 10 °C et 25 °C. Ce modèle repose sur une architecture de réseau de neurones profonds avec des cellules LSTM, permettant d'obtenir une précision avec une MAE de 1,17 %.

Dans (Chemali et al., 2017) les auteurs ont proposé un modèle basé sur un réseau récurrent de cellules de mémoire longue et courte (LSTM) et cellule RNN combinée pour l'estimation

du SOC. Ce modèle innovant combine des cellules LSTM, capables de capturer des patrons temporels à long terme avec des cellules récurrentes. Leur approche a été testée sur un jeu de données collecté à des températures ambiantes comprises entre 10 °C et 25 °C, démontrant une précision d'une MAE de 0,57 % à température ambiante fixe et une MAE de 1,6 % sur un jeu de données avec une température ambiante variée.

De nombreuses études ont également exploré l'utilisation des réseaux neuronaux convolutifs temporels (TCN) pour les tâches d'estimation de l'état de charge des batteries. (Yahia et al., 2023) ont développé un modèle TCN en utilisant comme données d'entrée les séquences de tension V_t , de courant I_t et de température T_t ainsi que les moyennes temporelles de tension V_{avg_t} et du courant I_{avg_t} . Les résultats obtenus par cette méthode se sont révélés comparables à ceux des modèles basés sur les réseaux de neurones récurrents et convolutifs, démontrant ainsi l'efficacité du TCN pour cette tâche de modélisation du SOC.

(Liu et al., 2021) ont combiné une architecture de type réseau neuronal convolutif temporel avec le mécanisme d'apprentissage par transfert pour améliorer l'estimation de l'état de charge. Cette méthode s'est avérée particulièrement efficace, atteignant une précision avec une MAE de 0,67 %. L'étude a également mis en avant les avantages de l'apprentissage par transfert, qui permet de transférer des connaissances d'une batterie à une autre tout en réduisant la quantité de données nécessaires pour l'entraînement du modèle. Cela facilite grandement l'adaptation à de nouvelles batteries, rendant la méthode plus flexible et applicable à une variété de configurations sans avoir besoin d'une collecte de données massive.

Les récentes avancées dans l'estimation de l'état de charge se sont de plus en plus orientées vers l'utilisation de réseaux basés sur des architectures de transformateurs. Les transformateurs, initialement développés pour des tâches de traitement du langage naturel, ont révolutionné le domaine de l'apprentissage automatique en offrant des performances de pointe dans une grande variété d'applications. Contrairement aux réseaux de neurones récurrents qui traitent les données de manière séquentielle, les transformateurs se distinguent par leur capacité à capturer des relations contextuelles à longue portée au sein des données

grâce à un mécanisme d'attention. Leur flexibilité et leur puissance ont fait des transformateurs une option prometteuse pour surmonter les limitations des approches traditionnelles telles que les RNN. Dans le travail de (Hannan et al., 2021), les auteurs ont proposé un modèle d'architecture de transformateur basé sur un cadre d'apprentissage auto-supervisé. Ce modèle a démontré des performances remarquables, avec une MAE très faible de 0,44 % dans des conditions de température ambiante constante, et une MAE de 0,7 % dans des conditions de température ambiante variables. Le modèle utilise la séquence $[V_t, I_t, T_t]$ pour estimer directement le SOC correspondant sans avoir besoin d'ajouter d'autres variables caractéristiques. Le modèle a pu être efficacement entraîné en seulement 5 époques et avec 20 % des données d'entraînement totales, permettant un transfert à une nouvelle cellule Lithium-ion avec une chimie différente, tout en maintenant des performances comparables à celles des modèles entraînés à partir de zéro.

2.3 Limites des méthodes d'estimation de l'état de charge

L'estimation de l'état de charge a suscité l'intérêt de la communauté de l'apprentissage automatique, et de nombreux algorithmes aux performances intéressantes ont été proposés à différentes température ambiantes.

Cependant, une analyse approfondie de la littérature scientifique met en lumière un déficit de recherches concernant l'application de ces méthodes dans des environnements à températures basses. Alors que les batteries lithium-ion – largement utilisées dans les véhicules électriques et les systèmes de stockage d'énergie – voient leurs performances significativement altérées par le froid, peu de travaux de recherche se sont focalisés sur l'implémentation conditions de températures basses (e.g. $-10\text{ }^{\circ}\text{C}$ et $-20\text{ }^{\circ}\text{C}$). La Table 1 donne un aperçu sur les températures considérées dans des travaux similaires ainsi que la précision de chaque travail permettant ainsi d'établir une comparaison.

Table 1: Comparaison avec les travaux similaires

Methodes	Erreur Absolue Moyenne (MAE)	Températures ambiante (°C)
Architecture Transformer (Hannan et al., 2021)*	0.44%	−20, −10, 0, 10, 25, 40
Proposé (C-BLSTM-AE)	0.52%	−20, −10, 0, 10, 25, 40
LSTM-RNN (Chemali et al., 2017)	0.57%	0, 10, 25
Réseau de Neurones Dense (Chemali et al., 2018)	0.61%	−20, −10, 0, 10, 25
Architecture TCN (Liu et al., 2021)	0.67%	0, 10, 25
Proposé (CatBoost)	0.69%	−20, −10, 0, 10, 25 40
Architecture LSTM (Wong et al., 2021)	1.17%	25

*Ce papier a utilisé deux jeu de données combinés pour l’entraînement du modèle

3. PROBLÉMATIQUE

Malgré les défis techniques et opérationnels, une estimation précise de l’état de charge est requise pour assurer la performance et la sécurité des systèmes de batteries, en particulier dans les applications critiques comme les véhicules électriques. C’est pourquoi le développement de méthodes et de solutions pour l’estimation précise de l’état de charge suscite un intérêt croissant au sein de l’industrie et la communauté scientifique.

L’estimation de l’état de charge à basse température soulève des défis particuliers. A température basse, le froid altère significativement le comportement des batteries, influençant leur comportement dynamique et compliquant davantage l’évaluation précise de l’état de charge.

Ainsi, la conception de modèles robustes, capables de s’adapter aux variations de température, représente un enjeu majeur. Une telle avancée permettrait de répondre aux attentes des utilisateurs dans des environnements divers et de maintenir une performance optimale des batteries, indépendamment des conditions climatiques.

4. OBJECTIF DE RECHERCHE

Ce travail vise à investiguer l'implémentation des méthodes d'apprentissage automatique pour estimer l'état de charge des batteries lithium-ion dans des conditions de charge dynamiques à différentes températures ambiantes. Contrairement aux modèles paramétriques, cette estimation est basée sur l'inférence directe des signaux mesurés émis par la batterie au pourcentage de charge restant. Les modèles d'intelligence artificielle offrent l'avantage de ne pas prendre en compte les caractéristiques chimiques internes de la batterie ni de recourir à un modèle électrique équivalent, ce qui constitue un atout pour l'estimation de l'état de charge qui est souvent influencé par des facteurs internes et externes à la batterie rendant ainsi l'estimation difficile. En particulier, l'estimation de l'état de charge à basse température soulève des défis majeurs en raison de l'altération du comportement électrochimique et dynamique de la batterie sous l'effet du froid.

L'objectif de ce mémoire est de combler les lacunes identifiées dans la littérature en proposant des modèles d'apprentissage automatique pour l'estimation de l'état de charge incluant le scénario couramment négligé des températures négatives. Alors que très peu de recherches ont considéré de telles conditions, cette mémoire propose des modèles d'estimation basés sur l'apprentissage automatique à 40 °C, 25 °C, 10 °C, 0 °C, -10 °C et -20 °C sous diverses conditions de charge. Ce mémoire améliore ainsi la compréhension du comportement de l'état de charge dans les environnements froids, élargissant ainsi l'applicabilité de l'estimation basée sur l'apprentissage automatique.

Afin de réaliser l'objectif global, des sous-objectifs ont été définis :

Étape 1 – Collecter les données d'entrée pour une phase de nettoyage et de prétraitement, assurant la qualité et la cohérence des données avant le début de la modélisation.

Étape 2 – Développer deux méthodes d'estimation en établissant la formulation mathématique du problème de modélisation ce qui permet une approche structurée et rigoureuse.

Étape 3 – Par le biais d’expérimentations, déterminer de façon empirique les meilleures longueurs de séquence et les valeurs optimales des hyperparamètres qui améliorent la performance de l’estimation en termes de précision.

Étape 4 – Comparer la performance de deux approches, non seulement en termes de précision d’estimation mais en évaluant aussi la de consommation des ressources.

5. MÉTHODOLOGIE

Cette section décrit la méthodologie adoptée pour l’estimation de l’état de charge. La méthodologie se compose de plusieurs étapes clés, elle commence par une phase de prétraitement des données qui comprend l’exploration, la gestion des valeurs manquantes et aberrantes, l’augmentation et la standardisation des données. Ensuite, une modélisation est effectuée à l’aide d’un réseau de neurone d’architecture hybride (C-BLSTM-AE) et un modèle à base d’arbres de décision (CatBoost) entraînés sur les données préparées. Enfin, une phase d’évaluation est menée sur les données de test, en utilisant différentes métriques de regression. Cette méthodologie est illustrée dans la Figure 6.




Figure 6: Le diagramme montrant les étapes suivies dans la méthodologie

5.1 Prétraitement et préparation des données

Avant l'élaboration des modèles, les données de la batterie sont collectées et préparées pour le traitement. La phase initiale consiste en une exploration des données, incluant la production de visualisations qui permettent d'acquérir une vue d'ensemble sur les caractéristiques des données. Vient ensuite l'élimination des valeurs aberrantes et des valeurs manquantes, afin de garantir que l'algorithme d'apprentissage s'entraîne sur des données fiables – une condition nécessaire (mais non suffisante) pour développer des modèles robustes. Enfin, une analyse approfondie des anomalies est menée, notamment pour identifier les écarts persistants issus de la base de données originale. Comme illustré dans Figure 7, ces anomalies se présentent sous deux formes : le premier type d'anomalies concerne des cycles de décharge incomplets, qui ne reflètent pas la variation réelle de l'état de charge. Le

deuxième type d'anomalies est liée à la présence de segments de données où les enregistrements restent constants en raison de l'application d'une limitation du courant à basse température pour prévenir le vieillissement prématuré de la batterie. Pour résoudre ces anomalies, les données concernées ont été éliminées.




Figure 7: Anomalies présentes dans le jeu de données

Ensuite, une étape d'augmentation est effectuée pour enrichir le jeu de données qui consiste à ajouter un segment au début du cycle en dupliquant la valeur initiale de chaque variable caractéristique. Cette technique a démontré sa pertinence à accommoder les algorithmes d'apprentissage à mieux apprendre les patrons en début de cycle (P. Emadi et al. 2023). Finalement, l'étape de la standardisation, consiste à transformer les variables indépendantes des modèles pour aligner l'échelle sur laquelle elles varient. La technique de normalisation min-max est utilisée pour standardiser les variables caractéristiques d'entrée sur une échelle standard en appliquant

$$X_{normalized} = (X - X_{min}) / (X_{max} - X_{min}) \quad (4)$$

Cette transformation permet d'accélérer la convergence des algorithmes d'optimisation qui sont au cœur des algorithmes d'apprentissage ainsi que d'éviter que certaines variables ne dominent le processus d'apprentissage.

5.2 Modélisation

Pour modéliser la variation de l'état de charge en fonction des paramètres mesurés de la batterie, deux méthodes sont présentées: la première traite le problème en tenant compte de l'aspect séquentiel des données d'entrée et repose sur l'apprentissage profond pour prédire l'état de charge. La seconde méthode considère la forme tabulaire des données et utilise un algorithme d'apprentissage automatique particulièrement adapté aux données structurées.

Le premier algorithme d'apprentissage est un réseau de neurones de plusieurs étages (Jogunola et al., 2022), C-BLSTM-AE (*Convolutional Bidirectional Long Short-Term Memory Autoencoder*, en anglais), estime l'état de charge en exploitant les mesures historiques de la batterie, telles que la tension V_t , le courant I_t et la température T_t . Cette méthode utilise la configuration plusieurs-à-un (*many-to-one* en anglais) dans laquelle le réseau reçoit une série d'entrées successives de longueur T_w des signaux historiques de la batterie et produit une seule valeur de l'état de charge à la fin de la séquence. Chaque entrée est traitée dans l'ordre, en tenant compte des dépendances temporelles. Cette méthode d'estimation peut être décrite par l'équation suivante:

$$\widehat{SOC}_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-(T_w-1)}) \quad (5)$$

où $x_t = [V_t, I_t, T_t]$ représente les mesures de la batterie, à savoir la tension, le courant et la température.

La deuxième méthode est basée sur l'algorithme *CatBoost* (Friedman, 2001). Le modèle peut être formulé comme une correspondance directe entre les quantités mesurées et le SOC correspondant:

$$\widehat{SOC}_t = f([V_t, I_t, T_t, V_{avg_t}, I_{avg_t}]) \quad (6)$$

où V_{avg_t} , I_{avg_t} , et T_t représentent respectivement la tension moyenne, le courant moyen et la température mesurés de la batterie à l'instant t . Des expériences ont montré que l'introduction des valeurs moyennes permet de capturer les patrons dans la fenêtre de données considérée permettant ainsi d'améliorer substantiellement la précision du modèle (Vidal et al., 2020).

5.3 Expérimentations

Une exploration approfondie a été menée pour déterminer les meilleures longueurs de séquence (T_W et L_{avg}) en termes de précision pour les deux modèles proposés à chaque température ambiante.

Les deux modèles C-BLSTM-AE et CatBoost sont évalués en utilisant différentes tailles de fenêtres temporelles pour les données d'entrée. Le modèle C-BLSTM-AE utilise des séquences d'entrée de longueur T_W de 200, 300, 400, 500, 600 et 700 secondes, tandis que le modèle CatBoost utilise des fenêtres de longueur L_{avg} pour le calcul des moyennes de courant et de tension V_{avg_t} et I_{avg_t} respectivement. Les deux figures 8 et 9 montre que la longueur de la fenêtre influence la performance de l'estimation. Les figures montrent aussi que cet effet dépend de la température ambiante de la batterie. Les modèles démontrent une tendance à obtenir des performances optimales avec des fenêtres de longueurs allant de 300 à 400 secondes aux températures positives, contrairement aux températures négatives où les modèles nécessitent des segments de données plus longs (supérieurs à 500 secondes).




Figure 8: Erreurs d'estimation du modèle C-BLSTM-AE pour différentes valeurs de T_W à chaque condition de température ambiante




Figure 9: Erreurs d'estimation du modèle CatBoost pour différentes valeurs L_{avg} à chaque condition de température ambiante

Afin d'assurer la convergence optimale pour les algorithmes d'apprentissage, les valeurs de plusieurs paramètres liés à chaque méthode doivent être fixées. Ces paramètres, à définir avant l'entraînement et qui impactent la performance des modèles résultats, sont appelés les hyperparamètres. Ils ont le rôle de contrôler le processus d'entraînement du modèle, en influençant des aspects tels que la vitesse d'apprentissage, la taille des lots, le nombre d'estimateur et le nombre d'époques. L'ajustement adéquat des hyperparamètres est

accompli en utilisant la méthode *GridSearch* (Pedregosa, 2011), qui consiste à effectuer une recherche exhaustive sur un espace de valeurs prédéfinies pour chaque hyperparamètre. *GridSearch* explore toutes les combinaisons possibles de valeurs d'hyperparamètres et évalue les performances de chaque configuration. L'objectif est d'identifier la meilleure combinaison de valeurs qui minimisent l'erreur des modèles tout en évitant les problèmes de surapprentissage et de sous-apprentissage.

Les modèles proposés ont été validés à l'aide d'une base de données publique partagée par l'université McMaster et contenant les signaux mesurés d'une batterie de type de lithium-ion ainsi que sa capacité correspondante (Vidal et al., 2020). La batterie a été soumise à des cycles de charge et de décharge dynamiques représentatifs de profils réels rencontrés dans les applications de véhicules électriques sous différentes températures ambiantes (40 °C, 25 °C, 10 °C, 0 °C, -10 °C, -20 °C).

5.4 Évaluation des résultats

Les étapes suivies pour le développement, l'entraînement et le test des modèles s'appuient sur l'approche systématique standard en science des données. L'évaluation des modèles proposés repose sur leurs performances en termes des métriques de régression à savoir MAE, RMSE et MAX ainsi que le temps de calcul en CPU.

6. CONTRIBUTION DU TRAVAIL DE RECHERCHE

Ce mémoire contribue à combler une lacune dans la recherche sur l'estimation du SOC, en particulier dans des conditions de températures négatives, un domaine encore peu exploré. Alors que seules quelques études ont pris en compte des températures négatives, ce travail se distingue en proposant des estimations à -10 °C et -20 °C sous diverses profils de charge dynamique. Le jeu de données utilisé inclut à la fois des températures négatives et positives, ainsi que des profils de charge variés, permettant une évaluation robuste des modèles dans des conditions réalistes et agressives.

7. ORGANISATION DU MÉMOIRE

La contribution de ce travail de recherche se reflète dans celle de l'article (Zilali et al., 2025) intitulé "*Machine Learning-based State of Charge Estimation: A Comparison between CatBoost model and C-BLSTM-AE model*" accepté au journal *Machine Learning with Application* et publié le 21 février 2025. Organisation du mémoire

Au-delà de cette introduction générale, le mémoire est présenté sous forme d'articles et divisé en deux chapitres et conclu par une synthèse générale. Le premier chapitre introduit les concepts fondamentaux de l'intelligence artificielle, en expliquant sa distinction de la programmation classique, son objectif principal et explorant quelques techniques spécifiques qui sont utilisées dans ce travail. Le deuxième chapitre est consacré à la présentation de l'article publié portant sur le développement de modèles d'apprentissage automatique pour l'estimation de l'état de charge. L'article détaille les approches et les méthodologies utilisées pour concevoir et tester ces modèles.

CHAPITRE 1 NOTIONS DE BASE SUR L'INTELLIGENCE ARTIFICIELLE

Ce chapitre a pour vocation de mettre en avant les concepts fondamentaux et les techniques de base nécessaires pour une meilleure compréhension du contenu de l'article. Ce chapitre présente comment les deux approches d'apprentissage automatique – C-BLSTM-AE, une architecture deep learning hybride et CatBoost, une méthode de boosting d'arbres de décision – peuvent résoudre la tâche de l'estimation du SOC. Chaque méthode apporte ses points forts : le C-BLSTM-AE qui excelle dans la modélisation des dynamiques temporelles contenues dans les données, tandis que CatBoost offre une alternative efficace en terme de consommation des ressources de calcul. Les techniques présentées trouvent des applications bien au-delà des batteries, dans tous les problèmes de régression multivariée et séquentielle.

L'intelligence artificielle (IA) est une branche de l'informatique qui vise à développer des systèmes capables d'effectuer des tâches qui, normalement, nécessitent l'intelligence humaine. Contrairement aux logiciels traditionnels, l'IA cherche à doter les systèmes d'une forme d'autonomie dans leur raisonnement, leur permettant de s'adapter à des situations complexes sans intervention humaine systématique (McCarthy et al., 1955). Dans la programmation traditionnelle, les développeurs écrivent des règles explicites qui définissent comment les données doivent être traitées. Les règles sont codées dans les programmes auxquels les données sont entrées pour générer ensuite les réponses ou les résultats. En apprentissage automatique, le processus est inversé. Le système reçoit des données ainsi que les réponses. À partir de cela, le modèle apprend les règles ou les relations qui existent entre les données et les réponses. Ces règles sont ensuite utilisées pour faire des prédictions ou prendre des décisions sur de nouvelles données (Figure 10).




Figure 10: Programmation classique vs apprentissage automatique

Apprentissage automatique

L'apprentissage automatique ou *machine learning* (ML) en anglais, est une sous-branche de l'intelligence artificielle (voir Figure 11). Il se concentre sur la capacité des systèmes à apprendre à partir de données sans être explicitement programmés pour chaque tâche (Mitchell, 1997). En d'autres termes, grâce à des algorithmes d'apprentissage, le ML permet d'analyser des données, d'identifier des patrons, et de prendre des décisions basées sur ces patrons. Les applications du ML incluent des analyses descriptives et prédictives.




Figure 11: Relation entre l'IA et l'apprentissage automatique

1.1.1 Arbre de décision

Les arbres de décision en anglais *Decision Trees* (DT), sont une méthode d'apprentissage supervisé largement utilisée pour les tâches de classification et de régression. Comme illustré dans Figure 12, la logique d'un arbre de décision repose sur la division des données en sous-groupes basés sur des règles de décision simples dérivées des variables caractéristiques des données. Chaque nœud interne de l'arbre représente une caractéristique, chaque branche représente une règle de décision, et chaque feuille représente un résultat. L'avantage des arbres de décision réside dans leur simplicité et leur capacité à représenter des patrons complexes de manière intuitive et graphique. Cependant, ils peuvent être sujets au sur-apprentissage surtout lorsqu'ils deviennent trop profonds (Breiman, Friedman, Olshen, & Stone, 1984).




Figure 12: La logique d'un arbre de décision

1.1.2 Apprentissage par ensemble

L'apprentissage par ensemble ou *Ensemble Learning* en anglais, est une technique d'apprentissage automatique qui combine les prédictions de plusieurs modèles appelés *apprenants de base* pour améliorer la performance globale (G. James et al, 2013). L'idée principale est que la combinaison de plusieurs prédicteurs, permet de compenser les faiblesses de chacun et de renforcer la robustesse et la généralisation du modèle final (G. James et al, 2013). Parmi les méthodes les plus courantes, on retrouve le *bagging* (comme le Random Forest), le *boosting* (comme *CatBoost* ou *LightGbm*). L'apprentissage par ensemble est largement utilisé dans les compétitions de science des données et dans des applications critiques, grâce à sa capacité à fournir des prédictions plus stables et plus fiables (Chen, T et al, 2015).

1.1.3 Boosting du gradient

Le *boosting* du gradient ou en anglais *Gradient Boosting* est une technique qui améliore la performance des arbres de décision en les combinant en une série de modèles faibles pour créer un modèle robuste. Contrairement à l'arbre de décision qui se base sur la prédiction d'un arbre unique comme montré dans Figure 8, le *boosting* du gradient construit

successivement des arbres, où chaque nouvel arbre corrige les erreurs commises par les arbres précédents en minimisant une fonction de perte spécifique à chaque itération.

Cette technique est particulièrement puissante et elle est à la base de plusieurs algorithmes d'apprentissage tels que *XgBoost*, *LightGbm* and *CatBoost* connus pour leur puissance prédictive en classification et en régression surtout pour les données tabulaires. (Friedman, 2001). L'algorithme construit initialement un arbre de décision simple, qui effectue des prédictions sur le jeu de données puis exploite la technique de *gradient boosting* pour corriger les erreurs de prédiction. Le nombre d'arbres est augmenté itérativement et chaque nouvel arbre corrige les erreurs résiduelles des arbres précédents. Cet ensemble d'arbres collabore pour affiner la précision prédictive, aboutissant à un modèle robuste capable de gérer les relations complexes entre le vecteur d'entrée et le SOC correspondant.

Le développement a été réalisé avec Scikit-learn (Pedregosa et al., 2011), un framework dédié aux algorithmes d'apprentissage automatique. Pour évaluer la robustesse des modèles, une validation croisée 5 folds a été appliquée. L'exploration hyperparamétrique a porté sur 700 à 2000 arbres et un taux d'apprentissage variant entre 0,02 et 0,2, avec une optimisation par Grid Search pour identifier la configuration optimale (voir résultats dans les Tableaux 1.

Table 2 : Résultats de Grid Search dans l'exploration hyperparamétrique

Temperature (° C)	Nombre d'arbres	Pas d'apprentissage
25, 10, 40	1000	0.05
-10, -20	1000	0.1
AllPositives, AllNegatives	1500	0.1

Apprentissage profond

L'apprentissage profond ou *Deep Learning* (DL) en anglais est une sous-partie de l'apprentissage automatique. Il s'agit d'une méthode d'apprentissage qui repose sur des réseaux neuronaux à plusieurs couches, d'où l'appellation réseaux de neurones profonds. Ces réseaux peuvent modéliser des relations complexes dans les données et sont particulièrement

efficaces pour des tâches comme la reconnaissance d'images et la compréhension du langage naturel (Manel, 2023). L'apprentissage profond a été responsable de nombreuses avancées récentes en IA, notamment grâce à sa capacité à traiter de grandes quantités de données avec une précision remarquable.

1.1.4 Réseau de neurones simple

Un réseau de neurones est un ensemble de nœuds (qu'on appelle neurone ou unité) interconnectés qui définit une relation entre des variables d'entrées et des variables de sorties (voir Figure 13). Il calque le principe de fonctionnement du cerveau humain pour l'apprentissage. Chaque neurone établit une relation mathématique entre les variables entrantes ($X_1, X_2, \dots, X_m$) et sortantes (Z) du neurone. Les variables d'entrées sont pondérées par des poids ($\omega_1, \omega_2, \dots, \omega_m$), auxquelles est ajoutée une bias b . Et pour réduire la linéarité dans la relation établie, le signal passe à travers une fonction d'activation, qu'on le note f , avant de sortir du neurone. La relation pour chaque neurone est écrite comme suit :

$$Z = f(\sum_{i=1}^m \omega_i * X_i + b) \quad (7)$$

où i et m représentent respectivement le rang de l'observation dans l'ensemble des données d'entrées et le nombre total d'entrées.

Une couche de neurones est un ensemble de neurones artificiels ayant le même nombre d'entrées. Le réseau de neurone est une succession de couches de neurones telle que le nombre de neurones sur chaque couche est égale au nombre d'entrées de la couche suivantes. Il est divisé en trois parties principales : une couche d'entrée qui est la première couche, une couche de sortie qui est la dernière couche, et les autres couches sont appelées couches cachées. La couche de sortie possède la même dimension que la variable à prédire, à partir de laquelle on calcule la fonction de perte, qui mesure l'erreur entre la prédiction et les valeurs réelles (Propagation avant). Le principe d'apprentissage est basé sur un algorithme d'optimisation qui minimise la fonction de perte en fonction des différents poids des neurones, à travers le processus de retro-propagation.




Figure 13: Fonctionnement d'un neurone artificiel

1.1.5 Réseau de neurones convolutif

Un réseau de neurones convolutifs (CNN), en anglais *Convolutional Neural Network*, est un type de réseau neuronal artificiel conçu pour traiter les données structurées en grille, comme les images. Leur force réside dans leur capacité à capturer les relations spatiales entre les pixels grâce à des opérations de convolution comme illustré dans Figure 14. Contrairement aux réseaux neuronaux traditionnels, les CNNs utilisent des filtres ou noyaux de convolution qui parcourent les données d'entrée pour extraire des caractéristiques locales, telles que les bords, les textures, ou des motifs plus complexes (LeCun et al., 1998). Cette approche permet de détecter des caractéristiques hiérarchiques à différents niveaux de profondeur du réseau. La convolution est une opération clé dans les CNNs. Elle consiste à appliquer un filtre de petite dimension sur l'ensemble de l'image d'entrée, générant ainsi une carte des caractéristiques (*feature map*). Cette opération permet non seulement de réduire le nombre de paramètres, rendant le modèle plus efficace, mais aussi de détecter des motifs répétitifs indépendamment de leur position dans l'image (Bengio et al., 2017).




Figure 14: L'image est décomposée en motifs locaux tels que les contours et les textures

1.1.6 Réseau de neurones récurrent

Les réseaux neuronaux récurrents (ou récursifs) en anglais *Recurrent Neural Networks* (RNNs) sont un type de réseau de neurones artificiels particulièrement adapté au traitement des données séquentielles, comme le texte et les séries temporelles. Contrairement aux réseaux neuronaux classiques, les RNNs possèdent des connexions récurrentes qui leur permettent de conserver une mémoire des états précédents (voir Figure 15), ce qui est essentiel pour modéliser les dépendances temporelles (Karpathy, 2015). Cependant, les RNNs traditionnels souffrent souvent du problème de la disparition ou de l'explosion des gradients, rendant difficile l'apprentissage de longues séquences. Pour pallier ces limitations, des variantes comme les LSTM (Long Short-Term Memory) a été développée, offrant de meilleures performances sur des séquences longues et complexes (Schuster & Paliwal, 1997) (Cho et al., 2014; Hochreiter & Schmidhuber, 1997).




Figure 15: Cellule LSTM

1.1.7 Auto-encodeur

Un auto-encodeur est un type spécifique de réseau de neurone, principalement conçu pour encoder l'entrée en une représentation compressée et significative, puis la décoder de manière que l'entrée reconstruite soit aussi proche que possible de l'originale (Bank, 2020), Figure 16. L'AE est un modèle de compression de signal basé sur un réseau neuronal, il est donc utilisé dans la plupart des cas pour l'extraction de caractéristiques pertinentes à partir de données complexes. Son rôle principal est de réduire la dimension des données d'entrée tout en conservant l'information la plus importante, ce qui facilite leur utilisation des modèles d'apprentissage automatique.




Figure 16: Principe de fonctionnement d'un auto-encodeur

1.1.8 C-BLSTM-AE

Dans cette section, le détail l'approche hybride d'apprentissage profond C-BLSTM-AE est présenté, comme illustré dans la Figure 17. Premièrement, le bloc CNN reçoit la séquence d'entrée afin d'extraire les motifs présents dans les signaux. Ensuite, le vecteur résultant est transmis à un bloc BLSTM, qui apprend les dépendances temporelles présentes. Cette combinaison de ces deux blocs permet d'obtenir une représentation encodée qui préserve les caractéristiques spatio-temporelles de la séquence d'entrée. Par la suite, cette représentation minimale est décodée à l'aide d'un bloc LSTM, ce qui simplifie l'architecture en comparaison avec l'utilisation d'un BLSTM dans la phase de décodage. Enfin, le vecteur résultant à la sortie du BLSTM-AE est traité par une couche LSTM-AE, puis transmis à deux couches denses pour effectuer la prédiction finale.




Figure 17: Architecture du C-BLSTM-AE

Pour la reproduction de l'architecture, les détails de la structure du modèle C-BLSTM-AE sont présentés dans le Tableau 2. Le tableau fournit une vue d'ensemble des différentes couches utilisées, du nombre de neurones associées à chacune, ainsi que du nombre total de paramètres à entraîner

.Tableau 3: Détail de l'architecture C-BLSTM-AE

Type de couche	Nombre de neurones	Nombre de paramètres
Couche d'entrée	3	3

Couche de convolution 1D	32	4832
Couche de convolution 1D	32	20512
Max pooling	5	0
Couche BLSTM	128	164864
Couche d'aplatissement	128	0
Couche de répétition	128	0
Couche LSTM	64	5718272
Couche dense	32	2080
Couche dense	1	33

Les configurations expérimentales adoptées pour l'entraînement du modèle, en fonction des différentes conditions de température et des scénarios de données, sont résumées dans le Tableau 3. Ce tableau précise les fichiers de températures associées à chaque cas, les taux d'apprentissage utilisés, ainsi que les tailles de lot correspondantes.

Table 4: Les hyperparamètres optimales de l'architecture C-BLSTM-AE

Temperature (° C)	Pas d'apprentissage	Taille du lot
25, 0	1e-04	128
40	1e-04	256
10, -10, -20	1e-05	128
AllPositives, AllNegatives	1e-05	256

Le modèle est implémenté sous TensorFlow à l'aide de la fonction d'activation ReLU en couche finale, assurant des sorties stables comprises entre 0 et 1 pour accommoder la variation du SOC. L'entraînement est réalisé sur 400 époques en utilisant l'optimiseur Adam avec un taux d'apprentissage compris entre 10^{-5} et 10^{-4} et des tailles de batch allant de 64 à 512.

Apprentissage par transfert de connaissance

L'apprentissage par transfert de connaissance, ou *Transfer Learning* (TL) en anglais, est une technique d'apprentissage automatique qui consiste à réutiliser un modèle pré-entraîné pour

résoudre une nouvelle tâche, différente mais liée à celle pour laquelle le modèle a été initialement entraîné (Weiss et al., 2016).

Comme le montre la Figure 18, le modèle est d'abord entraîné sur une tâche source en utilisant un large volume de données annotées. Une fois ce pré-entraînement terminé, le modèle obtenu est réutilisé pour résoudre une nouvelle tâche cible, cette fois-ci avec peu ou pas d'annotations supplémentaires.




Figure 18: Illustration de la technique Transfer Learning

Cette technique s'avère particulièrement intéressante pour les tâches où les données annotées sont rares ou coûteuses à collecter, tout en présentant l'avantage supplémentaire de réduire le temps de calcul.


Ce chapitre présente les concepts fondamentaux des techniques d'apprentissage automatique adoptées dans la littérature pour l'estimation de l'état de charge. Le détail des différentes techniques étudiées est proposé, suivie d'une justification des méthodes retenues dans ce mémoire pour réaliser l'estimation.

CHAPITRE 2

ESTIMATION DE L'ETAT DE CHARGE A BASE D'APPRENTISSAGE AUTOMATIQUE : COMPARAISON ENTRE LE MODELE CATBOOST ET LE MODELE C-BLSTM-AE

Résumé en français du premier article

Cet article présente une étude approfondie sur l'utilisation des modèles d'apprentissage automatique pour l'estimation de l'état de charge (SOC) des batteries lithium-ion. L'état de charge est un paramètre clé dans un système de gestion de batterie (BMS) pour les batteries lithium-ion. Une estimation précise du SOC est essentielle pour améliorer la longévité des batteries et assurer la sécurité des utilisateurs, faisant un élément crucial d'un BMS efficace. Cet article propose deux méthodes basées sur l'apprentissage automatique pour l'estimation du SOC. La première est une méthode hybride d'apprentissage profond basée sur une architecture hybride (C-BLSTM-AE), qui repose sur l'extraction de caractéristiques abstraites présents dans les données d'entrée. La seconde est une méthode d'apprentissage d'ensemble (*CatBoost*) qui utilise la technique d'amélioration par gradient (*Gradient Boosting* en anglais) pour améliorer la prédiction réalisée par ses arbres de décision le constituant. La performance des modèles est évaluée en comparant leur précision de régression et leur utilisation des ressources de calcul. Le modèle C-BLSTM-AE a obtenu une faible erreur absolue moyenne (MAE) de 0,52 % dans des conditions de température ambiante fixe, et a maintenu une MAE de 1,03 % pour des températures ambiantes variables. Le modèle *CatBoost* a atteint une MAE de 0,69 % dans des conditions de température fixe et une MAE de 1,09 % pour des températures variables.



Machine learning-based state of charge estimation: A comparison between CatBoost model and C-BLSTM-AE model

Abderrahim Zilali^{a,*}, Mehdi Adda^a, Khaled Ziane^b, Maxime Berger^a

^a Département de mathématiques, informatique et génie, Université du Québec à Rimouski, Rimouski, QC G56 3A1, Canada

^b Centre de Recherche et d'Innovation en Intelligence Énergétique CR2Ie, 175 Rue de la Vérendrye, Sept-Îles, QC G4R 5B7, Canada

ARTICLE INFO

Keywords:

SOC estimation
Machine learning
Deep learning
Auto-Encoder
Gradient Boosting

ABSTRACT

The State of Charge (SOC) is a key metric within a Lithium-ion battery management system (BMS). Accurate SOC estimation is essential for enhancing battery longevity and ensuring user safety, making it a critical component of an effective BMS. Although SOC estimation has become an active research area for the machine learning (ML) community, only a handful of works have considered its estimation at negative temperatures. This paper proposes the application of two machine learning-based approaches for SOC estimation that perform well at wide range of temperatures (positive and negative) and varying dynamic loads. The first one is a hybrid deep learning approach based on the Convolutional BLSTM Auto-Encoder (C-BLSTM-AE) model that relies on extracting abstract features from input data. The second one is a CatBoost model that leverages the gradient boosting technique to enhance the prediction made by its constituent trees. The performance of the models is evaluated by comparing their regression accuracy and computational resource utilization. The C-BLSTM-AE model achieves a low Mean Absolute Error (MAE) of **0.52 %** under fixed ambient temperature conditions and maintains a MAE of **1.03 %** for variable ambient temperatures. The CatBoost model achieves a MAE of **0.69 %** with fixed temperature settings and a MAE of **1.09 %** under variable temperature conditions.

1. Introduction

Lithium-ion (Li-ion) batteries are becoming increasingly prevalent in the automotive industry because of their high energy density and minimal environmental impact. Particularly in electric vehicles (EVs), their demand increased by about 65 % between 2021 and 2022 (Busch et al., 2024). A battery management system (BMS) is required to ensure effective integration of the battery pack; it has several responsibilities, such as thermal management, ensuring cell balancing and battery equalization, and estimating battery states, namely State of Health (SOH) and State of Charge (SOC) (Cao & Emadi, 2011). SOC is essential for the reliable operation of the electric drive system since this quantity directly gauges a vehicle's remaining driving range, and is crucial for enhancing battery safety and preventing irregular charging and discharging (An et al., 2021). SOC is defined as the ratio between the remaining available capacity and the nominal capacity, which can be written as (Hu et al., 2022).

$$SOC_t = C_t / C_n$$

(1)

where SOC_t is the SOC value at time t , C_t is the instantaneous capacity and C_n is the nominal capacity. Dynamic SOC estimation is inherently challenging since SOC cannot be directly measured. Therefore, its estimation uses measurable quantities such as battery voltage and current, temperature, and other variables. For practical applications, several methods are used for SOC estimation (How et al., 2019). The Coulomb Counting method also referred to as the Ampere-hour counting method, is the most basic approach for estimating the SOC of batteries (Zhang et al., 2020). According to Fan et al. (2022), the Coulomb counting method is by far the most extensively used for SOC estimation due to its small computational requirements, which makes it easy to implement on a BMS chip with low processing power. It involves integrating the battery current to ascertain the stored charge, which is then divided by the battery's total charge capacity to determine the SOC (Ng et al., 2009) as described in 2.

$$SOC_t = SOC_0 - \int_0^t \eta I(t) dt / C_n \quad (2)$$

* Corresponding author.

E-mail addresses: abderrahim.zilali@uqar.ca (A. Zilali), mehdi_adda@uqar.ca (M. Adda), khaled.ziane@cegepsi.ca (K. Ziane), maxime_berger@uqar.ca (M. Berger).

<https://doi.org/10.1016/j.mlwa.2025.100629>

Received 22 October 2024; Received in revised form 27 November 2024; Accepted 7 February 2025

Available online 12 February 2025

2666-8270/© 2025 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

where SOC_0 is the initial SOC value and I is the electric current at time t . The coulombic efficiency η represents the ratio of consumed electrons and available electrons during charging and discharging, which is assumed to be 0.9 and 1.0 during charging and discharging, respectively. While implementing Coulomb Counting for dynamic SOC estimation is relatively straightforward, it faces accuracy limitations due to errors in current integration (Sepasi et al., 2014). The accuracy of the Coulomb Counting integration method is also influenced by the initial SOC, and factors such as temperature drift and noise in the current sensor can result in cumulative errors throughout the integration process (Fan et al., 2022).

Another method commonly employed is the Open Circuit Voltage (OCV) method. The OCV method is based on a lookup table directly mapping the OCV of a battery with its SOC. The OCV uses the stable battery electromotive force in the open circuit state and SOC relationship to estimate the SOC value (Zheng et al., 2018). This estimation method relies on an approximate linear relationship between SOC and OCV. However, this correlation is inconsistent across different chemistries due to limitations such as variations in capacity and electrode material, and some chemistries, such as lithium-based, do not exhibit such a relationship (Hannan et al., 2017). Therefore, this approach is of limited use to estimate the SOC of Li-ion batteries.

Kalman Filter (KF)-based method is another widely used estimation technique. The main principle of the KF-based SOC estimation method is to relate the measured battery signals (voltage, current and temperature) with the battery model. The first step is to estimate a pre-determined SOC using the Coulomb Counting method. This calculation requires the initial SOC obtained from the SOC-OCV relationship. The second step involves estimating the model voltage using the chosen battery model. The parameters for this model can be determined based on the measured voltage, current, and temperature using various Parameter Identification Methods (PIMs) (Wang et al., 2016). The final step is to update the Kalman gain by comparing the model voltage with the measured voltage and using the voltage error to adjust the Kalman gain. The updated gain is then used to calculate the estimated SOC using a KF algorithm (Shrivastava et al., 2019). Due to its high accuracy and self-correcting features, KF-based SOC estimation is one of the preferred methods for online SOC estimation. However, the performance of KF-based SOC estimation heavily relies on the accuracy of the battery equivalent circuit model and the measurement covariance information (Xia et al., 2015).

The limitations in current SOC estimation methods have motivated the battery community to investigate more efficient and accurate techniques. With the rapid advancement of artificial intelligence, machine learning-based SOC estimation has become increasingly popular (Ng et al., 2020), leading to the development of various estimation techniques. However, only a few studies have addressed SOC estimation at negative temperatures, leaving an area of research that still needs further exploration. This paper proposes and validates the performance of two machine learning-based approaches for SOC estimation at both positive and negative temperatures, and under varying dynamic loads.

The remainder of the paper is organized as follows. Section II provides the background and literature review, offering an in-depth examination of existing research and foundational concepts related to machine learning-based SOC estimation for Li-ion batteries in EVs. Section III presents the methodology and details the proposed models and the rationale behind their selection. It also elaborates on the dataset, discussing its attributes, sources, and the preprocessing steps to prepare the data for model training. Section IV outlines the experimental setup and training process, including the configurations, tools, and procedures used to implement and evaluate the machine learning models. Section V presents the models' evaluation, showcasing the results, comparative analysis, and discussions on the effectiveness of the applied techniques regarding regression accuracy and computational resource utilization. Finally, section VI concludes the paper by summarizing the key findings

and their implications for SOC estimation.

2. Background and literature review

Machine learning (ML) is a paradigm that enables systems to learn from data without being explicitly programmed. This section presents the foundational concepts of the main machine learning algorithms used for SOC estimation. First, key definitions are presented, and then a review of existing machine learning-based methods is provided.

2.1. Dense neural network

A Dense Neural Network (DNN) is a machine learning model characterized by its multiple layers of interconnected neurons, designed to capture complex patterns in data. Each neuron in a DNN receives inputs from all neurons in the previous layer and performs nonlinear calculations (Bengio et al., 2017). By stacking multiple layers, DNNs can learn increasingly abstract representations of the input data, enabling them to identify high-level patterns that are not immediately apparent in the raw data (LeCun et al., 2015).

2.2. Convolutional neural network

A convolutional neural network (CNN) is a type of artificial neural network comprising, in most cases, of a convolutional layer and a pooling layer (Chollet, 2021; Li et al., 2021). The convolution layer contains many convolution filters, each acting as a template that determines whether a particular local feature is present in the input tensor (Pang et al., 2017). A convolution filter relies on a straightforward operation called a convolution, where matrix elements are repeatedly multiplied, transforming the input data into a feature map. The feature map is then passed to a pooling layer that provides a way to condense a large matrix into a smaller summary vector (James et al., 2013). CNN demonstrated outstanding results in computer vision and large-scale models due to their ability to extract complex features.

2.3. Long short-term memory

Long Short-Term Memory (LSTM) is a type of artificial neural network capable of capturing the spatiotemporal meaning within data (Jain et al., 2016). They have succeeded on many end-to-end learning tasks, spatially in Natural Language Processing (NLP). LSTMs address the vanishing and exploding gradient problems that hinder traditional recurrent neural networks (RNNs) in processing long sequences (Pascanu et al., 2013). One key advantage of LSTMs is their ability to store values over both short and long time intervals (Yu et al., 2019).

2.4. Bidirectional long short-term memory

Bidirectional Long Short-Term Memory (BLSTM) networks are an advanced type of RNN that enhances the standard LSTM architecture. Unlike traditional LSTMs, which only consider prior information in the sequence, BLSTMs process data in both forward and backward directions, which enables them to capture context from both past and future states (Schuster & Paliwal, 1997). BLSTMs have also succeeded in NLP tasks. For instance, they are widely used in named entity recognition, machine translation, and sentiment analysis, where understanding the surrounding context is crucial (Huang et al., 2015).

2.5. Auto-Encoder

An Auto-Encoder (AE) is a specific type of neural network which is mainly designed to encode the input into a compressed and meaningful representation and then decode it back such that the reconstructed input is as similar as possible to the original one (Bank et al., 2020). AE is a kind of signal compression model based on a neural network; therefore it

Table 1
Performance comparison with literature methods.

Method	Lower Error (MAE)	Temperatures (°C)
Transformer (Hannan et al., 2021) *	0.44 %	−20, −10, 0, 10, 25, 40
Proposed (C-BLSTM-AE)	0.52 %	−20, −10, 0, 10, 25, 40
LSTM-RNN (Chemali et al., 2017)	0.57 %	0, 10, 25
DNN (Chemali et al., 2018)	0.61 %	−20, −10, 0, 10, 25
TCN (Liu et al., 2021)	0.67 %	0, 10, 25
Proposed (CatBoost)	0.69 %	−20, −10, 0, 10, 25, 40
LSTM (Wong et al., 2021)	1.17 %	25

* This paper used two distinct datasets from the LG LiNiMnCoO₂ and Panasonic LiNoCoAlO₂ cells.

is used in most cases for feature extraction (Yan & Han, 2018).

2.6. Temporal convolutional network

A Temporal Convolutional Network (TCN) is a neural network for sequence modeling tasks. It leverages causal and dilated convolutions to capture long-range dependencies in sequential data, ensuring that the model predictions at any time step depend only on past inputs, not future ones (Lea et al., 2017). TCN is known for their ability to handle long sequences efficiently, maintain a stable memory footprint, and avoid issues related to vanishing gradients, which are common in RNNs (Bai et al., 2018).

2.7. Transformers

A transformer network is a type of deep learning model primarily designed for handling sequential data, making it highly effective for tasks such as time series forecasting and signal processing (Benidis et al., 2022). Unlike RNNs that process data sequentially, transformers leverage a mechanism called self-attention (Vaswani et al., 2017), which allows them to simultaneously process and attend to all elements of a sequence. This parallel processing capability not only accelerates computation but also enables the model to capture long-range dependencies more effectively (Rae et al., 2019).

2.8. Gradient boosting

Gradient boosting is an ensemble learning technique that builds a predictive model in an iterative, stage-wise manner (Freund et al., 1999). The main idea is to construct the model incrementally by adding weak learners, typically decision trees, to correct errors made by previous models. The process starts with a simple model and iteratively adds new models that aim to minimize a specified loss function through gradient descent. This method has proven highly effective and is at the core of many successful algorithms known for their state-of-the-art performance on tabular data.

2.9. Machine learning-based SOC estimation

In the last decade, machine learning has grown rapidly, revolutionizing numerous fields and redefining the state of the art in many domains. SOC estimation has withdrawn the attention of the ML community, and since then, several techniques have been proposed.

In Chemali et al. (2018), a DNN is used to estimate a battery SOC based on the input vector $[V_t, T_t, V_{avg_t}, I_{avg_t}]$ encompassing instantaneous voltage and battery temperature as well as averaged voltage and averaged current. The model achieved a Mean Absolute Error (MAE) of 1.10 % for a 25 °C dataset and a MAE of 2.17 % for a −20 °C dataset. In Vidal et al. (2020), the authors instead proposed a Feedforward Neural Network (FNN) to estimate SOC and showed that this model is capable of estimating the battery SOC with accuracy under 1 % MAE. Because of

the limitation of a DNN to process sequence data, including V_{avg_t} and I_{avg_t} , helps to capture the underlying trend in the averaged sequence, which translates into better estimation accuracy.

Other works focused on the premise of CNN to estimate SOC. (Bhattacharjee et al., 2021) proposed a 1D CNN-based estimator in conjunction with a transfer learning mechanism. The proposed algorithm generalized better and succeeded in estimating SOC for batteries with different chemical characteristics than the one used for training the model. Additionally, the presented framework enabled the CNN model to learn effectively with a significantly reduced amount of battery data. (Fan et al., 2022) proposed a U-Net architecture that only inputs voltage and current sequences to estimate SOC under dynamic temperature conditions. The proposed method can estimate the SOC at constant temperatures with a MAE within 1.1 % and RMSE of 1.4 %. For varying temperatures, the model achieved a MAE within 1.5 % and RMSE within 1.8 %. (Hannan et al., 2020) implemented a learning rate strategy to create a SOC estimation model using a Full Convolutional Network (FCN). The model achieved a RMSE of 0.85 % and a MAE of 0.7 % at 25 °C, and 2.0 % RMSE and 1.55 % MAE across ambient temperatures ranging from −20 °C to 25 °C.

Since the battery-measured signals are time series data, the use of LSTM has also received attention for SOC estimation. (Chemali et al., 2017) proposed a LSTM-RNN model that achieved a low MAE of 0.57 % at fixed ambient temperature and a MAE of 1.6 % on a dataset with ambient temperature ranging between 10 °C and 25 °C. The network model extracts high-level features from the input sequence comprising voltage, current, and battery surface temperature. In Wong et al. (2021) the authors estimated Li-ion battery SOC by using the measured voltage, current, and temperature values, with 1.17 % MAE and 1.57 % RMSE.

Many works have also focused on using TCN for SOC modeling tasks. (Yahia et al., 2023) used $[V_t, I_t, T_t, V_{avg_t}, I_{avg_t}]$ to train a TCN for SOC estimation. The proposed method achieved results comparable to those of RNN and CNN. (Liu et al., 2021) used TCN along with transfer learning; the method demonstrated effectiveness for SOC estimation and achieved an accuracy of 0.67 % MAE. The study promoted the application of transfer learning, which facilitates knowledge transfer between different batteries and requires only a small amount of battery data.

The latest contributions in the SOC estimation task focused on using transformer-based networks. Transformers have revolutionized the field of machine learning by providing state-of-the-art performance in various applications (Islam et al., 2023), owing to their ability to learn contextual relationships within data without relying on the sequential nature of RNN. In Hannan et al. (2021), the authors proposed a deep learning transformer model, using a Self-Supervised-Learning (SSL) framework, that achieves very low errors: RMSE of 0.90 % and MAE of 0.44 % at a constant ambient temperature, and RMSE of 1.19 % and MAE of 0.7 % at varying ambient temperatures. Moreover, the model can be effectively trained with only 5 epochs and 20 % of the total training data and enables transferability to a new Li-ion cell with different chemistry, maintaining performance comparable to models trained from scratch.

The literature review reveals that only a few studies have focused on SOC estimation at negative temperatures. This work addresses that gap by providing ML-based estimation models at −10 °C and −20 °C under various load conditions, offering new insights into SOC behavior in sub-zero conditions. Table 1 compares the proposed estimation performance and other methods from the literature that utilized the same dataset.

3. Methodology

This section outlines the framework adopted for SOC estimation, the mathematical formulation of the approach, and the methods employed. We propose estimation models at different temperature settings and varying loads.

To obtain accurate estimation results, two methods are presented: one that deals with the problem considering the sequential aspect of the input data and relies on deep learning to predict the SOC and another




Fig. 1. The adopted workflow for SOC estimation.

Table 2
Cell specifications.

Type	LG 18650HG2
Chemistry	Li [NiMnCo]O ₂ (H-NMC) / Graphite + SiO
Nominal capacity	3 Ah
Nominal Voltage	3.6 V
Energy Density	240 (Wh/Kg)

that relies traditional machine learning and considers the tabular aspect of the data. Models are proposed for predicting the SOC at constant ambient temperatures and at varying temperatures. The models are presented for each of the ambient temperatures, i.e. 25 °C, 40 °C, 10 °C, 0 °C, −10 °C and −20 °C and models for 25 °C, 40 °C and 10 °C combined referred to as AllPositives model and finally AllNegatives model that combines 0 °C and −10 °C and 20 °C data.

The C-BLSTM-AE method estimates the SOC by leveraging historical battery measurements, i.e. voltage, current, and temperature. This method uses a segment of length m of history battery signals to estimate a point SOC. This estimation method can be described as:

$$\widehat{SOC}_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-(m-1)}) \quad (3)$$

where $x_t = [V_t, I_t, T_t]$ represents the battery measurement, i.e. current, voltage and temperature.

The results of this deep learning method are compared with a traditional machine learning method based on CatBoost learning algorithm for estimating the SOC of the battery. The model can be formulated as a direct mapping between the measured quantities and the corresponding SOC:

$$\widehat{SOC}_t = f([V_t, I_t, T_t, V_{avg}, I_{avg}, T_{avg}]) \quad (4)$$

where V_{avg} , I_{avg} , and T_t represent the measured voltage, current, and temperature of the battery at time step t , respectively.

The procedure adopted for this work can be summarized into six main steps, as depicted in Fig. 1. The workflow includes the following processes: data description and exploration, data preprocessing which includes cleaning the dataset from missingness and testing anomalies, data augmentation, data standardization and finally model building and

evaluation.

3.1. Dataset description and exploration

To validate our models, raw data from a brand-new cylindrical 18,650 LiNiMnCoO₂ cell by LG provided by McMaster University in Hamilton, Ontario, Canada (Vidal et al., 2020) are used. The drive cycle power profiles are for an electric Fiat 500e Hatchback vehicle with an energy capacity of 42.0 kWh. The battery consists of 192 cells of type LG 18650HG2. The battery is scaled for a smaller pack of 8 kWh to conduct the tests. To simulate the behavior changes of the cell under actual driving conditions, data was gathered by exposing the battery cell to various load profiles from velocity profiles of driving cycles used for fuel economy measurements, namely HWFET, UDDS, US06, and LA92, at different ambient temperatures (25 °C, 40 °C, 10 °C, 0 °C, −10 °C, and −20 °C). To mimic real-world driving dynamics, the cell was also subjected to a random combination of the standard drive cycles (Geetha & Subramani, 2019). The specification of the cell is given in Table 2.

The dataset comprises various measured variables for analyzing battery behavior over time. Key columns include Time, and Voltage (measured directly at the battery terminal), and Current (in Amps). It also records Ah (instant capacity in amp-hours, reset after each cycle), Wh (energy in watt-hours), and Power (in watts). Additionally, to keep track of the thermal conditions of the battery, the Temperature column tracks the battery's surface temperature in degrees Celsius. Fig. 2 depicts the dynamic aspects of discharge phase during UDDS drive cycle at ambient temperatures of 25 °C and 0 °C.

3.2. Data preprocessing

3.2.1. Handling outliers and missingness

To our knowledge, no documented work regarding the preprocessing of this dataset exists. This section includes cleaning anomalies such as missing values, outliers, and non-informative segments. Business filters were used for outlier detection for each sensor. The outlier variables were subsequently replaced with missing values. Missing value imputation was done using the nearest neighbor method. The dataset does not suffer severe missingness; only a handful of cases have been found.




Fig. 2. Battery measurements during UDDS cycle at ambient temperatures of 25 °C and 0 °C.




Fig. 3. Testing Anomalies, (a): Incomplete test cycles. (b): Current limit.

3.2.2. Handling testing anomalies

During the experiments, certain discharge records remained incomplete, yet they were included in the dataset accessible to the public. Specifically, at $-40\text{ }^{\circ}\text{C}$, during the mixed4, mixed5, mixed6, mixed7, and mixed8 cycles, the battery was not fully charged at the beginning of each cycle leading to incomplete cycles as illustrated in Fig. 3.a. Consequently, these files were excluded and were not utilized in the subsequent phases. Unlike in laboratory test conditions where a constant current (CC) discharging is performed, in EVs, the load for the traction battery is usually very unsteady during driving (Sarasketa-Zabala et al., 2015) because of the acceleration and deceleration of the vehicle (Keil &

Jossen, 2017). Moreover, due to regenerative braking, driving does not entail a straightforward discharging process, which results in repeated charging periods. For $-10\text{ }^{\circ}\text{C}$ experiments, a current limit was set to prevent premature aging caused by the high charging currents (Vidal et al., 2020), which introduced sequences of constant current measurements, as highlighted in Fig. 3.b, which alters the underlying trend in the data. These sequences were deleted to keep the consistency of the trends in the measurements.

3.2.3. Data augmentation

To ensure that the learning algorithms are not impacted by a lack of




Fig. 4. Features augmentation.




Fig. 5. C-BLSTM-AE architecture.

initial data, the dataset is augmented by appending the first readings of the vector $[V_0, I_0, T_0, SOC_0]$ at the beginning of each cycle as described in Fig. 4. This augmentation serves two key purposes: 1) Preservation of data, by preventing the exclusion of valuable initial data points ensuring that the entire cycle of data is utilized effectively, and 2) improved estimation by enabling the estimation of the earliest SOC values that fall below the upper limit of the time window. This is crucial for accurately capturing the initial behavior and trends of the cycle at high SOC values, providing a more comprehensive and precise understanding of the SOC behavior from the very beginning of the cycle. In essence, this data augmentation technique maximizes the use of available data. It also enhances the accuracy of early SOC estimations, thereby improving the overall performance and reliability of the learning algorithms.

3.2.4. Standardization

Since the input features vary across different ranges, standardization enhances stability in the optimization process, facilitating convergence during gradient-based training. It alleviates problems associated with vanishing and exploding gradients, enabling models to reach optimal

solutions efficiently. The minimum-maximum normalization method is employed to standardize all input features to a standard scale using Eq. (5).

$$X_{normalized} = (X - X_{min}) / (X_{max} - X_{min}) \quad (5)$$

where $X_{normalized}$ is the value of the variable after normalization, X_{min} and X_{max} are, respectively the minimum and the maximum values of the variable.

3.2.5. Deep learning approach: C-BLSTM-AE

In this section, we introduce the proposed hybrid deep learning approach C-BLSTM-AE. As depicted in Fig. 5, the CNN block scans through the input sequence and extracts significant features from the data, and the resulting feature map is fed to a BLSTM block that learns the temporal dependencies among the sequence. The result of the two blocks is an encoded representation that preserves the spatial-temporal characteristics of the input sequence. An LSTM block then decodes the latent representation using an LSTM unit at the decoder, which renders the architecture less complex compared to a BLSTM used at the decoder

Algorithm 1: Pseudocode for Building a tree in CatBoost Algorithm

Input: $M, \{(x_i, y_i)\}_{i=1}^n, \alpha, L, \{\sigma_i\}_{i=1}^n, Mode$
Output: T, M
 $grad \leftarrow CalcGradient(L, M, y)$
 $r \leftarrow random(1, s)$
if $Mode = Plain$ **then**
 $G \leftarrow (grad_i)_{i=1..n}$
else
 $G \leftarrow (grad_{\sigma_r(i)})_{i=1..n}$
end
 $T \leftarrow emptytree$
foreach *step of top-down procedure* **do**
 foreach *candidate split c* **do**
 $T_c \leftarrow addsplit(c, T)$
 if $Mode = Plain$ **then**
 $\Delta(i) \leftarrow avg(grad_p(i))$ for $p : leaf_f(p) = leaf_f(i)$, for $i = 1..n$
 else
 $\Delta(i) \leftarrow avg(grad_{\sigma_r(i)})$ for $p : leaf_{f'}(p) = leaf_f(i), \sigma_r(p) < \sigma_r(i)$, for $i = 1..n$
 end
 $loss(T_c) \leftarrow cos(\Delta, G)$
 end
 $T \leftarrow argmin_{T_c}(loss(T_c))$
end
if $Mode = Plain$ **then**
 $M_{f'}(j) \leftarrow M_{f'}(j) - \alpha \cdot avg(grad_p(j))$ for $p : leaf_f(p) = leaf_f(j)$ for $j' = 1..s, j = 1..n$
else
 $M_{f', \sigma_j(i)} \leftarrow M_{f', \sigma_j(i)} - \alpha \cdot avg(grad_{f', j}(p))$ for $p : leaf_{f'}(p) = leaf_f(i), \sigma_r(p) \leq j$ for
 $j' = 1..s, i = 1..n, j \geq \sigma_r(i) - 1$
end
return T, M

Fig. 6. Pseudocode for CatBoost Algorithm.

Table 3
Optimal hyperparameters for DL algorithm by temperature condition.

Temperature (° C)	Learning Rate	Batch Size
25	1e-04	128
40	1e-04	256
10	1e-05	128
0	1e-04	128
-10	1e-05	128
-20	1e-05	128
AllPositives	1e-05	256
AllNegatives	1e-05	256

Table 4
Optimal hyperparameters for CatBoost algorithm by temperature condition.

Temperature (° C)	No. of Trees	Learning Rate
25	1000	0.05
40	1000	0.05
10	1000	0.05
0	1000	0.1
-10	1000	0.1
-20	1000	0.1
AllPositives	1500	0.1
AllNegatives	1500	0.1

stage of the network (Jogunola et al., 2022). Consequently, the encoded information from the BLSTM-AE output is decoded by the single layer of LSTM-AE before being fed into two fully connected layers for the final prediction.

3.2.6. Machine learning approach: CatBoost algorithm

Along with the proposed deep learning approach, a machine learning approach that utilizes CatBoost algorithm for making SOC predictions is proposed. CatBoost is known for its efficiency and high predictive power on tabular data. The algorithm starts by using a simple decision tree that makes predictions on the dataset and leverages the gradient boosting

technique to correct the prediction mistakes. It iteratively increases the number of trees used, each newly created tree focusing on correcting the errors made by the previous ones. This ensemble of trees works together to refine the prediction accuracy, leading to a robust model that can effectively handle the complex relationships between the input vector and the corresponding SOC. The final model aggregates all the trees, where the combined predictions yield a more accurate SOC estimation. The process of tree building is presented in Fig. 6.

4. Experimental setup and training

For training, mean absolute error (MSE) defined by 6, was chosen as the overall loss function evaluated during the training phase of the models.

$$MSE = \frac{1}{N} \sum_{n=1}^N (\widehat{SOC}_n - SOC_n)^2 \quad (6)$$

where N is the length of the data and SOC is the true value while $\widehat{SOC}$ is the output of the proposed network at time n.

To assess the goodness of fit of the models, the performance of the proposed models on testing cycles is evaluated using the root mean square error (RMSE) defined in Eq. (7), and the MAE, as defined in Eq. (8) and mean absolute maximal error defined as the highest error observed in the predictions as depicted in Eq. (9).

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\widehat{SOC}_n - SOC_n)^2} \quad (7)$$

$$MAE = \frac{1}{N} \sum_{n=1}^N (|\widehat{SOC}_n + SOC_n|) \quad (8)$$

$$MAX = max_N (|\widehat{SOC}_n + SOC_n|) \quad (9)$$

TensorFlow is used for DL model implementation. TensorFlow is an open-source deep learning software library for defining, training and




Fig. 7. C-BLSTM-AE estimations errors at different T_W for each different temperature condition.




Fig. 8. CatBoost estimations errors at different L_{avg} for each temperature condition.

Table 5
Optimal time window lengths for each method broken by temperature condition.

Temperature (° C)	Time Window Length	
	C-BLSTM-AE (T_W)	CatBoost (L_{avg})
25	300	300
40	300	300
10	300	500
0	400	600
-10	500	600
-20	500	500
AllPositives	400	300
AllNegatives	500	600

deploying machine learning models (Abadi et al., 2016). For training C-BLSTM-AE model, ReLU activation function is employed to activate the final neuron responsible for the prediction, primarily due to its positivity, which accommodates our use case where the predicted quantity is constrained between 0.0 and 1.0. Additionally, the ReLU

Table 6
C-BLSTM-AE Estimation Results.

Temperature (° C)	MAE	RMSE	MAX	CPU time (s)
25	0.55	0.79	2.93	35,415
40	0.52	0.69	2.14	17,324
10	1.44	1.88	7.00	32,718
0	0.78	1.05	3.50	32,507
-10	0.80	1.11	5.85	63,856
-20	1.31	1.79	7.54	28,615
AllPositives	1.03	1.64	8.48	102,733
AllNegatives	1.13	1.58	9.69	141,274

activation function exhibits reduced sensitivity to random initialization, ensuring stability (Schmidt-Hieber, 2020). The model is trained for 400 epochs and, an early stopping mechanism is implemented, this helps prevent overfitting by halting training if there is no improvement in the loss function. To optimize the loss during training, we utilize the Adam optimizer (Zhang, 2018), which iteratively adjusts the network's parameters (weights and biases) based on the gradient of the loss function. The learning rate is set between 10e-05 and 10e-04 and batch size is

Table 7
CatBoost Estimation Results.

Temperature (° C)	MAE	RMSE	MAX	CPU time (s)
25	0.69	0.92	4.59	20
40	1.00	1.45	6.77	14
10	1.54	1.97	6.98	19
0	1.11	1.55	8.17	13
-10	1.33	1.81	8.41	14
-20	1.90	2.56	15.06	13
AllPositives	1.09	1.54	8.17	31
AllNegatives	1.64	2.23	10.89	24

tested on batches of 64, 128, 256 and 512 instances.

For training the CatBoost model Scikit-learn framework is utilized. Scikit-learn is another open-source package designed for implementing and designing machine learning algorithms. A 5-fold cross-validation is used to ensure that the model's performance is assessed across different subsets of the data, enhancing the reliability and the robustness of the model. The number of trees is explored across values of 700, 1000, 1500, and 2000, with the learning rate ranging from 0.02, 0.05, 0.1, to 0.2, which allows for a comprehensive evaluation of model performance across different configurations. Grid Search scheme is followed to determine the optimal hyperparameter settings for each model. This




Fig. 9. C-BLSTM-AE estimation results for single ambient temperature.




Fig. 10. CatBoost estimation results for single ambient temperature.




Fig. 11. C-BLSTM-AE estimation results for multiple ambient positive temperatures.




Fig. 12. C-BLSTM-AE estimation results for multiple ambient negative temperatures.

method evaluates exhaustively the hyperparameters space, systematically identifying the configuration that minimizes the loss function. The optimal settings are reported in Table 3 and Table 4.

All models studied were trained in a virtualized environment on a Windows 10, version 22H2 operating system with Intel(R) Xeon(R) Gold 6248R CPU at 3.00 GHz clock frequency and 32 GB of RAM.

5. Model evaluation

5.1. Time window length experimentation

The proposed models use segments of historical measurements as input to generate predictions. This section examines the impact of varying the time window lengths on performance metrics. Both models, C-BLSTM-AE and CatBoost, are evaluated using a range of time windows for input data. The C-BLSTM-AE model is tested with input sequence lengths T_W of 200, 300, 400, 500, 600, and 700 ss, while the CatBoost model examines averaging windows L_{avg} of the same lengths for voltage




Fig. 13. CatBoost estimation results for multiple ambient negative temperatures.

and current data. Fig. 7 and Fig. 8 illustrate that the time window length influences performance, but the effect varies depending on the ambient temperature. Except at 10 °C, models tend to perform optimally with shorter windows (300–400 ss) at positive temperatures. Conversely, models at negative temperatures require longer segments of historical data (longer than 500 s).

This assessment helps identify the most effective window durations for both models in terms of performance. This analysis can help in optimizing the conditions under which the models are implemented to achieve better accuracy and reliability. In Table 5 we summarize lengths of time windows that yielded optimal results for both models.

6. Results

To allow for comparison, the C-BLSTM-AE model and the CatBoost model are validated on the same validation cycles. Along with the aforementioned regression metrics, CPU time corresponding to model training under each temperature condition is presented to ensure a comprehensive evaluation of the models' performance, balancing accuracy with computational efficiency.

In terms of accuracy C-BLSTM-AE model achieved below 1.31 % MAE for all temperature conditions. Except at 10 °C which seems to be challenging for both models, the model recorded the best performance at positive ambient temperatures with a MAE of below 0.78 % with the best MAE results at 40 °C and 25 °C of 0.52 % and 0.55 % respectively. The performance slightly degraded at negative ambient temperatures especially at –20 °C. Aggregated temperatures models recorded a MAE of around 1.03 % for positive temperatures and 1.13 % for negative temperatures (Table 6). The CatBoost model maintained below 1.90 % MAE for all temperature conditions. The model recorded the best performance at positive ambient temperatures with a MAE of below 0.69 % with the best results at 25 °C and jumped to above 1 % for the rest of the conditions. The performance further degraded at negative temperatures and attained 1.33 % at –10 °C and 1.90 % at –20 °C. Aggregated temperatures models recorded a MAE of around 1.09 % for positive temperatures and 1.64 % for negative temperatures. RMSE results show high variability in predictions compared to C-BLSTM-AE results, this is further supported by high values of MAX reaching 15 % at –20 °C as

depicted in Table 6 and Table 7. Another considered aspect is the computation speed. Deep learning model requires extensive back-propagation time to calculate gradient updates, leading to longer CPU computation times. As demonstrated in Table 6, training the C-BLSTM-AE model took several thousand CPU seconds and the CPU time positively correlates with the length of the historical input sequence. In contrast, training the CatBoost model was much faster, requiring significantly less time, measured in mere units of seconds as shown in Table 7.

6.1. Results interpretation

The estimation performance is illustrated in Figs. 9–13, where the estimated SOC profiles are compared with the ground truth SOC. Notably, in Figs. 9 and Fig. 11, the C-BLSTM-AE model shows a strong alignment with the actual SOC curve, with only minor divergences observed, particularly towards the end of the cycle. Fig. 12 displays a fluctuating behavior in the estimations, which supports our observation regarding the challenges faced in estimation under cold conditions, particularly at –10 °C and –20 °C. Fig. 10 shows the performance of the CatBoost model, where the errors are more pronounced compared to those of the DL model. There are significant divergences during mixed load cycles, and the deviations become even more noticeable under cold conditions, as highlighted in Fig. 13.

This paper makes a significant contribution by addressing gaps in the current research landscape, particularly in the aspect of SOC estimation at extremely cold temperatures. While only a handful of studies have considered negative temperatures, this work tackles this challenge by providing estimations at –10 °C and –20 °C under various loads. Additionally, we explored the potential of simple yet powerful machine learning algorithms, such as CatBoost, which offers lower calculation times compared to more complex deep learning algorithms. By focusing on these underexplored areas, our research not only enhances the understanding of battery SOC estimation in warm and cold climates but also introduces efficient and practical solutions for industrial applications.

7. Conclusion

In this paper, two machine learning methods are proposed for SOC estimation task. The proposed methods establish a nonlinear mapping relation between the measurable quantities and the corresponding SOC. The proposed DL model, C-BLSTM-AE, leverages a hybrid architecture to estimate the SOC, demonstrating accurate estimation across different drive cycles and ambient temperatures, with a MAE of 0.52 % for a single ambient temperature and a MAE of 1.03 % for multiple ambient temperatures. Even though traditional machine learning methods did not receive much attention for SOC estimation task, the proposed CatBoost model shows potential for SOC estimation with a MAE of <1.90 % within a short computation time. Since ambient temperature significantly affects the prediction, both models show a trend of decreasing accuracy as the ambient temperature decreases with the higher error observed at -20°C . CatBoost model is more sensitive to changes in temperature compared to C-BLSTM-AE model. We note that estimations at 10°C present a challenging case for the models. Overall C-BLSTM-AE model consistently outperforms CatBoost model in terms of MAE, RMSE, and MAX across all temperature conditions. Furthermore, the C-BLSTM-AE estimated SOC is more stable and comply with the physical property of being between 0.0 and 1.0, in contrast to CatBoost negative estimations near the value 0 %. These shortcomings can be overlooked given computation efficiency of the model, which completes in just a few seconds, whereas the regression results of C-BLSTM-AE require several hours of CPU time, with processing time increasing in proportion to the input sequence length.

This work addresses the gap in ML-based SOC estimation by including the commonly neglected scenario of negative temperatures. While only a handful of studies have considered such conditions, this research provides ML-based estimation models at 40°C , 25°C , 10°C , 0°C , -10°C , and -20°C under various load conditions. By tackling this challenge, the paper enhances our understanding of SOC behavior in cold environments, thus broadening the applicability of ML-based SOC estimation.

CRediT authorship contribution statement

Abderrahim Zilali: Conceptualization, Methodology, Software, Validation, Visualization, Writing – review & editing, Writing – original draft. **Mehdi Adda:** Conceptualization, Methodology, Supervision, Validation, Writing – review & editing. **Khaled Ziane:** Resources, Supervision, Validation, Writing – review & editing. **Maxime Berger:** Visualization, Supervision, Validation, Writing – review & editing.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

Data used for this research paper is open to the public.

References

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C. et al. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*.
- An, F., Jiang, J., Zhang, W., Zhang, C., & Fan, X. (2021). State of energy estimation for lithium-ion battery pack via prediction in electric vehicle applications. *IEEE Transactions on Vehicular Technology*, 71(1), 184–195.
- Bai, S., Kolter, J.Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*.
- Bank, D., Koenigstein, N., & Giryas, R. (2020). Autoencoders. *arXiv preprint arXiv:2003.05991*.
- Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning*. Cambridge, MA, USA: MIT press. Vol. 1.
- Benidis, K., Rangapuram, S. S., Flunkert, V., Wang, Y., Maddix, D., Turkmen, C., et al. (2022). Deep learning for time series forecasting: Tutorial and literature survey. *ACM Computing Surveys*, 55(6), 1–36.
- Bhattacharjee, A., Verma, A., Mishra, S., & Saha, T. K. (2021). Estimating state of charge for xEV batteries using 1D convolutional neural networks and transfer learning. *IEEE Transactions on Vehicular Technology*, 70(4), 3123–3135.
- Busch, P., Pares, F., Chandra, M., Kendall, A., & Tal, G. (2024). Future of global electric vehicle supply chain: Exploring the impact of global trade on electric vehicle production and battery requirements. *Transportation Research Record*, Article 03611981241244797.
- Cao, J., & Emadi, A. (2011). Batteries need electronics. *IEEE Industrial Electronics Magazine*, 5(1), 27–35.
- Chemali, E., Kollmeyer, P. J., Preindl, M., Ahmed, R., & Emadi, A. (2017). Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries. *IEEE Transactions on Industrial Electronics*, 65(8), 6730–6739.
- Chemali, E., Kollmeyer, P. J., Preindl, M., & Emadi, A. (2018). State-of-charge estimation of Li-ion batteries using deep neural networks: A machine learning approach. *Journal of Power Sources*, 400, 242–255.
- Chollet, F. (2021). *Deep learning with python*. Simon and Schuster.
- Fan, X., Zhang, W., Zhang, C., Chen, A., & An, F. (2022). SOC estimation of Li-ion battery using convolutional neural network with U-net architecture. *Energy*, 256, Article 124612.
- Freund, Y., Schapire, R., & Abe, N. (1999). A short introduction to boosting. *Journal-Japanese Society For Artificial Intelligence*, 14(771–780), 1612.
- Geetha, A., & Subramani, C. (2019). Development of driving cycle under real world traffic conditions: A case study. *International Journal of Electrical and Computer Engineering*, 9(6), 4798–4803.
- Hannan, M., How, D., Lipu, M.H., Mansor, M., Ker, P., Dong, Z. et al. (2021). Towards accurate state of charge estimation for lithium-ion batteries using self-supervised transformer model: A deep learning approach.
- Hannan, M. A., How, D. N., Lipu, M. H., Ker, P. J., Dong, Z. Y., Mansur, M., et al. (2020). SOC estimation of Li-ion batteries with learning rate-optimized deep fully convolutional network. *IEEE Transactions on Power Electronics*, 36(7), 7349–7353.
- Hannan, M. A., Lipu, M. H., Hussain, A., & Mohamed, A. (2017). A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 78, 834–854.
- How, D. N., Hannan, M., Lipu, M. H., & Ker, P. J. (2019). State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review. *IEEE access : practical innovations, open solutions*, 7, 136116–136136.
- Hu, C., Cheng, F., Ma, L., & Li, B. (2022). State of charge estimation for lithium-ion batteries based on TCN-LSTM neural networks. *Journal of the Electrochemical Society*, 169(3), Article 030544.
- Huang, Z., Xu, W., & Yu, K. (2015). Bidirectional LSTM-CRF models for sequence tagging. *arXiv preprint arXiv:1508.01991*.
- Islam, S., Elmekki, H., Elsebai, A., Bentahar, J., Drawel, N., Rjoub, G., et al. (2023). A comprehensive survey on applications of transformers for deep learning tasks. *Expert Systems with Applications*, Article 122666.
- Jain, A., Zamir, A. R., Savarese, S., & Saxena, A. (2016). Structural-rnn: Deep learning on spatio-temporal graphs. In *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning*. New York: Springer.
- Jogunola, O., Adebisi, B., Hoang, K. V., Tsado, Y., Popoola, S. I., Hammoudeh, M., et al. (2022). CBLSTM-AE: A hybrid deep learning framework for predicting energy consumption. *Energies*, 15(3), 810.
- Keil, P., & Jossen, A. (2017). Impact of dynamic driving loads and regenerative braking on the aging of lithium-ion batteries in electric vehicles. *Journal of the Electrochemical Society*, 164(13), A3081.
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2017). Temporal convolutional networks for action segmentation and detection. In *proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12), 6999–7019.
- Liu, Y., Li, J., Zhang, G., Hua, B., & Xiong, N. (2021). State of charge estimation of lithium-ion batteries based on temporal convolutional network and transfer learning. *IEEE access : practical innovations, open solutions*, 9, 34177–34187.
- Ng, K. S., Moo, C.-S., Chen, Y.-P., & Hsieh, Y.-C. (2009). Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied energy*, 86(9), 1506–1511.
- Ng, M.-F., Zhao, J., Yan, Q., Conduit, G. J., & Seh, Z. W. (2020). Predicting the state of charge and health of batteries using data-driven machine learning. *Nature Machine Intelligence*, 2(3), 161–170.
- Pang, Y., Sun, M., Jiang, X., & Li, X. (2017). Convolution in convolution for network in network. *IEEE transactions on neural networks and learning systems*, 29(5), 1587–1597.
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. In *International conference on machine learning*.
- Rae, J.W., Potapenko, A., Jayakumar, S.M., & Lillicrap, T.P. (2019). Compressive transformers for long-range sequence modelling. *arXiv preprint arXiv:1911.05507*.
- Sarasketa-Zabala, E., Gandiaga, I., Martinez-Laserna, E., Rodriguez-Martinez, L., & Villarreal, I. (2015). Cycle ageing analysis of a LiFePO₄/graphite cell with dynamic

- model validations: Towards realistic lifetime predictions. *Journal of Power Sources*, 275, 573–587.
- Schmidt-Hieber, J. (2020). Nonparametric regression using deep neural networks with ReLU activation function.
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11), 2673–2681.
- Sepasi, S., Ghorbani, R., & Liaw, B. Y. (2014). A novel on-board state-of-charge estimation method for aged Li-ion batteries based on model adaptive extended Kalman filter. *Journal of Power Sources*, 245, 337–344.
- Shrivastava, P., Soon, T. K., Idris, M. Y. I. B., & Mekhilef, S. (2019). Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries. *Renewable and Sustainable Energy Reviews*, 113, Article 109233.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., et al. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Vidal, C., Kollmeyer, P., Naguib, M., Malysz, P., Gross, O., & Emadi, A. (2020). Robust xev battery state-of-charge estimator design using a feedforward deep neural network. *SAE International Journal of Advances and Current Practices in Mobility*, 2 (2020–01–1181), 2872–2880.
- Wang, B., Liu, Z., Li, S. E., Moura, S. J., & Peng, H. (2016). State-of-charge estimation for lithium-ion batteries based on a nonlinear fractional model. *IEEE Transactions on Control Systems Technology*, 25(1), 3–11.
- Wong, K. L., Bosello, M., Tse, R., Falcomer, C., Rossi, C., & Pau, G. (2021). Li-ion batteries state-of-charge estimation using deep lstm at various battery specifications and discharge cycles. In *Proceedings of the conference on information technology for social good*.
- Xia, B., Wang, H., Tian, Y., Wang, M., Sun, W., & Xu, Z. (2015). State of charge estimation of lithium-ion batteries using an adaptive cubature Kalman filter. *Energies*, 8(6), 5916–5936.
- Yahia, D., Degaa, L., Sara, D., Allah, N. S., Mourad, L. M., & Rizoug, N. (2023). A temporal convolution network to electric vehicle battery State-of-charge estimation. In *2023 9th International Conference on Control, Decision and Information Technologies (CoDIT)*.
- Yan, B., & Han, G. (2018). Effective feature extraction via stacked sparse autoencoder to improve intrusion detection system. *IEEE access : practical innovations, open solutions*, 6, 41238–41248.
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235–1270.
- Zhang, S., Guo, X., Dou, X., & Zhang, X. (2020). A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery. *Sustainable Energy Technologies and Assessments*, 40, Article 100752.
- Zhang, Z. (2018). Improved adam optimizer for deep neural networks. In *2018 IEEE/ACM 26th international symposium on quality of service (IWQoS)*.
- Zheng, Y., Ouyang, M., Han, X., Lu, L., & Li, J. (2018). Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. *Journal of Power Sources*, 377, 161–188.

CONCLUSION GÉNÉRALE

Au terme de cette étude approfondie sur l'application des modèles d'apprentissage automatique pour l'estimation de l'état de charge, plusieurs conclusions importantes peuvent être tirées.

Premièrement, ce mémoire a souligné l'importance cruciale d'une estimation fiable de l'état de charge dans des conditions de charge dynamiques. Les différentes méthodes d'estimation ont été identifiées, leurs potentiels mis en lumière, ainsi que leurs points forts et limitations clairement délimités.

Deuxièmement, ce mémoire met la lumière sur un axe de recherche très peu exploré dans la littérature scientifique, à savoir l'estimation de l'état de charge dans des conditions de températures extrêmement froides. Ces environnements extrêmes posent des défis à la précision des modèles d'estimation, en raison des altérations significatives des propriétés électrochimiques des batteries à basse température. Ainsi, ce travail contribue à combler cette lacune importante dans la recherche en proposant des modèles pour l'estimation à -10°C et -20°C sous différents profils de charge et décharge.

Au cours de cette recherche, des modèles d'apprentissage automatique, sont mis en avant visant à estimer l'état de charge en fonction des paramètres mesurables de la batterie. Les paramètres examinés incluent la tension, le courant ainsi que la température de surface de la batterie. La performance des modèles est évaluée sur la base de l'erreur absolue moyenne (MAE). Le modèle basé sur C-BLSTM-AE obtient une MAE de 0,52 % dans des conditions de température ambiante fixe et une MAE de 1,03 % pour des températures ambiantes variables. Le modèle à base de CatBoost atteint une MAE de 0,69 % pour des températures fixes et une MAE de 1,09 % dans des conditions de température variable.

L'une des contributions de cette étude réside dans l'établissement des liens de causalité entre la longueur de la séquence de données et la température extérieure, permettant ainsi un choix

judicieux de la longueur de la fenêtre d'observation qui correspond bien à la température ambiante.

L'analyse des résultats a été effectuée en tenant compte des métriques de régression et de la capacité de calcul, dans le but d'obtenir des modèles à base de données fiables et précis permettant de prédire avec précision l'état de charge de la batterie tout en ayant une idée sur la consommation de ressources. La performance des modèles est évaluée sur la base de l'erreur absolue moyenne (MAE). Le modèle basé sur C-BLSTM-AE obtient une MAE de 0,52 % dans des conditions de température ambiante fixe et une MAE de 1,03 % pour des températures ambiantes variables. Le modèle à base de CatBoost atteint une MAE de 0,69 % pour des températures fixes et une MAE de 1,09 % dans des conditions de température variable. En termes de consommation CPU, le modèle C-BLSTM-AE nécessite environ 36.000 secondes de traitement pour les données à 25 °C, et plus que 141.000 secondes pour les données à températures variables, tandis que le modèle CatBoost ne requiert qu'une vingtaine de secondes de temps de calcul dans les deux cas.

Les résultats de cette recherche montrent une tendance claire dans l'estimation; plus les températures baissent, plus les estimations nécessitent une extension dans la longueur des séquences. Cela signifie que l'estimation précise de l'état de charge à des températures extrêmement basses nécessite l'analyse de séquences temporelles plus longues, car la dynamique des phénomènes électrochimiques devient plus complexe et variable sous ces conditions. Ce phénomène pourrait s'expliquer par la complexité accrue des phénomènes physiques à des températures plus basses, où les variations sont plus prononcées et conséquentes.

Les données utilisées dans cette recherche sont issues d'une seule batterie de chimie spécifique en simulant son comportement dans des conditions de conduite réelle. Bien que les cycles de décharges utilisés reproduisent des scénarios proches de la réalité, en capturant les variations de vitesse et les profils d'accélération, ils ne reflètent pas entièrement la variabilité rencontrée dans des conditions de conduite réelles. Ce mémoire constitue ainsi une base de réflexion pour les futures recherches visant à améliorer l'estimation de l'état de

charge à l'aide d'algorithmes d'apprentissage automatique. Il explore des pistes prometteuses, notamment en ce qui concerne le choix des algorithmes, l'optimisation de l'architecture et des hyperparamètres, tout en abordant le compromis entre précision et temps de calcul. Bien que ces contributions ouvrent des perspectives intéressantes, elles nécessitent d'être approfondies et validées par des travaux ultérieurs.

Ce travail de recherche suggère que les futures pistes de recherche devraient prendre en compte le vieillissement des batteries pour l'estimation de l'état de charge, ainsi que la transférabilité des connaissances entre des modèles entraînés sur différentes batteries, ce qui permet une meilleure généralisation et robustesse des modèles d'estimation, même sur des batteries de compositions chimiques différentes.

Ce travail de recherche suggère que les futures pistes de recherche devraient prendre en compte le vieillissement des batteries pour l'estimation de l'état de charge, ainsi que la transférabilité des connaissances entre les modèles entraînés sur différentes batteries, ce qui permet une meilleure généralisation des modèles d'estimation, même sur des batteries de compositions chimiques différentes. Plusieurs axes seront à explorer:

- Premièrement, l'intégration de données issues de vraies conditions de conduite, notamment ceux issues des environnements soumis à des variations climatiques extrêmes comme au Canada (environ 40 °C et -40 °C en hiver) est importante. Ces conditions influencent significativement les propriétés électrochimiques des batteries causant leur dégradation accélérée. Cette prise en compte permettrait de valider plus finement les modèles et d'en accroître la robustesse.
- Deuxièmement, augmenter la diversité des jeux de données en testant différentes chimies de batteries (LFP, LTO, sodium-ion) est particulièrement intéressantes pour leur meilleure performance en basses températures comparées à la chimie lithium-ion.
- Troisièmement, l'optimisation des modèles d'apprentissage automatique ainsi que l'exploration de nouveaux algorithmes sont nécessaires. Une attention particulière

doit porter sur l'efficacité des modèles en évaluant l'importance économique et pratique.

RÉFÉRENCES BIBLIOGRAPHIQUES

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., & Devin, M. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467.
- An, F., Jiang, J., Zhang, W., Zhang, C., & Fan, X. (2021). State of energy estimation for lithium-ion battery pack via prediction in electric vehicle applications. *IEEE Transactions on Vehicular Technology*, 71(1), 184–195.
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv preprint arXiv:1803.01271.
- Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. 1). MIT press Cambridge, MA, USA.
- Benidis, K., Rangapuram, S. S., Flunkert, V., Wang, Y., Maddix, D., Turkmen, C., Gasthaus, J., Bohlke-Schneider, M., Salinas, D., & Stella, L. (2022). Deep learning for time series forecasting: Tutorial and literature survey. *ACM Computing Surveys*, 55(6), 1–36.
- Bhattacharjee, A., Verma, A., Mishra, S., & Saha, T. K. (2021). Estimating state of charge for xEV batteries using 1D convolutional neural networks and transfer learning. *IEEE Transactions on Vehicular Technology*, 70(4), 3123–3135.
- Busch, P., Pares, F., Chandra, M., Kendall, A., & Tal, G. (2024). Future of Global Electric Vehicle Supply Chain: Exploring the Impact of Global Trade on Electric Vehicle Production and Battery Requirements. *Transportation Research Record*, 03611981241244797.
- Cao, J., & Emadi, A. (2011). Batteries need electronics. *IEEE Industrial Electronics Magazine*, 5(1), 27–35.
- Chemali, E., Kollmeyer, P. J., Preindl, M., Ahmed, R., & Emadi, A. (2017). Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries. *IEEE Transactions on Industrial Electronics*, 65(8), 6730–6739.
- Chemali, E., Kollmeyer, P. J., Preindl, M., & Emadi, A. (2018). State-of-charge estimation of Li-ion batteries using deep neural networks: A machine learning approach. *Journal of Power Sources*, 400, 242–255.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
- Fan, X., Zhang, W., Zhang, C., Chen, A., & An, F. (2022). SOC estimation of Li-ion battery using convolutional neural network with U-Net architecture. *Energy*, 256, 124612.
- Freund, Y., Schapire, R., & Abe, N. (1999). A short introduction to boosting. *Journal—Japanese Society For Artificial Intelligence*, 14(771–780), 1612.
- Geetha, A., & Subramani, C. (2019). Development of driving cycle under real world traffic conditions: a case study. *International Journal of Electrical and Computer Engineering*, 9(6), 4798–4803.

- M Hannan, Dickson How, M. S. Hossain Lipu et al. Towards Accurate State of Charge Estimation for Lithium-ion Batteries using Self-supervised Transformer Model: A Deep Learning Approach, 08 July 2021, PREPRINT (Version 1) available at Research Square [<https://doi.org/10.21203/rs.3.rs-687515/v1>]
- Hannan, M. A., How, D. N., Lipu, M. H., Ker, P. J., Dong, Z. Y., Mansur, M., & Blaabjerg, F. (2020). SOC estimation of Li-ion batteries with learning rate-optimized deep fully convolutional network. *IEEE Transactions on Power Electronics*, 36(7), 7349–7353.
- Hannan, M. A., Lipu, M. H., Hussain, A., & Mohamed, A. (2017). A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 78, 834–854.
- He, H., Zhang, X., Xiong, R., Xu, Y., & Guo, H. (2012). Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles. *Energy*, 39(1), 310–318.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.
- How, D. N., Hannan, M., Lipu, M. H., & Ker, P. J. (2019). State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review. *IEEE Access*, 7, 136116–136136.
- Hu, C., Cheng, F., Ma, L., & Li, B. (2022). State of charge estimation for lithium-ion batteries based on TCN-LSTM neural networks. *Journal of the Electrochemical Society*, 169(3), 030544.
- Huang, Z., Xu, W., & Yu, K. (2015). Bidirectional LSTM-CRF models for sequence tagging. *arXiv preprint arXiv:1508.01991*.
- Islam, S., Elmekki, H., Elsebai, A., Bentahar, J., Drawel, N., Rjoub, G., & Pedrycz, W. (2023). A comprehensive survey on applications of transformers for deep learning tasks. *Expert Systems with Applications*, 122666.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning. In: *springer New York*.
- Jogunola, O., Adebisi, B., Hoang, K. V., Tsado, Y., Popoola, S. I., Hammoudeh, M., & Nawaz, R. (2022). CBLSTM-AE: a hybrid deep learning framework for predicting energy consumption. *Energies*, 15(3), 810.
- Karpathy, A. (2015). The Unreasonable Effectiveness of Recurrent Neural Networks. Andrej Karpathy blog. Retrieved 21 May 2015 from <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>
- Keil, P., & Jossen, A. (2017). Impact of dynamic driving loads and regenerative braking on the aging of lithium-ion batteries in electric vehicles. *Journal of the Electrochemical Society*, 164(13), A3081.
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2017). Temporal convolutional networks for action segmentation and detection. *proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*,
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.

- Lipu, M. H., Hussain, A., Saad, M., Ayob, A., & Hannan, M. (2018). Improved recurrent NARX neural network model for state of charge estimation of lithium-ion battery using pso algorithm. 2018 IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE),
- Liu, Y., Li, J., Zhang, G., Hua, B., & Xiong, N. (2021). State of charge estimation of lithium-ion batteries based on temporal convolutional network and transfer learning. *IEEE Access*, 9, 34177–34187.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12–12.
- Mitchell, T. M., & Mitchell, T. M. (1997). *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.
- Ng, K. S., Moo, C.-S., Chen, Y.-P., & Hsieh, Y.-C. (2009). Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied energy*, 86(9), 1506–1511.
- Ng, M.-F., Zhao, J., Yan, Q., Conduit, G. J., & Seh, Z. W. (2020). Predicting the state of charge and health of batteries using data-driven machine learning. *Nature Machine Intelligence*, 2(3), 161–170.
- Pang, Y., Sun, M., Jiang, X., & Li, X. (2017). Convolution in convolution for network in network. *IEEE transactions on neural networks and learning systems*, 29(5), 1587–1597.
- Pedregosa, F. a. V., Gael and Gramfort, Alexandre and Michel, Vincent and Thirion, Bertrand and Grisel, Olivier and Blondel, Mathieu and Prettenhofer, Peter and Weiss, Ron and Dubourg, Vincent and Vanderplas, Jake and Passos, Alexandre and Cournapeau, David and Brucher, Matthieu and Perrot, Matthieu and Duchesnay, Edouard. (2011). *Scikit-learn: Machine Learning in Python*. *Journal of Machine Learning Research*, 12.
- Placke, T., Klopsch, R., Dühnen, S., & Winter, M. (2017). Lithium ion, lithium metal, and alternative rechargeable battery technologies: the odyssey for high energy density. *Journal of Solid State Electrochemistry*, 21, 1939–1964.
- Rae, J. W., Potapenko, A., Jayakumar, S. M., & Lillicrap, T. P. (2019). Compressive transformers for long-range sequence modelling. *arXiv preprint arXiv:1911.05507*.
- Sarasketa-Zabala, E., Gandiaga, I., Martinez-Laserna, E., Rodriguez-Martinez, L., & Villarreal, I. (2015). Cycle ageing analysis of a LiFePO₄/graphite cell with dynamic model validations: Towards realistic lifetime predictions. *Journal of Power Sources*, 275, 573–587.
- Schmidt-Hieber, J. (2020). Nonparametric regression using deep neural networks with ReLU activation function.
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11), 2673–2681.
- Sepasi, S., Ghorbani, R., & Liaw, B. Y. (2014). A novel on-board state-of-charge estimation method for aged Li-ion batteries based on model adaptive extended Kalman filter. *Journal of Power Sources*, 245, 337–344.

- Sesidhar, D., Badachi, C., & Green II, R. C. (2023). A review on data-driven SOC estimation with Li-Ion batteries: Implementation methods & future aspirations. *Journal of Energy Storage*, 72, 108420.
- Shen, P., Ouyang, M., Lu, L., Li, J., & Feng, X. (2017). The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE Transactions on Vehicular Technology*, 67(1), 92–103.
- Shrivastava, P., Soon, T. K., Idris, M. Y. I. B., & Mekhilef, S. (2019). Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries. *Renewable and Sustainable Energy Reviews*, 113, 109233.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Vidal, C., Kollmeyer, P., Naguib, M., Malysz, P., Gross, O., & Emadi, A. (2020). Robust xev battery state-of-charge estimator design using a feedforward deep neural network. *SAE International Journal of Advances and Current Practices in Mobility*, 2(2020-01-1181), 2872–2880.
- Waag, W., Fleischer, C., & Sauer, D. U. (2014). Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles. *Journal of Power Sources*, 258, 321–339.
- Wang, B., Liu, Z., Li, S. E., Moura, S. J., & Peng, H. (2016). State-of-charge estimation for lithium-ion batteries based on a nonlinear fractional model. *IEEE Transactions on Control Systems Technology*, 25(1), 3–11.
- Wong, K. L., Bosello, M., Tse, R., Falcomer, C., Rossi, C., & Pau, G. (2021). Li-ion batteries state-of-charge estimation using deep lstm at various battery specifications and discharge cycles. *Proceedings of the conference on information technology for social good*,
- Xia, B., Wang, H., Tian, Y., Wang, M., Sun, W., & Xu, Z. (2015). State of charge estimation of lithium-ion batteries using an adaptive cubature Kalman filter. *Energies*, 8(6), 5916–5936.
- Xiong, R., Cao, J., Yu, Q., He, H., & Sun, F. (2017). Critical review on the battery state of charge estimation methods for electric vehicles. *IEEE Access*, 6, 1832–1843.
- Yahia, D., Degaa, L., Sara, D., Allah, N. S., Mourad, L. M., & Rizoug, N. (2023). A Temporal Convolution Network to Electric vehicle Battery State-of-Charge Estimation. *2023 9th International Conference on Control, Decision and Information Technologies (CoDIT)*,
- Yan, B., & Han, G. (2018). Effective feature extraction via stacked sparse autoencoder to improve intrusion detection system. *IEEE Access*, 6, 41238–41248.
- Zhang, S., Guo, X., Dou, X., & Zhang, X. (2020). A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery. *Sustainable Energy Technologies and Assessments*, 40, 100752.
- Zhang, Z. (2018). Improved adam optimizer for deep neural networks. *2018 IEEE/ACM 26th international symposium on quality of service (IWQoS)*,

- Zheng, Y., Ouyang, M., Han, X., Lu, L., & Li, J. (2018). Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. *Journal of Power Sources*, 377, 161–188.
- Zilali, A., Adda, M., Ziane, K., & Berger, M. (2025). Machine Learning-based State of Charge Estimation: A Comparison between CatBoost model and C-BLSTM-AE model. *Machine Learning with Applications*, 100629.
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big data*, 3, 1–40.
- Eddahech, A. (2013). Modélisation du vieillissement et détermination de l'état de santé de batteries lithium-ion pour application véhicule électrique et hybride (Doctoral dissertation, Université Sciences et Technologies–Bordeaux I).
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, No. 1). New York: springer.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., ... & Zhou, T. (2015). Xgboost: extreme gradient boosting. *R package version 0.4–2*, 1(4), 1–4.
- Garreta, R., & Moncecchi, G. (2013). Learning scikit-learn: machine learning in python (Vol. 2013). Birmingham: Packt Publishing.
- Emadi, P. J. K. F. K. M. N. A. (2023). Tesla Model 3 2170 Li-ion Cell Dataset and Battery SOC Estimation Blind Modeling Tool. *Borealis*, (VI).
- Saisset, R. (2004). Contribution à l'étude systémique de dispositifs énergétiques à composants électrochimiques (Doctoral dissertation, Institut National Polytechnique).