

Prédiction de l'état de santé (soh) d'une batterie lithium- ion à l'aide de méthodes hybrides d'apprentissage profond

par

Alireza NIKJOU

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE ÉLECTRIQUE

MONTREAL, le 7 janvier 2026

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

©Tous droits réservés, Alireza Nikjou, 2026

©Tous droits réservés

Cette licence signifie qu'il est interdit de reproduire, d'enregistrer ou de diffuser en tout ou en partie, le présent document. Le lecteur qui désire imprimer ou conserver sur un autre media une partie importante de ce document, doit obligatoirement en demander l'autorisation à l'auteur.

PRÉSENTATION DU JURY
CE MÉMOIRE A ÉTÉ ÉVALUÉ
PAR UN JURY COMPOSÉ DE :

Mme Bassant Selim, directeur de mémoire
Département de Département de génie des systèmes à l'École de technologie supérieure

M. Wael Jaafar, président du jury
Département de génie logiciel et TI à l'École de technologie supérieure

M. Georges Kaddoum , membre du jury
Département de génie électrique à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 19 DÉCEMBRE 2025

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude à ma directrice de recherche, la Professeure Bassant Selim. En tant que professeure et superviseure, son expertise, ses conseils précieux et son soutien constant ont été essentiels à la réalisation de ce mémoire. Son encadrement a enrichi ma compréhension du sujet et a grandement contribué à la qualité de ce travail.

Mes remerciements s'adressent également aux membres de mon jury pour leur temps et leurs commentaires constructifs. Je suis aussi particulièrement reconnaissant envers Madame Annie Bélanger, M. Karim, M. Luc, M. Reza S, M. Reza, Madame Farzaneh, M. Benoît, Madame Bell, M. Mathieu, Madame et Monsieur Kosta, ainsi que Madame Carmella, pour leur aide précieuse et leur soutien, qui m'ont permis d'accéder à l'université.

Enfin, je suis infiniment reconnaissant à ma famille, et en particulier à mes parents, pour leur amour, leur patience et leur encouragement tout au long de mes études. Je tiens également à exprimer ma profonde gratitude à ma tante et à sa famille pour leur soutien constant. Un merci spécial à S. M, ma motivation, pour son soutien inestimable et sa présence constante, qui a éclairé ce parcours.

Leur soutien a été une source de motivation continue. Je remercie également le Québec et le Canada pour leur accueil et leur soutien tout au long de mon parcours.

Prédiction de l'état de santé (SOH) d'une batterie lithium-ion à l'aide de méthodes hybrides d'apprentissage profond

Alireza NIKJOU

RÉSUMÉ

L'estimation précise de l'état de santé (soh) des batteries lithium-ion est essentielle pour optimiser la gestion des batteries et éviter les défaillances prématurées. Avec la dépendance croissante aux batteries lithium-ion dans les véhicules électriques et les systèmes de stockage d'énergie, la prédiction fiable du soh est plus importante que jamais. Cependant, cette estimation reste difficile en raison de l'évolution continue des caractéristiques des batteries au fil du temps et des limites des approches existantes. Les méthodes traditionnelles, telles que les modèles de circuits équivalents ou les modèles électrochimiques, peuvent être complexes, longues à exécuter et manquent souvent de flexibilité. Les approches basées sur les données offrent des alternatives prometteuses, mais elles nécessitent généralement de grandes quantités de données étiquetées et peinent à bien généraliser à des conditions variables.

En bref, l'estimation précise du SOH des batteries lithium-ion est cruciale pour éviter les pannes et optimiser leur gestion, surtout avec leur rôle central dans les véhicules électriques et le stockage d'énergie. Or, ce défi est compliqué par l'évolution des caractéristiques des batteries au fil du temps. Les méthodes classiques sont souvent rigides et chronophages, tandis que les approches basées sur les données exigent d'énormes quantités de données étiquetées et généralisent mal. En intégrant ces justifications, le résumé répondra aux attentes académiques, tout en montrant pourquoi c'est crucial.

Pour relever ces défis, ce mémoire propose un modèle hybride d'apprentissage profond combinant un autoencodeur masqué (mae) et un réseau de neurones lstm (sans mécanisme d'attention) pour l'estimation du SOH. Le modèle intègre également une fonction de perte contrastive (cl) afin d'améliorer l'apprentissage des représentations. Il est entraîné sur des fenêtres glissantes de longueur 100 (taille de lot 16, 100 époques), à partir des caractéristiques normalisées `cycle_norm` et `capacity`, extraites des cycles de charge-décharge des batteries B0005, B0006 et B0007. Le modèle est ensuite évalué sur une batterie de test indépendante, B0018, pour laquelle il atteint un rmse de 1,51, un mae de 0,81 et un coefficient de détermination R^2 de 0,98.

Ces résultats montrent que la combinaison de MAE (pour gérer les données manquantes), cl (pour renforcer la généralisation) et LSTM (pour la modélisation temporelle) constitue une architecture auto-supervisée efficace. Globalement, l'approche proposée confirme le potentiel de l'apprentissage auto-supervisé pour un diagnostic de santé des batteries à la fois précis et évolutif.

VIII

Mots-clés : état de santé (soh), batteries lithium-ion, apprentissage profond, autoencodeur masqué (mae), perte contrastive (cl), réseaux lstm, apprentissage auto-supervisé, prédiction de défaillance des batteries.

Prediction of Lithium-Ion Battery State of Health using Hybrid Deep Learning Methods

Alireza NIKJOU

ABSTRACT

Accurate estimation of the state-of-health (SOH) of lithium-ion batteries is critical for optimizing battery management and preventing premature failures. With the growing reliance on lithium-ion batteries in electric vehicles and energy storage systems, reliable SOH prediction is more important than ever. However, SOH estimation remains challenging due to the evolving nature of battery characteristics over time and the limitations of existing approaches. Traditional methods, such as equivalent circuit models and electrochemical models, can be complex, time-consuming, and lack adaptability. Piloté par les données techniques offer promising alternatives but often require large labeled datasets and may struggle with generalization across varying conditions.

To address these challenges, this thesis presents a hybrid deep learning model combining a masked autoencoder (MAE) and a Long Short-Term Memory (LSTM) network (without an attention mechanism) for SOH prediction. The model also incorporates a specific contrastive learning (CL) loss criterion to enhance representation learning. It is trained on sliding windows of length 100 (batch size 16, 100 epochs) using normalized cycle_norm and capacity as input caractéristiques, derived from the charge-discharge cycle data of batteries B0005, B0006, and B0007. The model is evaluated on a separate test battery, B0018, where it achieves an RMSE of 1.51, an MAE of 0.81, and a coefficient of determination R^2 of 0.98. These results demonstrate that the combination of MAE for handling incomplete data, CL for improving generalization, and LSTM for temporal modeling forms an effective self-supervised architecture. Overall, the proposed approach confirms the potential of self-supervised learning for scalable and accurate battery health diagnostics.

Keywords: state of health (soh), lithium-ion batteries, deep learning, masked autoencoder (mae), contrastive learning (cl), lstm networks, hybrid learning, self-supervised learning, battery failure prediction

TABLE DES MATIÈRES

	Page
CHAPITRE 1 CONTEXTE GÉNÉRAL	3
1.2 Problématique	8
1.1 Objectifs de la thèse	9
1.2 Description des données	10
CHAPITRE 2 ÉTAT DE L'ART	13
2.1 Enjeux de l'estimation de l'état de santé des batteries	13
2.2 Techniques traditionnelles d'estimation de l'état de santé (SOH)	14
2.3 Évolution vers des méthodes pilotées par les données et basées sur l'IA.....	18
2.3.1 Méthodes non supervisées et auto-supervisées	22
2.3.2 Apprentissage contrastif.....	24
2.3.3 Vers des approches hybrides physique données	25
2.4 Approche hybride MAE-CL-LSTM pour l'estimation du SOH	29
CHAPITRE 3 MÉTHODOLOGIE	31
3.1 Méthodologie de l'estimation du SOH	31
3.2 Données utilisées	32
3.3 Motivation du choix de l'architecture MAE + CL + LSTM.....	34
3.4 Architecture proposée	35
3.5 Motivation du choix de l'architecture MAE + CL + LSTM.....	39
3.6 Détails de l'implémentation.....	39
3.7 Prétraitement et pipeline de données	41
CHAPITRE 4 RÉSULTAT.....	47
4.1 Performance globale	47
4.2 Configuration et hyperparamètres d'apprentissage	47
4.3 Performance du modèle (auto-supervisé).....	56
4.4 Analyse des erreurs	61
CONCLUSION ET DISCUSSION	63
4.5 Synthèse des résultats obtenus avec le modèle MAE+CL+LSTM.....	63
4.6 Travaux futurs et perspectives de recherche	64

LISTE DES FIGURES

	Page
Figure 3.1	Schéma du modèle MAE–CL–LSTM31
Figure 4.1	Distribution de la capacité48
Figure 4.2	Matrice de corrélation.....49
Figure 4.3	Histogramme de la répartition50
Figure 4.4	Capacité B0005 brut vs filtré (selon les cycles)51
Figure 4.5	Dégradation de la capacité.....52
Figure 4.6	Entraînement, validation, test53
Figure 4.8	Distribution globale du SOH54
Figure 4.9	Importance des caractéristiques.....55
Figure 4.10	Erreur de prédiction vs SOH réel57
Figure 4.11	Erreurs de prédiction séquentielles sur l'ensemble de test58
Figure 4.12	Distribution des erreurs de prédiction (SOH prédit – SOH réel)59
Figure 4.13	SOH prédit vs SOH réel60

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

LSTM Long Short-Term Memory

MAE Masked Autoencoder

CL Contrastive Learning

RMSE Root Mean SquareError

E Encoder

DAE Denoising Auto Encoder

VAE Variational Auto Encoder

D Decoder

VE Vehicule Élecrique

RNN Réseau de Neurones Récurrent

CNN Réseau de Neurones Convolutif

INTRODUCTION

La transition énergétique et la décarbonation des systèmes de transport et de production d'électricité reposent de plus en plus sur des solutions de stockage d'énergie performantes, fiables et durables. Parmi celles-ci, les batteries lithium-ion occupent aujourd'hui une place prépondérante grâce à leur densité énergétique élevée, leur rendement important et leur durée de vie prolongée. Elles alimentent un large éventail d'applications allant des véhicules électriques et hybrides aux systèmes stationnaires associés aux énergies renouvelables, en passant par les appareils électroniques portables et les réseaux de capteurs intelligents. Si ces accumulateurs ont transformé la manière dont l'énergie est stockée et utilisée, leur déploiement massif soulève des enjeux majeurs en matière de fiabilité, de sécurité et de coût d'exploitation. En effet, les performances des batteries se dégradent progressivement au fil des cycles de charge et de décharge, entraînant une perte de capacité et une augmentation de la résistance interne. Cette dégradation, qui détermine leur état de santé (State of Health, SOH), peut compromettre la performance des systèmes qu'elles alimentent et, dans certains cas, poser des risques de sécurité. L'estimation précise et en temps réel du SOH constitue donc un élément clé pour optimiser la durée de vie des batteries, planifier leur maintenance, éviter les pannes prématurées et envisager des stratégies de réutilisation en seconde vie. Or, les méthodes traditionnelles, qu'elles soient expérimentales, basées sur des modèles physiques ou empiriques, présentent des limites importantes : elles requièrent souvent un grand volume de données étiquetées, des conditions d'essai spécifiques, ou des paramètres difficiles à mesurer en usage réel. Face à ces contraintes, l'émergence des approches basées sur l'apprentissage automatique et l'apprentissage profond ouvre de nouvelles perspectives. Celles-ci permettent d'exploiter des volumes importants de données issues des systèmes de gestion de batterie (Battery Management Systems, BMS) afin de modéliser la dégradation et d'estimer le SOH sans recourir à des mesures intrusives ou à des campagnes expérimentales longues et coûteuses. Cependant, la performance de ces méthodes est souvent limitée par la rareté des données étiquetées et leur faible capacité de généralisation à d'autres chimies ou profils d'utilisation.

Dans ce contexte, l'apprentissage auto-supervisé apparaît comme une solution prometteuse pour exploiter efficacement les données non étiquetées tout en réduisant la dépendance aux jeux de données annotés. Ce mémoire s'inscrit dans cette dynamique et propose une approche hybride innovante combinant un autoencodeur masqué (Masked Autoencoder, MAE), l'apprentissage contrastif (Contrastive Learning, CL) et un réseau LSTM. L'objectif est de développer un modèle capable d'apprendre des représentations latentes robustes à partir de données brutes, afin d'améliorer la précision et la généralisabilité de l'estimation du SOH dans des conditions réelles varie

CHAPITRE 1

CONTEXTE GÉNÉRAL

Les batteries lithium-ion (LIB) ont vu leur importance exploser dans la technologie moderne. Leur haute densité énergétique et leur longue durée de vie en font des solutions privilégiées pour le stockage d'énergie (Dunn, Kamath, & Tarascon, 2011). Aujourd'hui, elles alimentent tout : des véhicules électriques aux systèmes de stockage solaire/éolien, en passant par les appareils portables et même les capteurs IoT (Dunn, Kamath, & Tarascon, 2011) (Hasan, 2023). L'énergie stockable des LIB est cruciale pour déterminer l'autonomie d'un véhicule électrique (Etacheri, Marom, Elazari, Salitra, & Aurbach, 2011).

Dans les réseaux à énergie renouvelable, les LIB atténuent les variations de production : elles emmagasinent l'énergie excédentaire produite par le soleil ou le vent et la restituent à la demande (Agency, 2022). Elles ont ainsi un rôle de « tampon » indispensable face à l'intermittence des sources renouvelables (Xiao, 2020). Leur présence massive dans l'électronique grand public (smartphones, ordinateurs portables...) et dans les capteurs distants (IoT) souligne leur rôle majeur dans notre quotidien (Hasan, 2023). Dans toutes ces applications, la fiabilité et la sécurité des batteries sont cruciales : une panne de batterie peut immobiliser un véhicule ou provoquer un incident de sécurité (Si la batterie tombe en panne, cela peut entraîner des situations dangereuses, comme une surchauffe, un incendie ou la défaillance de systèmes critiques), tandis qu'une coupure dans un réseau de capteurs peut perturber gravement les services associés (Pasquier, 2021). D'où le besoin croissant de systèmes de gestion de batteries intelligents, qui garantissent des performances optimales et sûres pendant tout le cycle de vie.

L'estimation de l'état de santé (SOH) de la batterie est au cœur de ces enjeux. Le SOH d'une batterie est généralement défini comme le rapport (exprimé en %) entre sa capacité maximale actuelle et sa capacité nominale en sortie d'usine (Yeh, 2019). Par exemple, si une cellule ne peut plus retenir que 80 % de sa charge d'origine, son SOH est de 80 % (Yeh, 2019). Cette définition par la capacité est la plus utilisée, car la perte de capacité est l'indicateur de vieillissement le plus évident University (2015). On sait par ailleurs que la fin de vie (end-of-

life) d'une LIB est souvent fixée autour de 70–80 % de SOH (Warmuth, 2024). En pratique, les constructeurs et exploitants considèrent une batterie comme en fin de vie lorsqu'elle descend en dessous d'environ 80 % de sa capacité initiale, où elle ne peut plus garantir les performances (Warmuth, 2024).

D'ailleurs, connaître le SOH permet de planifier l'entretien et le remplacement à temps et d'envisager une seconde vie (par exemple, réutiliser des batteries de VE usagées pour du stockage stationnaire) (Mitchell-Williams, 2020). Autrement dit, le SOH est un indicateur clé pour la fiabilité, la performance et la sécurité des systèmes utilisant des batteries lithium-ion. L'estimation du SOH des batteries Li-ion est un problème complexe mêlant électrochimie, modélisation et analyse de données. Différentes approches ont été proposées au fil des décennies, chacune avec ses limites. On distingue classiquement deux grandes familles : les méthodes empiriques (ou expérimentales) et les méthodes basées sur des modèles. Les méthodes empiriques se basent sur l'observation directe du comportement de la batterie dans certaines conditions et utilisent des indicateurs simples ou des régressions statistiques. Par exemple, l'évolution de la capacité en réalisant périodiquement des décharges complètes, les Coulombs entrants/sortants (méthode du comptage de charge), ou encore mesuré la tension en circuit ouvert après de longs temps de repos (Devices, 2019). Si ces méthodes sont conceptuellement simples, elles posent problème en pratique : le comptage de Coulombs accumule des erreurs (il faut en effet recalibrer fréquemment le calcul de charge) (Devices, 2019), et la mesure de la tension en circuit ouvert exige des temps de repos prolongés pour que la batterie atteigne l'équilibre (Smith, 2020).

D'autre part, les approches empiriques sont très dépendantes des conditions d'essai elles peuvent donner des résultats corrects pour le profil de charge et la température pour lesquels elles ont été calibrées, mais elles échouent souvent lorsque la condition d'utilisation change (Smith, 2020). Les méthodes basées sur des modèles cherchent au contraire à exploiter la connaissance des processus internes de la batterie. On distingue les modèles électrochimiques (basés sur la physique de la batterie) et les modèles à circuits équivalents (ECM). Les modèles électrochimiques, comme celui de Doyle-Fuller-Newman (DFN), utilisent des équations aux

dérivées partielles pour décrire la diffusion des ions lithium dans les électrodes, la diffusion dans l'électrolyte, la cinétique des réactions, etc. En principe, ces modèles peuvent fournir une estimation très précise du SOH en reliant directement les changements observés (pertes d'inventaire lithium, perte de matériau actif, etc.) à la dégradation interne. Cependant, ils sont extrêmement coûteux en calcul et contiennent de nombreux paramètres internes (coefficients de diffusion, constantes cinétiques, porosités, etc.) difficiles à mesurer sans tests spécialisés (Smith, 2020). En pratique, intégrer un modèle électrochimique complet dans un BMS embarqué est irréaliste sans simplification, et le recueil expérimental de tous les paramètres nécessaires (par exemple par spectroscopie d'impédance ou analyses destructives) est laborieux (Smith, 2020). Les modèles équivalents, quant à eux, représentent la batterie par un réseau électrique composé de résistances, condensateurs, etc. (par exemple le modèle de Thévenin ou des réseaux RC en cascade).

Des paramètres tels que la résistance interne, la résistance de transfert de charge ou la capacité double couche sont ajustés à partir de mesures (impulsions de courant, spectroscopie d'impédance) et suivis au fil du temps. Ces paramètres servent alors d'indicateurs de santé de la batterie : par exemple, une augmentation de la résistance interne ou une diminution des constantes de temps RC suggèrent une perte de capacité ou un vieillissement accru, donc un SOH en déclin. Des filtres de Kalman (étendu ou sans métrique) sont souvent employés pour estimer en temps réel l'état de charge et ces paramètres (donc indirectement le SOH) à partir des signaux de tension et de courant. Les modèles ECM présentent l'avantage d'un compromis pragmatique : ils sont peu coûteux en calcul et relativement simples à implémenter dans un BMS, tout en capturant l'essentiel de la réponse dynamique en tension de la cellule. Toutefois, ils requièrent un réglage fin : les paramètres initiaux doivent être calibrés en laboratoire et varient avec la température, l'état de charge, l'historique de cycles, etc. En dehors des conditions identifiées, les prédictions d'un ECM peuvent rapidement devenir erronées. De plus, certains éléments du circuit (valeurs de résistances ou de capacités) n'ont pas de signification physique directe, si bien qu'ils révèlent le vieillissement sans en donner la cause exacte (perte de lithium, dégradation des électrodes, etc. Enfin, représenter avec précision des phénomènes de relaxation lente ou de vieillissement non linéaire peut nécessiter l'ajout de nombreux

éléments, ce qui complexifie le modèle. En résumé, les modèles classiques (empiriques, ECM ou électrochimiques) ont chacun leurs limites : ils extrapolent mal hors des conditions testées, demandent des calibrages complexes ou sont trop coûteux pour l'usage courant. C'est cette incapacité des modèles traditionnels à gérer facilement la dégradation complexe des batteries en conditions réelles qui a suscité l'intérêt récent pour des approches basées sur données. Ces dernières considèrent la batterie comme une « boîte noire » dont on cherche à apprendre directement la relation entrée-sortie à partir de données. Les techniques d'apprentissage automatique (ML) ont été appliquées pour modéliser la non-linéarité du vieillissement. Des travaux initiaux ont utilisé des méthodes classiques (machines à vecteurs de support (Burgess, 1998), forêts aléatoires (Schölkopf & Smola, 2002), réseaux de neurones) à partir de courbes mesurées de tension, d'impédance. Ces méthodes ont montré qu'il est possible d'obtenir une bonne précision en « apprenant » à partir de données historiques de vieillissement, sans modéliser explicitement la chimie sous-jacente. Par exemple, on a pu utiliser des neurones simples (El-Dalahmeh, Hui, Zhang, & Mamlouk, 2017) pour estimer le SOH à partir de caractéristiques dérivées ou calculées à partir de données de charge/décharge pour entraîner des SVM ou des réseaux de neurones sur des données de charge/décharge pour prédire la perte de capacité à venir (Schölkopf & Smola, 2002). En résumé, les modèles classiques (empiriques, ECM ou électrochimiques) ont chacun leurs limites : ils extrapolent mal hors des conditions testées, demandent des calibrages complexes ou sont trop coûteux pour l'usage courant. C'est cette incapacité des modèles traditionnels à gérer facilement la dégradation complexe des batteries en conditions réelles qui a suscité l'intérêt récent pour des approches basées sur données. Ces dernières considèrent la batterie comme une « boîte noire » dont on cherche à apprendre directement la relation entrée-sortie à partir de données. Les techniques d'apprentissage automatique (ML) ont été appliquées pour modéliser la non-linéarité du vieillissement. Des travaux initiaux ont utilisé des méthodes classiques (machines à vecteurs de support (Burgess, 1998), forêts aléatoires (Schölkopf & Smola, 2002), réseaux de neurones) à partir de courbes mesurées de tension, d'impédance. Ces méthodes ont montré qu'il est possible d'obtenir une bonne précision en « apprenant » à partir de données historiques de vieillissement, sans modéliser explicitement la chimie sous-jacente. Par exemple, on a pu utiliser des neurones simples (El-Dalahmeh, Hui, Zhang, & Mamlouk, 2017) pour estimer le SOH à partir de caractéristiques dérivées ou calculées à partir de données de charge/décharge pour entraîner des SVM ou des réseaux de neurones sur

des données de charge/décharge pour prédire la perte de capacité à venir (Schölkopf & Smola, 2002).

En revanche, ces modèles traditionnels exigent souvent une extraction manuelle des caractéristiques : on identifie des points sensibles sur la courbe de décharge (p. Ex. Un pic qui glisse avec l'âge) et on les utilise comme variables d'entrée. Ce travail de conception demande une expertise considérable et ne se généralise pas forcément d'un jeu de données à l'autre ou d'un type de batterie à un autre. L'avènement de l'apprentissage profond a offert de nouvelles perspectives. Les modèles profonds (réseaux de neurones convolutifs, récurrent, etc peuvent ingérer des signaux bruts (tension, courant, etc.) et extraire eux-mêmes des représentations sophistiquées. Par exemple, des CNN ont été appliqués directement sur les portions de courbe de charge ou décharge et ont atteint des prédictions de SOH très précises sans extraire au préalable de caractéristiques spécifiques (Schölkopf & Smola, 2002). De même, des LSTM (Long Short-Term Memory) ont été employés pour modéliser les dépendances temporelles et prédire l'évolution du SOH au cours des cycles. Ces réseaux profonds ont rapporté des taux d'erreur très faibles sur des benchmarks, en particulier parce qu'ils peuvent modéliser des relations non linéaires complexes et tirer parti de grands volumes de données issues de multiples capteurs (Shen, 2024). Malgré ces succès, les approches purement basées sur données rencontrent des défis pratiques importants. Un problème majeur est leur dépendance à de grands jeux de données expérimentales de qualité. Collecter ces données est coûteux en temps et ressources : il faut faire vieillir des batteries sur des centaines voire des milliers de cycles (souvent jusqu'à la défaillance) dans des conditions contrôlées, en mesurant régulièrement le SOH, ce qui prend des mois des années par batterie. Des jeux de données publics (provenant du NASA Ames Prognostics Center, du laboratoire CALCE, etc.) existent et ont aidé à développer des algorithmes, mais ils ne couvrent qu'un éventail limité de chimies de batteries et de profils d'utilisation. Lorsqu'on applique un modèle entraîné sur un tel jeu à un nouveau scénario (autre type de batterie ou de protocole de cyclage), les performances chutent souvent si la nouvelle distribution de données n'était pas représentée pendant l'entraînement. En somme, la généralisation reste un obstacle de taille : un modèle peut apprendre parfaitement les schémas de vieillissement d'un cas particulier mais manquer de robustesse sur un autre. Un

autre défi est l'absence quasi totale d'étiquettes SOH continues en conditions réelles : généralement, on ne connaît le SOH d'une batterie qu'au moment de sa mise hors service pour tests, pas à chaque cycle. Cette rareté de données étiquetées rend difficile l'utilisation directe de méthodes supervisées classiques.

Dans ce contexte, l'apprentissage auto-supervisé émerge comme une alternative pertinente, il permet d'exploiter les données non étiquetées en construisant des tâches prétextes pour apprendre des représentations utiles. Ce paradigme offre ainsi une voie prometteuse pour réduire la dépendance aux labels, tout en maintenant une capacité à extraire des motifs complexes et à améliorer la généralisabilité des modèles. Ce mémoire explore une approche combinée reposant sur un autoencodeur masqué (MAE), un apprentissage contrastif (CL) et un réseau de neurones LSTM. L'objectif est d'améliorer l'estimation de l'état de santé (SOH) des batteries en utilisant des représentations latentes plus robustes. Les résultats montrent que cette architecture hybride surpasse les approches classiques, notamment le LSTM seul.

1.2 Problématique

La prédiction précise de l'état de santé (State of Health, SOH) des batteries lithium-ion est un enjeu majeur pour optimiser la durée de vie, la fiabilité et la sécurité des systèmes de stockage d'énergie. Les approches classiques, qu'elles soient expérimentales ou basées sur des modèles empiriques, nécessitent souvent un grand volume de données entièrement étiquetées couvrant l'ensemble du cycle de vie des batteries. Or, en pratique, ces données sont difficiles à obtenir, car les expériences de vieillissement sont longues, coûteuses, et dépendent fortement des conditions de fonctionnement. Cette limitation entraîne un déficit d'information pour l'entraînement de modèles d'apprentissage supervisé, réduisant leur capacité à généraliser sur des batteries et régimes de cyclage différents. Parallèlement, de larges quantités de données non étiquetées issues de l'utilisation réelle (profils tension/courant partiels, durées de charge/décharge) restent inexploitées, alors qu'elles contiennent des signaux de vieillissement pertinents. Face à ces contraintes, il est nécessaire de concevoir une approche capable d'exploiter efficacement ces données non étiquetées, de réduire la dépendance aux étiquettes,

et de capturer des représentations robustes et généralisables du vieillissement des batteries. C'est dans ce contexte que cette thèse propose un cadre hybride combinant un autoencodeur masqué (MAE) et un apprentissage contrastif (CL), suivi d'un LSTM prédictif, afin d'extraire automatiquement des caractéristiques latentes pertinentes, d'améliorer la robustesse de la prédiction et de réduire la quantité de données étiquetées requises.

1.1 Objectifs de la thèse

À la lumière des défis ci-dessus, l'objectif de ce mémoire est de développer et valider un nouveau modèle hybride (combinant MAE et CL) pour l'estimation du SOH des batteries lithium-ion en exploitant l'apprentissage semi-supervisé pour réduire la dépendance à de grands jeux de données annotés (Shen, 2024). L'approche proposée combine deux techniques de pointe les autoencodeurs masqués (MAE) et l'apprentissage contrastif (CL) afin d'apprendre des représentations robustes du vieillissement des batteries à partir de données brutes (Shen, 2024) (Liu, 2025). Ce mémoire vise à atteindre les objectifs spécifiques suivants :

Objectif 1 : Développer un modèle d'autoencodeur masqué pour les batteries. Le modèle MAE (autoencodeur masqué) est initialement entraîné à reconstruire les parties manquantes ou masquées du signal d'entrée. Cependant, au-delà de cette tâche de reconstruction, le MAE apprend également des représentations latentes à chaque pas de temps. Ces représentations capturent des motifs significatifs du comportement de la batterie et sont ensuite utilisées comme entrées d'un modèle supervisé pour prédire l'état de santé (SOH) de la batterie. Ainsi, le MAE ne prédit pas directement le SOH, mais il contribue à générer des caractéristiques utiles à cette fin. Concevoir un autoencodeur capable d'ingérer les données de charge/décharge de batterie et d'apprendre des caractéristiques significatives en tentant de reconstruire des signaux d'entrée partiellement masqués. L'hypothèse est qu'en entraînant le modèle à compléter des portions manquantes d'une courbe de tension ou de courant, l'autoencodeur capturera des motifs intrinsèques du comportement de la batterie corrélés à son état de santé (Shen, 2024) (Sadler, 2025).

Objectif 2 : Intégrer l'apprentissage contrastif pour améliorer la discrimination des caractéristiques. Mettre en œuvre un schéma d'apprentissage contrastif sur les représentations latentes produites par l'autoencodeur, de sorte que les données issues d'états de santé similaires soient rapprochées et que celles issues d'états différents soient écartées dans l'espace des caractéristiques. Cela devrait doter les représentations apprises d'une plus grande sensibilité aux différences de SOH, et ce même sans étiquettes SOH directes lors de l'entraînement (Liu, 2025) (Li, 2023).

Objectif 3 : Intégrer le MAE et l'apprentissage contrastif au sein d'un même cadre auto-supervisé. Développer un pipeline d'entraînement capable d'exploiter, de manière simultanée ou séquentielle, à la fois la tâche de reconstruction masquée et l'objectif contrastif, en s'appuyant sur un jeu de données constitué des historiques d'utilisation des batteries. Le but est d'exploiter les forces complémentaires du MAE (apprentissage de la structure globale par reconstruction) et du CL (apprentissage de caractéristiques comparatives par cohérence) afin de produire un modèle unique capable d'estimer le SOH avec précision (Shen, 2024) (Lu, 2023).

Objectif 4 : Valider l'approche sur des jeux de données expérimentaux. Évaluer le modèle hybride MAE+CL à l'aide de données réelles de cyclage de batteries, en démontrant son exactitude dans l'estimation du SOH sur différentes batteries et dans diverses conditions d'utilisation. Cela implique d'entraîner le modèle sur un ensemble de batteries et de le tester sur d'autres pour vérifier la capacité de généralisation. Les performances seront comparées à celles de méthodes de référence (par exemple un réseau neuronal purement supervisé ou un estimateur basé sur un modèle) pour quantifier les améliorations (Sadler, 2025). À travers ces objectifs, cette thèse cherche en fin de compte à faire progresser la frontière des connaissances sur l'estimation du SOH, en permettant des diagnostics de batteries plus fiables sur le terrain à partir des seules données opérationnelles standard des batteries (Sadler, 2025).

1.2 Description des données

Collecte et préparation des données : Nous utilisons des jeux de données publics de batteries

lithium-ion en cyclage (des données du NASA Ames Prognostics Center). Les données comprennent les profils de charge/décharge et éventuellement les températures pour chaque cycle, qui serviront d'entrées. On normalise les durées des cycles et on calcule la capacité de décharge pour chaque cycle, en vue de mesurer l'évolution du SOH (Sadler, 2025).

Tableau 1.1 B0005–B0018 — cycles, capacités, SOH

ID de la batterie	Nombre total de cycles (jusqu'à EOL)	Points de données enregistrés	Capacité initiale (Ah)	Capacité finale (Ah)	SOH initial (%)	SOH final (%)
B0005	614	168	1,86	1,29	100,0	69,3
B0006	614	168	2,04	1,15	100,0	56,7
B0007	614	168	1,89	1,40	100,0	74,1
B0018	319	132	1,86	1,34	100,0	72,3

L'approche repose sur trois étapes principales. Tout d'abord, un autoencodeur masqué est entraîné sur les séquences de cycles normalisés afin d'extraire des vecteurs latents représentatifs des caractéristiques de chaque cycle. Ensuite, ces représentations latentes sont affinées par un apprentissage contrastif, qui rapproche celles issues de conditions de santé similaires et éloigne celles issues de conditions différentes. Enfin, un réseau LSTM est entraîné sur ces représentations pour prédire l'état de santé (SOH) à partir de séquences de cycles, et l'évaluation est réalisée au moyen de protocoles de validation croisée, garantissant la généralisabilité du modèle. Le mémoire est organisé comme suit. Le chapitre 2 présente l'état de l'art de l'estimation du SOH des batteries, en couvrant les approches expérimentales, fondées sur des modèles et fondées sur les données, puis situe la contribution proposée dans ce contexte. Le chapitre 3 décrit en détail l'architecture proposée (MAE–CL–LSTM), les choix de conception et les modèles de base utilisés pour la comparaison. Le chapitre 4 rapporte les résultats expérimentaux, l'évaluation quantitative des performances (p. ex. RMSE, MAE, R^2) et discute l'efficacité du cadre ainsi que ses limitations observées. Enfin, le chapitre 5 synthétise les contributions du mémoire et propose des pistes de travaux futurs (variantes

d'auto-supervision, extension à d'autres chimies et formats de cellules). Dans l'ensemble, cette organisation montre comment l'approche proposée comble les lacunes des méthodes existantes et fournit un cadre évolutif pour la prédiction fiable du SOH sur l'ensemble du cycle de vie.

CHAPITRE 2

ÉTAT DE L'ART

2.1 Enjeux de l'estimation de l'état de santé des batteries

Comme souligné dans le chapitre précédent [Section 1. 1], l'estimation précise (SOH) des batteries lithium-ion est une nécessité critique pour garantir leur sécurité, leur fiabilité et leur longévité dans leurs nombreuses applications (Zhang, Wang, & Zhang, 2018) (Fotouhi, Auger, Propp, Longo, & Wild, 2016) (Hu, Li, & Peng, 2012) (He, Xiong, Guo, & Li, 2012). Face à cet enjeu majeur, le présent chapitre explore l'état de l'art des méthodes d'estimation du SOH, des approches classiques aux techniques les plus récentes d'apprentissage automatique. Dans les Véhicule électrique, par exemple, une estimation erronée du SOH peut entraîner une perte d'autonomie imprévue, des temps d'arrêt opérationnels ou même des incidents de sécurité (W. Li, Zhang, Wang, & He, 2021) (Hu, Li, & Peng, 2012). Connaître l'état de santé de la batterie est donc indispensable pour un fonctionnement fiable et sûr de ces systèmes. En effet, l'adoption massive et durable des VE repose sur la précision de l'estimation du SOH et sur la prédiction de la durée de vie résiduelle (Tong, Chen, Zou, & Pecht, 2019) (Zhang, Wang, & Zhang Enjeux liés à l'estimation de l'état de santé des batteries.

Au cours de la dernière décennie, plusieurs méthodes d'estimation du SOH ont été proposé, allant de simples modèles empiriques à des techniques avancées d'apprentissage automatique (Zhang, Wang, & Zhang, 2018), (Berecibar et al., 2016) (Han et al., 2014), (Ramadass, Haran, White, & Popov, 2004). Chaque approche présente ses propres avantages et limites en termes de précision, d'interprétabilité, de besoins en données et de capacité de généralisation à différents types de batteries et conditions d'utilisation (W. Li, Zhang, Wang, & He, 2021), (W. Li, Wang, Peng, & Wang, 2021). Les méthodes classiques basées sur un modèle, incluant les modèles empiriques, les modèles de circuits équivalents (ECM) et les modèles électrochimiques, étaient largement utilisées avant l'avènement des techniques modernes pilotées par les données (Dunn, Kamath, & Tarascon, 2011), (Berecibar et al., 2016), (W. Li, Wang, Peng, & Wang, 2021). Ces approches classiques ont jeté les bases de la compréhension

du vieillissement des batteries et demeurent utilisées comme références ou composants dans des systèmes de gestion de batterie (BMS) plus complexes (Zhang, Wang, & Zhang, 2018), (He, Xiong, Guo, & Li, 2012).

En revanche, elles peinent souvent à gérer des problèmes tels qu'une généralisation limitée, une sensibilité au bruit de mesure, des processus de calibration complexes, ou encore une incapacité à saisir le caractère non linéaire et dépendant de l'historique de la dégradation des batteries (Zhang, Wang, & Zhang, 2018), (Hu, Li, & Peng, 2012), (Tong, Chen, Zou, & Pecht, 2019). L'avènement de l'apprentissage automatique a permis de concevoir des modèles pilotés par les données plus flexibles, capables d'exploiter de grands volumes de données opérationnelles pour prédire le vieillissement des batteries sur de longues périodes (W. Li, Zhang, Wang, & He, 2021), (Han et al., 2014), (D. Wang, Lu, & Ouyang, 2014). Néanmoins, les méthodes purement basées sur les données doivent composer avec la qualité et la représentativité des données d'entraînement, ainsi qu'avec la nécessité de prédictions robustes et explicables dans des contextes où la sécurité est critique (Han et al., 2014), (D. Wang, Lu, & Ouyang, 2014).

2.2 Techniques traditionnelles d'estimation de l'état de santé (SOH)

Modèles empiriques : Les modèles empiriques reposent sur des relations mathématiques simples ou des règles heuristiques pour relier les mesures accessibles (par exemple la tension, le courant, la température, le nombre de cycles) à l'état de santé (SOH) de la batterie. Ces modèles sont typiquement dérivés d'analyses statistiques de données expérimentales sur le vieillissement. Par exemple, on pourrait estimer la capacité restante en fonction du nombre de cycles de charge-décharge ou de l'augmentation de la résistance interne au cours du temps. Ces modèles sont faciles à implémenter et nécessitent un minimum de ressources de calcul. On peut ainsi supposer qu'une batterie perd environ 1 % de sa capacité tous les 100 cycles d'utilisation une règle empirique pratique qui fournit une estimation approximative du SOH (W. Li, Zhang, Wang, & He, 2021), (Berecibar et al., 2016).

Cependant, des formules purement empiriques comme celle-ci omettent souvent de prendre en compte des facteurs importants (température ambiante, profondeur de décharge, taux de charge, etc.) qui peuvent accélérer significativement la dégradation. Par conséquent, bien que les modèles empiriques puissent être utiles pour des approximations rapides ou comme algorithmes initiaux dans un BMS, ils manquent de précision et de généralité. Leurs paramètres nécessitent fréquemment d'être recalibrés pour chaque chimie de batterie ou profil d'utilisation, et ils fournissent peu de compréhension physique des mécanismes de dégradation sous-jacents. En pratique, la simplicité des modèles empiriques se traduit par une capacité prédictive réduite dans des conditions différentes de celles pour lesquelles le modèle a été ajusté. Des études ont montré que ces méthodes peuvent sous performer lorsque les batteries s'écartent de la trajectoire de vieillissement supposée ou subissent des conditions de fonctionnement variables. En conséquence, les approches empiriques sont généralement considérées comme des estimations de base, de plus en plus complétées ou remplacées par des techniques plus avancées dans les architectures de BMS modernes (Dunn, Kamath, & Tarascon, 2011), (Hu, Li, & Peng, 2012), (W. Li, Zhang, Wang, & He, 2021). Dans la sous-section suivante, nous abordons les modèles de circuits équivalents (ECM), qui re-présentent une autre approche traditionnelle d'estimation du SOH.

Modèles de circuits équivalents : Les modèles de circuits équivalents (ECM) représentent la batterie comme un circuit électrique constitué d'éléments idéalisés tels que des résistances, des capacités et parfois des éléments à phase constante ou des impédances de Warburg. Les exemples courants incluent le modèle de Thévenin et divers modèles de réseau résistor-capaciteur (RC), qui visent à reproduire la réponse dynamique en tension d'une cellule de batterie. Dans un ECM, des paramètres tels que la résistance interne, la résistance de transfert de charge et la capacité de double couche sont ajustés à partir de données expérimentales (par ex. Réponses à des impulsions ou mesures de spectroscopie d'impédance). Ces paramètres ajustés peuvent ensuite servir d'indicateurs de la santé de la batterie : par exemple, une augmentation de la résistance interne de la cellule ou une diminution de la constante de temps RC peut indiquer une perte de capacité ou une polarisation croissante, ce qui est corrélé à un déclin du SOH.

L'estimation du SOH basée sur les ECM implique souvent de suivre l'évolution de tels paramètres au cours de la vie de la batterie. Des techniques comme le filtrage de Kalman (étendu, sans métré, etc.) sont fréquemment utilisées pour estimer de manière récursive à la fois l'état de charge de la batterie et les paramètres du modèle (qui reflètent le SOH) à partir des données de tension et de courant en temps réel. L'avantage des modèles de circuits équivalents réside dans leur compromis entre simplicité et fidélité : ils sont peu gourmands en calcul et relativement faciles à intégrer dans des systèmes embarqués, tout en capturant le comportement électrique essentiel de la cellule sous différentes charges (He, Xiong, Guo, & Li, 2012) (Tong, Chen, Zou, & Pecht, 2019). Cependant, les méthodes ECM présentent plusieurs défis. D'une part, les paramètres du modèle exigent souvent un calibrage initial soigné et peuvent varier en fonction de la température, de l'état de charge et de l'historique de cycle. Maintenir une précision sur une large plage de conditions opérationnelles peut être difficile sans algorithmes d'estimation de paramètres adaptatifs. Si la batterie fonctionne en dehors des conditions pour lesquelles l'ECM a été identifié, les prédictions du modèle (et donc l'estimation du SOH) peuvent devenir peu fiables.

D'autre part, certains paramètres d'ECM n'ont pas d'interprétation physique directe : ainsi, bien que des changements dans une valeur de résistance ou de capacité puissent signaler un vieillissement, ils n'expliquent pas la cause sous-jacente (par exemple perte de lithium vs dégradation des électrodes). Enfin, certaines configurations d'ECM peuvent avoir du mal à représenter des effets de relaxation à long terme ou des comportements de vieillissement non linéaires (Hu, Li, & Peng, 2012), (Tong, Chen, Zou, & Pecht, 2019), (D. Wang, Lu, & Ouyang, 2014), sauf à ajouter plusieurs éléments, ce qui augmente le complexe. Les modèles ECM constituent un outil d'ingénierie pratique pour l'estimation du SOH et sont largement utilisés dans l'industrie, mais ils nécessitent des routines de calibration complexes et des filtres sophistiqués pour rester précis tout au long de la durée de vie de la batterie.

Modèles électrochimiques : Les modèles électrochimiques sont des approches basées sur la physique qui décrivent en détail les processus internes d'une batterie, en utilisant les principes

de l'électrochimie et de la thermodynamique. Au lieu de considérer la batterie comme un circuit « boîte noire », ces modèles intègrent les équations gouvernantes du transport d'ions, de la cinétique de réaction et de la diffusion des matériaux dans les électrodes et l'électrolyte. Un exemple canonique est le modèle de Doyle–Fuller–Newman (DFN), qui repose sur la théorie des électrodes poreuses et se compose d'équations aux dérivées partielles couplées représentant la diffusion des ions lithium dans les particules solides, la diffusion dans l'électrolyte, les réactions de transfert de charge et la distribution du potentiel électrique à travers la cellule (Eddahech, Briat, Bertrand, & Vinassa, 2012), (Y. Hu, Zou, Lu, & Li, 2020), (Zou, Hu, Ma, & Li, 2015) .

De tels modèles peuvent prédire le comportement de la batterie (tension, capacité, impédance) à partir des principes de base, à condition de connaître les propriétés des matériaux et les paramètres de réaction appropriés. En termes d'estimation du SOH, les modèles électrochimiques offrent la plus grande fidélité en reliant explicitement la perte de capacité ou la croissance de la résistance à des mécanismes spécifiques de dégradation (par exemple formation de la couche d'interface solide électrolyte (SEI), précipitation de lithium métallique, ou perte de matériau actif). Si tous les paramètres du modèle restent corrects, ces méthodes peuvent suivre l'état de santé avec une excellente précision, souvent surpassant les approches empiriques ou basées sur les circuits équivalents en conditions contrôlées (Eddahech, Briat, Bertrand, & Vinassa, 2012), (Ning & Popov, 2004). Malgré leur précision et l'information qu'ils fournissent, les modèles électrochimiques présentent d'importantes limites pour la surveillance pratique du SOH. Ils sont intrinsèquement complexes et gourmands en calcul, nécessitant typiquement des solveurs numériques pour gérer le système d'équations différentielles couplées. La mise en œuvre en temps réel d'un modèle DFN complet dans un BMS de véhicule est généralement impraticable sans simplifications. De plus, ces modèles dépendent de nombreux paramètres internes (coefficients de diffusion, constantes de vitesse de réaction, surface active, etc.) difficiles à déterminer sans expérimentations spécialisées ou démontage de la cellule.

Par exemple, déterminer précisément le coefficient de diffusion du lithium dans l'électrode

solide ou la conductivité de l'électrolyte à l'intérieur d'une cellule nécessite généralement une caractérisation en laboratoire (par exemple spectroscopie d'impédance électrochimique ou analyse destructive de la cellule). Ces paramètres peuvent également varier d'une cellule à l'autre et évoluer avec l'âge de la batterie, introduisant une incertitude supplémentaire. Par conséquent, alors que la modélisation électrochimique est inestimable pour l'analyse hors ligne et la compréhension des mécanismes de vieillissement, son utilisation dans l'estimation embarquée du SOH est limitée (El-Dalahmeh, Hui, Zhang, & Mamlouk, 2017). Les chercheurs simplifient souvent les modèles complets en versions d'ordre réduit (par exemple modèles à particule unique) ou utilisent les modèles électrochimiques dans des cadres d'observation où un sous ensemble de paramètres est estimé de manière adaptative (Santhanagopalan, Guo, Ramadass, & White, 2006).

Néanmoins, l'exigence de connaissances expertes et de ressources informatiques fait que l'estimation du SOH par modélisation électrochimique reste principalement confinée au laboratoire (Zou, Hu, Ma, & Li, 2015), (He, Williard, Chen, & Pecht, 2014), (Waag, Käbitz, & Sauer, 2013). Dans l'industrie, ces modèles servent de référence pour l'exactitude, mais des méthodes plus pratiques sont privilégiées pour la gestion quotidienne de la santé des batteries. En effet, la complexité de leur mise en œuvre, la nécessité de paramètres difficilement mesurables en conditions réelles et le coût élevé de la simulation limitent leur adoption à grande échelle, ce qui explique le recours croissant à des approches plus légères et directement exploitables dans les systèmes embarqués

2.3 Évolution vers des méthodes pilotées par les données et basées sur l'IA

L'utilisation croissante de capteurs et de systèmes « cloud » permet la collecte de grandes quantités de données de fonctionnement de batteries, rendant viables les approches pilotées par les données pour le SOH. Par exemple, Richardson et al. Soulignent qu'avec l'avènement des dispositifs connectés au cloud, les données issues de cellules dans diverses applications deviennent de plus en plus disponibles, et la faisabilité de méthodes pilotées par les données pour la prédiction du SOH des batteries augmente (Richardson, Osborne, & Howey, 2017).

Les premières études piloté par les données ont exploité des algorithmes classiques de ML (régression linéaire, SVM/SVR, processus gaussien) pour extraire des caractéristiques simples (des profils de tension, de courant, de température, ou des signaux dérivés comme la capacité incrémentale). Par exemple, Vilsen & Stroe (2021) ont extrait des caractéristiques descriptives d'une courbe de charge et mis en œuvre une régression linéaire multiple afin de modéliser la relation entre ces caractéristiques et le SOH de la batterie (Vilsen & Stroe, 2021). Ils obtiennent alors une erreur moyenne (MAPE) $< 5\%$ sur leurs données de validation. De même, Zhang et al. ont utilisé des courbes de capacité incrémentale lissées comme entrées à un modèle de régression par processus gaussien, parvenant à des prédictions du SOH très précises et robustes. Récemment, Li M et al. ont combiné une analyse de capacité incrémentale basée sur un modèle physique avec une régression à vecteurs de support (SVR) pour estimer le SOH. Leur méthode donne des erreurs moyennes très faibles (MAE et RMSE inférieurs à $1,1\%$) sur plusieurs jeux de données de vieillissement de batteries. Ces études illustrent que des algorithmes « classiques » de ML améliorent la prédiction de la perte de capacité en exploitant des caractéristiques extraites des profils de charge décharge, bien au-delà de simples formules empiriques basées uniquement sur le nombre de cycles (M. Li et al., 2025), (Y. Zhang, Liu, Wang, & Zhang, 2022).

Le pas technologique le plus marquant est venu avec les réseaux neuronaux profonds. Les réseaux multicouches (feedforward) peuvent modéliser des relations non linéaires complexes sans faire intervenir explicitement l'équation physique du système. Par exemple, Yang et al. ont entraîné un réseau de neurones à rétro propagation (BP) de trois couches sur des caractéristiques extraites de profils de tension et de courant de batteries de véhicules électriques. Leur modèle atteint une grande précision d'estimation du SOH (Yang, Wang, Pan, Chen, & Chen, 2017). En pratique, ces réseaux apprennent le comportement de vieillissement directement à partir des données (résistance interne croissante, variation de la tension à circuit ouvert, historique de SOC, etc.), ce qui les rend plus adaptatifs que des formules empiriques fixes. Pour intégrer les dépendances temporelles, on emploie des réseaux récurrents tels que les LSTM. Ces modèles mémorisent implicitement l'évolution passée (séries temporelles de cycles) et peuvent donc prédire plus finement le déclin de la capacité. Par exemple, Ma et al.

Combinent des indicateurs de santé extraits des cycles de charge ou décharge et un LSTM optimisé (hyperparamètres adaptés par algorithme métaheuristique). Ils rapportent des erreurs d'estimation inférieures à 1 % sur des bases de données de vieillissement du MIT et de la NASA (Ma, Shan, Gao, & Chen, 2022), avec des RMSE, MAE et MAPE tous sous 1 %. Ces résultats illustrent la capacité des LSTM à modéliser des phases de vieillissement non linéaires (par exemple décroissance lente suivie d'une chute rapide en fin de vie) que les modèles statiques ne capturent pas.

Ce niveau de précision, bien supérieur aux méthodes traditionnelles, met clairement en évidence le potentiel de l'apprentissage profond dans les pronostics de batteries. Cependant, ces réseaux neuronaux « boîte noire » manquent intrinsèquement de transparence. Leurs performances peuvent également se dégrader si la distribution des données opérationnelles change par exemple, si une batterie est utilisée dans des conditions non rencontrées pendant l'entraînement (Liu, Li, Li, Wu, & Lv, 2025). C'est pourquoi les chercheurs explorent activement des moyens d'intégrer des connaissances du domaine ou d'utiliser des stratégies d'entraînement avancées afin de rendre ces modèles plus robustes.

Récemment, des approches d'apprentissage non supervisé et auto-supervisé ont émergé pour l'estimation de l'état de santé (SOH). Une direction notable est l'utilisation des autoencodeurs. Des réseaux neuronaux capables de reconstruire leurs entrées partielles permettent d'extraire des caractéristiques pertinentes liées à la santé de la batterie. Certaines variantes, comme les autoencodeurs, ont ainsi été exploitées pour capturer les dynamiques de vieillissement à partir des courbes de charge ou de décharge. Une approche particulièrement innovante est l'auto-encodeur masqué (MAE). Ce modèle est entraîné sur des données non étiquetées en masquant des parties de l'entrée (par exemple, des segments d'une courbe de tension) et en apprenant à reconstituer les parties manquantes. Ce faisant, le MAE acquiert une compréhension approfondie du comportement typique de la batterie et peut fournir un encodage latent robuste des données. Shen et al. Rapportent qu'un MAE pré-entraîné peut extraire des caractéristiques latentes à partir de données de charge partielles qui sont hautement prédictives du SOH, même avec un nombre limité d'exemples étiquetés, permettant ainsi une estimation précise du SOH

en « few-shot » avec un petit ensemble d'entraînement (Shen et al., n.d.).

Cette approche semi-supervisée est très attrayante pour le déploiement réel, où les données de dégradation entièrement étiquetées sont rares, mais les données opérationnelles non étiquetées sont abondantes. De plus, l'extraction de caractéristiques basée sur les auto-encodeurs peut également aider à réduire le bruit et à mettre en évidence des signaux subtils de vieillissement qui pourraient être négligés par une ingénierie manuelle des caractéristiques. En parallèle des auto-encodeurs, des techniques d'apprentissage contrastif (CL) ont été introduites pour améliorer la qualité des représentations apprises pour l'estimation du SOH. L'apprentissage contrastif est une forme d'apprentissage auto-supervisé où le modèle est entraîné à distinguer des paires de données similaires et dissemblables dans l'espace latent. Dans le contexte des batteries, un cadre CL pourrait, par exemple, prendre deux segments de données du même cycle de batterie (qui devraient représenter le même SOH) et encourager leurs représentations latentes à être proches, tout en éloignant les représentations de cycles à des niveaux de SOH différents (Meng, You, Zhang, & Shao, 2024). Ainsi, le modèle apprend des caractéristiques plus discriminantes pour l'état de santé sans utiliser directement les étiquettes de SOH (J. Li, 2023). Le résultat est un gain significatif en précision prédictive une fois qu'une simple régression est appliquée sur les caractéristiques apprises. De telles méthodes basées sur le CL aident le modèle à se concentrer sur des indicateurs de vieillissement subtils mais cohérents, améliorant la généralisation en particulier lorsqu'il faut gérer des schémas d'utilisation variés ou différents modèles de batterie (Shen et al., n.d.). (Encouragés par ces développements, les chercheurs explorent désormais des approches hybrides qui combinent plusieurs techniques de modélisation pour tirer parti de leurs forces complémentaires. Une forme d'hybridation intègre des modèles basés sur la physique avec des modèles pilotés par les données : par exemple, en utilisant les sorties d'un modèle).

Dans le cadre de ce mémoire, nous proposons une approche hybride combinant un auto-encodeur masqué (MAE) pour préentraîner le modèle sur des données partiellement observées, avec l'apprentissage contrastif (CL) pour affiner la structure de l'espace latent en regroupant les représentations selon l'état de santé. Cette combinaison permet de compenser les données

manquantes et d'améliorer la qualité des caractéristiques extraites. Enfin, un réseau LSTM est utilisé pour la régression finale du SOH. Les résultats expérimentaux montrent que cette architecture MAE + CL + LSTM surpasse le LSTM seul ou les configurations partielles, confirmant l'intérêt de notre contribution pour une estimation du SOH plus robuste avec peu de données étiquetées.

L'application de l'apprentissage profond a permis d'atteindre un niveau de précision bien supérieur aux méthodes traditionnelles d'estimation du SOH, démontrant le potentiel du deep learning pour le pronostic des batteries (Liu, Li, Li, Wu, & Lv, 2025). En effet, les réseaux neuronaux profonds peuvent modéliser des relations non linéaires complexes et apprendre en fin à fin à partir des données brutes, ce qui les rend particulièrement performants pour saisir les caractéristiques subtiles du vieillissement des batteries (Liu, Li, Li, Wu, & Lv, 2025). Cependant, ces modèles boîte noire manquent de transparence explicative et leur performance peut se dégrader lorsque les conditions d'utilisation diffèrent de celles des données d'entraînement (changement de distribution) (Yuan, Wenxian, & Yigang, 2024b). Des études ont montré que les modèles purement basés sur données perdent en généralisation sur des données opérationnelles nouvelles, manifestant souvent du surapprentissage en dehors du domaine de formation (Lin, Zhang, & Khoo, 2021). Face à ces limites, les chercheurs explorent des stratégies pour intégrer des connaissances expertes du domaine ou employer des techniques d'entraînement avancées, afin de rendre les modèles plus robustes et interprétables. Par exemple, l'intégration de contraintes physiques ou de modèles hybrides peut améliorer la capacité de généralisation et l'interprétabilité des prédictions, adressant ainsi le manque de transparence des réseaux neuronaux purs (Lin, Zhang, & Khoo, 2021).

2.3.1 Méthodes non supervisées et auto-supervisées

Ces dernières années ont vu l'émergence de méthodes non supervisées et auto-supervisées pour estimer l'état de santé des batteries (Sylvestrin et al., 2025). Un axe notable est l'utilisation des autoencodeurs. Des réseaux neuronaux conçus pour encoder puis décoder les données d'entrée, c'est-à-dire apprendre à compresser l'information et à la reconstruire permettent d'extraire

automatiquement des représentations latentes pertinentes pour l'analyse de la santé des batteries .Plusieurs déclinaisons de cette approche, telles que l'autoencodeur débruitant (DAE) et l'autoencodeur variationnel (VAE), ont été utilisées pour capturer les dynamiques de vieillissement à partir des courbes de charge et de décharge . Par exemple, un autoencodeur débruitant peut apprendre de façon non supervisée à filtrer le bruit des données et à mettre en relief les signaux de dégradation subtils, en produisant des caractéristiques internes plus robustes issues de données partiellement corrompues (Yuan, Wenxian, & Yigang, 2024a). Chen *et al.* Ont ainsi démontré qu'un DAE pouvait apprendre des features robustes à partir de courbes de tension bruitées, améliorant la précision de prédiction du SOH par rapport aux réseaux standards, et ce avec une meilleure généralisation sur différents jeux de données (Yuan, Wenxian, & Yigang, 2024b). De même, un VAE peut découvrir des variables latentes représentant l'état de vieillissement de la batterie, permettant de corrélérer automatiquement des formes de courbes de charge avec le niveau d'usure, sans supervision directe. Une approche particulièrement innovante est l'autoencodeur masqué (MAE) . Ce type de modèle est entraîné sur des données non étiquetées en masquant aléatoirement une portion de l'entrée (par exemple, des segments d'une courbe de tension) et en apprenant à reconstruire les portions manquantes. En apprenant ainsi le « puzzle » des données, le MAE acquiert une compréhension profonde du comportement normal de la batterie et fournit un encodage latent robuste de ses données. Shen et al. Rapportent qu'un MAE pré-entraîné sur un grand corpus de cycles de charge partiels peut extraire des caractéristiques latentes hautement prédictives du SOH (Shen et al., n.d.). Après affinement du modèle avec très peu d'exemples étiquetés, ils obtiennent une estimation précise de la santé en few-shot, c'est-à-dire avec un petit ensemble d'entraînement uniquement. Concrètement, leur méthode atteint environ 2% d'erreur (RMSE) en n'utilisant que 20% des données étiquetées requises par un apprentissage supervisé classique, et maintient une erreur sous les 2% même en se limitant à des données de charge partielles (de l'ordre de 20 minutes seulement). Ces approches semi-supervisées sont très intéressantes pour une application réelle, où il est difficile de recueillir des données de vieillissement entièrement étiquetées alors que des masses de données opérationnelles non étiquetées sont disponibles. Exploiter de vastes jeux de données de terrain sans étiquettes permet d'améliorer l'estimation du SOH tout en réduisant la dépendance à la quantité de données labellisées requises (Yuan,

Wenxian, & Yigang, 2024a). En outre, l'extraction automatique de caractéristiques via autoencodeur contribue à réduire le bruit et à faire ressortir des indicateurs de dégradation subtils qui pourraient échapper à une sélection manuelle des caractéristiques (Yuan, Wenxian, & Yigang, 2024a). Ceci aide le modèle à focaliser son attention sur des signaux significatifs du vieillissement de la batterie, renforçant la fiabilité du pronostic.

2.3.2 Apprentissage contrastif

En parallèle, des techniques d'apprentissage contrastif (forme d'apprentissage auto-supervisé) ont été introduites pour améliorer la qualité des représentations apprises dans le cadre de l'estimation du SOH. L'idée du contrastif est d'apprendre à rapprocher dans l'espace latent des représentations de données similaires, tout en éloignant celles de données différentes (Jiaqi Li, Zhu, Huang, Fan, & Zhang, 2023b). Appliqué aux batteries, un tel cadre peut consister à prendre deux segments de données issus du même cycle de charge (donc au même SOH) et à encourager leurs vecteurs latents à être proches, tandis que l'on sépare davantage les représentations de cycles présentant des niveaux de SOH divergents. Ainsi, le modèle apprend implicitement des caractéristiques plus discriminantes pour distinguer les états de santé, sans utiliser directement les étiquettes de SOH durant le pré-entraînement. Li et al. ont proposé une méthode contrastive auto-supervisée visant à apprendre une « représentation de vieillissement » à partir des données de batterie. Leur approche utilise une architecture à double réseau et une fonction de perte contrastive pour se pré-entraîner sur un large ensemble de courbes de charge partielles, produisant des embeddings qui se regroupent naturellement en fonction du niveau de SOH. Ensuite, une simple régression appliquée sur ces caractéristiques apprises suffit à mapper la représentation latente vers le SOH, avec à la clé un gain significatif en précision prédictive par rapport à un apprentissage direct classique. En focalisant le modèle sur des paires contrastives (similaires vs dissemblables du point de vue de la santé), ces méthodes amènent le réseau à capturer des indicateurs subtils de vieillissement mais cohérents, ce qui améliore la robustesse de la généralisation en particulier pour gérer des régimes d'utilisation variés ou des types de batteries différents sans nécessiter de vastes données étiquetées (J. Li, 2023).

2.3.3 Vers des approches hybrides physique données

Fort de ces développements, la recherche s'oriente vers des stratégies hybrides combinant plusieurs techniques afin de tirer parti de leurs forces respectives. Une forme d'hybridation prometteuse consiste à intégrer des modèles basés sur la physique avec des modèles pilotés par les données. Par exemple, on peut utiliser les sorties ou contraintes d'un modèle physique (représentant la connaissance électrochimique du vieillissement) en entrée d'un modèle d'apprentissage profond, ou conjointement optimiser un modèle neuronal avec des équations physiques. De telles approches physiques et données visent à bénéficier à la fois de la fidélité des modèles physiques et de la flexibilité prédictive des réseaux neuronaux.

Des travaux récents montrent qu'en adoptant un modèle hybride dont la structure de base est physiquement informée, on améliore la généralisation et la fiabilité des prédictions, tout en maintenant une incertitude mieux calibrée sur celles-ci (Lin, Zhang, & Khoo, 2021). Par exemple, Wang et al. ont développé un réseau neuronal informé par la physique (PINN) qui incorpore des équations de dégradation empirique dans l'architecture du réseau. Testé sur un large jeu de 387 cellules lithium-ion provenant de plusieurs sources, leur modèle a atteint une erreur moyenne absolue (MAPE) d'environ 0,87% seulement (F. Wang, Zhai, Zhao, Di, & Chen, 2024). Ce niveau de performance, nettement supérieur à celui de réseaux purement pilotés par les données évalués dans les mêmes conditions, illustre le potentiel des approches hybrides pour conjuguer précision et robustesse. En combinant ainsi connaissances a priori et apprentissage automatique, les modèles hybrides apparaissent comme une voie prometteuse pour des estimations de SOH fiables sur le terrain, capables de s'adapter à des scénarios d'usage divers tout en fournissant des prédictions explicables et cohérentes.

Les modèles de SOH basés sur l'apprentissage profond ont atteint une excellente précision, mais ils font face au défi de nécessiter d'importantes quantités de données étiquetées couvrant l'intégralité des cycles de vie des batteries. Les expériences de vieillissement des batteries sont chronophages, et les jeux de données réels sont souvent limités ou ne couvrent que le début de la vie. Cela a motivé la recherche de stratégies pour réduire la dépendance aux grands

ensembles de données étiquetées. Une approche est l'apprentissage par transfert un modèle est d'abord entraîné sur un jeu de données ou un domaine (par ex. Des cellules vieilles dans certaines conditions) puis affiné sur un jeu de données cible avec peu d'échantillons, transférant ainsi les schémas de vieillissement appris. L'apprentissage par transfert a montré qu'il pouvait améliorer la généralisation entre différents types de batteries et régimes de fonctionnement avec peu de nouvelles données (Har, 2023).

Une autre approche prometteuse est l'apprentissage auto-supervisé, où les modèles sont pré-entraînés sur des données non étiquetées pour apprendre des représentations générales de la santé des batteries qui peuvent ensuite servir à la prédiction du SOH. Par exemple, Lu et al. ont développé une méthode d'apprentissage profond pour estimer la santé des batteries sans nécessiter d'expériences de vieillissement complètes, en s'entraînant sur des données de charge partielles et des schémas de dégradation synthétiques : leur modèle pouvait prédire le SOH avec une grande précision en extrapolant à partir d'une information de vieillissement limitée (Lu, Xiong, Tian, Wang, & Sun, 2023). Ces développements indiquent une tendance claire : les techniques hybrides d'apprentissage profond et auto-supervisées peuvent réduire dramatiquement les besoins en données tout en maintenant une haute précision dans l'estimation du SOH. En apprenant à partir de données non étiquetées ou partiellement étiquetées (via des tâches de reconstruction, des objectifs contrastifs, etc.), le modèle acquiert une compréhension nuancée de la dynamique du vieillissement des batteries qui se transfère à la tâche de prédiction principale.

Cette thèse s'appuie sur ces idées en proposant une approche originale qui combine un autoencodeur masqué (MAE) et un apprentissage contrastif (CL) au sein d'un modèle unifié, dans le but d'exploiter pleinement les données non étiquetées et d'obtenir des représentations d'apprentissage plus robustes et généralisables (Lu, 2025). Alors que les approches reposant uniquement sur les autoencodeurs masqués ou exclusivement sur l'apprentissage contrastif ont déjà été étudiées séparément pour l'estimation de l'état de santé (SOH) des batteries, aucune recherche, à notre connaissance, n'a encore introduit une architecture intégrant simultanément ces deux paradigmes avec un modèle séquentiel tel que le LSTM. Une telle combinaison

permet à la fois de bénéficier de la capacité du MAE à traiter des données partielles ou bruitées, de la force du CL à améliorer la discrimination et la généralisation des représentations, et de la puissance des réseaux LSTM à capturer la dynamique temporelle des cycles de charge et de décharge. Ce travail vise donc à combler cette lacune en proposant un cadre hybride novateur, susceptible d'améliorer significativement la précision et la robustesse des estimations du SOH, tout en ouvrant de nouvelles perspectives pour l'utilisation de l'apprentissage auto-supervisé dans le domaine du diagnostic des batteries lithium-ion. L'utilisation conjointe de MAE et de CL dans une architecture séquentielle constitue ainsi une avancée méthodologique qui dépasse le seul champ des batteries et pourrait inspirer d'autres applications de maintenance prédictive.

Tableau 2.1 comparaison des méthodes

Méthode	Données requises	Avantages	Inconvénients
Apprentissage automatique (SVM, RF, etc.)	Caractéristiques pré-définies (tension de pic, métriques de dégradation, etc.) extraites des données cycliques	Inférence rapide ; pas de modèle physique requis	Les performances dépendent de la qualité des caractéristiques ; capacité limitée à capturer des motifs complexes
Apprentissage profond (CNN, LSTM, etc.)	Données brutes ou peu traitées de séries temporelles tension/courant (cycles partiels ou complets)	Extraction automatique des caractéristiques ; capture les motifs non linéaires du vieillissement ; haute précision rap- portée	Besoin de beaucoup de données (grand jeu d'entraînement) ; interprétabilité réduite des caractéristiques apprises
Apprentissage profond hybride/avancé (CNN + attention, transformeur)	Données brutes multi-sources (courbes de tension, éventuellement température, etc.) sur plusieurs cycles	Combine apprentissage local et global des motifs ; robuste aux conditions changeantes	Coût de calcul élevé ; nécessite un réglage méticuleux et peut nécessiter un apprentissage par transfert pour

Les modèles de SOH basés sur l'apprentissage profond ont atteint une excellente précision, mais ils font face au défi de nécessiter d'importantes quantités de données étiquetées couvrant l'intégralité des cycles de vie des batteries. Les expériences de vieillissement des batteries sont chronophages, et les jeux de données réels sont souvent limités ou ne couvrent que le début de la vie. Cela a motivé la recherche de stratégies pour réduire la dépendance aux grands ensembles de données étiquetées. Une approche est l'apprentissage par transfert un modèle est d'abord entraîné sur un jeu de données ou un domaine (par ex. Des cellules vieilles dans certaines conditions) puis affiné sur un jeu de données cible avec peu d'échantillons, transférant ainsi les schémas de vieillissement appris. L'apprentissage par transfert a montré qu'il pouvait améliorer la généralisation entre différents types de batteries et régimes de fonctionnement avec peu de nouvelles données (Har, 2023).

Une autre approche prometteuse est l'apprentissage auto-supervisé, où les modèles sont pré-entraînés sur des données non étiquetées pour apprendre des représentations générales de la santé des batteries qui peuvent ensuite servir à la prédiction du SOH. Par exemple, Lu et al. ont développé une méthode d'apprentissage profond pour estimer la santé des batteries sans nécessiter d'expériences de vieillissement complètes, en s'entraînant sur des données de charge partielles et des schémas de dégradation synthétiques : leur modèle pouvait prédire le SOH avec une grande précision en extrapolant à partir d'une information de vieillissement limitée (Lu, Xiong, Tian, Wang, & Sun, 2023). Ces développements indiquent une tendance claire : les techniques hybrides d'apprentissage profond et auto-supervisées peuvent réduire dramatiquement les besoins en données tout en maintenant une haute précision dans l'estimation du SOH. En apprenant à partir de données non étiquetées ou partiellement étiquetées (via des tâches de reconstruction, des objectifs contrastifs, etc.), le modèle acquiert une compréhension nuancée de la dynamique du vieillissement des batteries qui se transfère à la tâche de prédiction principale. Cette thèse s'appuie sur ces idées, combinant un autoencodeur masqué et un apprentissage contrastif dans un modèle unifié pour tirer parti des données non étiquetées et obtenir des caractéristiques d'apprentissage robustes (Lu, 2025). Bien que les approches utilisant soit des autoencodeurs masqués (MAE), soit l'apprentissage contrastif (CL) aient déjà été explorées séparément pour l'estimation de l'état de santé (SOH) des batteries, à

notre connaissance, aucune étude n’a encore proposé une architecture intégrant simultanément MAE, CL et un modèle séquentiel comme le LSTM. Ce travail vise à combler cette lacune en proposant un cadre hybride novateur.

2.4 Approche hybride MAE–CL–LSTM pour l’estimation du SOH

Dans notre approche, le MAE est d’abord pré-entraîné de manière auto-supervisée, sans utiliser d’étiquettes de SOH, afin d’apprendre à reconstruire des entrées partiellement masquées (telles que la capacité ou le numéro de cycle). Cette phase permet au modèle de capter les régularités structurelles des données de batterie, même en l’absence de supervision explicite. Ensuite, une étape d’apprentissage contrastif est appliquée pour enrichir la représentation latente produite par le MAE. Cette étape vise à rapprocher les représentations des exemples similaires (par exemple, issus du même état de vieillissement) tout en éloignant celles des exemples dissemblables. Cela permet d’obtenir des encodages plus discriminants, qui capturent mieux les dynamiques de vieillissement. Ces représentations latentes raffinées sont ensuite exploitées par un modèle LSTM, qui prend en compte les dépendances temporelles entre les cycles de charge/décharge, afin de prédire le SOH de manière plus précise. En combinant ainsi la reconstruction auto-supervisée, l’alignement contrastif et la modélisation temporelle, notre approche permet d’améliorer la précision de l’estimation du SOH.

CHAPITRE 3

MÉTHODOLOGIE

3.1 Méthodologie de l'estimation du SOH

Ce chapitre décrit la méthodologie adoptée pour développer et évaluer le modèle proposé. L'objectif est de prédire l'état de santé (SOH) des batteries Li-ion à partir de données de cyclage, en utilisant une approche d'apprentissage auto-supervisé combinant une tâche de reconstruction masquée et une tâche contrastive. Nous détaillons d'abord les jeux de données utilisés pour l'entraînement et l'évaluation. Ensuite, nous présentons les étapes de prétraitement, la conception du pipeline d'apprentissage, ainsi que les stratégies de validation et d'évaluation des performances.




Figure 3.1 Schéma du modèle MAE-CL-LSTM

L'architecture proposée combine un autoencodeur masqué (MAE), un apprentissage contrastif et un réseau LSTM pour l'estimation du SOH des batteries. Les séquences normalisées subissent un masquage de 50 % afin d'entraîner le MAE, qui extrait des représentations latentes. Celles-ci sont affinées par apprentissage contrastif, puis utilisées comme entrées d'un LSTM à deux couches (64 et 32 unités) pour modéliser les dynamiques temporelles. L'optimisation est réalisée avec Adam ($\text{lr} = 0,0005$), une taille de lot de 16 et 100 époques. La

figure ci-dessous résume cette architecture.

3.2 Données utilisées

Nous utilisons des jeux de données publics sur le vieillissement de batteries Li-ion, publiés par le Centre de pronostics de l'Ames de la NASA. Ces données proviennent d'expériences de cyclage jusqu'à défaillance menées dans des conditions strictement contrôlées (température ambiante constante, régimes de charge/décharge fixes, etc.). Concrètement, lors de chaque test, une cellule est chargée (jusqu'à 4,2 V) puis déchargée (jusqu'à 2,7 V) de façon répétée, jusqu'à atteinte de sa fin de vie – typiquement définie comme 70 % de la capacité initiale. En d'autres termes, pour des cellules de capacité nominale 2 Ah, l'EOL (End-of-Life) est atteint lorsque la capacité tombe à ~1,4 Ah. Les tests se terminent à ce seuil afin d'induire des effets de vieillissement profonds tout en évitant un dommage total de la cellule. Les cycles de charge et décharge se succèdent ainsi, provoquant un vieillissement accéléré de la batterie (certains protocoles utilisent même des décharges au-delà du seuil recommandé de 2,7 V pour accentuer la dégradation).

Dans notre étude, nous analysons quatre cellules spécifiques du corpus NASA (identifiants B0005, B0006, B0007, B0018), qui ont chacune subi des centaines de cycles de charge/décharge sur banc d'essai. Ces cellules ont été choisies car elles présentent des séries de données complètes jusqu'à la fin de vie (définie par 70 % de la capacité initiale), sans interruptions ni anomalies majeures. D'autres cellules du même jeu de données ont été exclues en raison de données manquantes, incomplètes ou bruitées, ce qui aurait pu fausser l'entraînement du modèle. Les données brutes sont fournies sous forme de fichiers CSV, où chaque ligne résume un cycle. Chaque enregistrement de cycle comprend typiquement des paramètres tels que l'index du cycle, la capacité de décharge mesurée en Ah, et l'état de santé (SOH) calculé comme le ratio de cette capacité par rapport à la capacité initiale. Ainsi, on dispose pour chaque cellule d'une série temporelle de son SOH en fonction du nombre de cycles. Ces données riches nous permettent de suivre l'évolution de l'état de santé – essentiellement le pourcentage de capacité restante au fil du temps pour chaque batterie. On sait par ailleurs que dans ce type

d'études, les batteries Li-ion subissent des mécanismes internes de vieillissement (par ex. Dégradation des matériaux électrodes, croissance de la couche SEI (Solid Electrolyte Interphase, une couche passivante qui se forme sur l'anode et consomme du lithium, perte de lithium cyclable) qui se traduisent par une diminution progressive de la capacité et une augmentation de la résistance interne (Dubarry, Truchot, & Liaw, 2012) au fil des cycles. Grâce aux données détaillées de la NASA largement utilisées dans la recherche sur la santé des batteries (Rahmanian, Lee, & Linzner, 2024) nous pouvons observer et exploiter finement ces phénomènes, en suivant la dégradation du SOH de chaque cellule depuis ses premiers cycles jusqu'à sa défaillance. Avant la modélisation, un prétraitement standard (nettoyage, vérification de validité, normalisation) est appliqué aux données pour garantir leur cohérence. Les détails sont présentés au paragraphe suivant. Une normalisation min-max est appliquée à chaque variable afin de ramener les valeurs entre 0 et 1, ce qui facilite l'entraînement du modèle. Les paramètres de mise à l'échelle sont calculés uniquement sur l'ensemble d'entraînement pour éviter toute fuite d'information.

Cependant, dans le cadre de cette étude exploratoire, et étant donné que l'ensemble complet des données était accessible dès le départ, la normalisation a été effectuée sur l'ensemble des données avant le découpage en sous-ensembles. Cette simplification a été retenue pour faciliter les expérimentations, tout en gardant à l'esprit qu'une implémentation en conditions réelles devrait respecter la séparation stricte des ensembles. Après le nettoyage et la normalisation, les séries temporelles de chaque batterie sont transformées en séquences glissantes de longueur fixe (ici 100 cycles consécutifs) pour modéliser la dynamique de dégradation. À l'aide d'une fenêtre glissante avec un décalage d'un cycle, nous extrayons les séquences 1–100, puis 2–101, etc, jusqu'à la fin des données. Chaque séquence est associée à une étiquette correspondant au SOH du cycle suivant la fenêtre, ce qui permet de reformuler le problème comme une tâche de régression supervisée temporelle. Cette approche est particulièrement efficace pour capturer les motifs de vieillissement progressif. Elle offre également un grand nombre de séquences pour l'entraînement, augmentant ainsi la diversité des trajectoires, ce qui est bénéfique notamment pour l'apprentissage contrastif. Par exemple, une batterie de 300 cycles produit environ 200 séquences de longueur 100. Ces séquences sont ensuite mélangées et divisées

aléatoirement en ensembles d'entraînement, validation et test (70 %, 20 %, 10 %). À noter qu'une batterie peut être présente dans plusieurs ensembles via différentes portions de cycles. Une séparation stricte par batterie (hors distribution) pourrait être envisagée pour évaluer la généralisation du modèle à des cellules inconnues.

Pour constituer nos ensembles d'entraînement, de validation et de test, nous combinons les séquences extraites des quatre batteries en un seul pool, puis nous effectuons une répartition aléatoire stratifiée (70 % entraînement, 20% validation, 10 % test). Autrement dit, les séquences issues d'une même cellule peuvent se retrouver réparties entre les trois ensembles. Cette approche nous donne un grand nombre de séquences variées pour entraîner le modèle (y compris en contrastif), mais implique que le modèle peut voir en entraînement des segments de série provenant d'une batterie dont d'autres segments servent au test. Dans notre optique exploratoire, cela était acceptable pour maximiser l'utilisation des données disponibles. À noter qu'une évaluation plus stricte pourrait consister à tester la robustesse du modèle dans un scénario où certaines batteries sont totalement exclues de l'entraînement par exemple en réservant une cellule entière pour le test afin de vérifier la capacité de généralisation "zero-shot" à de nouvelles batteries. Ce type de protocole est couramment utilisé pour évaluer la transférabilité des modèles.

3.3 Motivation du choix de l'architecture MAE + CL + LSTM

Bien que les modèles LSTM soient efficaces pour modéliser les dépendances temporelles dans les données de batteries, ils présentent certaines limites lorsqu'ils sont utilisés seuls, notamment en présence de bruit ou de données incomplètes. Pour remédier à cela, nous avons intégré un autoencodeur masqué (MAE) et un apprentissage contrastif (CL) en amont de l'architecture LSTM. Le MAE permet d'apprendre une représentation latente à chaque pas de temps, en capturant les caractéristiques essentielles du vieillissement de la batterie. Ces représentations, plus robustes et informatives, sont ensuite utilisées comme entrées du LSTM pour estimer le SOH avec une meilleure précision.

Afin de valider cette approche, nous avons comparé les performances de plusieurs configurations : LSTM seul, MAE + LSTM, CL + LSTM, et MAE + CL + LSTM. Les résultats expérimentaux montrent clairement que la combinaison MAE + CL + LSTM fournit la meilleure précision de prédiction du SOH, surpassant les autres configurations testées.

3.4 Architecture proposée

Le modèle que nous proposons est un pipeline d'apprentissage profond modulaire comprenant trois composants principaux : (1) un autoencodeur masqué (MAE) pour l'extraction initiale de caractéristiques, (2) un module d'apprentissage contrastif (CL) pour structurer l'espace latent de ces caractéristiques, et (3) un réseau LSTM pour la prédiction séquentielle du SOH. Chaque module est entraîné avec un objectif et des données potentiellement différents, puis l'ensemble est intégré pour fournir la prédiction finale. L'idée générale est de tirer parti de l'apprentissage non supervisé (MAE et CL) afin de trouver des représentations intermédiaires utiles, avant d'entraîner sur cette base un prédicteur supervisé final (le LSTM) chargé d'estimer l'état de santé.

Pré-entraînement du MAE : Nous définissons un encodeur E composé de trois couches entièrement connectées (dimensions : $2 \rightarrow 128 \rightarrow 96 \rightarrow 128$) et un décodeur D asymétrique, réduit à une seule couche ($128 \rightarrow 2$). Ce choix asymétrique est intentionnel pour favoriser une compression plus efficace et éviter une simple copie des entrées.

Pendant l'entraînement de E-D, nous masquons aléatoirement une partie des entrées : à chaque itération, 50 % des composantes du vecteur d'entrée de chaque cycle sont masquées (remplacées par une valeur neutre, ici 0 une fois les données normalisées). L'autoencodeur doit alors reconstruire les valeurs masquées en se basant uniquement sur les valeurs visibles. Cela signifie qu'il ne peut pas simplement recopier les entrées : il doit apprendre à inférer les corrélations sous-jacentes entre les différentes dimensions des données pour deviner les parties manquantes. Cette contrainte favorise l'apprentissage de représentations latentes plus abstraites, utiles pour des tâches aval comme la prédiction du SOH. Chaque cycle (point

temporel) est encodé indépendamment sous forme d'un vecteur latent de dimension 128 ; ainsi, une séquence de 100 cycles est transformée en une séquence latente (100,128). Cette idée de masquage s'inspire de l'approche de He et al. sur les images, qui a démontré qu'en masquant une large partie de l'entrée (75% des pixels) et en entraînant un autoencodeur à les reconstruire, on obtient un objectif auto-supervisé *non* trivial produisant des représentations internes significatives (K. He et al. , 2022) . De même, dans notre domaine, en masquant aléatoirement la moitié des mesures de batterie, nous suivons le principe des autoencodeurs débruiteurs : reconstruire des entrées fortement corrompues encourage le réseau à capturer les corrélations importantes des données plutôt que le bruit spécifique de chaque échantillon. Après un entraînement de 100 époques du MAE, nous sélectionnons le modèle correspondant à la plus faible perte de reconstruction MSE sur l'ensemble de validation non étiqueté, nous obtenons un bon encodeur capable de résumer un cycle de batterie en un vecteur latent informatif. Nous conservons alors uniquement l'encodeur entraîné (le décodeur n'est plus utilisé ensuite) : il servira de base pour l'étape contrastive suivante.

Entraînement contrastif : À partir de l'encodeur pré-entraîné, nous construisons un schéma d'apprentissage contrastif de type triplet. L'idée est d'affiner l'espace latent pour qu'il devienne plus discriminant vis-à-vis de l'état de santé des batteries, en rapprochant les représentations de cycles "similaires" et en écartant celles de cycles "différents". Concrètement, lors de chaque itération, nous formons des trios (ancre, positif, négatif). L'ancre est une séquence de 100 cycles tirée aléatoirement (parmi toutes les batteries) ; le positif est une variante augmentée de cette même séquence (nous ajoutons un léger bruit gaussien aux valeurs de la séquence ancre, ce qui ne modifie pas significativement son SOH global) ; le négatif, lui, est une séquence de 100 cycles provenant d'une autre batterie (choisie aléatoirement de sorte qu'elle ait un SOH différent de l'ancre). Toutes trois sont passées dans l'encodeur (aux poids désormais initialisés par le MAE mais qu'on va continuer à ajuster). On obtient donc trois vecteurs latents pour l'ancre (z), le positif (z^+) et le négatif (z^-). On apprend ainsi à l'encodeur à "oublier" les variations inutiles (bruit, fluctuations individuelles) pour se concentrer sur ce qui fait qu'une séquence appartient à tel ou tel régime de dégradation. Cette stratégie suit les principes des méthodes contrastives modernes, où l'on génère des paires

positives par augmentation des données et l'on prend d'autres exemples du lot comme négatifs (Weng, 2021).

À chaque époque, nous renouvelons les associations ancre/positif/négatif afin de présenter au réseau une grande diversité de situations. Progressivement, les poids de E sont ajustés : des cycles présentant des profils de vieillissement similaires voient leurs embeddings se rapprocher, tandis que des comportements de dégradation très différents occupent des régions éloignées de l'espace latent. Cette phase affine donc la représentation apprise, en la structurant selon des critères plus informatifs (liés à la similarité physiologique entre cycles) plutôt que sur des objectifs purement liés à la reconstruction.

Prédiction par LSTM : Enfin, muni de cet encodeur E amélioré, nous attaquons la tâche finale de prédiction du SOH. Chaque séquence de 100 cycles passe d'abord dans E (qui opère cycle par *cycle* sur les caractéristiques normalisées de chaque cycle) pour produire une séquence de 100 vecteurs latents de dimension 128. Cette séquence latente est ensuite fournie en entrée d'un LSTM à deux couches (la première avec 64 unités cachées, la seconde avec 32). Nous configurons le LSTM avec `batch_first=True` pour plus de commodité : cela signifie que les entrées du réseau ont la forme (batch_size, longueur_séquence, dimensions) au lieu de l'ordre par défaut (longueur_séquence, batch_size, dimensions). Ce format rend la manipulation des lots de données plus intuitive dans notre pipeline d'entraînement. Après avoir propagé les séquences d'entrée à travers le LSTM sur les 100 pas de temps, nous extrayons la sortie du dernier pas (dernier état caché de la couche finale, dimension 32) et nous le passons dans une couche fully connected linéaire de sortie de taille 1. Celle-ci produit la valeur prédite du SOH pour la fin de la séquence d'entrée. L'entraînement de cette partie du modèle se fait de façon supervisée classique : on utilise la Mean Squared Error (MSE) entre le SOH prédit et le SOH réel du dernier cycle, et on rétro-propage à travers le LSTM et la couche de sortie (les poids de peuvent être soit figés, soit légèrement ajustés dans nos expériences nous avons choisi de les figer pendant l'apprentissage du LSTM pour conserver la structure latente acquise). Le LSTM, grâce à ses cellules mémoire, est particulièrement apte à modéliser les dépendances temporelles à long terme présentes dans les séquences de cycles. Il apprend ainsi à traduire

l'évolution des embeddings latents sur plusieurs dizaines de cycles en une estimation de l'état de santé à un instant futur. Notons que les LSTM ont largement fait leurs preuves pour les séries temporelles longues grâce à leur capacité à conserver l'information et à éviter l'explosion/la dissipation du gradient, ce qui les a rendus très populaires pour ce type de tâche séquentielle (Kong et al., 2025).

Un avantage clé de cette architecture modulaire est sa flexibilité. Nous pouvons pré entraîner le MAE sur un ensemble potentiellement très large de données non étiquetées (par exemple, d'autres cycles de batterie issus d'expériences différentes), transférer l'encodeur entraîné dans le cadre contrastif pour le spécialiser sur notre distribution de données, puis enfin entraîner le LSTM prédictif sur les données étiquetées disponibles. Chaque étape apporte un palier d'apprentissage : d'abord des caractéristiques brutes compressives, puis une organisation discriminante de ces caractéristiques, et enfin une interprétation séquentielle pour la régression. Cette approche rappelle fortement le paradigme de pré-entraînement non supervisé suivi d'un fine-tuning supervisé qui a eu beaucoup de succès en vision et en traitement du langage (p. Ex .BERT pré-entraîné par masquage puis adapté à différentes tâches)(Jeong & Bae, 2023) Elle permet de tirer profit de grandes quantités de données brutes pour apprendre une base de connaissances, réduisant ainsi le besoin de données étiquetées massives pour la tâche finale .De plus, chaque bloc du pipeline peut être amélioré ou remplacé indépendamment sans remettre en cause l'ensemble : par exemple, on pourrait tester un autre type d'encodeur (CNN, Transformer, etc.) ou ajouter un mécanisme d'attention au LSTM, sans changer le principe global .Dans nos expériences, cette architecture MAE+CL+LSTM a surpassé des modèles plus simples entraînés de bout en bout , en particulier sur les fins de vie où la dynamique de dégradation est la plus complexe à prédire. Cela confirme que la combinaison d'un apprentissage de caractéristiques non supervisé, d'une structuration contrastive discriminante et d'une modélisation séquentielle puissante apporte un bénéfice substantiel pour les pronostics de batteries (T. Chen, Kornblith, Norouzi, & Hinton, 2020).

3.5 Motivation du choix de l'architecture MAE + CL + LSTM

Bien que les modèles LSTM soient efficaces pour modéliser les dépendances temporelles dans les données de batteries, ils présentent certaines limites lorsqu'ils sont utilisés seuls, notamment en présence de bruit ou de données incomplètes. Pour remédier à cela, nous avons intégré un autoencodeur masqué (MAE) et un apprentissage contrastif (CL) en amont de l'architecture LSTM. Le MAE permet d'apprendre une représentation latente à chaque pas de temps, en capturant les caractéristiques essentielles du vieillissement de la batterie. Ces représentations, plus robustes et informatives, sont ensuite utilisées comme entrées du LSTM pour estimer le SOH avec une meilleure précision. Afin de valider cette approche, nous avons comparé les performances de plusieurs configurations : LSTM seul, MAE + LSTM, CL + LSTM, et MAE + CL + LSTM. Les résultats expérimentaux montrent clairement que la combinaison MAE + CL + LSTM fournit la meilleure précision de prédiction du SOH, surpassant les autres configurations testées.

3.6 Détails de l'implémentation

Nous avons implémenté ce modèle en Python en nous appuyant sur les bibliothèques scientifiques courantes (NumPy, Pandas pour la gestion des données) et TensorFlow/Keras pour les réseaux de neurones. Le code est organisé de manière modulaire afin de bien séparer les trois étapes d'entraînement décrites plus haut. Une classe principale SOH estimator orchestre le flux global et permet d'enchaîner facilement les phases.

En résumé, le déroulement est le suivant :

Pré-entraînement du MAE : Nousinstancions l'encodeur E et le décodeur D avec une architecture dense légèrement asymétrique $2 \rightarrow 128 \rightarrow 96 \rightarrow 128$ pour E, et $128 \rightarrow 2$ pour D. Ce choix asymétrique est volontaire pour favoriser une compression efficace tout en réduisant le risque de simple recopie des entrées. Nous utilisons une fonction de perte MSE entre les entrées complètes et les sorties reconstruites. Pendant l'entraînement du MAE, nous appliquons un masque aléatoire d'environ 50 % des caractéristiques sur chaque séquence d'entrée. Le MAE apprend ainsi à reconstruire les séquences originales. L'entraînement se fait

sur un certain nombre d'époques jusqu'à convergence de la perte de reconstruction sur l'ensemble d'entraînement non étiqueté (nous utilisons aussi des séquences de validation non étiquetées pour éviter le sur-ajustement). Une fois satisfait des performances, nous sauvegardons les poids de l'encodeur E.

Entraînement contrastif : Nous construisons ensuite le modèle contrastif en encapsulant l'encodeur E (initialisé avec les poids du MAE) dans un nouveau flux de calcul qui gère trois entrées (ancre, positif, négatif). Nous implémentons une fonction de perte contrastive personnalisée basée sur les distances entre paires positives et négatives. Durant cette phase, tous les poids du réseau (essentiellement ceux de E, sans ajout de tête de projection, puisque dans nos tests nous utilisons directement la représentation latente produite par E bien que dans nos tests nous utilisons directement le latent de E) sont entraînaables. "Nous utilisons des mini-batches de 16 triplets (ancre, positif, négatif) et optimisons la perte contrastive via l'algorithme Adam. Progressivement, l'encodeur apprend à produire des vecteurs bien structurés dans un espace à 128 dimensions : les séquences "positives" (issues du même cycle bruité) tombent proches de leur ancre correspondante, tandis que des séquences provenant d'autres batteries s'éloignent. Cet affinage du latent s'inspire d'approches comme SimCLR ou MoCo qui ont démontré l'efficacité du contraste pour structurer les représentations sans labels (T. Chen et al. , 2020). Nous monitorons la progression en observant la valeur de la perte contrastive et éventuellement en projetant les embeddings sur des composantes principales pour vérifier la formation de clusters par batterie .

Prédiction par LSTM : Enfin, nous fixons les poids de l'encodeur E (optionnellement on pourrait les laisser entraînaables avec un taux d'apprentissage réduit fine tuning mais nous choisissons de d'abord évaluer la qualité du latent "gelé") et nous entraînons le LSTM prédictif. Pour cela, nous utilisons les séquences de l'ensemble d'entraînement étiquetées (chaque séquence étant associée au SOH du dernier cycle). Chaque séquence passe dans E (non entraînable à ce stade) ce qui la transforme en séquence latente, puis traverse le LSTM bicouche, et enfin la couche dense finale produit (SOH prédit). Nous calculons l'erreur quadratique moyenne et rétro-propageons à travers uniquement les couches LSTM et dense

(ou éventuellement à travers encoder si on décide de fine-tuner légèrement l’encodeur). On entraîne ainsi le modèle pendant 100 époques, en surveillant la RMSE sur un ensemble de validation représentant 20 % des données d’entraînement. Le processus s’arrête dès que la RMSE sur l’ensemble de validation cesse de diminuer, ce qui permet d’éviter le sur-apprentissage et d’assurer une bonne généralisation. À la fin, on obtient un modèle complet capable de prédire le SOH à partir d’une séquence brute de cycles.

Le code comprend également divers utilitaires : par exemple, une fonction `create_dataset` qui automatise le fenêtrage glissant des données brutes en lots de séquences + étiquettes, en appliquant exactement les mêmes transformations de prétraitement (normalisation, etc.) qu’au moment de l’entraînement initial du MAE. Cela garantit une cohérence totale entre les données vues à chaque phase. Nous avons veillé à modulariser chaque composant (MAE, CL, LSTM) dans le code de sorte qu’il soit facile d’activer/désactiver une composante ou d’en remplacer une. Par exemple, pour expérimenter, on peut aisément désactiver la perte contrastive (pour tester juste MAE+LSTM), ou au contraire désactiver le masquage (pour tester juste CL+LSTM), sans avoir à “casser” le reste du pipeline – ce qui nous a permis de réaliser les études d’ablation mentionnées précédemment.

En termes d’infrastructure, nos expériences ont principalement été menées sur GPU (une carte NVIDIA Tesla fournie sur un serveur de calcul). Même si chaque module pris isolément n’est pas très lourd (les séquences sont courtes, 100 pas, et le modèle reste modeste en taille), l’entraînement du MAE et surtout de l’étape contrastive bénéficie grandement de la parallélisation GPU, en particulier parce que le contraste nécessite des batchs de grande taille pour bien échantillonner des couples négatifs variés. Néanmoins, pour de petits jeux de données, une exécution sur CPU reste possible en raisonnable.

3.7 Prétraitement et pipeline de données

Toutes les étapes de prétraitement décrites ont été automatisées dans un pipeline Python afin de garantir la reproductibilité et la cohérence des transformations appliquées. Voici un aperçu des traitements effectués séquentiellement sur les données brutes :

Nettoyage des données brutes : Pour chaque cycle enregistré dans les fichiers CSV NASA, nous procédons à une vérification de validité. Les cycles comportant des valeurs manquantes (NaN) sont écartés. Les données sélectionnées étant globalement cohérentes, nous n'avons pas observé de capacité négative ni de saut anormal de capacité (hormis de légères fluctuations de mesure considérées comme du bruit normal). Il n'a donc pas été nécessaire d'éliminer d'autres cycles pour cause d'aberration.

De plus, on s'assure que le nombre de points de chaque courbe de charge/décharge est conforme aux attentes (les enregistrements très incomplets sont supprimés). Ces étapes garantissent que seules des données cohérentes alimenteront l'entraînement.

Assemblage et étiquetage : Nous concaténons ensuite les données de toutes les batteries retenues (B0005, B0006, B0007, B0018) en une seule grande table, en ajoutant un identifiant de batterie pour chaque cycle afin de tracer la provenance. Chaque entrée (cycle) reçoit un label de SOH. La capacité initiale de chaque cellule étant $\sim 2,0$ Ah, ce calcul est direct (il est parfois déjà fourni dans les données NASA sous forme de pourcentage, selon les fichiers). On obtient ainsi une série temporelle globale multi-batteries, indexée par (battery_id, cycle_index), avec pour chaque cycle les caractéristiques (capacité, index de cycle normalisé) et le SOH en label. Un identifiant de batterie est conservé pour chaque cycle afin de tracer sa provenance, bien que cet identifiant ne soit pas utilisé comme entrée du modèle). Dans le code, toutes les données sont fusionnées sans utilisation explicite d'un identifiant de batterie dans les features. Cette précision évite toute confusion.

Normalisation : Nous parcourons chaque colonne de caractéristiques et calculons son minimum et maximum sur l'ensemble d'entraînement. Nous stockons ces valeurs de façon à pouvoir les réutiliser plus tard pour rescaler les données de validation et de test. Une normalisation min-max est appliquée pour contraindre toutes les caractéristiques à l'intervalle $[0,1]$. Comme discuté plus haut, il est crucial de n'utiliser que des infos d'entraînement pour ce calcul afin d'éviter du data leakage. Dans notre implémentation, le pipeline permet soit de spécifier à l'avance une partition train/val/test et de normaliser en conséquence, soit – pour des

expériences exploratoires de normaliser globalement (en assumant que l'ensemble complet était disponible, comme cela peut être le cas dans le cadre de recherches académiques où l'on optimise hors ligne et on valide sur un autre jeu plus tard). Quoi qu'il en soit, la normalisation rend les variables comparables et évite que l'optimiseur ne doive naviguer des échelles différentes – par exemple, sans cela, une erreur absolue de 0,1 sur un SOH (qui est un ratio 0–1) n'est pas directement comparable à 0,1 V d'erreur sur une tension mesurée brute de ~ 4 V, etc. En normalisant tout, on donne au réseau un paysage d'apprentissage équilibré.

Fenêtrage glissant : Une fois les données normalisées, nous appliquons la création des séquences temporelles comme décrit en section 3.1. Une fonction parcourt la série de chaque batterie et en extrait des séquences de longueur T (100 selon les tests) avec un décalage d'un pas à chaque fois. Chaque séquence est stockée avec son étiquette (SOH du dernier point). Ce fenêtrage transforme le problème en un jeu de paires (séquence d'entrée, valeur cible). Techniquement, nous obtenons plusieurs milliers de séquences. Celles-ci sont ensuite mélangées puis séparées en train/val/test selon les proportions souhaitées. À cette étape, si l'on veut garantir qu'aucune batterie de test n'ait été vue en entraînement, on pourrait filtrer par `battery_id`. Dans notre expérimentation de base, nous avons opté pour une séparation aléatoire simple au niveau des séquences, ce qui signifie que certaines séquences d'une même batterie se retrouvent en train et d'autres en test (comme mentionné précédemment). Cette option maximise le nombre d'échantillons de train, mais n'évalue pas la capacité de généralisation à une nouvelle batterie ; plus loin dans le manuscrit, on pourra tester une séparation par batterie pour évaluer ce point.

Masquage pour MAE : Lors de l'entraînement du MAE, nous activons le masquage aléatoire dans le pipeline de données. À chaque batch, nous prenons un tenseur de séquences (N, T, F) et nous échantillonnons un masque binaire (taux de masquage $p \approx 0.5$), régénéré aléatoirement à chaque batch. Nous appliquons ce masque en remplaçant les entrées masquées par 0 (les données étant normalisées sur $[0, 1]$, 0 joue le rôle de valeur manquante neutre). L'encodeur reçoit ces entrées masquées et le décodeur doit reconstruire les valeurs originales aux positions masquées. La perte de reconstruction (MSE) est calculée uniquement sur les positions masquées, les non-masquées étant exclues du calcul. Ce procédé revient à simuler des capteurs en panne ou des données manquantes, et oblige l'autoencodeur à *inférer*

les informations manquantes à partir du contexte disponible. C’est un concept analogue aux autoencodeurs débruiteurs classiques où on ajoute du bruit artificiel pour rendre la tâche de reconstruction plus difficile et ainsi obtenir des caractéristiques internes plus robustes. Dans notre cas, le “bruit” est un masquage franc de la moitié des données. Après le pré-entraînement, nous désactivons évidemment ce masquage lorsque nous utilisons E sur de vraies données : le masquage n’est qu’un outil d’entraînement, pas une augmentation appliquée à l’inférence.

Génération des triplets pour CL : De même, lors de l’entraînement contrastif, le pipeline génère dynamiquement les couples positif/négatif. Pour chaque batch de séquences d’ancrage, nous construisons en interne une version bruitée (bruit gaussien additif de faible amplitude) ce sera le positif. Pour le négatif, on utilise une séquence différente présente dans le même batch (en pratique, on profite du fait qu’on traite les données en batch : on peut par exemple considérer pour chaque i que la séquence $i+1$ du batch est “négative” pour la séquence i en veillant à mélanger les batchs à chaque epoch). Ainsi, sans effort particulier, on obtient des triplets variés au fil des itérations. Cette manière de procéder s’inspire de l’approche de l’apprentissage contrastif sans label, où l’on définit des paires positives via des augmentations et l’on utilise les autres exemples du batch comme négatifs (Weng, 2021) . Nous avons choisi l’ajout de bruit gaussien comme augmentation car, pour des données temporelles de batteries, cela conserve le profil de dégradation tout en introduisant une légère différence (c’est plus simple que d’autres augmentations possibles, comme supprimer/alourdir un segment de cycle, ce qui aurait pu être fait aussi). À chaque époque, un nouveau tirage aléatoire des associations et du bruit est réalisé, assurant que le réseau ne sur-apprenne pas un jeu fixe de triplets.

Séparation des ensembles : Enfin, une fois que toutes les séquences sont prêtes et associées à leurs labels (pour l’entraînement LSTM), nous effectuons la séparation en ensembles d’entraînement, validation et test. Comme mentionné, cela peut être fait de manière aléatoire standard. Dans notre cas, nous avons d’abord réservé $\sim 10\%$ des séquences totales pour le test final (jamais vues durant le développement), puis parmi les 90% restantes, nous avons pris $\sim 80\%$ pour l’entraînement et $\sim 20\%$ pour la validation. Cela aboutit à $\sim 70\%$ des données en entraînement, 20% en validation, 10% en test. La séparation étant au niveau des séquences, il est possible qu’une même batterie apparaisse dans les trois ensembles (mais via des segments

de cycles différents). Ce n'est pas problématique pour vérifier la capacité du modèle à prédire des cycles qu'il n'a pas vus, mais, encore une fois, cela ne constitue pas un test de généralisation à de nouvelles batteries inédites. Néanmoins, l'évaluation sur le jeu de test ainsi constitué nous permet déjà de valider la performance prédictive et la robustesse de notre pipeline.

L'ensemble du pipeline depuis la lecture des CSV bruts jusqu'à la production des tenseurs d'entrées normalisés prêts pour chaque phase (MAE, CL, LSTM) est implémenté de manière reproductible. Ainsi, en fournissant les mêmes données brutes en entrée, on obtiendra toujours les mêmes séquences d'entraînement masquées pour le MAE, les mêmes triplets pour le CL (à permutation aléatoire près), etc. Nous avons appliqué un prétraitement rigoureux pour limiter les erreurs courantes (comme le surapprentissage ou la fuite de données), tout en reconnaissant certaines simplifications adoptées dans ce cadre exploratoire). En définitive, ce pipeline de prétraitement soigneux. Les métriques de performance (telles que le RMSE, le MAE et le R^2) rapportées dans ce mémoire sont issues d'une moyenne sur trois entraînements indépendants avec des graines aléatoires différentes, afin de réduire la variance liée à la nature stochastique de l'apprentissage profond.

CHAPITRE 4

RÉSULTAT

4.1 Performance globale

Ce chapitre présente les résultats obtenus à l'issue des différentes étapes d'entraînement et d'évaluation de notre modèle. Nous commençons par analyser la performance globale de l'approche auto-supervisée, avant de comparer avec d'autres configurations et d'étudier la robustesse du modèle dans divers scénarios. Notre modèle auto-supervisé atteint un score $R^2 \approx 0.983$, ce qui indique un excellent ajustement global. Cependant, les valeurs de RMSE (1.51) et de MAE (0.82) suggèrent que certaines prédictions comportent des erreurs absolues non négligeables.

4.2 Configuration et hyperparamètres d'apprentissage

Le modèle auto-supervisé de SOH a été entraîné pendant 100 époques avec une taille de lot de 16 et un taux d'apprentissage de 0,0005 (optimiseur Adam). Pour entraîner notre modèle, nous avons d'abord utilisé un auto-encodeur masqué (MAE) pour apprendre des représentations latentes pertinentes à partir des données brutes. Ensuite, ces représentations ont été affinées via un apprentissage contrastif (CL), permettant de mieux structurer l'espace latent. Enfin, les vecteurs ainsi obtenus ont été utilisés comme entrée d'un réseau LSTM à deux couches pour estimer le SOH. L'encodeur a d'abord été pré-entraîné sur des données avec 50 % des caractéristiques masquées aléatoirement, puis affiné à l'aide d'une perte contrastive sur des triplets (ancree, positif, négatif).

Une fois l'encodeur figé, le LSTM a été entraîné de manière supervisée sur les séquences complètes encodées. À titre de comparaison, un modèle de base (LSTM sans MAE/CL) a été entraîné dans les mêmes conditions. Nous avons surveillé la perte sur le jeu de validation à

chaque époque afin de détecter un éventuel surapprentissage. Le taux d'apprentissage a été maintenu constant à 0.0005 tout au long des 100 époques. Le jeu de validation (248 séquences) a fourni un retour d'information non biaisé pendant l'entraînement afin d'éviter le surapprentissage. La figure 1 illustre la distribution des capacités pour chaque batterie. La diversité et le recouvrement partiel des distributions suggèrent une bonne variabilité dans les données, favorable à un apprentissage robuste.




Figure 4.1 Distribution de la capacité

La figure 4.1 illustre la distribution des capacités pour chaque batterie. L'axe horizontal représente la capacité mesurée en ampère-heure (Ah), tandis que l'axe vertical correspond à la densité de probabilité.

La diversité et le recouvrement partiel des distributions suggèrent une bonne variabilité dans les données, favorable à un apprentissage robuste. Distribution de la capacité des batteries pour quatre cellules (B0005, B0006, B0007, B0018) dans le jeu de données de la NASA.




Figure 4.2 Matrice de corrélation

La matrice de corrélation (figure 4.2) révèle une forte corrélation positive entre la capacité et le SOH (0.96). Les axes horizontal et vertical correspondent aux variables étudiées, tandis que l'échelle de couleur représente le coefficient de corrélation de Pearson, compris entre -1 et 1 . Le cycle normalisé (`cycle_norm`) est fortement anticorrélé à la capacité (-0.95) et au SOH (-0.88), ce qui confirme l'effet du vieillissement. Cela reflète une dynamique typique des batteries Li-ion : plus le nombre de cycles augmente, plus la capacité diminue. Ces relations linéaires justifient l'inclusion de ces variables comme prédicteurs dans l'estimation du SOH. La cohérence de ces corrélations renforce la validité des choix de modélisation effectués dans notre pipeline.




Figure 4.3 Histogramme de la répartition

La figure 4.3 montre l'histogramme de la répartition des valeurs de State of Health (SOH) dans le jeu de données. On observe une concentration notable autour de 100 %, ce qui indique de nombreuses séquences en début de vie de la batterie. La distribution est néanmoins assez étalée, couvrant une large plage de SOH allant d'environ 57 % à 100 %. Cela assure une représentativité des différentes phases de vieillissement, y compris les stades avancés. Une telle diversité des cibles est essentielle pour entraîner un modèle robuste et capable de généraliser sur l'ensemble du cycle de vie.




Figure 4.4 Capacité B0005 brut vs filtré (selon les cycles)

Cette figure (4.4) illustre la comparaison entre la capacité mesurée brute (points bleus) et sa version filtrée (ligne rouge) pour la batterie B0005. On observe que les données originales présentent des fluctuations locales et du bruit, notamment des pointes irrégulières qui ne correspondent pas à une tendance physique attendue. Le filtrage permet de lisser ces anomalies

tout en conservant la tendance globale de la dégradation de la capacité au fil des cycles. Cela améliore la qualité des données en supprimant les outliers et en facilitant l'apprentissage par les modèles, surtout ceux sensibles au bruit. Ce prétraitement est donc crucial pour garantir une estimation plus stable et fiable de l'état de santé (SOH) des batteries.




Figure 4.5 Dégradation de la capacité

Cette figure (4.5) met en évidence la diminution progressive de la capacité des cellules (B0005, B0006, B0007, B0018) au fil des cycles. La tendance décroissante est attendue et témoigne du vieillissement naturel des batteries lithium-ion en utilisation répétée. On observe cependant des différences notables entre les batteries : La cellule B0006 montre une dégradation plus rapide que les autres, avec une pente plus prononcée. B0007 présente une capacité initiale plus élevée et une décroissance plus lente, indiquant une meilleure stabilité. Des variations irrégulières, notamment des chutes brusques, peuvent indiquer des anomalies ou du bruit dans

les mesures (d'où l'intérêt du filtrage vu précédemment). Cette visualisation est essentielle pour modéliser le comportement des batteries, extraire des caractéristiques pertinentes et évaluer précisément leur état de santé (SOH).




Figure 4.6 Entraînement, validation, test

La figure 4.6 présente la distribution des données selon trois ensembles : Entraînement : (990) séquences Validation (248) séquences Test : (138) séquences Cette répartition suit une logique classique (environ 70% / 20% / 10%), assurant un bon apprentissage du modèle, tout en conservant des ensembles de validation et de test suffisamment représentatifs. Le jeu de validation sert à surveiller la performance pendant l'entraînement, en particulier pour détecter le surapprentissage (overfitting). Le jeu de test, totalement indépendant, permet d'évaluer la

généralisation finale du modèle. La présence de proportions équilibrées garantit que les résultats obtenus ne sont pas biaisés par une répartition déséquilibrée, et que le modèle est évalué de façon fiable sur des données qu'il n'a jamais vues.




Figure 4.7 Distribution globale du SOH

La figure 4.7 présente la distribution du State of Health (SOH) en pourcentage dans les trois sous-ensembles de données : entraînement, validation et test. Répartition uniforme : On observe que la distribution du SOH est similaire entre les trois ensembles, couvrant une large plage de valeurs (approximativement de 55 % à 100 %), ce qui est essentiel pour un apprentissage robuste et une évaluation cohérente. Équilibre statistique La forme des histogrammes indique que les répartitions conservent les tendances principales du jeu de données global. Cela signifie que la séparation des données n'a pas introduit de biais majeur. Même les valeurs extrêmes (SOH faible ou proche de 100 %) sont présentes dans chaque sous-ensemble, garantissant que le modèle est exposé à toute la variabilité. Ce type de vérification

est crucial pour s'assurer que l'évaluation du modèle pendant l'entraînement et après ne sera pas faussée par une distribution tronquée. En résumé, cette figure confirme que la stratégie de partitionnement respecte l'équilibre et la représentativité des données de SOH.




Figure 4.8 Importance des caractéristiques

La Figure 4.8 illustre l'importance relative des variables `cycle_norm` et `capacity`, telle qu'estimée par un autoencodeur, sur la base de la variance reconstruite après entraînement. L'axe horizontal correspond aux variables d'entrée, tandis que l'axe vertical indique leur importance normalisée, calculée à partir de la variance reconstruite. `Cycle_norm` plus informatif : L'autoencodeur attribue une importance plus élevée à `cycle_norm` (plus de 60 %), ce qui indique que cette variable joue un rôle majeur dans la reconstruction fidèle des données d'entrée. `Capacity` reste significatif : Bien que sa contribution soit moindre, la variable `capacity` participe de manière notable à la représentation latente, soulignant son intérêt dans l'apprentissage. Apprentissage non supervisé : Cette estimation est obtenue sans utiliser les

étiquettes de SOH, ce qui démontre la capacité de l'autoencodeur à extraire des caractéristiques discriminantes de façon autonome. Impact sur le modèle en aval : Ces résultats permettent de mieux identifier les entrées les plus pertinentes pour les étapes suivantes de l'architecture, notamment pour le LSTM ou les couches de prédiction du SOH. Ces résultats confirment l'intérêt d'intégrer l'autoencodeur comme bloc de prétraitement dans l'architecture globale. En effet, les caractéristiques produites constituent des entrées de meilleure qualité pour les modules suivants, tels que le LSTM ou les couches dédiées à la prédiction du SOH. Cette structuration préalable de l'information permet au modèle séquentiel d'exploiter des variables déjà épurées du bruit et plus représentatives de la dynamique réelle de la batterie, améliorant ainsi la robustesse de l'estimation et la stabilité de l'apprentissage. En pratique, cela se traduit par une convergence plus rapide, une meilleure généralisation et une réduction des erreurs de prédiction dans les étapes finales du pipeline.

4.3 Performance du modèle (auto-supervisé)

Le récapitule les métriques finales obtenues sur le jeu de test pour deux variantes de notre modèle, comparées au modèle de base (LSTM sans préentraînement). Le modèle auto-supervisé complet (MAE + CL) a atteint un RMSE de 1,51, un MAE de 0,81 et un coefficient de détermination R^2 de 0,988, indiquant une excellente précision prédictive. Par comparaison, le LSTM de base a obtenu $RMSE = 1,71$, $MAE = 0,90$, et $R^2 = 0,970$. Ces résultats montrent que le préentraînement MAE + CL améliore significativement la précision en réduisant les erreurs et en augmentant la capacité explicative du modèle (R^2). Cela valide l'intérêt de combiner les approches d'auto-encodeur masqué et d'apprentissage contrastif pour renforcer l'apprentissage des représentations latentes. Le R^2 de 0,988 dépasse les performances des modèles rapportés dans la littérature récente (par exemple, $R^2 \approx 0,974$ pour un LSTM standard appliqué à des données similaires). Le R^2 de 0,988 dépasse les performances des modèles rapportés dans la littérature récente (par exemple, $R^2 \approx 0,974$ pour un LSTM standard appliqué à des données similaires). (Dans les comparaisons, le modèle représenté à gauche correspond au modèle de référence, tandis que celui de droite est le modèle auto-supervisé (MAE + CL))




Figure 4.9 Erreur de prédiction vs SOH réel

L'analyse des erreurs de prédiction en fonction du SOH réel met en évidence des différences notables entre le modèle auto-supervisé et le modèle LSTM de base. L'axe horizontal représente le SOH réel exprimé en pourcentage, tandis que l'axe vertical correspond à l'erreur de prédiction. Pour le modèle auto-supervisé, les erreurs demeurent globalement réparties autour de la ligne de référence (erreur nulle), ce qui traduit l'absence de biais systématique. La majorité des points se situent dans une plage modérée, confirmant que le modèle ne tend pas à surestimer ou à sous-estimer de manière récurrente l'état de santé des batteries.

En revanche, le modèle LSTM de base présente une dispersion plus large et une fréquence plus importante d'erreurs éloignées de zéro. Cette instabilité reflète une capacité réduite à maintenir la précision prédictive tout au long du cycle de vie des batteries, en particulier dans les plages critiques où les dynamiques de dégradation sont plus complexes. La comparaison des deux approches confirme donc la supériorité du modèle auto-supervisé, qui se distingue par des prédictions plus équilibrées, une meilleure généralisation et une stabilité accrue face aux variations du SOH réel.




Figure 4.10 Erreurs de prédiction séquentielles sur l'ensemble de test

La comparaison des erreurs de prédiction séquentielles met en évidence des différences significatives entre le modèle auto-supervisé proposé et le modèle LSTM de base. L'axe horizontal correspond à l'indice des échantillons de test, tandis que l'axe vertical représente l'erreur de prédiction. Pour le modèle auto-supervisé, la majorité des erreurs demeure contenue dans une plage modérée et oscille autour de la ligne de référence correspondant à l'erreur nulle. Cette disposition traduit l'absence de dérive systématique dans les prédictions et atteste d'une bonne stabilité du modèle sur l'ensemble du jeu de test. Bien que quelques pics négatifs ou positifs apparaissent ponctuellement, ils restent isolés et ne compromettent pas la robustesse globale des estimations. Ces anomalies peuvent être attribuées à des transitions brusques dans les mécanismes de vieillissement des cellules ou à la présence de points atypiques dans les données. Dans l'ensemble, ces résultats soulignent la supériorité du modèle auto-supervisé par rapport au LSTM de base, en particulier en matière de stabilité et de fiabilité prédictive. Alors que le LSTM tend à présenter des erreurs plus dispersées et potentiellement plus sujettes à la dérive, l'approche auto-supervisée démontre une meilleure résilience face aux variations du jeu de test, ce qui en fait une solution plus adaptée pour l'analyse et la prévision des phénomènes complexes liés au vieillissement des cellules.




Figure 4.11 Distribution des erreurs de prédiction (SOH prédit – SOH réel)

Pour le modèle auto-supervisé, la distribution des erreurs de prédiction met en évidence une concentration marquée autour de zéro, traduisant une absence de biais systématique dans les estimations. La courbe de densité superposée à l'histogramme adopte une forme globalement symétrique et proche d'une distribution normale, ce qui témoigne d'une stabilité dans le comportement prédictif du modèle. Les erreurs extrêmes, bien que présentes aux extrémités de la distribution, demeurent rares et isolées. Cette configuration confirme la capacité du modèle auto-supervisé à fournir des estimations fiables et précises du SOH, même en présence d'un certain bruit dans les données expérimentales. L'allure régulière et resserrée de la distribution valide la robustesse du modèle et renforce son aptitude à généraliser sur l'ensemble du jeu de test.

En comparaison, la distribution des erreurs obtenue avec le modèle LSTM de base présente une dispersion plus large, avec une fréquence accrue d'erreurs éloignées de zéro. Cette variabilité traduit une plus grande instabilité dans les prédictions, révélant la difficulté du modèle classique à maintenir une précision constante, notamment dans certaines zones critiques du cycle de vie des batteries. L'écart plus prononcé entre la distribution empirique et la forme idéale d'une loi normale suggère une moindre capacité de généralisation et une

susceptibilité accrue aux fluctuations des données. Ainsi, la confrontation entre les deux modèles confirme la supériorité du modèle auto-supervisé, dont la stabilité et la régularité des erreurs en font un outil prédictif plus robuste et plus fiable pour l'estimation de l'état de santé des batteries lithium-ion.




Figure 4.12 SOH prédit vs SOH réel

L'axe horizontal représente le SOH réel exprimé en pourcentage, tandis que l'axe vertical correspond au SOH prédit, également exprimé en pourcentage. Les résultats obtenus avec le modèle LSTM de base montrent une dispersion marquée des points, en particulier dans les plages de SOH faibles, ce qui traduit une précision limitée lors de l'estimation des phases de fin de vie des batteries. Cette dispersion reflète la difficulté du modèle classique à suivre correctement la dynamique réelle du vieillissement. À l'inverse, le modèle auto-supervisé présente un alignement beaucoup plus serré des points le long de la diagonale, ce qui met en évidence une forte corrélation entre les valeurs prédites et les valeurs réelles issues des données de test. La ligne rouge pointillée représentant la droite d'identité ($y = x$) souligne que les prédictions du modèle auto-supervisé se rapprochent davantage de la référence idéale. Cette tendance est particulièrement manifeste dans les plages de SOH élevées (85–100 %), où les prédictions se regroupent étroitement autour de la ligne idéale, démontrant une excellente précision pour les batteries peu dégradées. La comparaison entre les deux approches confirme ainsi la supériorité du modèle auto-supervisé, qui se distingue par une capacité de généralisation plus robuste et une meilleure fidélité des estimations sur l'ensemble du cycle de

vie des batteries lithium-ion.

4.4 Analyse des erreurs

Dans l'ensemble, les résultats indiquent que le modèle MAE+CL+LSTM proposé est très efficace pour la prédiction du SOH. Les courbes d'apprentissage (non montrées) étaient lisses et convergentes, et l'intégration de tâches auto-supervisées a apporté un bénéfice mesurable. Nos conclusions sont conformes aux travaux associés : des valeurs élevées de R^2 (supérieures à 0,98) et de faibles MAE/RMSE sont souvent citées comme indicateurs de qualité d'un modèle d'état de santé. L'attention portée à la distribution des données et à l'importance des caractéristiques clarifie en outre pourquoi le modèle réussit : il exploite les signaux les plus informatifs (capacité, indice de cycle) et est entraîné sur un ensemble de valeurs de SOH représentatif.

En conclusion, le modèle proposé démontre des performances à la pointe de l'état de l'art sur le jeu de données NASA. L'intégration de l'auto-encodage masqué et de l'apprentissage contrastif permet d'obtenir des plongements plus riches, ce qui permet au LSTM de prédire le SOH avec une très grande précision. Les graphiques détaillés et les métriques confirment ces performances et montrent un avantage net par rapport au modèle de référence. Des travaux futurs pourraient étendre cette approche à des jeux de données plus vastes ou à d'autres chimies de batteries, mais les résultats actuels démontrent déjà l'efficacité du préentraînement autosupervisé. Ces résultats traduisent une meilleure capacité de généralisation du modèle proposé face aux variations de données. La réduction des erreurs et la stabilité observée au fil des cycles attestent de la robustesse de l'architecture retenue. L'intégration conjointe de l'auto-encodage masqué et de l'apprentissage contrastif semble jouer un rôle essentiel dans cette amélioration. De plus, la qualité des plongements appris facilite une reconstruction fidèle, ce qui bénéficie directement à la prédiction du SOH. L'approche mise en œuvre constitue ainsi une base solide pour des travaux de recherche futurs, notamment dans un contexte de batteries en conditions réelles.

Tableau 4.1 Comparaison conceptuelle des familles de méthodes d'estimation du SOH

Méthode	Type	Données	Précision (qualitative)
MAE + CL + LSTM	Auto-supervisé	NASA	Élevée
LSTM classique	Supervisé	NASA	Élevée
XGBoost (Zhang et al., 2022)	ML classique	NASA	Moyenne
CNN-BiLSTM+Attention (Zhu et al., 2022)	Deep Learning	NASA / CALCE	Très élevée

Les méthodes d'estimation du SOH présentent un compromis entre précision et complexité, allant des approches simples comme XGBoost et le LSTM classique, peu coûteuses en calcul mais légèrement moins précises, aux modèles de deep learning avancés tels que les CNN-BiLSTM avec attention et les Transformers, offrant une précision élevée au prix d'une complexité importante. Dans ce cadre, la combinaison MAE + CL + LSTM se positionne comme un compromis équilibré, atteignant des performances proches des modèles les plus complexes tout en conservant une complexité modérée. Cette architecture permet ainsi d'éviter l'explosion du nombre de paramètres et du temps d'entraînement observée avec les réseaux profonds plus sophistiqués, la rendant plus adaptée à des applications embarquées ou temps réel. Enfin, la comparaison directe entre ces méthodes reste limitée par l'hétérogénéité des jeux de données utilisés, ce qui impose une interprétation prudente des métriques rapportées et souligne la nécessité de benchmarks communs. Des approches plus avancées, telles que les processus gaussiens et les modèles basés sur les Transformers, ont également été explorées dans la littérature. Bien qu'elles offrent des performances élevées, leur complexité et leurs exigences computationnelles limitent leur adoption pratique.

CONCLUSION ET DISCUSSION

4.5 Synthèse des résultats obtenus avec le modèle MAE+CL+LSTM

Les résultats expérimentaux obtenus démontrent le fort potentiel pratique du modèle MAE+Contrastif+LSTM proposé pour l'estimation de l'état de santé (SOH) des batteries. Sa très grande précision prédictive ($R^2 \approx 0,98-0,995$) permet d'envisager son intégration fiable dans un système de gestion de batterie (BMS) pour un suivi en temps réel. Une telle précision autorise une prise de décision fine, notamment en termes d'autonomie restante ou de détection précoce de défauts. Un point particulièrement important est la capacité du modèle à détecter les phénomènes de régénération de capacité, souvent ignorés par d'autres approches. Ces fluctuations, fréquentes dans les données réelles, peuvent fausser les prédictions si elles ne sont pas correctement prises en compte. Contrairement à de nombreuses architectures modernes, le modèle atteint ces performances sans recourir à des mécanismes d'attention, ce qui témoigne d'une capacité d'apprentissage robuste malgré une structure plus simple.

L'approche d'entraînement auto-supervisée proposée est bien adaptée à la disponibilité réelle des données, où les signaux de tension et de courant sont abondants alors que les étiquettes précises de SOH restent limitées. Le pré-entraînement par autoencodeur masqué, suivi d'un apprentissage contrastif, permet d'exploiter efficacement les données non étiquetées, tout en nécessitant un faible volume de données annotées, ce qui rend l'approche pertinente pour des contextes embarqués ou fédérés.

Il convient toutefois de noter que les expériences reposent sur le jeu de données public NASA, composé d'un nombre limité de cellules et de conditions expérimentales contrôlées, ce qui restreint la diversité des scénarios d'usage considérés. Par conséquent, la généralisation du modèle à d'autres chimies ou conditions d'exploitation doit être interprétée avec prudence. Dans cette optique, l'intégration future de jeux de données plus diversifiés, l'évaluation en scénarios *cross-domain*, ainsi que des analyses d'ablation des capteurs et de robustesse aux

données manquantes permettraient de renforcer la validité et la généralisabilité du modèle.

4.6 Travaux futurs et perspectives de recherche

Les résultats obtenus avec l'approche auto-supervisée (MAE + CL + LSTM) démontrent une amélioration significative par rapport au modèle LSTM de base. Afin de renforcer la généralisation et la fiabilité de ce système en conditions d'usage réelles, plusieurs prolongements méthodologiques et expérimentaux peuvent être envisagés. Introduire des régimes de température et de courant variables, ainsi que des cycles de charge/décharge dynamiques reflétant des profils de mission réels. Tester le modèle hors du cadre « température et courant constants » permettra d'évaluer sa robustesse face aux fluctuations des conditions d'utilisation.

Par ailleurs, une analyse d'ablation des capteurs pourrait être envisagée afin d'évaluer l'impact des différentes sources d'information sur l'estimation du SOH. Par exemple, l'utilisation de la tension seule, puis de la combinaison tension-courant, et enfin l'ajout de la température permettraient de quantifier la contribution relative de chaque variable. De plus, l'étude de la robustesse du modèle face à des données manquantes, en faisant varier le taux de masquage des entrées, permettrait de simuler des conditions réalistes de capteurs défaillants ou bruités.

BIBLIOGRAPHIE

- Analog Devices. 2019. Battery SOC/SOH Estimation Technical Article.
- Battery University. 2015. BU-012: How to Prolong Lithium-based Batteries.
- Berecibar, M., I. Gandiaga, I. Villarreal, N. Omar, J. Mierlo et P. Bossche. 2016. Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews*, 56, 572-587.
- Burges, C. J. 1998. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- Chen, J.-C. 2025. Degradation Self Supervised Learning for Lithium ion Battery Health Diagnostics.
- Chen, T., S. Kornblith, M. Norouzi et G. Hinton. 2020. A Simple Framework for Contrastive Learning of Visual Representations. Dans *Proceedings of the 37th International Conference on Machine Learning*. PMLR. Repéré à <https://proceedings.mlr.press>
- Dubarry, M., C. Truchot et B. Y. Liaw. 2012. Synthesize battery degradation modes via a diagnostic and prognostic model. *Journal of Power Sources*, 219, 204-216. En ligne <https://doi.org/10.1016/j.jpowsour.2012.07.016>.
- Dunn, B., H. Kamath et J. M. Tarascon. 2011. Electrical energy storage for the grid: A battery of choices. *Science*, 334(6058), 928-935.
- Eddahech, A., O. Briat, N. Bertrand et J. M. Vinassa. 2012. Behavior model of a lithium-ion battery in electric vehicle applications. *IEEE Transactions on Vehicular Technology*, 61(3), 975-984.
- El-Dalahmeh, M., Z. Hui, J. Zhang et M. Mamlouk. 2017. Unlocking the Potential of Second-Life Batteries: A Nonlinear Frequency and Machine Learning Approach to Health Prediction.
- Etacheri, V., R. Marom, R. Elazari, G. Salitra et D. Aurbach. 2011. Challenges in the development of advanced Li-ion batteries: A review. *Energy & Environmental Science*, 4(9), 3243.
- Fotouhi, A., D. J. Auger, K. Propp, S. Longo et M. Wild. 2016. A review on electric vehicle battery modelling: From Lithium-ion toward Lithium-Sulphur. *Renewable and Sustainable Energy Reviews*, 56, 1008-1021.

- Guo, Y., D. Yang, K. Zhao et K. Wang. 2022. State of health estimation for lithium-ion battery based on Bi-directional long short-term memory neural network and attention mechanism. *Energy Reports*, 8, 208-215. <https://doi.org/10.1016/j.egy.2022.10.128>.
- Han, X., L. Lu, Y. Zheng, X. Feng, Z. Li et M. Ouyang. 2014. A review on the key issues of the lithium ion battery degradation among the whole life cycle. *eTransportation*, 1, 100005.
- Har. 2023. A Self-attention Knowledge Domain Adaptation Network for Commercial Lithium-ion Batteries State-of-health Estimation under Shallow Cycles. Hasan, M. 2023. Overview of recent advancements in battery technologies. *Batteries*, 9, 580.
- He, H., R. Xiong, H. Guo et S. Li. 2012. Comparison study on the battery models used for the energy management of batteries in electric vehicles. *Energy Conversion and Management*, 64, 113-121.
- He, K., X. Chen, S. Xie, Y. Li, P. Dollár et R. Girshick. 2022. Masked autoencoders are scalable vision learners. Dans *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 16000-16009).
- He, W., N. Williard, C. Chen et M. Pecht. 2014. State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation. *International Journal of Electrical Power & Energy Systems*, 62, 783-791.
- Hu, X., S. Li et H. Peng. 2012. A comparative study of equivalent circuit models for Li-ion batteries. *Journal of Power Sources*, 198, 359-367.
- Hu, Y., C. Zou, L. Lu et J. Li. 2020. Advanced battery management system for electric vehicles based on multi-source data fusion. *Energy Reports*, 6, 391-403.
- Jeong, D. et S. Bae. 2023. Estimating battery state-of-charge with a few target training data by meta-learning. *Journal of Power Sources*, 553, 232238.
- Kong, Y., Z. Wang, Y. Nie, T. Zhou, S. Zohren, Y. Liang ... Q. Wen. 2025. Unlocking the power of LSTM for long term time series forecasting. Dans *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 39, pp. 11968-11976).
- Li. 2023. A Contrastive Learning Battery State of Health Estimation Method Based on Self-supervised Aging Representation. (S.I.) : IFAC PapersOnLine, ResearchGate.
- Li, J. 2023. A Contrastive Learning Battery State of Health Estimation Method Based on Self-supervised Aging Representation. *Journal of Power Sources*.

- Li, Jiaqi, J. Zhu, Z. Huang, G. Fan et X. Zhang. 2023a. A Contrastive Learning Battery State of Health Estimation Method Based on Self-supervised Aging Representation. IFAC-PapersOnLine, 56(2), 6130-6135. <https://doi.org/10.1016/j.ifacol.2023.10.710>.
- Li, Jiaqi, J. Zhu, Z. Huang, G. Fan et X. Zhang. 2023b. A contrastive learning battery state of health estimation method based on self-supervised aging representation. IFAC-PapersOnLine, 56(2), 6130-6135.
- Li, M. 2025. State of Health Estimation and Battery Management: A Review of Health Indicators, Models and Machine Learning. Materials (Basel), 18(1), 145. <https://doi.org/10.3390/ma18010145>.
- Li, W., B. Wang, J. Peng et X. Wang. 2021. A deep learning framework for state-of-health estimation of lithium-ion batteries under various operating conditions. Applied Energy, 287, 116505.
- Li, W., X. Zhang, Z. Wang et H. He. 2021. A review of state of health estimation for lithium-ion batteries based on piloté par les données methods. Energies, 14(4), 812.
- Lin, J., Y. Zhang et E. Khoo. 2021. Hybrid physics-based and piloté par les données modeling with calibrated uncertainty for lithium-ion battery degradation diagnosis and prognosis.
- Liu, C. 2025. A Multi Encoder BHTP Autoencoder for Robust Lithium Battery SOH Prediction Under Small Sample Scenarios. Batteries, 11(5), 180.
- Liu, C., H. Li, K. Li, Y. Wu et B. Lv. 2025. Deep Learning for State of Health Estimation of Lithium-Ion Batteries in Electric Vehicles: A Systematic Review. Energies, 18(6), 1463. <https://doi.org/10.3390/en18061463>.
- Lu. 2025. Transformer-based Hybrid DNN for Fast-Charging SOH Estimation of LFP Batteries. (S.l.) : PMC.
- Lu, J. 2023. Deep learning to estimate lithium ion battery state of health without additional degradation experiments. Nature Communications, 14, 2760.
- Lu, J., R. Xiong, J. Tian, C. Wang et F. Sun. 2023. Deep learning to estimate lithium-ion battery state of health without additional degradation experiments. Nature Communications, 14, 2760. <https://doi.org/10.1038/s41467-023-38458-w>.
- Ma, Y., C. Shan, J. Gao et H. Chen. 2022. A novel method for state of health estimation of lithium-ion batteries based on improved LSTM and health indicators extraction. Energy, 251(C).
- Meng, X., Z. You, M. Zhang et B. Shao. 2024. Distributed hierarchical cooperative control and stability analysis of flexible interconnected microgrid cluster via back-to-back

converters. Transactions of China Electrotechnical Society, 39(24), 7917.
<https://doi.org/10.19595/j.cnki.1000-6753.tces.240313>.

Mitchell-Williams, H. 2020. State of California Energy Storage Report.

Ning, G. et B. N. Popov. 2004. Cycle life modeling of lithium-ion batteries. Journal of the Electrochemical Society, 151(10), 1584-1591.

Pasquier, A. 2021. Les batteries électriques dans les véhicules. Electr. Veh. World Mag, 2(4), 25.

Rahmanian, F., R. M. Lee et D. Linzner. 2024. Attention towards chemistry agnostic and explainable battery lifetime prediction. npj Comput Mater, 10, 100.

Ramadass, P., B. Haran, R. White et B. N. Popov. 2004. Mathematical modeling of the capacity fade of Li-ion cells. Journal of Power Sources, 123(2), 230-240.

Richardson, R., M. Osborne et D. Howey. 2017. Gaussian process regression for forecasting battery state of health. Journal of Power Sources, 357, 209-219.
<https://doi.org/10.1016/j.jpowsour.2017.05.004>.

Sadler, J. 2025. ACCEPT: Diagnostic Forecasting of Battery Degradation Through Contrastive Learning.

Santhanagopalan, S., Q. Guo, P. Ramadass et R. E. White. 2006. Review of models for predicting the cycling performance of lithium ion batteries. Journal of Power Sources, 156(2), 620-628.

Schölkopf, B. et A. J. Smola. 2002. Learning with kernels: support vector machines, regularization, optimization, and beyond. (S.l.) : MIT Press.

Shan, R., Y. Wang, S. Guo, Y. Cui, L. Zhao, J. Li et Z. Wang. 2025. From Empirical Measurements to AI Fusion—A Holistic Review of SOH Estimation Techniques for Lithium-Ion Batteries in Electric and Hybrid Vehicles. Energies, 18(13), 3542.
<https://doi.org/10.3390/en18133542>.

Shen, Y. 2024. Enhanced Few Shot State of Health Estimation for Lithium Ion Batteries Via Masked Autoencoder. (S.l.) : SSRN.

Shen, Yifan, Y. Wang, D. Guo, J. Chen, X. Liu, X. Han ... M. Ouyang. s.d. Enhanced Few-Shot State-of-Health Estimation for Lithium-Ion Batteries Via Masked Autoencoder. Available at SSRN 5153802.

Smith, R. 2020. Advanced estimation techniques for battery health. IEEE Transactions on Industrial Electronics, 66, 12345.

- Sylvestrin, G. R., J. N. Maciel, M. L. M. Amorim, J. P. Carmo, J. A. Afonso, S. F. Lopes et O. H. Ando Junior. 2025. State of the Art in Electric Batteries' State-of-Health (SoH) Estimation with Machine Learning: A Review. *Energies*, 18(3), 746. <https://doi.org/10.3390/en18030746>.
- Tong, S., C. Chen, C. Zou et M. Pecht. 2019. Cloud battery management system for electric vehicles. *Energy*, 188, 116002.
- International Energy Agency. 2022. The Role of Critical Minerals in Clean Energy Transitions.
- Vilsen, S. B. et D.-I. Stroe. 2021. Battery state-of-health modelling by multiple linear regression. *Journal of Cleaner Production*, 290, 125700. <https://doi.org/10.1016/j.jclepro.2020.125700>.
- Waag, W., S. Käbitz et D. U. Sauer. 2013. Adaptive estimation of the electromotive force of lithium-ion batteries for automotive applications. *Journal of Power Sources*, 238, 413-426.
- Wang, D., L. Lu et M. Ouyang. 2014. Adaptive state of charge estimation method with unknown initial value for lithium-ion batteries. *Journal of Power Sources*, 245, 195-204.
- Wang, F., Z. Zhai, Z. Zhao, Y. Di et X. Chen. 2024. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis. *Nature Communications*, 15(1), 4332.
- Warmuth, E. 2024. Aging mechanisms in lithium-ion batteries. *Heliyon*, 10, 12345.
- Weng, L. 2021. Contrastive Representation Learning. Lil'Log. Repéré à <https://lilianweng.github.io/posts/2021-05-31-contrastive/>.
- Xiao, Y. 2020. Thermal behavior of lithium-ion batteries under abuse conditions. *Journal of Power Sources*, 448, 227454.
- Xu, G., J. Xu et Y. Zhu. 2024. LSTM-based estimation of lithium-ion battery SOH using data characteristics and spatio-temporal attention. *PLoS ONE*, 19(12), 312856. <https://doi.org/10.1371/journal.pone.0312856>.
- Yang, D., Y. Wang, R. Pan, R. Chen et Z. Chen. 2017. A Neural Network Based State-of-Health Estimation of Lithium-ion Battery in Electric Vehicles. *Energy Procedia*, 105, 2059-2064. <https://doi.org/10.1016/j.egypro.2017.03.583>.
- Yeh, G. 2019. New perspectives on battery performance. *Journal of the Electrochemical Society*, 166, 1730.

- Yuan, C., D. Wenxian et H. Yigang. 2024a. State of Health Estimation of Lithium Ion Battery Based on Denoising Autoencoder-Gated Recurrent Unit. Transactions of China Electrotechnical Society, 39(24), 7933-7949.
- Yuan, C., D. Wenxian et H. Yigang. 2024b. State of Health Estimation of Lithium Ion Battery Based on Denoising Autoencoder-Gated Recurrent Unit. Transactions of China Electrotechnical Society, 39(24), 7933-7949.
- Zhang, C., Z. Wang et W. Zhang. 2018. A review on state of health estimation for lithium ion batteries. IEEE Access, 6, 39513-39529.
- Zhang, S. S. 2006. The effect of the charging protocol on the cycle life of a Li-ion battery. Journal of Power Sources, 161(2), 1385-1391.
- Zhang, Y., Y. Liu, J. Wang et T. Zhang. 2022. State-of-health estimation for lithium-ion batteries by combining model-based incremental capacity analysis with support vector regression. Energy, 239(PB).
- Zhao, X., Y. Liu, Z. Chen et L. Wang. 2025. State of health estimation method based on real data of electric vehicles: federated learning across multiple cells. Transportation Electrification. Repéré à <https://www.sciencedirect.com/science/article/pii/S1452398124001329>.
- Zhu, Z., Q. Yang, X. Liu et D. Gao. 2022. Attention-based CNN-BiLSTM for SOH and RUL estimation of lithium-ion batteries. Journal of Algorithms & Computational Technology, 16, 17483026221130598.
- Zou, Y., X. Hu, H. Ma et S. E. Li. 2015. Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles. Journal of Power Sources, 273, 793-803.