

Estimation Optimisée des Paramètres de Batterie : Capacité, Résistances et SOC pour Véhicules Électriques : Une Approche Hybride Basée sur l'Algorithme Génétique et l'Intelligence Artificielle

Index Terms—Modélisation de batteries, État de Charge (SOC), État de Santé (SOH), circuit électrique équivalent, optimisation des paramètres, intelligence artificielle, estimation dynamique, véhicules électriques (VE).

Abstract—Dans cet article, nous présentons une méthode d'optimisation des principaux paramètres d'un modèle électrique équivalent de batterie ($R_{ohmique}$, R_1 , C_1) et de sa capacité (C_{bat}) en utilisant des techniques avancées d'intelligence artificielle. L'objectif est d'améliorer la précision de l'estimation de l'État de Charge (SOC) et de l'État de Santé (SOH). Nous introduisons une approche d'optimisation dynamique dans laquelle les résistances et les capacités sont ajustées à chaque étape de temps, tandis que C_{bat} est optimisé sur un cycle complet. Les résultats démontrent une amélioration significative en termes de réduction des erreurs de prédiction.

I. INTRODUCTION

L'estimation précise de l'État de Charge (SOC) et de l'État de Santé (SOH) est essentielle pour la gestion et le fonctionnement efficaces des batteries de véhicules électriques (VE). Le SOC fournit des informations sur l'énergie restante dans la batterie, tandis que le SOH indique la santé globale de la batterie et la dégradation de sa capacité au fil du temps. Ces deux paramètres sont cruciaux pour assurer un fonctionnement sûr et efficace des VE, ainsi que pour le développement de stratégies de maintenance prédictive et de gestion du cycle de vie des batteries [1]–[3].

Pour caractériser le comportement des batteries, les modèles électriques équivalents ont émergé comme des outils fondamentaux. Ces modèles représentent les caractéristiques électriques de la batterie par un ensemble de paramètres, tels que les résistances et les capacités,

qui sont essentiels pour simuler et comprendre les performances de la batterie. Parmi les modèles couramment utilisés figurent les modèles de circuits équivalents simples, qui incluent des composants tels que la tension en circuit ouvert, les résistances internes ($R_{ohmique}$, R_1), et les capacités (C_1 , C_{bat}) [4], [5]. Ces modèles offrent un moyen simplifié mais efficace de prédire le comportement de la batterie dans différentes conditions de fonctionnement.

Cependant, les méthodes traditionnelles d'estimation du SOC et du SOH, telles que les mesures statiques et les modèles fixes, présentent plusieurs limitations. Les mesures statiques, y compris celles dérivées des mesures de tension et de courant, sont souvent insuffisantes pour capturer la nature dynamique des performances de la batterie [6]–[8]. De plus, les modèles qui ne s'adaptent pas aux conditions changeantes peuvent échouer à prendre en compte les processus électrochimiques complexes, ce qui conduit à des estimations inexactes [9]. Par conséquent, il est nécessaire de recourir à des méthodes plus avancées qui optimisent dynamiquement les paramètres du modèle de batterie au fil du temps, garantissant que le modèle reste précis à mesure que la batterie subit divers cycles de charge-décharge.

Dans ce contexte, l'optimisation dynamique est essentielle pour capturer les complexités des processus électrochimiques qui influencent les performances de la batterie. L'optimisation des paramètres tels que les résistances internes ($R_{ohmique}$, R_1), les capacités (C_1) et la capacité (C_{bat}) à chaque étape de temps peut contribuer à améliorer la précision des estimations du SOC et du SOH. Cette approche s'adapte non seulement aux conditions changeantes de la batterie, mais tient également compte des non-linéarités et des effets de

vieillesse inhérents aux réactions électrochimiques des batteries [10], [11].

L'objectif de cet article est de proposer une méthode qui optimise les principaux paramètres d'un modèle électrique équivalent de batterie, à savoir $R_{ohmique}$, R_1 , C_1 et C_{bat} , en utilisant des techniques avancées d'optimisation. En ajustant dynamiquement ces paramètres à chaque étape de temps, nous visons à améliorer la précision de l'estimation du SOC et du SOH, permettant ainsi une meilleure gestion des batteries et prolongeant leur durée de vie dans les véhicules électriques.

A. Résultats de l'Optimisation

L'optimisation des paramètres de la batterie a été réalisée avec succès en utilisant un algorithme génétique, ce qui a permis de minimiser l'erreur entre les tensions réelles et estimées. Les résultats de l'optimisation sont présentés dans la Figure 1, qui compare les tensions réelles et estimées en fonction du SOC. Dans ce test, la capacité réelle est de 43 Ah, tandis que la capacité estimée par le modèle génétique C_{bat} est de 42,7501 Ah, avec une erreur de 0,0021 Ah. Cette analyse permet d'évaluer la performance de notre modèle d'estimation et démontre la capacité de l'algorithme génétique à trouver des solutions de paramètres proches des valeurs réelles, ce qui est crucial pour une estimation fiable de la capacité des batteries.




Fig. 1. Comparaison des tensions réelles et estimées.

Comme le montre la Figure 1, les résultats démontrent une estimation précise de la tension de la batterie, avec une différence minimale entre les valeurs réelles et estimées, ce qui est typique des problèmes d'optimisation. L'algorithme vise à minimiser l'erreur de

tension, et cela se reflète dans la proximité des courbes mesurées et simulées. Les petites divergences observées peuvent être attribuées aux approximations inhérentes au modèle et à la nature des processus dynamiques de charge et de décharge, qui ne sont pas entièrement linéaires.

Dans la section suivante, nous analyserons l'impact de l'évolution des paramètres sur l'estimation de l'état de santé (SOH).

B. Impact de l'Évolution des Paramètres sur l'Estimation de la Capacité

L'évaluation de l'impact de l'évolution des paramètres sur la précision des estimations du SOC et du SOH a été réalisée en modifiant les résistances et la capacité réelle, en les multipliant par des facteurs allant de 1,1 à 2, avec un pas de 0,1. Cette approche permet d'examiner comment les variations de ces paramètres influencent les estimations du SOC, du SOH, ainsi que les erreurs dans l'estimation de la capacité des batteries C_{bat} .

Les résultats obtenus pour chaque paramètre (R_{ohmic} , R_1 et C_1) sont présentés dans les tableaux suivants. Dans chaque cas, les autres paramètres ont été maintenus constants à leurs valeurs réelles afin d'isoler l'impact d'un paramètre spécifique sur l'estimation des propriétés électriques de la batterie.

Coef. R_{ohm}	Erreur	Capacité estimée (Ah)
1.1	0.0282	44.5108
1.2	0.0334	39.6266
1.3	0.0385	39.6505
1.4	0.0443	39.3466
1.5	0.0511	39.502
1.6	0.0563	38.1716
1.7	0.0614	37.7797
1.8	0.0672	37.2879
1.9	0.0729	37.3431
2.0	0.0789	37.7572

TABLE I

IMPACT DE LA VARIATION DE R_{OHM} SUR L'ESTIMATION DE LA CAPACITÉ.

L'analyse du tableau montre clairement que l'augmentation de R_{ohmic} a un impact direct sur l'estimation de la capacité de la batterie. À mesure que la résistance augmente, la capacité estimée diminue, ce qui est cohérent avec l'effet de la résistance interne sur les pertes d'énergie et la performance de la batterie. Les erreurs d'estimation augmentent également, ce qui indique que l'optimisation des paramètres résistifs est cruciale pour obtenir des résultats plus précis.

Coef. R_1	Erreur	Capacité estimée (Ah)
1.1	0.0244	44.0177
1.2	0.0433	38.0167
1.3	0.0601	36.8918
1.4	0.0760	37.4848
1.5	0.0918	36.2007
1.6	0.1083	34.4137
1.7	0.1235	34.2978
1.8	0.1387	35.1366
1.9	0.1587	35.3274
2.0	0.1744	34.7798

TABLE II

IMPACT DE LA VARIATION DE R_1 SUR L'ESTIMATION DE LA CAPACITÉ DE LA BATTERIE.

Dans le tableau II, la variation de R_1 présente un comportement similaire. À mesure que R_1 augmente, l'erreur dans l'estimation de la capacité devient plus significative, surtout pour des facteurs multiplicatifs supérieurs à 1,5. Ce phénomène est dû à l'impact de R_1 sur la gestion de l'énergie dans la batterie, en particulier sur l'impédance et les pertes d'énergie associées à la résistance interne. L'augmentation de R_1 entraîne des pertes plus importantes, ce qui dégrade la précision de l'estimation de la capacité.

Coef. C_1	Erreur	Capacité estimée (Ah)
1.1	0.0347	44.0916
1.2	0.0230	39.0897
1.3	0.0221	40.6222
1.4	0.0209	40.0393
1.5	0.0220	40.5522
1.6	0.0212	39.8766
1.7	0.0224	39.2832
1.8	0.0219	40.5237
1.9	0.0213	39.8405
2.0	0.0226	39.2222

TABLE III

IMPACT DE LA VARIATION DE C_1 SUR L'ESTIMATION DE LA CAPACITÉ DE LA BATTERIE.

Concernant C_1 (Table III), l'augmentation de C_1 semble avoir un effet moins prononcé sur l'estimation de la capacité par rapport à R_{ohmic} et R_1 . Cependant, l'erreur d'estimation reste significative, ce qui suggère que la capacité du condensateur joue un rôle clé dans la détermination des dynamiques de charge et de décharge de la batterie. De petites variations de C_1 peuvent entraîner des erreurs subtiles mais importantes dans l'estimation totale de la capacité de la batterie, en particulier lorsque des erreurs de mesure sont présentes dans les données.

C. Discussion

Les résultats obtenus de ces expériences montrent clairement que l'évolution des paramètres de la batterie influence de manière significative les estimations du SOC, du SOH et de la capacité. L'impact de la variation de chaque paramètre est différent, mais dans tous les cas, une augmentation des paramètres de résistance ou de capacité entraîne une augmentation de l'erreur d'estimation de la capacité. Cela démontre qu'une estimation précise de ces paramètres est essentielle pour obtenir des résultats fiables dans la gestion de la batterie et la prédiction de sa durée de vie.

Il est important de souligner que ces erreurs sont amplifiées en présence de bruit dans les mesures des paramètres. Les erreurs de mesure dans les résistances ou la capacité peuvent entraîner des estimations erronées du SOC et du SOH, ce qui peut avoir un impact direct sur la gestion de la batterie dans les véhicules électriques. Par conséquent, il est crucial de mettre en œuvre des méthodes robustes pour détecter et corriger ces erreurs, telles que l'utilisation de filtres de Kalman ou d'autres techniques de réduction du bruit.

1) *Impact de l'échelle des paramètres sur l'estimation de la tension:* Pour analyser l'effet de l'échelle des paramètres sur l'estimation de la tension, nous présentons une figure comparant les tensions réelles et estimées lorsque la résistance R_{ohm} est mise à l'échelle par un facteur de 2. Ce résultat met en évidence l'influence de ce paramètre sur le comportement de la tension de la batterie.




Fig. 2. Comparaison des tensions réelles et estimées pour $R_{ohm} \times 2$.

Comme montré dans la Figure 2, l'échelle de la résistance R_{ohm} par un facteur de 2 entraîne des change-

ments significatifs dans le profil de la tension. Cela démontre la sensibilité de la tension aux variations de R_{ohm} , ce qui influence à son tour la précision des estimations du SOC et du SOH. Les résultats soulignent l'importance d'une estimation précise des paramètres pour garantir une modélisation fiable et une gestion optimale de la batterie.

II. CONCLUSION

L'optimisation et l'estimation précise des paramètres de la batterie sont cruciales pour des prédictions fiables du SOC et du SOH. Les résultats mettent en évidence la sensibilité des modèles de batterie aux variations de résistance et de capacité, soulignant l'importance d'une identification précise des paramètres pour une gestion efficace de la batterie. La mise en œuvre de techniques avancées de réduction du bruit et de méthodes d'optimisation robustes peut améliorer considérablement la précision des estimations, garantissant ainsi de meilleures performances et une durée de vie plus longue des batteries de véhicules électriques.

Cette étude propose une méthode d'optimisation des paramètres clés du modèle électrique équivalent d'une batterie à l'aide d'un algorithme génétique. L'algorithme vise à minimiser l'erreur de prédiction de la tension en faisant évoluer les paramètres R_{ohmic} , R_1 et C_1 au cours des générations. Les résultats montrent que l'évolution de ces paramètres influence fortement les estimations, en particulier en présence de bruit ou d'erreurs de mesure. Par conséquent, améliorer la précision des mesures et appliquer des techniques d'optimisation robustes, telles que l'algorithme génétique, est essentiel pour obtenir des estimations fiables et précises dans la gestion de l'énergie des batteries.

REFERENCES

- [1] Hou, Jiayang, et al. "State of charge estimation for lithium-ion batteries based on battery model and data-driven fusion method." *Energy* 290 (2024): 130056.
- [2] Liu, Shiyu, et al. "State-of-health estimation of lithium-ion batteries using a kernel support vector machine tuned by a new nonlinear gray wolf algorithm." *Journal of Energy Storage* 102 (2024): 114052.
- [3] Hemdani, Jamila, et al. "State of health prediction of lithium-ion battery using machine learning algorithms." 2023 9th International Conference on Control, Decision and Information Technologies (CoDIT). IEEE, 2023.
- [4] Kroeze, Ryan C., and Philip T. Krein. "Electrical battery model for use in dynamic electric vehicle simulations." 2008 IEEE Power Electronics Specialists Conference. IEEE, 2008.
- [5] Madani, Seyed Saeed, Erik Schaltz, and Søren Knudsen Kær. "A review of different electric equivalent circuit models and parameter identification methods of lithium-ion batteries." *ECS Transactions* 87.1 (2018): 23.
- [6] Wang, Chao, et al. "An improved particle swarm optimization-cubature Kalman particle filtering method for state-of-charge estimation of large-scale energy storage lithium-ion batteries." *Journal of Energy Storage* 100 (2024): 113619.
- [7] HEMDANI, Jamila, et al. "An improved data-driven approach for NMC battery remaining useful life prediction." (2024).
- [8] HEMDANI, Jamila, et al. "An improved data-driven approach for NMC battery remaining useful life prediction." (2024).
- [9] Ezemobi, Ethelbert, et al. "State of health estimation of lithium-ion batteries in electric vehicles under dynamic load conditions." *Energies* 15.3 (2022): 1234.
- [10] Yang, Shichun, et al. *Advanced Battery Management System for Electric Vehicles*. Springer, 2023.
- [11] Jo, Sungwoo, Sunkyu Jung, and Taemoon Roh. "Battery state-of-health estimation using machine learning and preprocessing with relative state-of-charge." *Energies* 14.21 (2021): 7206.
- [12] Tao, Zhen, et al. "State of charge estimation of lithium Batteries: Review for equivalent circuit model methods." *Measurement* (2024): 115148.
- [13] Guo, Ruohan, and Weixiang Shen. "A review of equivalent circuit model based online state of power estimation for lithium-ion batteries in electric vehicles." *Vehicles* 4.1 (2021): 1-29.
- [14] UDHAYAKUMAR, K., S. DEVAKIRUBAKARAN, and K. SATHIYA SEKAR. "Advances in Batteries, Battery Modeling, Battery Management System, Battery Thermal Management, SOC, SOH, and Charge/Discharge Characteristics in EV Applications."
- [15] Shaheen, Abdullah M., et al. "Optimal parameter identification of linear and non-linear models for Li-Ion Battery Cells." *Energy Reports* 7 (2021): 7170-7185.
- [16] Zhao, Jinhui, et al. "Lithium battery model parameter identification based on the GA-LM algorithm." *International Journal of Green Energy* 21.5 (2024): 1147-1160.
- [17] Manriquez-Padilla, Carlos Gustavo, et al. "State of charge estimation model based on genetic algorithms and multivariate linear regression with applications in electric vehicles." *Sensors* 23.6 (2023): 2924.