

## Estimation des paramètres, de l'état de charge et de l'état de santé de la batterie lithium pour les véhicules électriques

La batterie lithium-ion présente une densité énergétique et un rendement élevé par rapport aux autres types de batteries. Ces caractéristiques, auxquelles s'ajoute un coût de fabrication en constante diminution, font de la batterie lithium le choix le plus attractif pour les véhicules électriques.

Pour assurer le bon fonctionnement de la batterie au lithium, un système de gestion fiable (Système de contrôle des batteries d'accumulateurs BMS) est indispensable. Celui-ci permet non seulement de superviser la batterie via différents indicateurs (état de charge SOC, état de santé SOH...) mais surtout d'assurer la sécurité et la fiabilité de la batterie.

L'estimation de l'état de charge et de la capacité (utilisée pour estimer l'état de santé SOH) sont les principales tâches d'un BMS. En effet, une estimation précise de l'état de charge de la batterie peut éviter une interruption imprévue du système et empêcher une surcharge ou une décharge excessive de la batterie, qui pourrait causer des dommages permanents à sa structure interne. D'autre part, la capacité de la batterie, qui est considérée comme un indicateur important de ses performances, est fortement affectée par divers mécanismes internes et externes ; ces facteurs entraînent une diminution progressive des performances de la batterie au fil du temps. Par conséquent, la capacité disponible de la batterie doit être estimée avec précision pour des raisons de fiabilité et pour une bonne gestion de l'utilisation de la batterie.

L'objectif de ce travail est d'étendre l'état de l'art des algorithmes utilisés pour estimer ces états. Les principales contributions sont :

- 1-Comparaison entre quatre algorithmes d'estimation de l'état de charge SOC de la batterie.
  - 2-Développement de deux nouvelles méthodes (AFFRLS et SFO) pour estimer en temps réel les paramètres du modèle d'une batterie.
  - 3-Développement d'un nouveau Framework pour l'estimation de la capacité totale de la batterie.
- Les performances de ces méthodes ont été vérifiées à l'aide d'ensembles de données fiables collectés auprès du :
- Laboratoire de batterie de l'Université McMaster à Hamilton, Ontario, Canada.
  - Groupe de recherche sur les batteries CALCE.
  - Trois scénarios d'une batterie lithium dans des applications de véhicules électriques et hybrides rechargeables.
  - Le centre d'excellence en matière de pronostics de la NASA.

**Mots-clés :** Système de gestion de batterie (BMS) ; Facteur d'oubli adaptatif moindres carrés récursifs (AFFRL) ; Algorithme d'optimisation de tournesol (SFO) ; État de charge (SOC) ; Véhicule électrique.

### ملخص

#### تقدير المعلمات ، حالة الشحن ، والحالة الصحية لبطارية الليثيوم للسيارات الكهربائية

تعتبر بطارية الليثيوم الخيار الأكثر جاذبية للسيارات الكهربائية من حيث تخزين الطاقة . لضمان تشغيل جيد لبطارية الليثيوم ، يجب تزويدها بنظام إدارة البطارية (BMS). وهو مجموعة من أنظمة التحكم التي تحمي سلامة استخدام البطارية وتراقب حالة استخدامها في جميع الأوقات عبر مؤشرات مختلفة (SOC, SOH, ...).

يعتبر تقدير حالة الشحن SOC والسعة Capacity من المهام الرئيسية لنظام إدارة البطارية. التقدير الدقيق لحالة شحن البطارية يمكن من منع تعطل النظام غير المخطط له ويمنع الشحن الزائد أو التفريغ الزائد للبطارية. من ناحية أخرى ، فإن سعة البطارية ، التي تعتبر مؤشرًا مهمًا ، تتأثر بشدة بالبيانات الداخلية وخارجية مختلفة ؛ تؤدي هذه العوامل إلى انخفاض تدريجي في أداء البطارية بمرور الوقت. لذلك ، يجب تقدير السعة المتاحة للبطارية بدقة لإدارة استخدام البطارية بشكل جيد.

الهدف من هذا العمل هو المساهمة في تقديم خوارزميات جديدة لتقدير هذه الحالات. المساهمات الرئيسية هي:

1-مقارنة بين أربع خوارزميات لتقدير حالة شحن البطارية SOC.

2-تطوير طريقتين جديدتين (AFFRLS و SFO) لتقدير معاملات نموذج البطارية.

3-تطوير إطار عمل جديد لتقدير السعة الكلية للبطارية باستخدام خوارزمية SFO.

**الكلمات المفتاحية :** نظام إدارة البطارية (BMS) ؛ عامل النسيان التكيفي تكراري المربع الصغرى (AFFRL) ؛ خوارزمية عباد الشمس (SFO) ؛ حالة الشحن (SOC).

Faculté des Sciences et Techniques  
Settat

## THÈSE DE DOCTORAT

Pour l'obtention de grade de Docteur en sciences et techniques

Formation Doctorale : Physique et Sciences de l'ingénieur

Spécialité : Génie électrique

Sous le thème

# Estimation des paramètres, de l'état de charge et de l'état de santé de la batterie lithium pour les véhicules électriques.

Présentée par :

**Mouncef EL MARGHICHI**

Soutenue le : 11/05/2022

A la Faculté des Sciences et Techniques de Settat devant le jury composé de :

Pr. Mohamed ABOULFATAH	PES	FST SETTAT	Président
Pr. Abderraouf ABOUDOU	PES	EST CASA	Rapporteur
Pr. Abdelkebir EL AMRI	PES	EST CASA	Rapporteur
Pr. Houssine BOUAYAD	PES	FST SETTAT	Rapporteur
Pr. El mostafa MAKROUM	PH	FST SETTAT	Examineur
Pr. Mostafa BOUZI	PES	FST SETTAT	Directeur de thèse

Année Universitaire : 2021/2022

## Remerciements :

Les travaux présentés dans ce mémoire de thèse ont été effectués au sein du centre d'études doctorales de la faculté des sciences et techniques de Settat au sein du laboratoire Mécanique, Informatique, Électronique et Télécommunications (MIET).

Tout d'abord, mes profonds remerciements au directeur du laboratoire MIET, Mr ERRKIK pour son accueil ainsi sa confiance.

Je tiens à exprimer ma reconnaissance à mon encadrant, le Dr Mostafa BOUZI, Professeur à la faculté des sciences et techniques de Settat, pour ses conseils et son soutien tout au long de ce projet de thèse, pour les conditions de travail très favorables à l'aboutissement de ces travaux, pour avoir cru en mes capacités et m'avoir permis d'entreprendre une tâche aussi intéressante et exigeante.

Je suis très reconnaissant aux deux rapporteurs de la thèse Mr Abderraouf ABOUDOU, Mr Abdelkebir EL AMRI et Mr Houssine BOUAYAD pour tout l'intérêt qu'ils ont bien voulu porter à ce travail et pour leurs précieuses et pertinentes remarques. Je tiens également à remercier sincèrement les membres du jury de thèse pour l'honneur qu'ils m'ont fait de participer à l'évaluation de ce travail Mr El mostafa MAKROUM, Mr Mohamed ABOULFATAH.

Enfin, j'aimerais profiter de l'occasion pour remercier ma famille et mes amis pour leur amour et leur soutien, ainsi qu'à toute personne ayant participé de près ou de loin à l'accomplissement de ce travail.

## Résumé :

# Estimation des paramètres, de l'état de charge et de l'état de santé de la batterie lithium pour les véhicules électriques

La batterie lithium-ion présente une densité énergétique et un rendement élevé par rapport aux autres types de batteries. Ces caractéristiques, auxquelles s'ajoute un coût de fabrication en constante diminution, font de la batterie lithium le choix le plus attractif pour les véhicules électriques.

Pour assurer le bon fonctionnement de la batterie au lithium, un système de gestion fiable (Système de contrôle des batteries d'accumulateurs BMS) est indispensable. Celui-ci permet non seulement de superviser la batterie via différents indicateurs (état de charge SOC, état de santé SOH...) mais surtout d'assurer la sécurité et la fiabilité de la batterie.

L'estimation de l'état de charge et de la capacité (utilisée pour estimer l'état de santé SOH) sont les principales tâches d'un BMS. En effet, une estimation précise de l'état de charge de la batterie peut éviter une interruption imprévue du système et empêcher une surcharge ou une décharge excessive de la batterie, qui pourrait causer des dommages permanents à sa structure interne. D'autre part, la capacité de la batterie, qui est considérée comme un indicateur important de ses performances, est fortement affectée par divers mécanismes internes et externes ; ces facteurs entraînent une diminution progressive des performances de la batterie au fil du temps. Par conséquent, la capacité disponible de la batterie doit être estimée avec précision pour des raisons de fiabilité et pour une bonne gestion de l'utilisation de la batterie.

L'objectif de ce travail est d'étendre l'état de l'art des algorithmes utilisés pour estimer ces états.

Les principales contributions sont :

- 1-Comparaison entre quatre algorithmes d'estimation de l'état de charge SOC de la batterie.
- 2-Développement de deux nouvelles méthodes (AFFRLS et SFO) pour estimer en temps réel les paramètres du modèle d'une batterie.
- 3-Développement d'un nouveau Framework pour l'estimation de la capacité totale de la batterie.

Les performances de ces méthodes ont été vérifiées à l'aide d'ensembles de données fiables collectés auprès du :

- Laboratoire de batterie de l'Université McMaster à Hamilton, Ontario, Canada.
- Groupe de recherche sur les batteries CALCE.
- Trois scénarios d'une batterie lithium dans des applications de véhicules électriques et hybrides rechargeables.
- Le centre d'excellence en matière de pronostics de la NASA.

**Mots-clés :** Système de gestion de batterie (BMS) ; Facteur d'oubli adaptatif moindres carrés récursifs (AFFRL) ; Algorithme d'optimisation de tournesol (SFO) ; État de charge (SOC) ; Véhicule électrique.

## ملخص :

## تقدير المعلمات ، حالة الشحن ، والحالة الصحية لبطارية الليثيوم للسيارات الكهربائية.

تعتبر بطارية الليثيوم الخيار الأكثر جاذبية للسيارات الكهربائية من حيث تخزين الطاقة . لضمان تشغيل جيد لبطارية الليثيوم ، يجب تزويدها بنظام إدارة البطارية (BMS). وهو مجموعة من أنظمة التحكم التي تحمي سلامة استخدام البطارية وتراقب حالة استخدامها في جميع الأوقات عبر مؤشرات مختلفة (SOC, SOH, ...).

يعتبر تقدير حالة الشحن SOC والسعة Capacity من المهام الرئيسية لنظام إدارة البطارية. التقدير الدقيق لحالة شحن البطارية يمكن من منع تعطل النظام غير المخطط له ويمنع الشحن الزائد أو التفريغ الزائد للبطارية. من ناحية أخرى ، فإن سعة البطارية ، التي تعتبر مؤشراً مهماً ، تتأثر بشدة بآليات داخلية وخارجية مختلفة ؛ تؤدي هذه العوامل إلى انخفاض تدريجي في أداء البطارية بمرور الوقت. لذلك ، يجب تقدير السعة المتاحة للبطارية بدقة لإدارة استخدام البطارية بشكل جيد.

الهدف من هذا العمل هو المساهمة في تقديم خوارزميات جديدة لتقدير هذه الحالات. المساهمات الرئيسية هي:

1-مقارنة بين أربع خوارزميات لتقدير حالة شحن البطارية SOC.

2-تطوير طريقتين جديدتين (AFFRLS و SFO) لتقدير معاملات نموذج البطارية.

3-تطوير إطار عمل جديد لتقدير السعة الكلية للبطارية باستخدام خوارزمية SFO.

الكلمات المفتاحية : نظام إدارة البطارية (BMS) ؛ عامل النسيان التكيفي تكراري المربع الصغرى (AFFRL) ؛ خوارزمية عباد الشمس (SFO) ؛ حالة الشحن (SOC).



## Abstract :

### **Estimation of parameters , state of charge, and state of health of the lithium battery for electric vehicles.**

With high energy density and efficiency compared with other type of batteries, along with a good life span, these features in addition of steadily decreasing cost of manufacture, makes the lithium battery the most appealing and attractive choice for electric vehicles.

To ensure good operation of the lithium battery a reliable management system (BMS) is a must. Which enable not only the supervision of the battery via different indicators (state of charge SOC, state of health SOH...) but most importantly ensure the safety and balance between the different cells.

Accurate state of charge and capacity (used to estimate the state of health) estimation are the main tasks of a BMS, which helps improve the system performance and reliability. In fact, precise SOC estimation of the battery can avoid unpredicted system interruption and prevent the batteries from being over charged and over discharged, which may cause permanent damage to the internal structure of the battery. In the other hand, online capacity estimation is a critical task to maintain the battery performance for electric vehicles.

The main objective of this work is to extend the state of art of the algorithms used to estimate these states. The main contributions are:

- 1-Comparison between four common algorithms used to estimate battery state of charge SOC.
- 2-The development of two new methods (AFFRLS and SFO) to estimate in real time battery model parameters, which is critical for SOC estimation methods based on battery models.
- 3-The development of a new Framework for the estimation of total battery capacity using the sunflower optimization algorithm SFO.

The performance of these methods is verified using reliable datasets collected from:

- Battery lab in McMaster University in Hamilton, Ontario, Canada.
- CALCE battery group.
- Electric and hybrid electric simulation.
- The Prognostics Center of Excellence, NASA.

**Keywords :** Battery management system (BMS); Adaptative forgetting factor recursive least square (AFFRL); Sunflower optimization algorithm (SFO); State of charge (SOC); Electric Vehicle.

# Table des matières :

<b>Liste des figures :</b> .....	<b>9</b>
<b>Liste des Tableaux :</b> .....	<b>12</b>
<b>Acronymes &amp; définitions :</b> .....	<b>13</b>
<b>Introduction Générale</b> .....	<b>15</b>
<b>Chapitre 1 : État de l’art des systèmes de gestion des batteries BMS</b> .....	<b>20</b>
1.1 Introduction .....	21
1.2 Batterie Lithium-ion : .....	21
1.2.1 Introduction .....	21
1.2.2 Principe de fonctionnement des batteries Li-ion .....	22
1.2.3 Terminologie des batteries .....	24
1.3 Modélisation des batteries Li-ion .....	25
1.3.1 Modèles de batterie du type comportemental ou boîte noire .....	26
1.3.2 Le modèle combiné .....	27
1.3.3 Le modèle simple .....	27
1.3.4 Le modèle d'hystérésis à l'état zéro .....	27
1.3.5 Le modèle autocorrectif amélioré.....	28
1.3.6 Modèles de circuit équivalent (MCE) .....	28
1.3.6.1 Modèle Rint.....	29
1.3.6.2 Modèle PNGV .....	30
1.3.6.3 Le modèle RC premier ordre (modèle de Thévenin premier ordre) .....	31
1.3.6.4 Le modèle RC premier ordre avec hystérésis à un état.....	31
1.3.6.5 Le modèle RC deuxième ordre (modèle de Thévenin deuxième ordre) .....	32
1.3.6.6 Le modèle RC deuxième ordre avec hystérésis .....	33
1.3.6.7 Le modèle RC troisième ordre.....	33
1.3.6.8 Le modèle RC du troisième ordre avec hystérésis.....	34
1.3.7 Modèles de batteries électrochimiques .....	34
1.4 Système de gestion BMS (Synthèse).....	35
1.4.1 Acquisition de données.....	36
1.4.2 Protection des cellules .....	36
1.4.3 Équilibrage des cellules .....	37

1.4.4 Gestion thermique .....	38
1.4.5 Gestion de l'énergie.....	39
1.4.6 Surveillance de l'état des batteries.....	40
1.5 Équilibrage des cellules.....	40
1.5.1 Contrôleurs d'équilibrage cellulaire passif.....	41
1.5.2 Contrôleurs d'équilibrage des cellules actives .....	41
1.5.2.1 Contrôleurs d'équilibrage de charge à base de condensateurs.....	42
1.5.2.2 Contrôleurs d'égalisation à base d'inductance /transformateur .....	43
1.5.2.3 Contrôleurs d'égalisation de charge à base de convertisseur .....	45
1.5.3 Conclusion sur les contrôleurs d'équilibrage des cellules .....	51
1.6 Revue des algorithmes d'estimation de l'état de charge SOC .....	52
1.6.1 Méthode de comptage coulomb.....	52
1.6.2 Estimation basée sur l'OCV.....	53
1.6.3 Méthodes à base de table de recherche.....	54
1.6.4 Estimation basée sur l'impédance.....	54
1.6.5 Estimation basée sur les modèles .....	55
1.6.6 Méthodes basées sur les observateurs.....	55
1.6.7 Estimateurs basés sur le filtre de Kalman.....	55
1.6.8 Méthodes à bases des données.....	56
1.6.9 Conclusion sur l'estimation de l'état de charge.....	56
1.7 Revue des méthodes d'estimation de la capacité des batteries (utilisées pour l'estimation de l'état de santé SOH) .....	57
1.7.1 Méthodes basées sur l'extraction des paramètres (Analyse de capacité différentielle) .....	58
1.7.2 Méthodes basées sur les modèles .....	59
1.7.3 Méthodes basées sur les données.....	60
1.7.4 Méthodes basées sur le comptage de coulomb et algorithme adaptatif .....	60
1.7.5 Méthodes d'estimation jointes .....	61
1.7.6 Conclusion sur l'estimation de la capacité .....	61
1.8 Conclusion.....	62

**Chapitre 2 : Comparaison des algorithmes d'estimation de l'état de charge des batteries lithium-ion pour les véhicules électriques ..... 63**

2.1 Introduction .....	64
2.2 État de charge SOC .....	64
2.3 Modèle utilisé.....	65
2.3.1 Modèle Rint.....	65
2.3.2 Modèle Thévenin.....	65
2.3. Algorithmes d'estimation SOC .....	66
2.3.1 Filtre de Kalman linéaire .....	66

2.3.2 Filtre de Kalman étendu (EKF) .....	68
2.3.3 Filtre de Kalman à point Sigma (SPKF).....	71
2.3.4 Réseau de neurones .....	72
2.3.5 Logique floue .....	73
2.4 Simulation, résultats et discussion.....	74
2.5 Résultats de la comparaison .....	80
2.6 Conclusion.....	81

**Chapitre 3 : Estimation en ligne des paramètres de la batterie lithium-ion pour les véhicules électriques ..... 82**

3.1 Introduction .....	83
3.2 L’algorithme AFFRLS .....	83
3.2.1 Introduction .....	83
3.2.2 Modèle utilisé .....	85
3.2.3 Implémentation de l’algorithme AFFRLS.....	87
3.2.4 Résultats de la comparaison .....	88
3.2.4.1 UDDS test.....	89
3.2.4.2 Test de stress dynamique (DST).....	93
3.2.4.3 Test FUDS (Federal urban driving schedule).....	96
3.2.5 Discussion .....	99
3.3 Algorithme Sunflower .....	100
3.3.1 Introduction .....	100
3.3.2 Modèle de la batterie .....	100
3.3.3 Formulation du problème .....	101
3.3.4 Algorithme Sunflower .....	102
3.3.5 Résultat et discussion .....	104
3.4 CONCLUSION .....	110

**Chapitre 4 : Estimation de la capacité de la batterie lithium-ion pour les véhicules électriques (état de santé SOH) par SFO ..... 111**

4.1 Introduction .....	112
4.2 Formulation du problème .....	113
4.3 Algorithme SFO .....	114
4.4 Framework proposé.....	115
4.5 Évaluation de l’ensemble des données de la batterie NASA.....	116
4.5.1 Ensemble de données de la NASA.....	117
4.5.2 Résultats et discussion.....	121
4.6 Application véhicules électriques et hybrides : .....	126

4.6.1 Premier scénario .....	126
4.6.2 Deuxième scénario .....	127
4.6.3 Troisième scénario .....	128
4.6.4 Résultats et discussion .....	129
4.7 Temps de calcul et exigence de mémoire .....	132
4.8 CONCLUSION .....	133
<b>Conclusion générale : .....</b>	<b>135</b>
<b>Références : .....</b>	<b>137</b>

## Liste des figures :

Figure 1 : Défaillance de la batterie lithium : (a) incendie d'un avion-cargo UPS (b) défaillance d'une batterie d'un Boeing 787 (c) incendie d'une batterie Chevrolet Volt trois semaines après un test de collision latérale [4] .....	16
Figure 2 : Fonctions d'un système de gestion des batteries BMS .....	17
Figure 1.1 : Diagramme de Ragone de diverses technologies de batteries avec spécification au niveau des cellules pour des applications automobiles [21].....	22
Figure 1.2 : Batterie Li-ion, représentation schématique (a), Structure interne (b) [22] .....	23
Figure 1.3 : Cellule module et pack [22].....	24
Figure 1.4 : Modèle Rint .....	29
Figure 1.5 : Modèle PNGV .....	30
Figure 1.6 : Schéma du modèle RC de premier ordre .....	31
Figure 1.7 : Schéma du modèle RC deuxième ordre.....	32
Figure 1.8 : Schéma du modèle RC troisième ordre .....	33
Figure 1.9 : Structure générale d'un BMS standard.....	35
Figure 1.10 : Limites opérationnelles des cellules : pas d'équilibrage (a) équilibrage correct (b) .....	37
Figure 1.11 : Schéma de principe de l'équilibrage actives des cellules .....	38
Figure 1.12 : Distribution de la chaleur dans un véhicule (a) [52], répartition inégale de la chaleur sur les surfaces cylindriques adjacentes des cellules dans un module (b) .....	39
Figure 1.13 : Structure général de l'unité de gestion de l'énergie .....	39
Figure 1.14 : Aperçu des tâches fondamentales effectuées par un système de surveillance des batteries.....	40
Figure 1.15 : CEC à résistance fixe (a), CEC à résistance shunt contrôlée (b) .....	41
Figure 1.16 : CEC à condensateur unique commuté (a), CEC à condensateur commuté à deux niveaux (b), Système modulaire (c).....	43
Figure 1.17 : CEC à inductance unique (a), CEC à inductance couplée (b).....	44
Figure 1.18 : CEC transformateur à enroulement unique (a), CEC à transformateur multi-enroulements (b).....	45
Figure 1.19 : CEC à base du convertisseur Cûk.....	46
Figure 1.20 : CEC à base du convertisseur Boost .....	47
Figure 1.21 : CEC à base du convertisseur Buck- Boost .....	47
Figure 1.22 : CEC à base du convertisseur ramp .....	48
Figure 1.23 : CEC à base du pont complet.....	49
Figure 1.24 : CEC résonant .....	49
Figure 1.25 : CEC flyback unidirectionnel(a) et bidirectionnel (b).....	50
Figure 1.26 : CEC shunt.....	50
Figure 1.27 : Relation OCV-SOC pour une batterie lithium-ion .....	53
Figure 1.28 : Méthodes utilisées pour l'estimation de la capacité des batteries.....	58
Figure 1.29 : Courbe DVA [130] .....	59
Figure 1.30 : Courbe ICA [138].....	59
Figure 2.31 : État de charge de la batterie d'un véhicule Tesla [193] .....	64
Figure 2.32 : Modèle Rint .....	65

## Liste des figures

---

Figure 2.33 : Modèle de circuit équivalent nRC (Modèle Thévenin) : deux branches (a), une branche (b) .....	66
Figure 2.34 : Les étapes d'un filtre Kalman linéaire .....	67
Figure 2.35 : Filtre de Kalman étendu EKF .....	69
Figure 2.36 : Linéarisation dans les algorithmes EKF et UKF (SPKF) [158].....	71
Figure 2.37 : Estimation de l'état de charge par réseau de neurones .....	72
Figure 2.38 : Structure ANFIS avec deux entrées [169] .....	74
Figure 2.39 : Plate-forme de test des batteries [8-10] .....	75
Figure 2.40 : Courbe OCV SOC pour la charge, la décharge et la courbe mixte .....	76
Figure 2.41 : Courant test DST .....	76
Figure 2.42 : Tension terminale réelle et estimée.....	77
Figure 2.43 : Erreur d'estimation du modèle .....	77
Figure 2.44 : Estimation du SOC par EKF.....	78
Figure 2.45 : Section agrandie de l'estimation du SOC par EKF .....	78
Figure 2.46 Estimation du SOC par SPKF.....	79
Figure 2.47 : Section agrandie de l'estimation du SOC par SPKF. ....	79
Figure 2.48 : Erreur d'estimation par EKF et SPKF .....	79
Figure 3.49 : Modèle utilisé .....	85
Figure 3.50 : Algorithme RLS [6].....	86
Figure 3.51 : Algorithme AFFRLS proposé.....	88
Figure 3.52 : Batterie LG 18650HG2.....	89
Figure 3.53 : Schéma du banc d'essai [184].....	90
Figure 3.54 : Courant test UDDS .....	90
Figure 3.55 : Identification des paramètres par RLS et AFFRLS pour le test UDDS : (a), (b) et (c) Identification des paramètres de Nernst K0, K1 et K2 respectivement (d) Identification de C1 (e) Identification de R1 (f) Identification de R2 (g) Identification de M (h) Identification du facteur d'oubli .....	92
Figure 3.56 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS.....	92
Figure 3.57 : Erreur d'estimation de la tension de sortie pour les deux algorithmes .....	92
Figure 3.58 : Proportion en pourcentage des points d'erreur relatifs absolus pour RLS et AFFRLS dans le test dynamique UDDS .....	93
Figure 3.59 : Courant test DST .....	93
Figure 3.60 : Identification des paramètres par RLS et AFFRLS pour le test DST : (a), (b) et (c) Identification des paramètres de Nernst K0, K1 et K2 respectivement (d) Identification de C1 (e) Identification de R1 (f) Identification de R2 (g) Identification de M (h) Identification du facteur d'oubli .....	95
Figure 3.61 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS.....	95
Figure 3.62 : Erreur d'estimation de la tension de sortie pour les deux algorithmes .....	95
Figure 3.63 : Proportion en pourcentage des points d'erreur relatifs absolus pour RLS et AFFRLS dans le test dynamique DST. ....	96
Figure 3.64 : Courant test FUDS.....	97

## Liste des figures

---

Figure 3.65 : Identification des paramètres par RLS et AFFRLS pour le test FUDS: (a), (b) et (c) Identification des paramètres de Nernst K0, K1 et K2 respectivement (d) Identification de C1 (e) Identification de R1 (f) Identification de R2 (g) Identification de M (h) Identification du facteur d'oubli .....	98
Figure 3.66 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS.....	98
Figure 3.67 : Erreur d'estimation de la tension de sortie pour les deux algorithmes .....	99
Figure 3.68 : Proportion en pourcentage des points d'erreur relatifs absolus pour RLS et AFFRLS dans le test dynamique FUDS.....	99
Figure 3.69 : Modèle de la batterie adopté.....	101
Figure 3.70 : Organigramme de l'algorithme proposé basé sur SFO.....	104
Figure 3.71 : Batterie A123.....	105
Figure 3.72 : Configuration expérimentale [8,10].....	106
Figure 3.73 : Courant dans les cycles de conduite DST, US06 et FUDS à 25°C.....	106
Figure 3.74 : Résultats de l'identification des paramètres K0 (a), K1 (b), R0 (c), R1 (d), C1 (e) .....	108
Figure 3.75 : Tension de sortie estimée par les deux algorithmes ainsi que la tension réelle .....	108
Figure 3.76 : Sections zoomées de la tension de sortie réelle et estimée par les algorithmes AFFRLS et SFO..	109
Figure 3.77 : Erreur d'estimation par les algorithmes AFFRLS et SFO .....	109
Figure 4.78 : Organigramme de l'algorithme SFO modifié.....	115
Figure 4.79 : Framework proposé pour l'estimation de la capacité totale .....	116
Figure 4.80 : SAMSUNG INR 18650-20R.....	117
Figure 4.81 : Courant mesuré pendant les différents cycles de charge (Batterie No.18) .....	118
Figure 4.82 : Courant mesuré pendant les différents cycles de décharge (Batterie No.18).....	119
Figure 4.83 : Tension mesurée pendant les différents cycles de charge (Batterie No.18).....	119
Figure 4.84 : Tension mesurée pendant les différents cycles de décharge (Batterie No.18).....	120
Figure 4.85 : Température mesurée pendant les différents cycles de charge (Batterie No.18) .....	120
Figure 4.86 : Température mesurée pendant les différents cycles de décharge (Batterie No.18) .....	120
Figure 4.87 : Impédance mesurée (Batterie No.18) .....	120
Figure 4.88 : Trajectoires de dégradation de la capacité des quatre batteries .....	121
Figure 4.89 : Trajectoires de dégénération de la capacité des quatre batteries avec leur APE correspondant en (%) : (a, b) batterie n°5, (c, d) batterie n°6, (e, f) batterie n°7, (g, h) batterie n°18.....	123
Figure 4.90 : RMSE (a) et MPAAE (b) des algorithmes dans tous les tests .....	125
Figure 4.91 : Variable x #EV1 .....	127
Figure 4.92 : Fonction de densité de probabilité pour les scénarios 2 et 3 [12] .....	127
Figure 4.93 : Variable x #EV2 .....	128
Figure 4.94 : Variable x #EV3 .....	128
Figure 4.95 : Estimation de la capacité et APE en (%) : (a, b) Scénario 1, (c, d) Scénario 2, (e, f) Scénario 3 ..	130
Figure 4.96 : RMSE (a) et MPAAE (b) des algorithmes dans tous les scénarios .....	130



## Liste des Tableaux :

Tableau 1.1 : Topologies d'équilibrage des cellules .....	51
Tableau 1.2 : Méthodes d'estimation du SOC .....	57
Tableau 1.3 : Méthodes d'estimation de la capacité.....	62
Tableau 2.4 : Paramètres batterie .....	74
Tableau 2.5 : RMSE, Erreur Moyenne et Max.....	77
Tableau 2.6 : Erreurs d'estimation du SOC des deux algorithmes pour le test DST .....	78
Tableau 2.7 : Comparaison entre les quatre algorithmes. ....	80
Tableau 3.8 : Paramètres de la batterie .....	89
Tableau 3.9 : Paramètres de l'algorithme SFO .....	104
Tableau 3.10 : Limites des paramètres de la batterie .....	105
Tableau 3.11 : Paramètres de la batterie .....	105
Tableau 4.12 : Paramètres de l'algorithme SFO .....	117
Tableau 4.13 : Paramètres de la batterie et autres constantes.....	117
Tableau 4.14 : Paramètres de la batterie .....	117
Tableau 4.15 : Spécifications des quatre batteries.....	121
Tableau 4.16 : Erreur Max et Moyenne en (%).....	125
Tableau 4.17 : Indicateurs de performance prédictifs .....	125
Tableau 4.18 : Paramètres de la batterie et autres constantes.....	126
Tableau 4.19 : Valeur Min, Max et Moyenne de l'erreur de prédiction en (%).....	131
Tableau 4.20 : Indicateurs de performance prédictifs .....	131
Tableau 4.21 : Temps moyen d'exécution d'un cycle en secondes .....	133
Tableau 4.22 : Mémoire allouée en Kb .....	133

## Acronymes & définitions :

SOH : L'état de santé (State of Health)  
SOP : L'état de puissance (State of Power)  
SOF : L'état de fonctionnement (State of Function)  
RUL : Durée de vie restante (Remaining useful life)  
BMS : Système de contrôle des batteries d'accumulateurs (Battery management system)  
AFFRLS : Facteur d'oubli adaptatif Moindres carrés récursifs (Adaptive Forgetting Factor Recursive Least Square)  
SFO : Algorithme d'optimisation Tournesol (Sunflower Optimization Algorithm)  
EKF : Filtre de Kalman étendu (Extended Kalman Filter)  
SPKF : Filtre Kalman à points sigma (Sigma Point Kalman Filter)  
DST : Test de stress dynamique (Dynamic Stress Test)  
FUDS : Programme fédéral de conduite en milieu urbain (Federal Urban Driving Schedule)  
UDDS : Programme de conduite urbaine sur dynamomètre (Urban Dynamometer Driving Schedule)  
VE : véhicules électriques  
TLS : Total des moindres carrés (Total least squares)  
AWTLS: Moindres carrés totaux pondérés approximatifs (Approximate Weighted Total Least Squares)  
NiCd: nickel-cadmium  
WLS : Moindres carrés pondérés (weighted least squares)  
SEI : Solid Electrolyte Interphase  
 $H_{\infty}$  : Filtres H infinis (H infinity filters)  
WTLS: Total pondéré des moindres carrés (Weighted Total Least Squares)  
DVA : Analyse de la tension différentielle (Differential Voltage Analysis)  
TSRLS : Moindres carrés récursifs à deux étages (Two Stage Recursive Least Squares)  
ICA : Analyse de la capacité incrémentielle (Incremental Capacity Analysis)  
AEKF : filtre de kalman adaptatif (Adaptive EKF)  
ECM : Modèles de circuits équivalents (Equivalent Circuit Models)  
FFRLS : Facteur d'oubli des moindres carrés récursifs (Forgetting Factor Recursive Least Squares)  
EM : Modèles électrochimiques (Electrochemical Models)  
EV : Véhicule électrique (Electric Vehicle)  
NN : Réseau de neurones (Neural Network)  
PHEV : Véhicule électrique hybride rechargeable (Plug-in hybrid electric vehicle)  
kNN : k-nearest neighbor  
DEKF : Filtre de Kalman étendu double (Dual Extended-Kalman-Filter)  
MKRVM : Multiple Kernel Relevance Vector Machine  
PIO : Observateur Proportionnel-Intégral (Proportional-Integral Observer)  
EMD : Décomposition en mode empirique (Empirical Mode Decomposition)  
PIDO : Observateur Proportionnel-Intégral-Différentiel (Proportional-Integral-Differential Observer)

DNN : Réseau neuronal profond (Deep Neural Network)

PCoE : Prognostics Center of Excellence

DCNN : Réseau neuronal à convolution profonde (Deep Convolution Neural Network)

APE : Erreur absolue en pourcentage (Absolute Percentage Error)

SOC : State of Charge (State of Charge)

MAE : Erreur absolue moyenne (Mean Absolute Error)

EKF : Filtre de Kalman étendu (Extended Kalman Filter)

MAPE : Pourcentage d'erreur absolue moyenne (Mean Absolute Percentage Error)

SPKF : Filtre Kalman à point sigma (Sigma Point Kalman Filter)

RMSE : Erreur quadratique moyenne (Root Mean Square Error)

# Introduction Générale

## Contexte des travaux de thèse

Dans le cadre économique mondial, la vente des véhicules électriques a explosé. Au cours du premier trimestre 2021, les ventes des voitures purement électriques ont atteint le total des ventes de toute l'année 2017 [1], la Chine, l'Europe et les États-Unis d'Amérique étant les plus grands marchés. La part de marché mondiale des VE a atteint 4.1% dans la même période avec une voiture sur quatre vendues provient de TESLA, une réussite remarquable pour une marque relativement nouvelle qui ne compte que 4 modèles [3].

Ce véritable boom est lié à la baisse spectaculaire du prix de production des batteries. De plus, le problème du réchauffement climatique et la pénurie annoncée des ressources fossiles incitent les gouvernements et le secteur privé à être vigilants, et à mettre en place des politiques de réduction des émissions de CO<sub>2</sub>. Dans ce contexte, le recours aux véhicules électriques est favorisé et encouragé par des subventions.

Si le véhicule électrique est bien connu au Maroc, les ventes restent limiter par des considérations purement budgétaires. En outre, les utilisateurs sont également limités par le manque de disponibilité des bornes de recharge publiques ainsi que par le temps de recharge des batteries [2]. Ci-dessous les mesures pertinentes introduites pour améliorer le secteur des véhicules électriques au Maroc :

- Introduction d'incitations fiscales pour promouvoir les véhicules à faible consommation de carburant
- Introduction de normes de limitation des émissions
- Diffusion d'audits énergétiques pour les véhicules utilitaires
- Installation des stations de recharge électrique (la société marocaine Vivo Energy a installé la première station de recharge rapide des batteries en 2016)

Le vrai problème pour les VE est la batterie, la production des batteries n'est pas exempte de pollution et le recyclage n'est pas encore efficace. Il est donc important de veiller à une utilisation optimisée des batteries des véhicules électriques. En effet, la durabilité et la performance des véhicules électriques reposent sur les batteries utilisées et leurs conditions d'utilisation.

## Objectifs des travaux de thèse et Contributions


Le stockage de l'énergie dans un véhicule électrique se fait dans des batteries constituées de cellules électrochimiques de type lithium-ion. Celles-ci sont généralement branchées les unes aux autres en série et en parallèle. La gestion de ces cellules nécessite une étroite surveillance par un calculateur dédié appelé communément système de gestion des batteries (Battery Management System BMS en anglais).

Le système de gestion des batteries (BMS) joue un rôle important pour assurer la sécurité, tout en maximisant l'énergie et/ou la puissance délivrée par la batterie ainsi que sa durée de vie.

Bien que les batteries au lithium-ion soient fiables et populaires, l'instabilité thermique et électrochimique des électrodes et l'inflammabilité de l'électrolyte rendent ces batteries sujettes à des défaillances catastrophiques. Les défaillances dues à des incendies et des explosions ont provoqué de nombreux accidents dans l'industrie de l'électronique grand public, de l'automobile et de l'aviation. La figure 1 montre l'incendie d'un avion-cargo (UPS) causée par l'allumage de batteries Li-Ion entraînant la mort de deux membres d'équipage en 2006 (a), la défaillance d'une batterie d'un Boeing 787 en 2013(b), et l'incendie d'une batterie Chevrolet Volt après un essai de collision latérale en 2012(c) [4].

Sur ces photos, on peut voir qu'un BMS fiable est de la plus haute priorité pour assurer la sécurité des batteries dans toutes les applications, en particulier dans les voitures électriques, où une panne de batterie peut mettre directement en danger la vie du passager.

Autre avantage offert par un BMS robuste est la possibilité de prolonger la durée de vie de la batterie en faisant fonctionner celle-ci dans des conditions favorables au-dessous des limites recommandées par le fabricant.



*Figure 1 : Défaillance de la batterie lithium : (a) incendie d'un avion-cargo UPS (b) défaillance d'une batterie d'un Boeing 787 (c) incendie d'une batterie Chevrolet Volt trois semaines après un test de collision latérale [4]*


Le BMS est responsable d'un ensemble d'opérations matérielles et logicielles qui maintiennent la batterie dans un état de sécurité à tout moment (figure 2). Au cœur du BMS se trouve un système de surveillance de la batterie, qui est conventionnellement requis pour effectuer les missions suivantes :

- ✓ Contrôle des surtensions et des sous-tensions ;
- ✓ Protection contre les courants forts ;
- ✓ Communication numérique vers/depus le BMS.
- ✓ Mesure de la tension et du courant des bus ;
- ✓ Mesure de la tension des cellules ;

En plus, les systèmes modernes de gestion des batteries doivent être capables de réaliser un certain nombre de fonctionnalités avancées [5], dont certaines sont énumérées ci-dessous :

- ✓ Équilibrage des cellules actif/passif ;

- ✓ Identification en ligne des paramètres de la batterie ;
- ✓ Estimation en ligne de divers états de la batterie, comme l'état de charge (SOC) ; l'état de santé (SOH), l'état de puissance (SOP) et l'état de fonctionnement (SOF) ;
- ✓ Estimation de la capacité totale
- ✓ Estimation de la durée de vie restante (RUL) ;
- ✓ Diagnostic et pronostic à bord ;



**Figure 2 : Fonctions d'un système de gestion des batteries BMS**

Reconnaissant ces exigences imposées aux systèmes modernes de gestion des batteries. Des chercheurs du monde universitaire et industriel ont été engagés pour développer des algorithmes avancés pour l'estimation des états de charge SOC, de santé SOH, de puissance SOP en temps réel. En plus de répondre aux besoins techniques pour la réalisation des architectures modernes du BMS, il y a aussi un besoin social de gagner la confiance du consommateur sur l'aspect sécurité des nouvelles technologies de batteries afin de renforcer l'utilisation future de ces dispositifs de stockage de l'énergie dans un plus grand nombre d'applications critiques y compris les véhicules électriques.

Pour une exploitation optimale de la batterie, l'état de charge SOC (State of Charge), et la capacité totale (utilisé pour l'estimation de l'état de santé SOH State of Health) sont les variables qui doivent être connues le plus précisément possible.

Par conséquent, cette thèse vise à étendre l'état actuel de l'art des algorithmes avancés ciblant l'estimation de ces variables. Tout d'abord, une étude comparative est réalisée entre quatre algorithmes courants utilisés pour estimer le SOC des batteries pour les véhicules électriques. Nous exposons cette comparaison ainsi que les résultats des simulations des algorithmes : Filtre de Kalman étendu EKF (Extended Kalman Filter), et du filtre de Kalman à points sigma SPKF (Sigma Point Kalman Filter) pour le test de stress dynamique DST (Dynamic stress test).

En outre, l'état de charge SOC de la batterie, qui ne peut être mesuré directement, doit être estimé avec précision. Les techniques les plus couramment utilisées pour estimer l'état de charge d'une batterie s'appuient sur l'utilisation des modèles à base de circuit électrique, le problème est que les paramètres de ces modèles sont affectés par des facteurs tels que la

température, le vieillissement de la batterie, l'état de charge, entraînant une erreur d'estimation du SOC [6]. Il est donc essentiel d'identifier avec précision ces paramètres. La mise à jour constante des paramètres du modèle, également appelée identification des paramètres en ligne, peut résoudre ce problème pour le BMS. Dans le cadre de cette thèse nous avons proposé deux nouveaux algorithmes pour l'estimation des paramètres en ligne. Les deux méthodes (AFFRLS, SFO) et les modèles développés sont adaptés pour les applications véhicules électriques :

1-L'algorithme AFFRLS (Adaptive Forgetting Factor Recursive Least Square).

Ici, les paramètres d'un modèle électrique équivalent sont identifiés sur la base de la méthode proposée et comparée à celle de RLS (Recursive least square) [6]. La tension de sortie estimée par les deux méthodes est comparée avec la tension mesurée réelle. L'exactitude de l'identification des paramètres du modèle de circuit est vérifiée à l'aide des données expérimentales fournies par l'Université McMaster de Hamilton, Ontario, Canada, réalisées sur la batterie Li-Ion LG 18650HG2 dans le profil UDDS (Urban Dynamometer Driving Schedule) [7], en plus de deux ensembles de données fournis par le groupe de recherche sur les batteries CALCE réalisés sur la batterie Li-Ion Samsung INR 18650-20R dans deux profils dynamiques : DST (Dynamic stress test) et FUDS (Federal urban driving schedule) [8-10].

2-L'algorithme SFO (Sunflower Optimization Algorithm). « *Meilleur article à la conférence IEEE GPECOM2020* »

Pour le deuxième algorithme (SFO), un modèle Thévenin est construit en utilisant la représentation d'état (state space model). L'identification des paramètres du modèle basé sur SFO est proposée et comparée à l'algorithme AFFRLS développé dans [11]. La tension de sortie estimée relevée par ces algorithmes est comparée à la tension de sortie réelle mesurée. Pour comparer l'efficacité de l'identification des paramètres du modèle de circuit équivalent, les données effectuées sur la cellule lithium A123 ANR26650m1A par le groupe de recherche sur les batteries CALCE pour les trois profils dynamiques suivants : DST, US06 (Supplemental Federal Test Procedure) et FUDS ont été utilisées.

Quant à l'estimation de la capacité totale de la batterie qui est une clé qui permet non seulement au BMS de calculer avec une bonne approximation la capacité maximale de stockage d'énergie et l'énergie restante dans une batterie, mais surtout d'anticiper les risques de défaillance, grâce à des indicateurs tels que l'état de santé (SOH) ; nous avons mis au point un nouveau framework basé sur l'algorithme SFO pour l'estimation de la capacité totale, cet algorithme est validé et comparé à quatre algorithmes récursifs robustes [12-13] (AWTLS, WTLS, WLS, TLS) à l'aide de l'ensemble de données sur le vieillissement des batteries de la NASA [14], en plus de trois scénarios d'une batterie dans des applications de véhicules électriques et hybrides rechargeables [12-13]. D'après nos recherches, il s'agit de l'une des premières tentatives d'estimation de la capacité en utilisant l'algorithme SFO.

Les nouvelles techniques présentées dans cette thèse ont été publiées dans six revues [15-20]. Vous trouverez ci-dessous les contributions réalisées dans cette thèse :

**1. Comparison of State of Charge Estimation Algorithms for Lithium Battery.** *In International Conference on Electronic Engineering and Renewable Energy, 2020 : Springer, pp. 293-300.*

**2. Robust Parameter Estimation of an Electric Vehicle Lithium-Ion Battery Using Adaptive Forgetting Factor Recursive Least Squares.** *International Journal of Intelligent Engineering and Systems*, 2020, 13(5), pp. 74–84.

**3. Online Parameter Estimation of an Electric Vehicle Lithium-Ion Battery Using AFFRLS.** *In 2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, 2020 : IEEE, pp. 1-6.

**4. Online Parameter Estimation of a Lithium-Ion Battery based on Sunflower Optimization Algorithm.** *In 2020 2nd Global Power, Energy and Communication Conference (GPECOM)*, 2020 : IEEE, pp. 53-58. « Meilleur article à la conférence IEEE GPECOM2020 »

**5. Online Parameter Estimation of a Lithium-Ion Battery based on Sunflower Optimization Algorithm .** *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 3, pp. 1505-1513, 2021.

**6. Battery Total Capacity estimation based on the Sunflower algorithm. (Q1)**

*E. Mouncef, B. Mostafa, Battery total capacity estimation based on the sunflower algorithm, J. Energy Storage*. 48 (2022) 103900. <https://doi.org/10.1016/j.est.2021.103900>.

## Organisation de la thèse

Cette thèse portant sur « Estimation des paramètres, de l'état de charge et de l'état de santé de la batterie lithium pour les véhicules électriques » est organisée en quatre chapitres. Une brève description de chaque chapitre est fournie ci-dessous.

Le premier chapitre présente une revue bibliographique sur les systèmes de gestion de la batterie, les modèles de batterie, les techniques d'équilibrage des cellules, les techniques d'estimation de l'état de charge et de la capacité totale (utilisé pour estimer l'état de santé SOH) de la batterie lithium-ion pour les applications de véhicules électriques.

Dans le deuxième chapitre, nous proposons une comparaison de quatre techniques utilisées pour l'estimation de l'état de charge avec simulation des résultats et comparaison.

Le troisième chapitre présente deux contributions réalisées dans le cadre de cette thèse au niveau de l'estimation en ligne des paramètres du modèle de la batterie lithium moyennant deux algorithmes : AFFRLS et SFO. Les deux méthodes et les modèles développés sont adaptés pour les applications véhicules électriques.

Dans le quatrième chapitre, une nouvelle technique d'estimation de la capacité d'une batterie est proposée, étudiée et validée sur deux bases de données [12-13] et comparée à quatre méthodes récursives robustes.



# Chapitre

# 1

---

## État de l'art des systèmes de gestion des batteries BMS

---

## 1.1 Introduction

Dans la majorité des applications réelles, une seule cellule ne peut pas générer suffisamment d'énergie pour accomplir une tâche donnée. C'est pourquoi on trouve souvent des blocs de batteries composés de nombreuses cellules connectées en série et/ou en parallèle pour atteindre une puissance et une énergie spécifiques. Afin de maintenir les cellules dans les limites de fonctionnement recommandées, les systèmes de gestion des batteries (BMS) sont généralement intégrés dans la conception du pack jouant le rôle du cerveau. Ce chapitre présente un état de l'art détaillé des BMS utilisés dans les applications véhicules électriques. Dans un premier lieu, on va traiter la problématique de la modélisation des cellules Li-ion en vue de l'estimation de l'état de charge (SOC : State of Charge), puis, on donnera une vue d'ensemble sur les techniques d'équilibrage des cellules ainsi que les différentes méthodes d'estimation de l'état de charge, et les algorithmes utilisés pour l'estimation de la capacité de la batterie (utilisé pour évaluer l'état de santé SOH : State of Health).

## 1.2 Batterie Lithium-ion :

### 1.2.1 Introduction

Les constructeurs automobiles se sont de plus en plus orientés sur la mobilité électrique. Les batteries lithium-ion sont devenues l'une des solutions les plus intéressantes pour les systèmes de stockage d'énergie des véhicules électriques en raison de leur faible poids, de leur énergie spécifique élevée et de leur faible taux d'autodécharge.

Le diagramme de Ragone figure 1.1 montre l'état actuel et prévisionnel des techniques de stockage (piles, supercondensateurs, accumulateurs électriques, etc.) par rapport aux exigences de l'USABC (United States Advanced Battery Consortium) [21].

Comme on peut le constater, les densités d'énergie et de puissance des techniques de stockage varient dans une large gamme. Cependant, une forte densité de puissance élevée ne s'accompagne généralement pas d'une densité d'énergie élevée.

Les supercondensateurs possèdent la puissance spécifique la plus élevée, ce qui leur permet de fournir une grande puissance de pointe instantanée, cependant ils ont une énergie spécifique faible. Les piles à combustible ont une densité d'énergie spécifique élevée mais nécessitent une infrastructure d'hydrogène.

Les cellules des batteries lithium-ion atteignent des densités d'énergie et de puissance gravimétriques les plus élevées de toutes les batteries rechargeables disponibles. Il est possible d'obtenir des durées de vie et des niveaux de sécurité très élevés en utilisant du titanate comme matériau actif négatif au lieu du carbone, mais cela entraîne des densités d'énergie nettement inférieures. Ces batteries constituent un choix intéressant pour les VE et les véhicules hybrides en raison de leur grande densité énergétique et de leurs grandes puissances. En conséquence, des recherches et des investissements considérables sont consacrés à leur développement afin d'améliorer leurs performances, leur fiabilité, leur sécurité et leur durabilité.



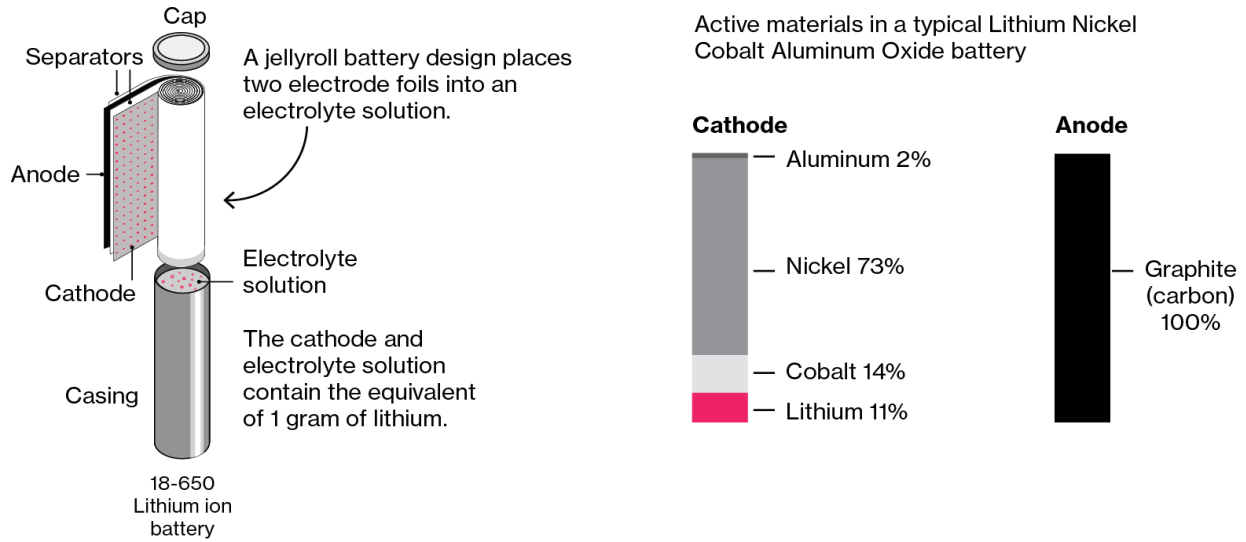


Figure 1.1 : Diagramme de Ragone de diverses technologies de batteries avec spécification au niveau des cellules pour des applications automobiles [21]

## 1.2.2 Principe de fonctionnement des batteries Li-ion

Une pile convertit l'énergie chimique en énergie électrique et vice versa. La configuration de base d'une pile se compose de quatre éléments principaux : l'électrode positive, le séparateur, l'électrolyte et l'électrode négative comme montre la figure 1.2 (a).





(b)


Figure 1.2 : Batterie Li-ion, représentation schématique (a), Structure interne (b) [22]

Les électrodes positives et négatives sont appelées cathodes et anodes. La batterie est connectée à une charge externe à l'aide des plaques collectrices de courant. Dans le cas des cellules Li-Ion, un collecteur en cuivre est utilisé pour l'électrode négative tandis qu'un collecteur en aluminium est utilisé pour l'électrode positive.

L'anode est l'électrode capable de fournir des électrons à la charge. L'anode est généralement constituée d'un mélange de carbone, la cathode est généralement constituée d'oxydes métalliques, tandis que l'électrolyte est composé de sels, de solvants et d'additifs figure I.2 (b).

En présence d'un courant de charge, une réaction de réduction-oxydation se produit. La réaction d'oxydation a lieu à l'anode où les particules de lithium piégées commencent à se détacher ou à diverger vers l'interface électrolyte-solide, divisant le lithium en ions et en électrons. Les ions de lithium sont transférés à travers la solution en raison de la différence de potentiel tandis que les électrons se déplacent à travers le collecteur de courant car la solution d'électrolyte sert de barrière aux électrons. La réaction de réduction a lieu à la cathode où les ions de lithium qui se déplacent depuis l'anode commencent à s'insérer et à réagir avec les électrons provenant du collecteur positif. Les réactions électrochimiques sont les suivantes :

Électrode positive :



Électrode négative :



Le processus d'insertion des ions lithium dans l'électrode se produit sans changement de la structure cristalline de l'électrode : mécanisme d'intercalation. L'ensemble du phénomène d'intercalation et de désintercalation est réversible, les ions de lithium passant d'une électrode à l'autre pendant la charge et la décharge. En théorie, ce phénomène pourrait se poursuivre indéfiniment. Malheureusement, en raison de la dégradation du matériau de la cellule et d'autres réactions chimiques irréversibles, la capacité et la puissance de la cellule se dégradent avec le nombre de cycles et d'utilisations.

## 1.2.3 Terminologie des batteries

### Cellule, modules et packs

Chaque VE contient un pack de batteries haute tension composé de plusieurs modules, chaque module étant constitué de plusieurs cellules. Une cellule est la plus petite unité connectée en parallèle ou en série pour former un module. Un module est ensuite connecté en parallèle ou en série pour former un pack (figure 1.3).




Figure 1.3 : Cellule module et pack [22]

### Capacité nominale

La capacité nominale  $C_n$  est déterminée par le fabricant, elle est égale au total des ampères-heures consommés pour décharger complètement une cellule depuis un état de charge de 100 % jusqu'à la tension de coupure. La capacité est alors calculée en multipliant le courant de décharge (en ampères) par le temps de décharge (en heures).

### État de charge SOC

Lorsqu'il s'agit de véhicules électriques, le SOC indique la capacité disponible de la batterie en pourcentage de la capacité maximale. En d'autres termes, il mesure la quantité d'énergie électrique contenue dans la batterie. Le SOC a une valeur de 0 à 1, représentant respectivement une batterie complètement déchargée et complètement chargée. Ce paramètre peut être comparé à la jauge du réservoir de carburant d'un véhicule à moteur à combustion interne.

### Tension en circuit ouvert OCV

Cette tension correspond à la tension aux bornes de la batterie lorsque aucune charge n'est appliquée (batterie à vide). Il existe une relation directe entre cette tension et l'état de charge SOC.

### La tension de coupure

La tension de coupure désigne la tension minimale admissible à partir de laquelle la batterie est considérée comme "vide".

### Tension terminale (Tension de sortie)

La tension terminale est la tension aux bornes de la batterie quand elle est soumise à une charge. Cette tension varie souvent en fonction de l'état de charge et le courant de décharge/charge.

### **Résistance interne**

La résistance interne d'une batterie limite la quantité de puissance délivrée par la batterie. Souvent, la résistance interne est conçue pour être faible afin de permettre de délivrer plus de puissance ; cependant, la résistance interne augmente avec le temps en raison de la dégradation de la batterie.

### **Taux de charge C**

Les taux de charge sont utilisés pour décrire et comparer les courants de décharge de différentes batteries. Le **taux C** est une valeur normalisée par rapport à la capacité de la batterie.

### **Cycle de vie**

Ce chiffre fait référence au nombre de fois où la batterie peut être chargée et déchargée avant d'être mise hors service.

### **Profondeur de décharge DOD**

La profondeur de décharge est une mesure qui indique le pourcentage de la capacité de la batterie qui a été utilisé. En d'autres termes, il s'agit de la représentation inverse du SOC et peut être calculé comme :  $DOD = 1 - SOC$ .

### **État de santé SOH**

Le SOH mesure la dégradation irréversible qui se produit dans la performance de la batterie en raison du fonctionnement cyclique et du vieillissement. Le SOH permet une comparaison facile avec une batterie saine. La meilleure façon d'évaluer la santé d'une batterie est de tester sa capacité. Certains facteurs qui affectent la capacité d'une batterie sont la température à différents SOC, le niveau de SOC auquel elle est chargée à chaque fois, le nombre de cycles et la profondeur de décharge (DOD). Souvent, les batteries sont mises hors service lorsque leur capacité globale chute à 80 %, ce que l'on appelle : évanouissement de la capacité.

## **1.3 Modélisation des batteries Li-ion**

Le BMS utilise des modèles mathématiques et des algorithmes d'estimation d'état pour exécuter les fonctions suivantes :

- ✓ Protection des cellules.
- ✓ Équilibrage des cellules.
- ✓ Gestion thermique.
- ✓ Gestion de l'énergie.

.....

L'une des principales exigences pour une mise en œuvre réussie du BMS est le développement d'un modèle de batterie de haute qualité. Le modèle doit être dynamiquement significatif tout en étant efficace, robuste et précis.

Dans la littérature, nombreux modèles de batterie ont été rapportés. Le choix entre ces modèles est un compromis entre la complexité du modèle, sa précision et l'effort de paramétrage. Les modèles peuvent être classés en trois catégories de complexité croissante : les modèles comportementaux (ou boîte noire) [23], les modèles de circuit équivalent [24] et les modèles électrochimiques [25]. Actuellement, les modèles de circuit équivalent sont couramment

utilisés dans les BMSs en raison de leur faible complexité de calcul et de leur précision acceptable.

### 1.3.1 Modèles de batterie du type comportemental ou boîte noire

Les modèles comportementaux ou de boîte noire simulent le comportement de la tension aux bornes des batteries sans qu'il soit nécessaire de spécifier ou d'approximer le comportement physique ou électrochimique sous-jacent. Ces modèles consistent en des fonctions qui nécessitent l'utilisation de données mesurées. On peut également utiliser des réseaux de neurones, des fonctions empiriques ou des tables de consultation. La loi de Peukert est l'un des premiers exemples bien connus de modèle comportemental pour les batteries, où une fonction empirique est utilisée pour décrire la dépendance de la capacité restante de la batterie par rapport au taux de décharge comme suit :

$$I^{PC} t = \text{const} \tan t \quad (1.3)$$

Où, I est le courant de décharge, t est le temps de décharge maximum et PC est le coefficient de Peukert qui varie de 1 à 2 [26]. La capacité de la batterie peut être calculée comme suit :

$$C_{n1} = C_n \left( \frac{I_n}{I_{n1}} \right)^{PC-1} \quad (1.4)$$

Où  $C_{n1}$  est la capacité restante de la batterie pour un courant de décharge de  $I_{n1}$  [26]. Une autre forme de modèle comportemental a été introduite par Shepherd [27], pour prédire la tension aux bornes de la batterie pendant les conditions de charge/décharge comme suit :

$$E(t) = E_0 + R_\alpha i(t) + \frac{K_1}{q_s(t)} \quad (1.5)$$

$E_0$  est la tension initiale de la cellule,  $R_\alpha$  est la résistance interne de la cellule,  $q_s(t)$  est la charge stockée instantanée, et  $K_1$  est une constante. Une autre variante a été apportée dans [28] :

$$E(t) = E_0 + R_\alpha i(t) + K_2 q_s(t) \quad (1.6)$$

Nernst a introduit deux autres constantes  $K_3$  et  $K_4$  qui sont utilisées pour l'ajustement des courbes comme suit :

$$E(t) = E_0 + R_\alpha i(t) + K_3 \frac{q_s(t)}{Q} - K_4 \ln\left(\frac{Q - q_s(t)}{Q}\right) \quad (1.7)$$

Où, Q est la capacité de charge totale de la cellule et les constantes  $K_1$ ,  $K_2$ ,  $K_3$ , et  $K_4$  peuvent être obtenues à partir des données expérimentales.

Plett a combiné une série de modèles comportementaux pour simuler le fonctionnement des batteries [29-31]. Quatre modèles ont été examinés dans sa publication, à savoir le modèle simple, l'hystérésis zéro, l'hystérésis à un état et le modèle d'autocorrection améliorée. Tous ces modèles sont basés sur les modèles de Peukert et de Shepherd. Ces modèles peuvent tenir compte de l'hystérésis des cellules, des constantes de temps de polarisation et des effets de perte

ohmique. Les modèles comportementaux permettent d'atteindre une précision de prédiction de la tension terminale allant jusqu'à 5% [32].

### 1.3.2 Le modèle combiné

Les modèles Shepherd/Unnewehr/Nernst sont associés pour former un "modèle combiné" dont les performances sont meilleures que celles de chaque modèle individuel [26]. Le modèle combiné est décrit comme suit :

$$z_{k+1} = z_k - \frac{\eta_i \Delta t}{C} i_k \quad (1.8)$$

$$y_k = K_0 + Ri_k + \frac{K_1}{z_k} - K_2 z_k + K_3 \ln(z_k) + K_4 \ln(1 - z_k) \quad (1.9)$$

Ce modèle a l'avantage d'être linéaire dans les paramètres, ce qui le rend plus facile à mettre en œuvre et à estimer. En conséquence, les quantités des paramètres inconnus du modèle peuvent être estimées à l'aide d'une procédure d'identification du système. Par exemple, étant donné un ensemble de N paramètres d'entrée-sortie de cellules ( $y_k$ ,  $i_k$ ,  $z_k$ ), les valeurs peuvent être résolues sous une forme fermée en utilisant l'estimation des moindres carrés [29-31].

### 1.3.3 Le modèle simple

Le modèle simple est obtenu à partir du modèle combiné. L'équation de sortie du modèle simple est divisée en deux parties additives : l'une dépendant uniquement du SOC ( $z_k$ ), et l'autre dépendant uniquement du courant ( $i_k$ ). Ce faisant, on obtient les équations (1.10) et (1.11) :

$$f(z_k) = OCV(z_k) = K_0 + \frac{K_1}{z_k} - K_2 z_k + K_3 \ln(z_k) + K_4 \ln(1 - z_k) \quad (1.10)$$

$$f(i_k) = Ri_k \quad (1.11)$$

Les équations (1.10) et (1.11) sont combinées en une seule équation pour une mise en œuvre plus facile et plus précise du modèle comme suit :

$$z_{k+1} = z_k - \frac{\eta_i \Delta t}{C} i_k \quad (1.12)$$

$$y_k = OCV(z_k) - Ri_k \quad (1.13)$$

Où OCV ( $z_k$ ) fait référence à la tension de circuit ouvert.

### 1.3.4 Le modèle d'hystérésis à l'état zéro

Un concept important qui est négligé par les deux modèles précédents est l'hystérésis. Pour une meilleure estimation du SOC, les effets d'hystérésis de la tension aux bornes doivent être pris en compte. Comme décrit dans [23], un simple terme est ajouté à l'équation de sortie (1.13) comme suit :

$$y_k = OCV(z_k) - s_k M(z_k) - Ri_k \quad (1.14)$$



Où  $s_k$  indique le signe du courant. Pour une valeur suffisamment petite et positive,  $s_k$  peut être calculé comme suit :

$$s_k = \begin{cases} +1 & : i_k > \varepsilon \\ -1 & : i_k < -\varepsilon \\ s_k & : |i_k| \leq \varepsilon \end{cases} \quad (1.15)$$

Notez également que  $M(z_k)$  est la moitié de la différence entre les valeurs de charge et de décharge [23]. En général, la valeur de  $M$  peut être considérée comme constante. Selon [30], le modèle d'hystérésis à l'état zéro est une amélioration par rapport au modèle simple, mais il ne donne qu'une approximation grossière du phénomène sous-jacent. Alors que le niveau d'hystérésis change lentement lorsque la cellule est chargée ou déchargée, le modèle estime que l'hystérésis bascule immédiatement entre ses valeurs positives et négatives maximales lorsque le signe du courant change.

### 1.3.5 Le modèle autocorrectif amélioré

Le modèle de batterie auto-correcteur amélioré est l'un des modèles les plus précis actuellement utilisés pour l'estimation du SOC de la batterie. Ce modèle peut capter avec précision la dynamique de la batterie et peut donc être mis en œuvre dans un BMS de véhicule car il tient compte de l'hystérésis, des constantes de temps de polarisation et des pertes ohmiques. Le modèle est décrit sous la forme suivante [30] :

$$\begin{bmatrix} f_{k+1} \\ h_{k+1} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} \text{diag}(\alpha) & 0 & 0 \\ 0 & F(i_k) & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f_k \\ h_k \\ z_k \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 - F(i_k) \\ \frac{-\eta i \Delta t}{C} & 0 \end{bmatrix} \begin{bmatrix} i_k \\ M(z, \ddot{z}) \end{bmatrix} \quad (1.16)$$

$$y_k = OCV(z_k) - h_k - Ri_k + Gf_k \quad (1.17)$$

Où  $z_k$  est l'état de charge,  $f_k$  est l'état du filtre passe-bas,  $h_k$  est l'état représentant l'effet d'hystérésis de charge ou de décharge,  $OCV$  est la tension de circuit ouvert,  $C_n$  est la capacité nominale de la batterie,  $R$  est la résistance interne de la batterie,  $G$  est la matrice de sortie du filtre passe-bas, et  $\alpha$  sont les pôles du filtre passe-bas.

### 1.3.6 Modèles de circuit équivalent (MCE)

Les modèles de circuit équivalent (MCE) sont des modèles basés sur des composants électriques tels que des sources de tension idéales, des résistances et des condensateurs pour simuler le comportement de la batterie [24]. La grande majorité des MCE sont des modèles semi-empiriques où le processus de calcul des sorties finales est basé sur deux activités

distinctes. Premièrement, l'OCV (tension de circuit ouvert) en fonction du SOC doit être connu à l'avance en effectuant des expériences en laboratoire où la batterie est soumise à des cycles de décharge et de repos. Deuxièmement, les paramètres du MCE, tels que les résistances et les condensateurs, doivent être calibrés à l'aide de données d'E/S et de techniques d'identification des paramètres telles que les méthodes des moindres carrés. Ils sont largement utilisés en raison de leur simplicité, du faible nombre de paramètres à régler et de leur facilité de mise en œuvre. Les systèmes actuels de gestion des batteries (BMS) se basent sur des modèles de circuits équivalents en raison de leur simplicité et de leur robustesse, qui permettent à ces modèles d'être mis en œuvre dans des applications en temps réel. Cependant, ils sont limités dans leur capacité à fournir un aperçu des réactions électrochimiques qui se produisent à l'intérieur de la cellule. Cette limitation les rend incapables de prédire les phénomènes électrochimiques tels que la dégradation de la cellule, l'affaiblissement de la capacité et l'affaiblissement de la puissance. Dans la littérature, ces modèles peuvent également être couplés ou intégrer à des modèles thermiques pour prédire le comportement global de la cellule, comme discuté dans [33].

### 1.3.6.1 Modèle Rint

Le modèle de Rint est le plus simple des MCE. Il est utilisé pour évaluer approximativement la tension de sortie de la batterie en fonction de deux paramètres essentiels : la tension de circuit ouvert (OCV) basée sur le SOC de la batterie, et la résistance interne de la batterie. En termes simples, la batterie est modélisée comme une source de tension idéale (OCV) et la résistance représente les pertes d'énergie. La figure 1.4 illustre le circuit du modèle Rint.




Figure 1.4 : Modèle Rint

La tension de sortie  $V_{out}$  également appelée tension terminale, est calculée comme suit :

$$V_{out} = V_{ocv}(SOC) - R_0 i \quad (1.18)$$

L'un des inconvénients de ce modèle est la dépendance des paramètres vis-à-vis du SOC et de la température. Les courbes de paramètres doivent être dérivées hors ligne de manière expérimentale en utilisant des cycles de charge et de décharge à courant constant et à tension constante tout en étant soumis à une température constante. Le dispositif expérimental est souvent composé d'un système de test de batterie, d'une chambre thermique pour le contrôle de l'environnement et d'un ordinateur. Des expériences similaires sont réalisées à différentes températures et des tables de correspondance sont créées pour les modèles. Ensuite, les données sont traitées à l'aide de logiciels tels que MATLAB pour l'identification des paramètres. D'autres techniques d'identification des paramètres comprennent les algorithmes génétiques et

la méthode des moindres carrés. Enfin, la tension de sortie de la batterie ne tient pas compte de l'effet hystérésis.

### 1.3.6.2 Modèle PNGV

Le gouvernement américain et le conseil américain pour la recherche automobile (USCAR) ont établi en 1993 le modèle PNGV (Partnership for a New Generation of Vehicles) basé principalement sur les caractéristiques de polarisation de la batterie. De plus, ce modèle a été adopté dans le manuel de test des batteries PNGV "PNGV battery test Manual", qui détaille les tests à effectuer sur les batteries. Le programme vise à améliorer la compétitivité nationale dans le domaine de la fabrication et à mettre en œuvre des innovations en matière d'économie d'énergie dans les véhicules particuliers [34].

Le modèle PNGV est illustré à la figure 1.5. Le modèle se compose de 5 paramètres :  $E$  représente la tension de circuit ouvert de la batterie.  $R_0$  est la résistance interne de la batterie.  $C$  représente la capacité des plaques parallèles et les effets de diffusion de la batterie.  $R_1$  représente la résistance non linéaire de la batterie due à la résistance de contact entre les plaques et l'électrolyte. Enfin,  $C_0$  représente la variation de l'OCV générée par l'accumulation du courant de charge et met à l'échelle la capacité de stockage de la batterie.




Figure 1.5 : Modèle PNGV

Le modèle PNGV peut être représenté par :

$$\begin{bmatrix} \dot{V}_0 \\ \dot{V}_1 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & -\frac{1}{R_1 C_1} \end{bmatrix} \begin{bmatrix} V_0 \\ V_1 \end{bmatrix} + \begin{bmatrix} \frac{1}{C_0} \\ \frac{1}{C_1} \end{bmatrix} [i] \quad (1.19)$$

Avec la tension aux bornes définie comme :

$$V_{out} = E - V_0 - V_1 - R_0 i \quad (1.20)$$

Avec des formes discrètes définies comme :

$$\begin{bmatrix} V_{0,k+1} \\ V_{1,k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 - \frac{T}{R_1 C_1} \end{bmatrix} \begin{bmatrix} V_{0,k} \\ V_{1,k} \end{bmatrix} + \begin{bmatrix} \frac{T}{C_0} \\ \frac{T}{C_1} \end{bmatrix} [i_{s,k}] \quad (1.21)$$

$$V_{out,k} = E(SOC) - V_{0,k} - V_{1,k} - R_0 I_{s,k} \quad (1.22)$$

### 1.3.6.3 Le modèle RC premier ordre (modèle de Thévenin premier ordre)

Le modèle RC du premier ordre se compose d'une paire RC connectée en série avec une résistance. Les équations d'état et de mesure du système sont représentées respectivement par (1.23) et (1.24). Le schéma de principe est illustré dans la figure 1.6. Ce modèle peut être facilement mis en œuvre dans des applications en temps réel en raison de sa simplicité.




Figure 1.6 : Schéma du modèle RC de premier ordre

$$\begin{bmatrix} V_{k+1} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} V_k \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} \\ -\frac{\eta_i \Delta t}{C} \end{bmatrix} [i_k] \quad (1.23)$$

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k \quad (1.24)$$

Où,  $z_k$  est l'état de charge de la batterie,  $V_k$  est la chute de tension aux bornes de la première paire RC,  $C$  est la capacité nominale de la batterie,  $R$  est la résistance ohmique de la batterie,  $y_k$  est la tension aux bornes de la batterie, et  $\eta_i$  est le coefficient coulombique. Les paramètres à optimiser sont donnés dans l'équation (1.25).

$$\theta = [R_0, R_1, C_1] \quad (1.25)$$

### 1.3.6.4 Le modèle RC premier ordre avec hystérésis à un état

L'état d'hystérésis est incorporé en ajoutant l'effet d'hystérésis de charge et de décharge de l'OCV au modèle RC du premier ordre (modèle de Thévenin premier ordre). Les équations

d'état et de mesure du système sont représentées par (1.26) et (1.27) respectivement. Alors que le vecteur paramétrique à optimiser est représenté par l'équation (1.28).

$$\begin{bmatrix} V_{k+1} \\ h_{k+1} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & F(i_k) & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} V_k \\ h_k \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} & 0 \\ 0 & 1 - F(i_k) \\ -\frac{\eta_i \Delta t}{C} & 0 \end{bmatrix} \begin{bmatrix} i_k \\ M(z, \ddot{z}) \end{bmatrix} \quad (1.26)$$

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k - h_k \quad (1.27)$$

$$\theta = [R_0, R_1, C_1, M, \gamma] \quad (1.28)$$

### 1.3.6.5 Le modèle RC deuxième ordre (modèle de Thévenin deuxième ordre)

Le modèle du deuxième ordre est présenté dans la figure 1.7 et ses équations d'état et de mesure sont représentées respectivement par les équations (1.29) et (1.30). Ce modèle est plus précis que les modèles précédents tout en restant suffisamment simple pour être mis en œuvre dans des applications en temps réel [24].




Figure 1.7 : Schéma du modèle RC deuxième ordre

$$\begin{bmatrix} V_{k+1}^1 \\ V_{k+1}^2 \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} V_k^1 \\ V_k^2 \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ -\frac{\eta_i \Delta t}{C} \end{bmatrix} [i_k] \quad (1.29)$$

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k^1 - V_k^2 \quad (1.30)$$

Où,  $V_k^1$  et  $V_k^2$  étant les chutes de tension aux bornes de la première et deuxième paire RC. Les paramètres à optimiser sont indiqués dans l'équation (1.31).

$$\theta = [R_0, R_1, C_1, R_2, C_2] \quad (1.31)$$

### 1.3.6.6 Le modèle RC deuxième ordre avec hystérésis

Ce modèle est formé en ajoutant un état d'hystérésis au modèle RC deuxième ordre. Les équations d'état et de mesure du système sont représentées respectivement dans les équations (1.32-1.33). Alors que le vecteur de paramètres à optimiser est représenté dans l'équation (1.34).

$$\begin{bmatrix} V_{k+1}^1 \\ V_{k+1}^2 \\ h_{k+1} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 & 0 \\ 0 & 0 & F(i_k) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} V_k^1 \\ V_k^2 \\ h_k \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} & 0 \\ \frac{\Delta t}{C_2} & 0 \\ 0 & 1 - F(i_k) \\ -\frac{\eta_i \Delta t}{C} & 0 \end{bmatrix} \begin{bmatrix} i_k \\ M(z, \dot{z}) \end{bmatrix} \quad (1.32)$$

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k^1 - V_k^2 + h_k \quad (1.33)$$

$$\theta = [R_0, R_1, C_1, R_2, C_2, M, \gamma] \quad (1.34)$$

### 1.3.6.7 Le modèle RC troisième ordre

Le modèle du troisième ordre est illustré à la figure 1.8 et les équations d'état et de mesure de ce système sont représentées par les équations (1.35) et (1.36) respectivement. Le vecteur paramétrique associé est donné par l'équation (1.37). Bien que la complexité de ce modèle augmente, il est plus précis dans la capture du comportement dynamique de la batterie [24].

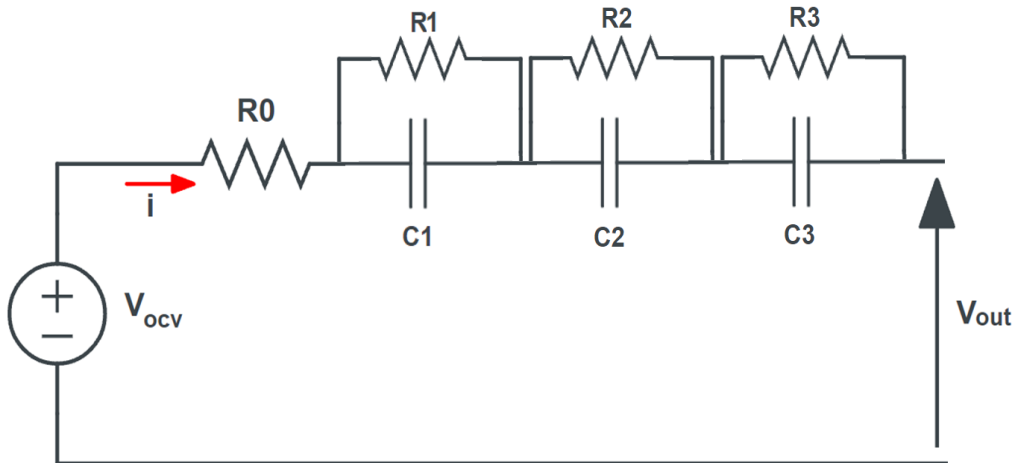


Figure 1.8 : Schéma du modèle RC troisième ordre

$$\begin{bmatrix} V_{k+1}^1 \\ V_{k+1}^2 \\ V_{k+1}^3 \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_3 C_3} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} V_k^1 \\ V_k^2 \\ V_k^3 \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ \frac{\Delta t}{C_3} \\ -\frac{\eta_i \Delta t}{C} \end{bmatrix} [i_k] \quad (1.35)$$

Où,  $V_k^3$  est la chute de tension aux bornes de la troisième paire RC.

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k^1 - V_k^2 - V_k^3 \quad (1.36)$$

$$\theta = [R_0, R_1, C_1, R_2, C_2, R_3, C_3] \quad (1.37)$$

### 1.3.6.8 Le modèle RC du troisième ordre avec hystérésis

Comme pour les modèles de premier et deuxième ordre, le modèle RC de troisième ordre peut être augmenté d'un état pour représenter l'effet d'hystérésis. Les équations d'état et de mesure du système sont représentées par les équations ci-dessous :

$$\begin{bmatrix} V_{k+1}^1 \\ V_{k+1}^2 \\ V_{k+1}^3 \\ h_{k+1} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 & 0 & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_3 C_3} & 0 & 0 \\ 0 & 0 & 0 & F(i_k) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} V_k^1 \\ V_k^2 \\ V_k^3 \\ h_k \\ z_k \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{C_1} & 0 \\ \frac{\Delta t}{C_2} & 0 \\ 0 & 1 - F(i_k) \\ -\frac{\eta_i \Delta t}{C} & 0 \end{bmatrix} \begin{bmatrix} i_k \\ M(z, \ddot{z}) \end{bmatrix} \quad (1.38)$$

$$y_k = V_{ocv}(z_k) - R_0 i_k - V_k^1 - V_k^2 - V_k^3 + h_k \quad (1.39)$$

$$\theta = [R_0, R_1, C_1, R_2, C_2, R_3, C_3, M, \gamma] \quad (1.40)$$

### 1.3.7 Modèles de batteries électrochimiques

De nombreuses approches pour modéliser les processus électrochimiques dans la batterie ont été proposées dans la littérature. La plupart des modèles sont dérivés du modèle électrochimique pseudo-bidimensionnel (P2D) basé sur la physique, appelé modèle de Doyle-Fuller-Newman [35-36], qui est basé sur la théorie des électrodes poreuses et des solutions concentrées. Le principal avantage du modèle P2D basé sur la physique rigoureuse est l'exactitude/précision accrue obtenue en modélisant les processus électrochimiques. Malheureusement, il est très complexe, nécessite beaucoup de temps de calcul et d'allocation de mémoire, et n'est pas adapté au contrôle en temps réel. Par conséquent, des simplifications du modèle P2D sont nécessaires. Dans la littérature, de nombreuses méthodes de réduction ont été explorées, toutes ayant pour but de réduire la complexité de calcul impliquée dans la résolution du modèle électrochimique basé sur la physique tout en maintenant une précision acceptable.

Ces méthodes peuvent être divisées en deux catégories. La première se base principalement sur la réduction de la complexité de calcul impliquée dans la résolution de la concentration de lithium dans les particules solides des électrodes, par exemple Subramanian et al. [37-38] ont développé un modèle simplifié en utilisant la technique de Lyapunov-Schmidt, des techniques de perturbation, la moyenne de volume et des simplifications basées sur l'intuition.

Leur approche fonctionne bien à des taux de décharge faibles à modérés, mais elle est peu performante pour les profils de courant hautement dynamiques tels que ceux rencontrés dans les applications de véhicules hybrides et électriques. Forman et al. [39] ont utilisé la quasi-linéarisation et l'approximation de Padé. Cette approche utilise un modèle quasilinearisé du courant d'intercalation pour résoudre les équations algébriques du modèle, puis une approximation de Padé de la diffusion sphérique est utilisée pour diminuer la complexité du modèle tout en maintenant un haut niveau de précision. Smith et al. [40-41] ont proposé un modèle simplifié utilisant la méthode de regroupement des résidus. Ils ont utilisé une technique d'optimisation non linéaire pour minimiser l'erreur dans la réponse en fréquence entre le modèle d'ordre complet et le modèle d'ordre réduit. Les fonctions de transfert dérivées sont représentées par une série tronquée de résidus groupés avec des valeurs propres similaires.

La deuxième catégorie de simplification du modèle est axée sur la réduction du modèle électrochimique dans son ensemble. La principale contribution consiste à éviter la résolution de grands ensembles d'équations différentielles algébriques de la distribution de la concentration en  $\text{Li}^+$  et de la distribution du potentiel de la phase électrolyte. Cela permet d'obtenir un modèle d'ordre réduit capable d'être calculé en temps réel. Cependant, cette stratégie de simplification du modèle entraîne une perte d'information. La performance diminue à des taux C plus élevés en comparaison avec le modèle d'ordre complet. En général, les hypothèses utilisées pour la réduction du modèle peuvent conduire à des erreurs si une large gamme de taux de C est considérée et si le modèle n'est pas ajusté par rapport aux conditions de fonctionnement de la batterie. Exemples de cette approche de modélisation, Haran et al. [42] ont développé à l'origine l'approche du modèle à particule unique (SPM) pour la batterie à hydrure métallique, et elle a été étendue au système au lithium par Santhanagopalan dans [43]. Dans ce modèle, la densité de courant volumétrique locale est constante à travers l'électrode (anode ou cathode) et égale à une valeur moyenne. Rahimian et al. [44] ont étendu le SPM en incluant une approximation polynomiale de la dynamique de l'électrolyte.

#### 1.4 Système de gestion BMS (Synthèse)

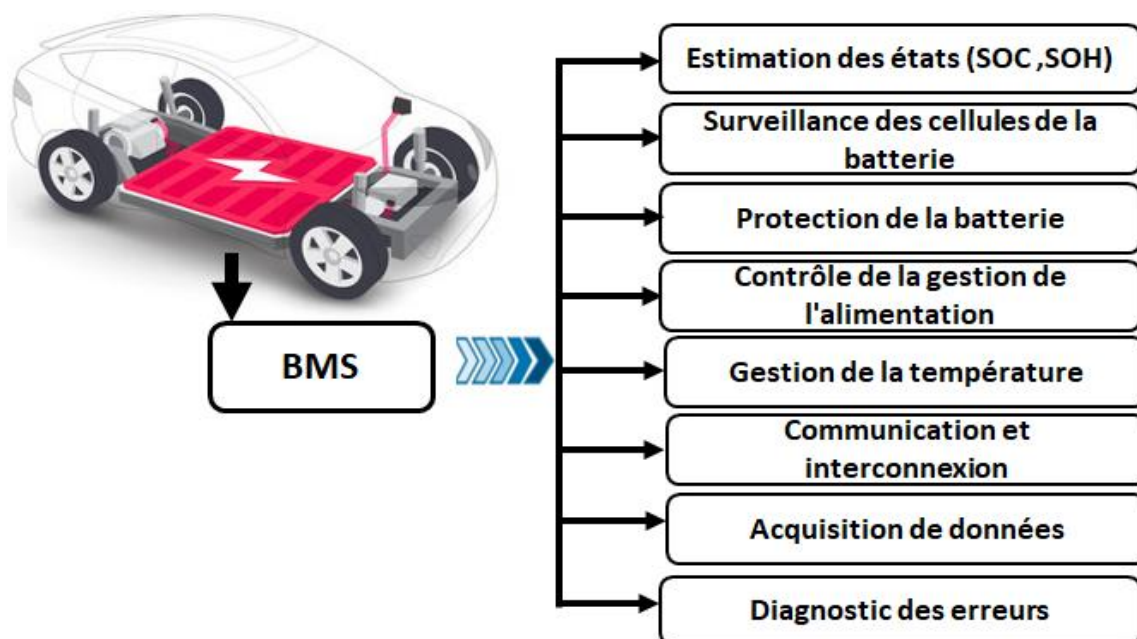


Figure 1.9 : Structure générale d'un BMS standard



La grande majorité des batteries nécessitent un BMS non seulement pour garantir un fonctionnement sécurisé, mais également pour aider la batterie à fonctionner au maximum de ses capacités énergétiques et de puissance, sans dépasser les limites de fonctionnement recommandées. Pour atteindre cet objectif, le système de gestion des batteries réalise plusieurs fonctions (figure 1.9). Les principales tâches accomplies par la BMS incluent les éléments suivants :

- ✓ Acquisition de données.
- ✓ Protection des cellules.
- ✓ Équilibrage des cellules.
- ✓ Gestion thermique.
- ✓ Gestion de l'énergie.
- ✓ Surveillance de l'état des batteries (SOC, SOH...).

### 1.4.1 Acquisition de données

L'acquisition de données comprend la mesure et le conditionnement (filtrage, amplification, etc.) de certaines des données les plus pertinentes de la batterie, qui sont ensuite transmises à d'autres unités de décision. Les mesures les plus pertinentes sont les tensions prises dans chaque cellule d'un bloc de batteries, le courant qui circule dans les modules parallèles d'un bloc et les températures de chaque cellule ou au moins de certains points thermiques critiques d'un pack. Les mesures de tension et de courant doivent être prises à des fréquences d'échantillonnage appropriées afin de pouvoir saisir les effets transitoires importants.

Alors que des mesures de tension d'une précision inférieure à 3 mV sont possibles grâce à des capteurs peu coûteux, l'acquisition précise du courant dans des applications à grande échelle avec plus de 15 000 cellules est une tâche plus difficile. Dans ces applications, le courant de la batterie/cellule est généralement mesuré à l'aide d'une résistance shunt ou d'un capteur à effet Hall. Alors que les résistances shunt souffrent de dérives induites par la température, les capteurs à effet Hall sont susceptibles aux erreurs induites par la compensation, ce qui exige un recalibrage périodique. C'est pourquoi, dans la littérature, les chercheurs ont porté leur attention sur des techniques plus avancées de conditionnement des batteries basées sur des modèles qui peuvent prendre en compte de manière adaptative les erreurs induites par les capteurs de tension et de courant [45]. De plus, grâce à une modélisation appropriée, il est possible de réduire le nombre total de capteurs de température requis, sans compromettre la performance du BMS dans son ensemble.

### 1.4.2 Protection des cellules

Le bloc de protection de la cellule fait intervenir des circuits de surveillance analogiques et numériques qui sont chargés de garantir à tout moment que la cellule ne franchira jamais les limites spécifiées. Ces limites comprennent les seuils de tension inférieur et supérieur, les niveaux de courant de décharge/charge maximum et les températures de fonctionnement minimum et maximum qui sont autorisées pour un fonctionnement sûr. Par exemple, dans les BMS classiques, la puissance de charge de la batterie est réduite au minimum à basse température afin d'éviter le dépôt de lithium dans les cellules et donc un endommagement permanent de la batterie. Dans des travaux plus récents [46-47], les chercheurs ont développé

certaines techniques de protection des batteries, en utilisant des interrupteurs à transistor pour interrompre le chemin du courant vers les cellules défectueuses d'un module. Cependant, en raison des pertes de conduction à l'état passant dans les dispositifs à semi-conducteurs et de la difficulté à prévoir leur comportement dans des conditions de défaut, cette méthode de protection peut ne pas être applicable à des applications critiques de sécurité à grande échelle.

### 1.4.3 Équilibrage des cellules

L'équilibrage des cellules, est une partie opérationnelle importante de tout système de gestion des batteries. Au cours de la durée de vie d'une batterie, les tensions et les capacités des cellules connectées en série peuvent varier à des rythmes différents, ce qui peut limiter considérablement la performance globale de la batterie. Par conséquent, en équilibrant la charge des cellules dans les modules, il est possible d'améliorer la distribution énergétique et la puissance de la batterie (figure 1.10).

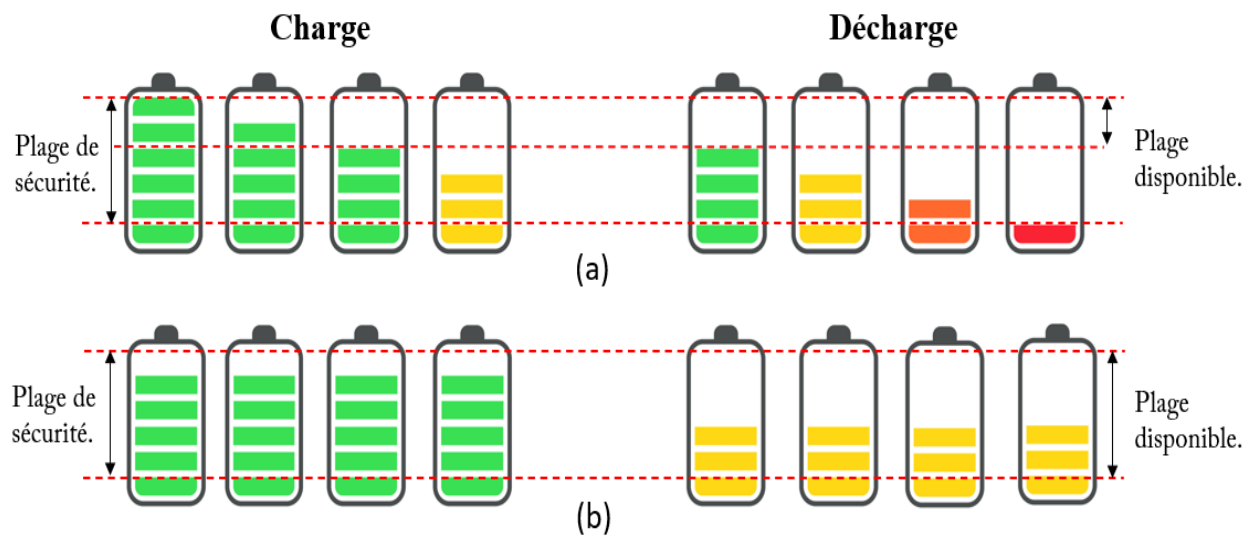


Figure 1.10 : Limites opérationnelles des cellules : pas d'équilibrage (a) équilibrage correct (b)

Dans la littérature, les techniques d'équilibrage des cellules sont généralement classées en deux grandes catégories : les méthodes passives et les méthodes actives. Les méthodes passives [48-49] utilisent des composants électriques tels que des résistances afin de limiter les tensions des cellules qui ont des capacités plus élevées en évacuant l'énergie supplémentaire sous forme de chaleur. Bien que simples, ces méthodes souffrent d'un manque d'efficacité important, ce qui en fait une approche peu attrayante pour les applications à grande échelle. En revanche, les méthodes actives [50-51] peuvent atteindre des rendements énergétiques bien plus élevés en transférant l'énergie des cellules de plus grande capacité vers ceux ayant une faible capacité. Comme le montre la figure 1.11, cela est généralement obtenu en utilisant des convertisseurs DC-DC. Par conséquent, les méthodes actives nécessitent des algorithmes de contrôle complexes et des interfaces électroniques supplémentaires, ce qui peut être coûteux.

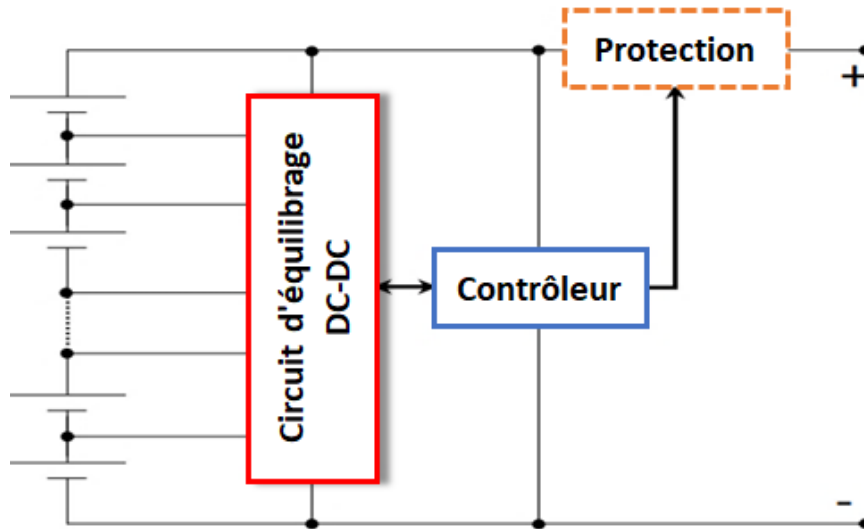



Figure 1.11 : Schéma de principe de l'équilibrage actives des cellules

### 1.4.4 Gestion thermique

Une gestion thermique adéquate est une exigence pour assurer un fonctionnement optimal des batteries [53]. En outre, comme le montre la figure 1.12 une distribution thermique inégale dans le bloc de batteries peut accentuer de plus l'équilibre de la charge dans les cellules, diminuant ainsi les performances de la batterie. Par conséquent, en fonction de la géométrie des cellules et des conditions d'application, le bloc de batterie est souvent équipé d'un système de gestion thermique active ou passive.

Les systèmes actifs sont généralement réalisés en utilisant des ventilateurs ou des pompes pour faire circuler un liquide de refroidissement autour des modules afin d'évacuer la chaleur de la batterie. En revanche, les systèmes de refroidissement passifs exploitent les propriétés physiques de certains fluides de refroidissement implantés entre des cellules adjacentes d'un même bloc pour absorber la chaleur générée pendant le fonctionnement. On peut également citer un refroidisseur thermoélectrique récemment mis au point, basé sur l'effet Peltier [54], et un système de gestion thermique flexible à base d'hydrogène [55].



(a)




Figure 1.12 : Distribution de la chaleur dans un véhicule (a) [52], répartition inégale de la chaleur sur les surfaces cylindriques adjacentes des cellules dans un module (b)

### 1.4.5 Gestion de l'énergie.

Dans la plupart des applications pratiques telles que les véhicules électriques et véhicules hybrides rechargeables ou le stockage en réseau, afin de pouvoir répondre rapidement aux demandes d'énergie en régime transitoire rapide, des systèmes de stockage d'énergie sont adoptés (SSE) [56]. Ces systèmes sont généralement composés de batteries à haute densité d'énergie pour les demandes d'énergie à long terme, et d'ultra-condensateurs (supercondensateurs) à haute densité d'énergie pour les demandes d'énergie transitoire à court terme. La figure 1.13 décrit le fonctionnement d'un SSE type à batterie/supercondensateur. Ces systèmes nécessitent un système de gestion d'énergie approprié qui peut prendre en charge l'équilibrage de la charge entre plusieurs batteries et autres dispositifs de stockage de l'énergie.

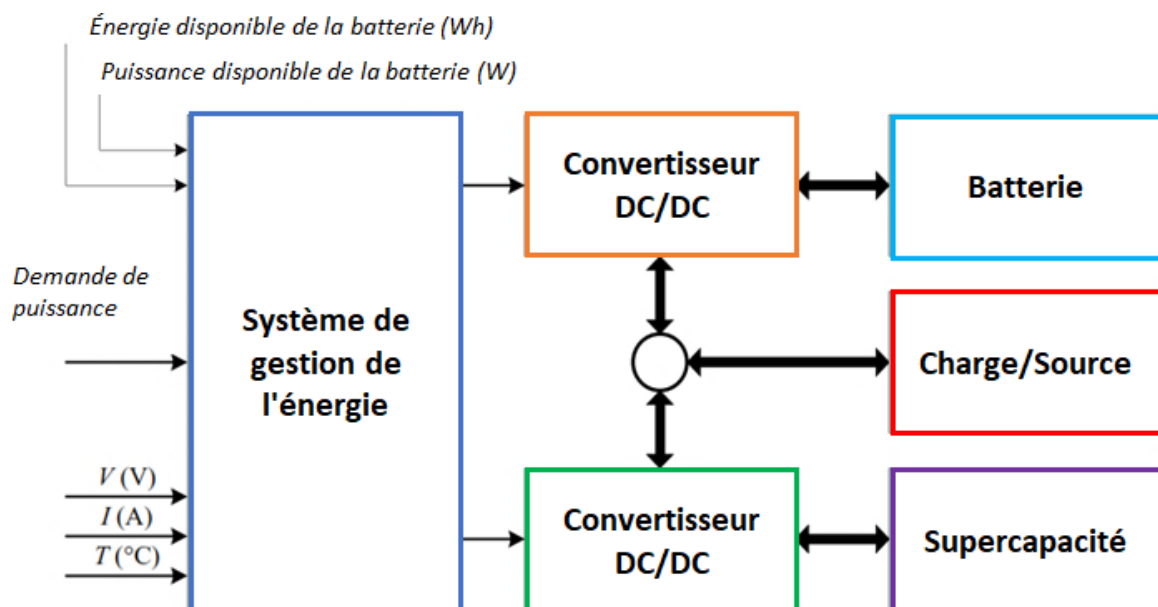


Figure 1.13 : Structure général de l'unité de gestion de l'énergie

On trouve plusieurs stratégies de gestion de l'énergie et/ou de la puissance pour les batteries [57]. La plupart de ces stratégies sont basées sur les prévisions actuelles et futures des états des batteries (SOC, SOP et SOH) fournies par le système de surveillance des batteries, afin de calculer la différence entre l'énergie demandée et l'énergie disponible. Par la suite, si la

demande de puissance dépasse les capacités de la batterie à un moment donné, le système de gestion de l'énergie agira immédiatement pour limiter la puissance de sortie de la batterie par le biais de l'unité de conversion. Cette opération est nécessaire pour une utilisation optimale des dispositifs de la batterie, sans les endommager gravement.

### 1.4.6 Surveillance de l'état des batteries

Pour un algorithme de gestion d'énergie efficace et robuste, il est nécessaire d'identifier en ligne les différents états de la batterie. À cette fin, des algorithmes de surveillance des états de la batterie (à savoir SOC, SOP et SOH) sont développés pour fournir aux autres unités décisionnelles une estimation raisonnable de ces états. Un défi fréquent dans la plupart des algorithmes de surveillance de l'état des batteries est la variation des caractéristiques de la batterie dans le temps, y compris les paramètres de capacité et d'impédance, en raison de la variation des conditions de fonctionnement et du vieillissement de la batterie [58]. Par conséquent, l'algorithme de surveillance de la batterie intégré doit être capable de corriger de manière adaptative ces variations pour obtenir des estimations précises et fiables de l'état de la batterie.

La structure globale d'un système de surveillance de l'état de la batterie est présentée à la figure 1.14. Dans la plupart des algorithmes de surveillance des batteries, une modélisation dynamique du système de batterie est souvent utilisée pour faciliter l'estimation en temps réel de l'état de la batterie (SOC, SOP et SOH). À chaque étape, l'algorithme tente de faire une estimation des paramètres d'impédance de la batterie, y compris la résistance en série et sa capacité en Ah.

Par la suite, en utilisant le modèle dynamique, une prédiction pour l'OCV (tension de circuit ouvert) de la batterie est effectuée, qui est ensuite appliquée soit à une table de consultation, soit à une fonction empirique prédéfinie pour estimer le SOC en temps réel. Par conséquent, ces informations sont traitées dans des algorithmes responsables de l'estimation des SOP, des SOF et des SOH, afin de réaliser un système de surveillance global de la batterie.

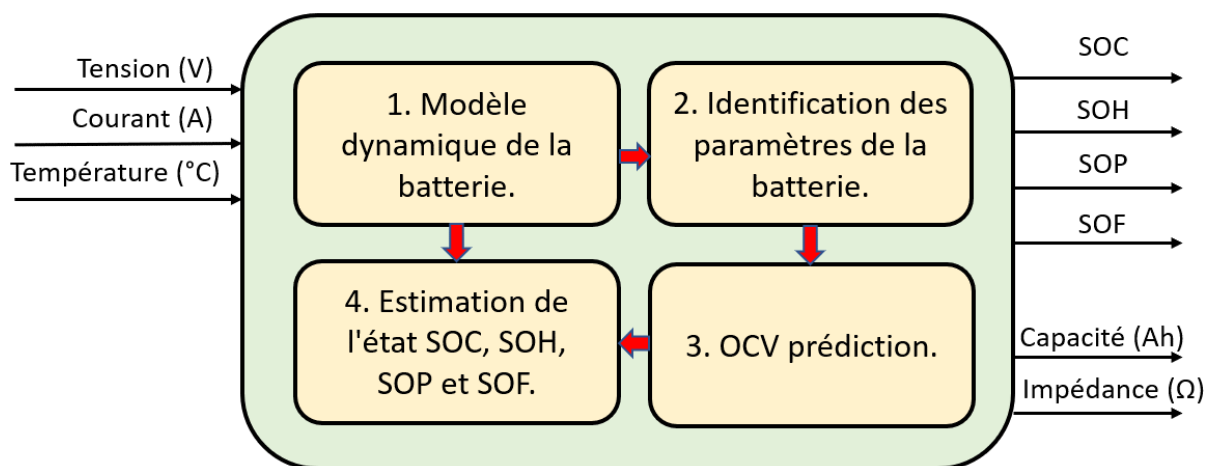


Figure 1.14 : Aperçu des tâches fondamentales effectuées par un système de surveillance des batteries

### 1.5 Équilibrage des cellules

Comme décrit précédemment, l'équilibrage des cellules est très important pour un fonctionnement sûr et fiable du BMS. L'équilibrage des cellules est une méthode permettant

d'égaliser les tensions et l'état de charge entre les batteries lorsqu'elles sont à pleine charge. Même deux cellules du même modèle et du même fabricant ne sont pas identiques. Il y a toujours de légères différences dans le SOC, la tension, le courant, l'impédance et les caractéristiques de température, etc. Sans un système équilibré, la tension d'une cellule particulière évoluera exclusivement au fil du temps, ce qui réduira la capacité globale du pack et entraînera un dysfonctionnement de la batterie. Les topologies d'équilibrage des cellules peuvent être classées en équilibrage actif et passif.

### 1.5.1 Contrôleurs d'équilibrage cellulaire passif

Dans cette approche, les cellules ayant un surplus d'énergie sont dissipées par des résistances jusqu'à ce que leur charge soit égale à celle des cellules les plus plates du pack. La technique d'équilibrage passif des cellules est facile à exécuter, mais moins efficace et ne doit pas être utilisée pendant la décharge. L'approche d'équilibrage des cellules par résistance shunt est la plus simple et peut être divisée en résistance fixe et résistance shunt contrôlée figure 1.15. Dans la méthode de la résistance shunt fixe, le courant est continuellement dérivé et la tension est limitée en faisant varier la résistance. Dans une approche de résistance shunt contrôlée, des interrupteurs/relais contrôlés sont utilisés au lieu de décharger continuellement les cellules les plus chargées [59]. Cette configuration est plus efficace et fiable et peut être utilisée dans le système d'équilibrage des batteries des VE. Cependant, elle dissipe également de l'énergie en chaleur et nécessite un système de gestion de la chaleur.

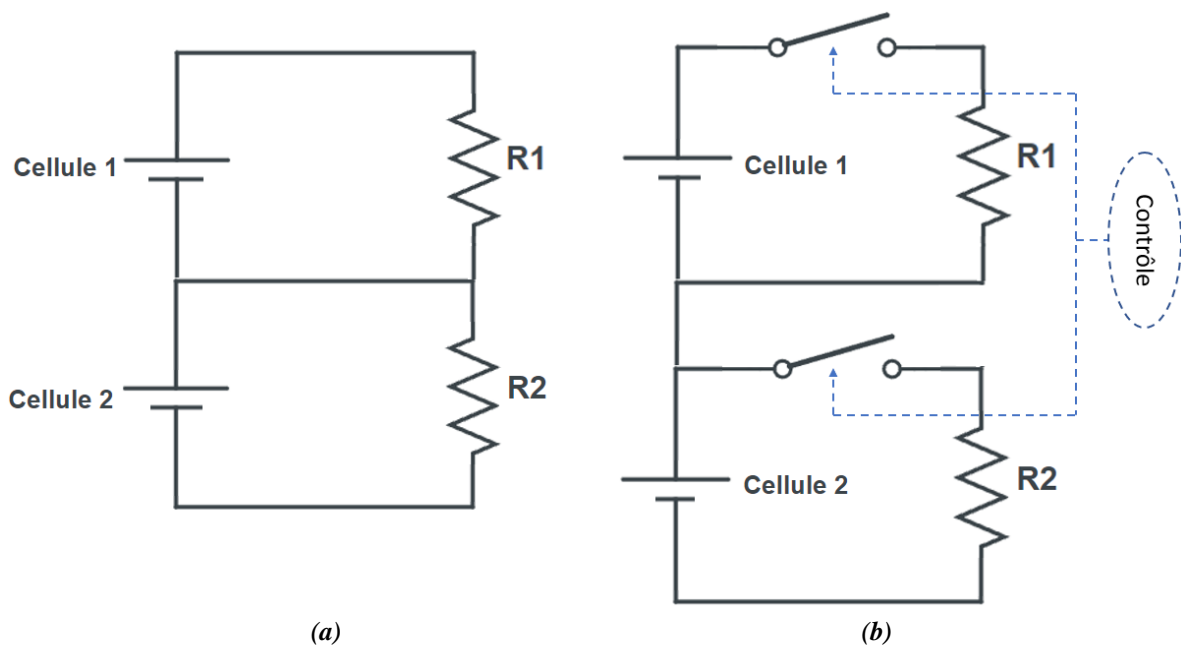


Figure 1.15 : CEC à résistance fixe (a), CEC à résistance shunt contrôlée (b)

### 1.5.2 Contrôleurs d'équilibrage des cellules actives

Les contrôleurs d'égalisation de charge actifs sont non dissipatifs et transfèrent l'énergie d'une cellule à l'autre, d'un pack à l'autre, d'un module à l'autre. La cellule la plus énergétique est autorisée à fournir l'énergie excessive à une autre cellule, un module ou un pack, de manière à

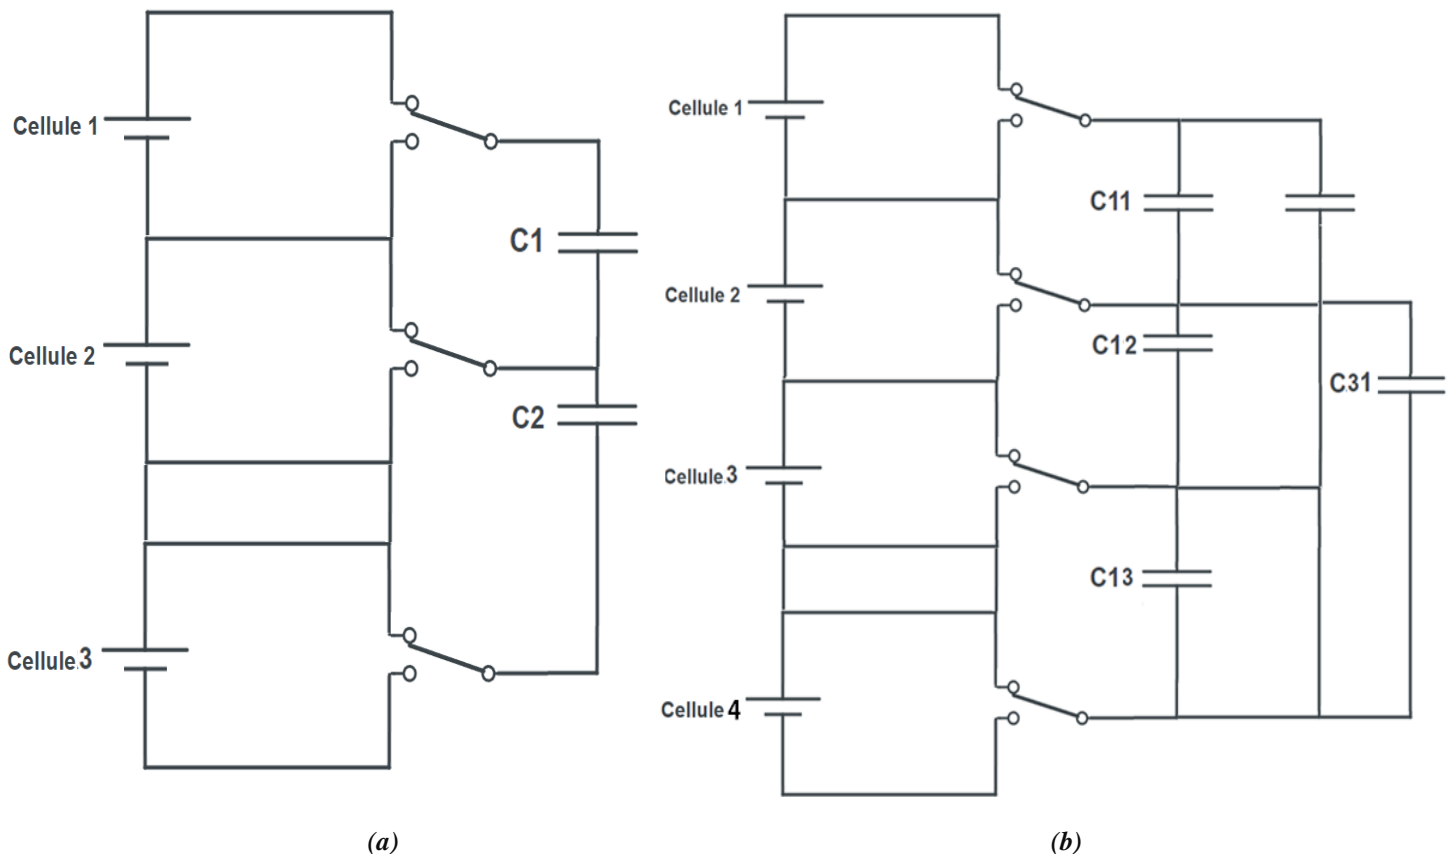
obtenir un niveau de charge ou de tension égal dans toutes les cellules de la batterie. Un certain nombre de contrôleurs actifs appliqués à l'égalisation des batteries des véhicules électriques sont basés sur des condensateurs, des inducteurs, des transformateurs et des convertisseurs de puissance.

### 1.5.2.1 Contrôleurs d'équilibrage de charge à base de condensateurs

Les contrôleurs d'égalisation de charge basés sur condensateur sont utilisés pour transférer l'énergie entre la cellule et le pack en stockant l'énergie dans un condensateur externe. Le contrôle de la commutation est effectué automatiquement en détectant les tensions des cellules sans contrôle du courant. Ces systèmes souffrent d'une énorme ondulation de courant. On peut les classer en contrôleurs à condensateur commuté à simple et à double étage.

La figure 1.16 (a) présente le CEC à condensateur unique commuté qui comporte un seul condensateur et un certain nombre de commutateurs pour égaliser les niveaux de charge des cellules [60]. Le CEC à condensateur commuté à deux niveaux est illustré dans la figure 1.16 (b). Dans cette technique, un condensateur à deux niveaux est utilisé pour réduire le temps d'égalisation à un quart de celui nécessaire dans la CEC à condensateur commuté simple [61].

Le système modulaire prend en compte le contrôle de la batterie en plusieurs modules pour l'équilibrage de la charge, comme le montre la figure 1.16 (c) [62]. Chaque module du bloc-batterie est équipé individuellement du système d'égalisation basé sur les condensateurs





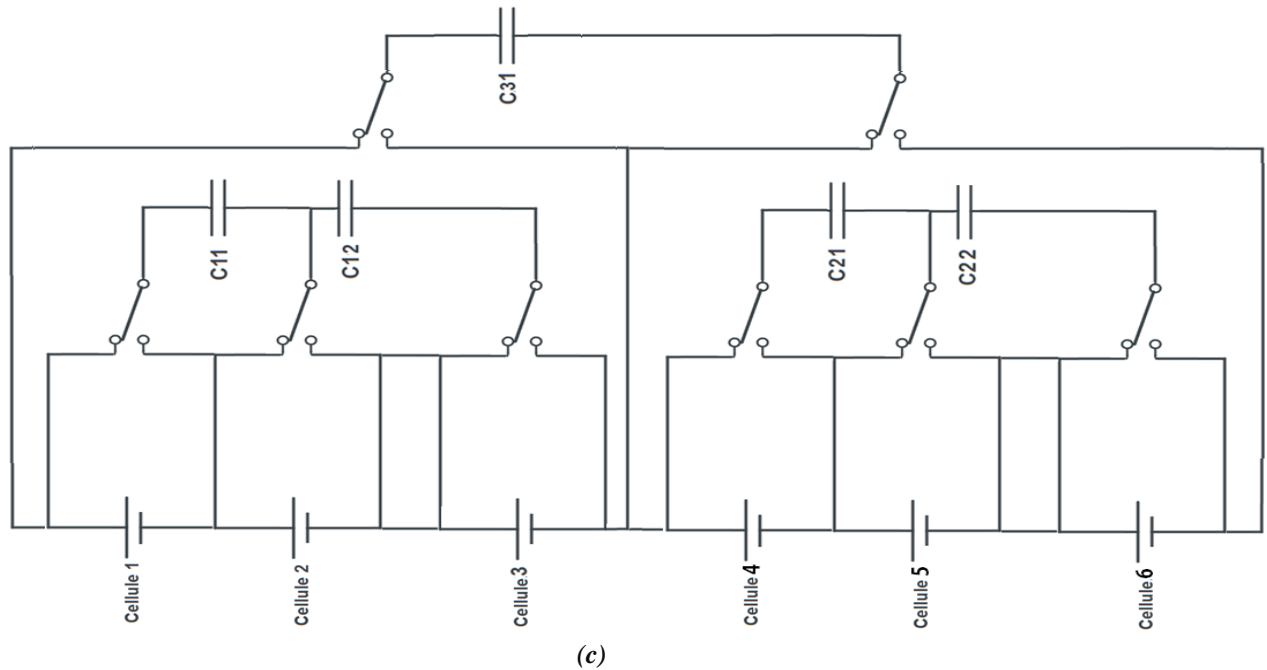


Figure 1.16 : CEC à condensateur unique commuté (a), CEC à condensateur commuté à deux niveaux (b), Système modulaire (c)

commutés et connecté au contrôleur d'égalisation maître d'un seul condensateur commuté, de sorte que l'égalisation au sein du bloc et des modules est effectuée en peu de temps et que les contraintes de tension et de courant sur les commutateurs sont faibles.

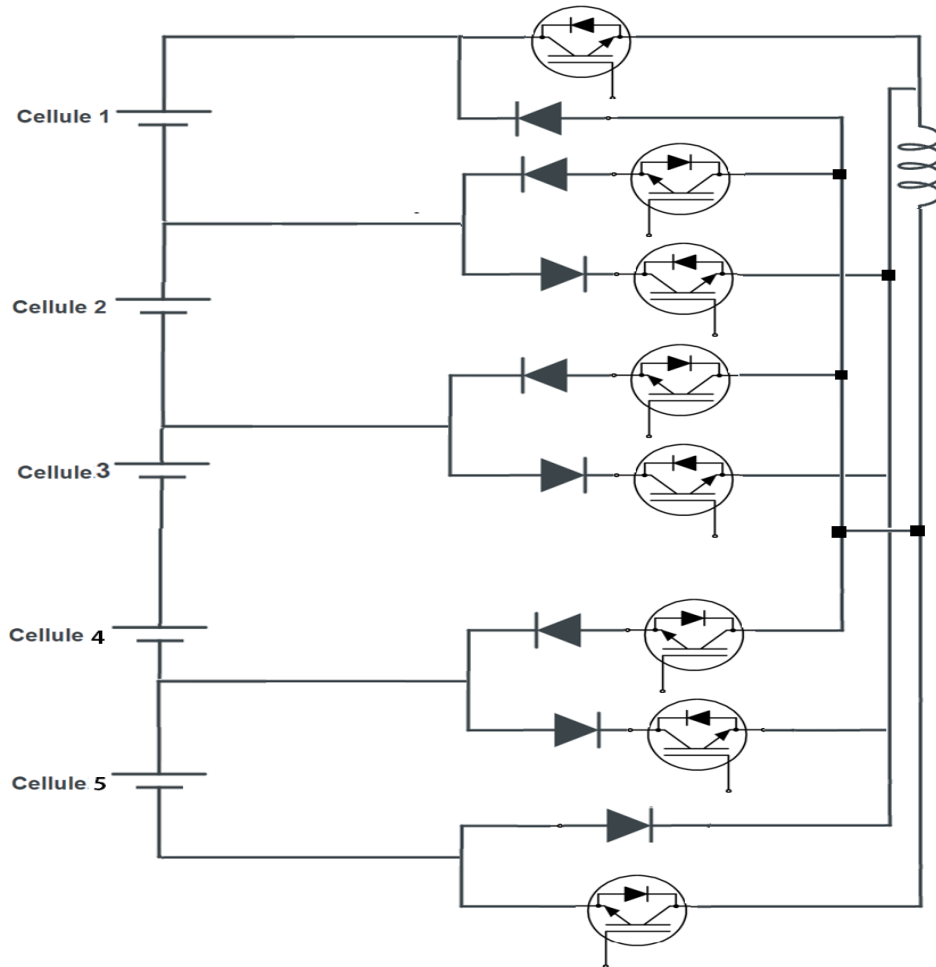
### 1.5.2.2 Contrôleurs d'égalisation à base d'inductance /transformateur

Les CEC à base d'inductance/transformateur utilisent des inductances ou des transformateurs pour transférer une énergie plus élevée d'une cellule, d'un module ou d'un pack vers le pack, le module ou une autre cellule. Ils prennent généralement moins de temps d'égalisation avec un courant d'égalisation élevé et une commutation à grande vitesse. Cependant, ils sont coûteux ; présentent quelques pertes magnétisantes ; et nécessitent des condensateurs comme filtre pour les hautes fréquences.


Le CEC à inductance unique figure 1.17 (a) utilise une inductance pour transférer l'énergie d'une cellule d'énergie supérieure à une cellule d'énergie inférieure. Ce montage est effective en termes de coût et de rapidité d'égalisation.

Le CEC basé sur une inductance couplée figure 1.17 (b) mesure les niveaux de tension des cellules de batterie adjacentes et commute la cellule de plus haute énergie en premier en envoyant un signal de modulation de largeur d'impulsion (PWM) aux commutateurs (ex : MOSFET) pour transférer l'énergie à la cellule de plus basse énergie dans l'ensemble du pack. Le temps d'égalisation est plus élevé que celui des circuits à inductance unique. Elle présente une bonne efficacité d'équilibrage ; cependant, elle présente également des pertes magnétisantes [63].





(a)



(b)

Figure 1.17 : CEC à inductance unique (a), CEC à inductance couplée (b)

Le CEC à transformateur à enroulement unique figure 1.18 : (a) permet au courant d'égalisation de passer pour transférer l'énergie du pack de cellules à la cellule d'énergie inférieure ou de la cellule supérieure au pack de cellules à travers le transformateur en contrôlant les commutateurs. Le problème de cette configuration est qu'elle est assez coûteuse.

La CEC à transformateur multi-enroulements utilise un transformateur à noyau unique avec un enroulement primaire et des enroulements multiples sur le côté secondaire pour permettre à chaque cellule de batterie d'être présente dans chaque enroulement secondaire. Il s'agit d'une CEC basée sur un transformateur partagé qui transfère l'énergie stockée du primaire à la cellule d'énergie inférieure détectée dans le secondaire du transformateur comme processus de transfert d'énergie, comme la structure flyback montrée dans la Fig. 18(b). Ce CEC est bon, cependant, il est coûteux, complexe à concevoir, et souffre de la saturation.

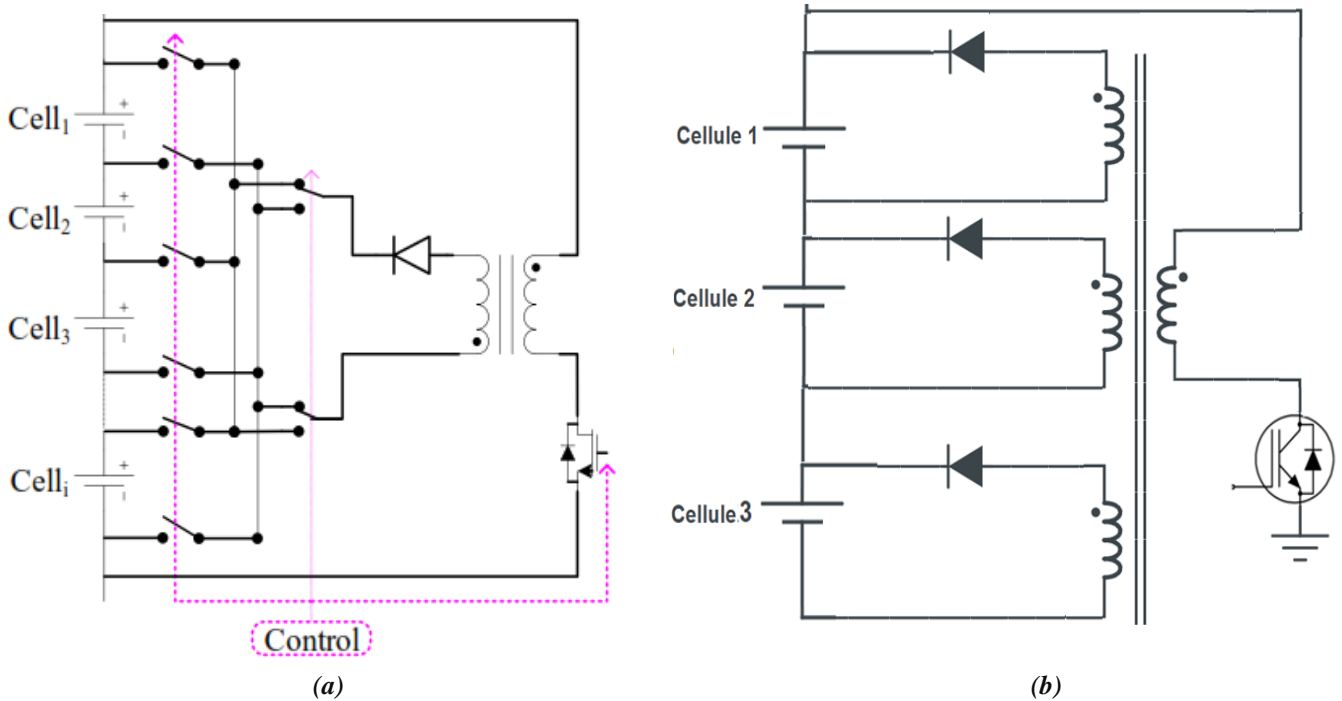


Figure 1.18 : CEC transformateur à enroulement unique (a), CEC à transformateur multi-enroulements (b)

### 1.5.2.3 Contrôleurs d'égalisation de charge à base de convertisseur

Les convertisseurs cûk, boost, buck-boost, ramp, à pont complet, résonant et flyback sont les catégories courantes pour les applications d'égalisation de charge. Ces types de CEC ont des caractéristiques efficaces avec un contrôle complet du processus d'égalisation en particulier dans les applications d'égalisation de charge des batteries des véhicules électriques ; cependant, la conception et la mise en œuvre sont assez coûteuses et complexes. Le contrôle de la commutation est réalisé avec un signal PWM au moyen d'un algorithme de contrôle intelligent.

Le CEC à base du convertisseur Cûk est utilisé pour le flux de charge bidirectionnel avec un contrôleur d'égalisation individuel ayant deux commutateurs, deux inductances et un condensateur qui égalise chaque paire de cellules voisines. La figure 1.19 montre la configuration du convertisseur Cûk. Ce processus d'égalisation prend plus de temps pour l'égalisation de charge d'un grand pack de batteries [64].

La figure 1.20 présente le convertisseur Boost CEC qui est utilisé pour l'équilibrage de la charge de chaque cellule en stockant l'énergie excessive dans une inductance parallèle, puis transfère l'énergie aux autres cellules en contrôlant le commutateur MOSFET. En outre, l'énergie peut être récupérée par le chemin parallèle avec un condensateur, comme le montre la figure 1.20 (b), pour distribuer l'énergie de façon efficace avec un temps d'équitation court. Dans ce contrôleur, les valeurs de tension des cellules de la batterie sont surveillées, puis le commutateur

correspondant à la cellule est contrôlé en conséquence pour utiliser le flux d'énergie de la cellule vers le pack au moyen d'un algorithme de contrôle intelligent.

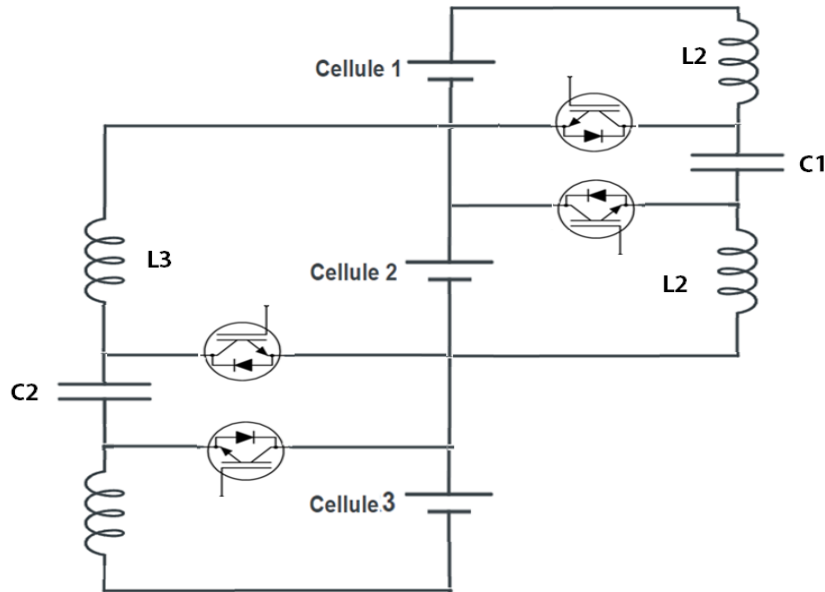
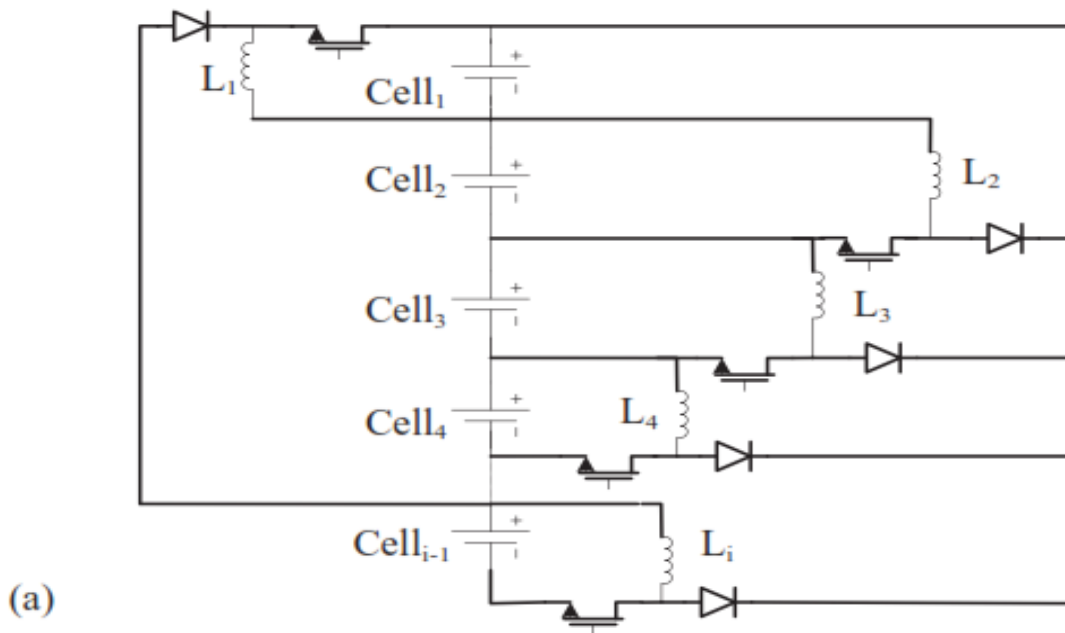


Figure 1.19 : CEC à base du convertisseur Cûk

Contrairement au convertisseur Boost, le fonctionnement du convertisseur Buck-Boost CEC Fig 1.21 est exécuté pour évacuer l'énergie de la cellule d'énergie supérieure vers la cellule adjacente par une commande de commutation via la détection et le calcul de la différence de tension de deux cellules de batterie adjacentes. Les CEC à convertisseur Buck/Boost sont applicables dans la conception modulaire hautement efficace du contrôleur d'égalisation bidirectionnel, cependant, ils nécessitent une commande intelligente pour sélectionner et commuter les cellules pour la commutation de l'énergie ; ils sont également coûteux et complexes.



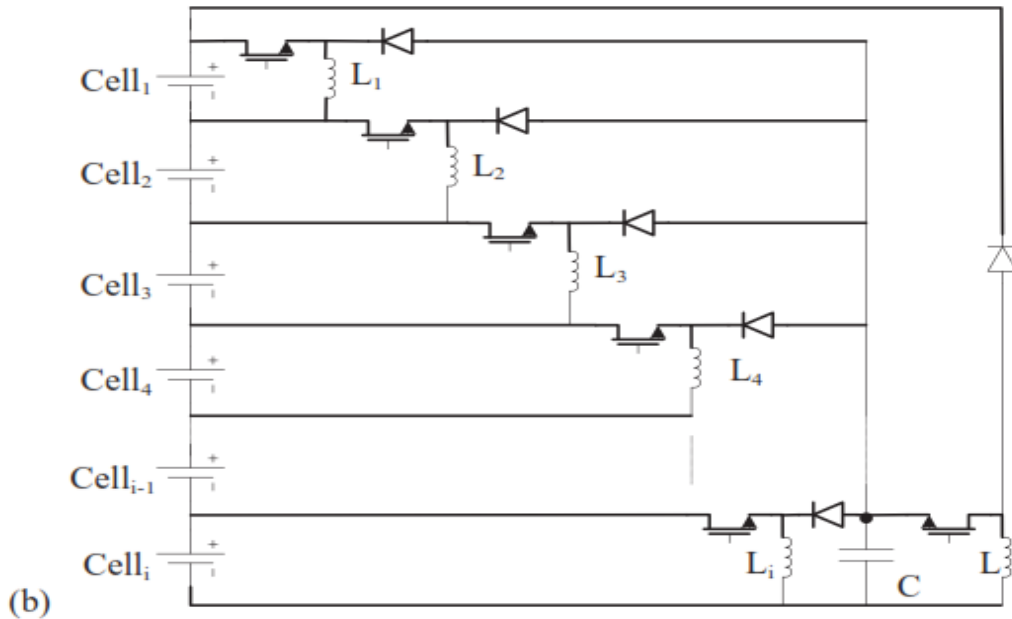


Figure 1.20 : CEC à base du convertisseur Boost

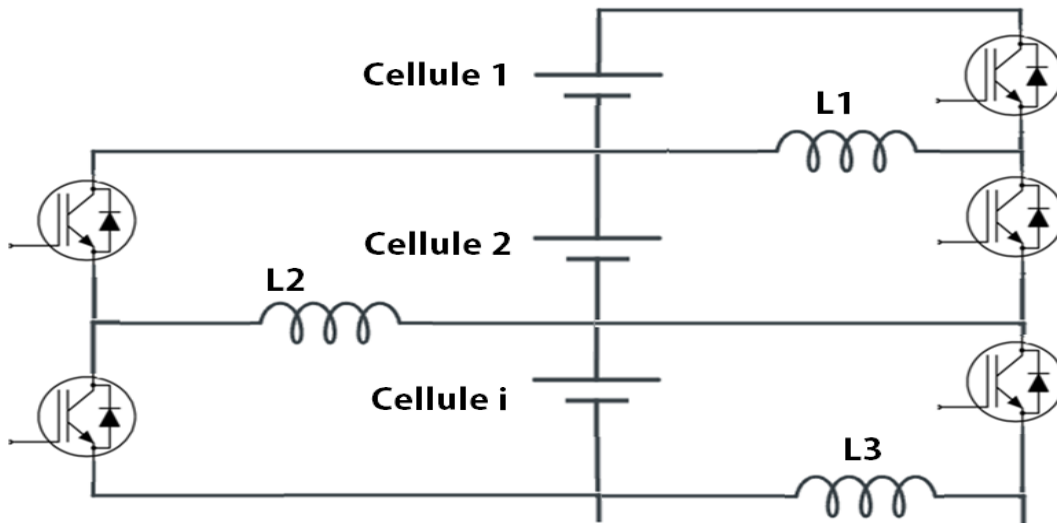


Figure 1.21 : CEC à base du convertisseur Buck- Boost

Le CEC à base du convertisseur Ramp est composé d'un transformateur à enroulements multiples (figure 1.22), où deux éléments de batterie adjacents sont connectés par paire à un enroulement secondaire du transformateur. Le fonctionnement du CEC à rampe est tel que les éléments impairs sont considérés comme fournissant le courant pour la charge du condensateur dans la première moitié du cycle et dans la seconde moitié du cycle, les éléments pairs sont autorisés à être rechargés par le condensateur ou vice versa selon la direction du courant dans le côté primaire du transformateur [65]. Ce CEC est plus pratique en termes de coût (nombre réduit d'enroulements), cependant, la conception est assez complexe.

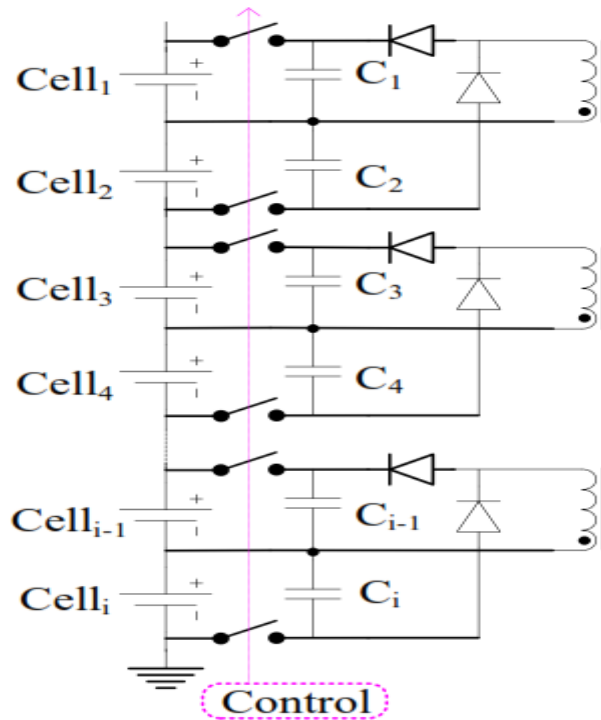


Figure 1.22 : CEC à base du convertisseur ramp

Le CEC en pont complet se compose d'un réseau de ponts de commutateurs en parallèle avec le module de cellule qui est utilisé pour l'égalisation de charge bidirectionnelle dans la conception modulaire (figure 1.23) [66]. Ce circuit peut être appliqué dans l'égalisation de la charge de la batterie du véhicule électrique comme un convertisseur DC/DC. Les opérations de contrôle des commutateurs et de sélection des cellules sont exécutées par un algorithme de contrôle intelligent automatisé. Cette configuration est plus efficace dans la batterie modulaire et dans les applications de haute puissance en particulier dans les VE, cependant, le coût de conception est élevé ; et nécessite un contrôle sophistiqué.

Le CEC à convertisseur résonant figure 1.24, utilise un circuit résonant pour commander les commutateurs et transférer l'énergie de la cellule d'énergie supérieure à la cellule d'énergie inférieure [67]. Les CEC à convertisseur résonant peuvent être des CEC à convertisseur quasi-résonant à tension nulle ou à courant nul, selon les fonctions de commutation. Le circuit résonant fonctionne avec la différence de tension entre deux cellules adjacentes. Le circuit résonant réservoir est formé par  $C_r$  et  $L_r$  pour fonctionner en commutation à courant nul pour l'égalisation bidirectionnelle de la charge de la batterie. L'inductance  $L$  est utilisée pour stocker l'énergie à échanger. Le convertisseur résonnant CEC a une haute efficacité d'égalisation due à la diminution des pertes de commutation, cependant, leur coût de conception et leur difficulté de mise en œuvre sont élevés.

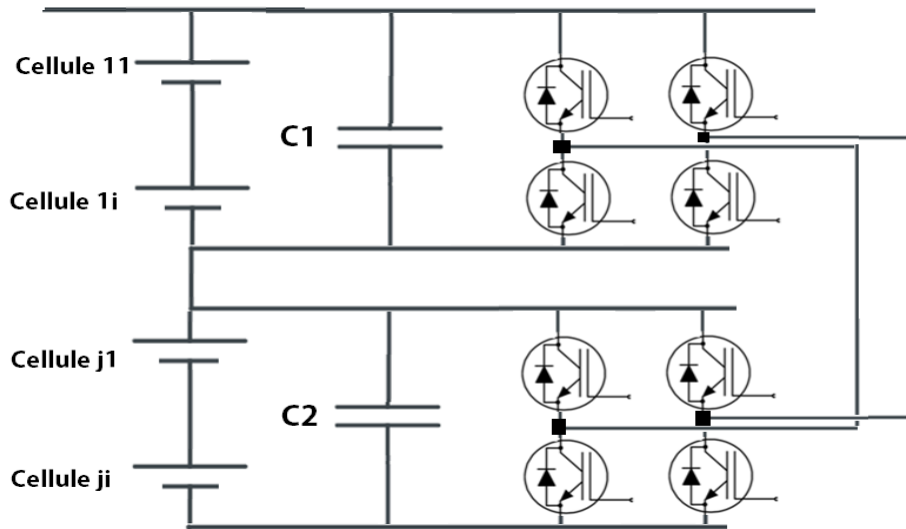


Figure 1.23 : CEC à base du pont complet




Figure 1.24 : CEC résonant

Les CEC à convertisseur flyback sont fiables pour une égalisation efficace de la charge des batteries grâce à leur structure d'isolation. Il utilise un transformateur qui transfère la puissance au circuit secondaire au niveau OFF de la commutation. La configuration peut être de CEC à convertisseur flyback unidirectionnel et bidirectionnel. Le CEC à convertisseur flyback unidirectionnel, figure 1.25 (a), permet au courant d'égalisation de transférer l'énergie soit de la cellule énergétique supérieure vers le module ou le pack, soit du pack ou du module vers la cellule énergétique inférieure. La conception et la mise en œuvre sont bonnes, mais il faut un contrôle intelligent en boucle fermée. Les pertes magnétiques ici sont faibles.

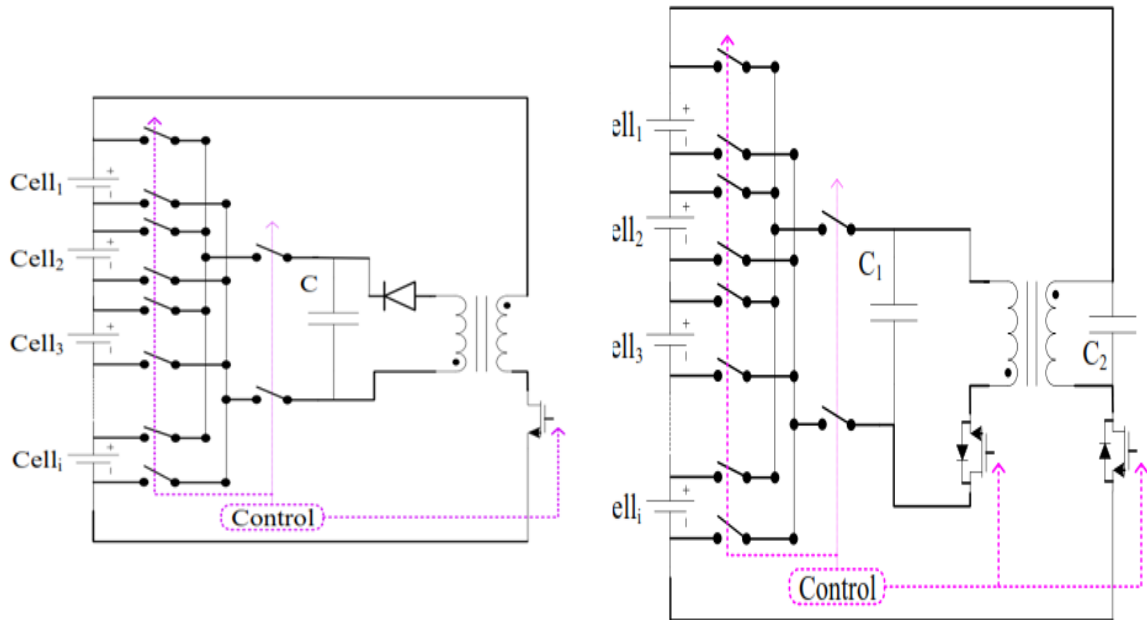


Figure 1.25 : CEC flyback unidirectionnel (a) et bidirectionnel (b)

Le CEC à convertisseur flyback bidirectionnel figure 1.25 (b), est le plus fiable dans le transfert d'énergie. Ces circuits sont développés en utilisant un transformateur à enroulement unique, un transformateur à enroulements multiples pour un contrôle centralisé, modulaire, individuel ou distribué de l'égalisation de la charge de la batterie [68]. Le mode de commutation à conduction discontinue peut être utilisé pour un équilibrage efficace avec des pertes et des contraintes réduites. Cependant, la conception du transformateur et du schéma de contrôle sont complexes.

Un autre CEC appelé CEC shunt (figure 1.26) où la cellule chargée au maximum est contournée avec un processus de shunt complet par les commutateurs série-parallèle. Ce montage est généralement utilisé dans les systèmes d'alimentation sans coupure coûteux pour remplacer les chargeurs parallèles individuels par un chargeur de masse avec convertisseur à courant contrôlé [69]. Dans ce système, la tension du bus varie en fonction du nombre de cellules de charge.

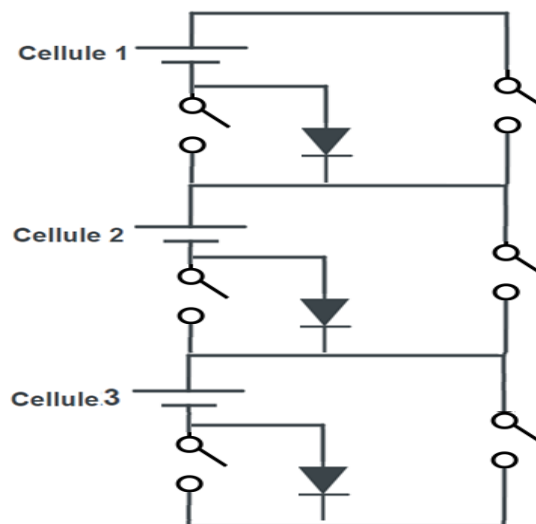


Figure 1.26 : CEC shunt

### 1.5.3 Conclusion sur les contrôleurs d'équilibrage des cellules

Le tableau 1.1 résume les avantages et les inconvénients des diverses topologies d'équilibrage des cellules. L'objectif principal est d'assurer un équilibrage dans un temps rapide avec des pertes faibles tout en étant simple et moins chères.

**Tableau 1.1 : Topologies d'équilibrage des cellules**

Topologie	Avantages	Désavantages	Temps/Difficulté /Pertes /Coût
Résistance Shunt fixe (Passive)	<ul style="list-style-type: none"> <li>✓ Implémentation simple</li> <li>✓ Encombrement faible</li> <li>✓ Coût faible</li> </ul>	<ul style="list-style-type: none"> <li>• Réponse lente</li> <li>• Pertes joules</li> <li>• Gestion thermique est nécessaire</li> <li>• Efficacité médiocre</li> </ul>	Lent/Simple/Très élevée/Très faible
Résistance Shunt contrôlée (Passive)	<ul style="list-style-type: none"> <li>✓ Implémentation simple</li> <li>✓ Encombrement faible</li> <li>✓ Coût faible</li> </ul>	<ul style="list-style-type: none"> <li>• Réponse lente</li> <li>• Pertes joules</li> <li>• Gestion thermique est nécessaire</li> <li>• Efficacité médiocre</li> </ul>	Lent/Simple/ élevée/Très faible
CEC à condensateur unique (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Contrôle simple</li> <li>✓ Haute efficacité</li> </ul>	<ul style="list-style-type: none"> <li>• Faible vitesse d'égalisation</li> </ul>	Faible/Moyenne/ Négligeable/Moyen
CEC à condensateur contrôlé (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Temps de réponse Rapide</li> <li>✓ Grande efficacité</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe</li> <li>• Difficulté de conception moyenne</li> </ul>	Moyen/Moyenne/ Négligeable/Moyen
Système modulaire condensateur (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Pertes négligeables</li> <li>✓ Grande efficacité</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle Complexe</li> <li>• Nombres importants des interrupteurs</li> <li>• Temps d'égalisation lent</li> </ul>	Moyen/Complexe/ Négligeable/Moyen
Inductance unique (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Pertes négligeables</li> <li>✓ Grande efficacité</li> <li>✓ Temps de réponse rapide</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe</li> <li>• Coût moyen</li> <li>• Nécessité d'un grand nombre de commutateurs et de diodes.</li> </ul>	Bon/Moyenne/ Négligeable/Moyen
CEC à inductance couplée (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Pertes négligeables</li> <li>✓ Grande efficacité</li> <li>✓ Temps de réponse rapide</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe</li> <li>• Coût moyen</li> <li>• Ajout d'un filtre est nécessaire</li> </ul>	Très bon/Moyenne/ Négligeable/Moyen
CEC à transformateur unique (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Pertes négligeables</li> <li>✓ Temps de réponse moyen</li> </ul>	<ul style="list-style-type: none"> <li>• Mode de charge uniquement</li> <li>• Complexité d'exécution et de contrôle</li> <li>• Coût Moyen</li> <li>• Problème de magnétisation.</li> </ul>	Moyen/Complexe / Négligeable/Moyen
CEC à transformateur multiple	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Pertes négligeables</li> <li>✓ Temps de réponse moyen</li> </ul>	<ul style="list-style-type: none"> <li>• Mode de charge uniquement</li> <li>• Complexité d'exécution et de contrôle</li> <li>• Coûteux</li> <li>• Encombrant</li> </ul>	Moyen/Complexe/ Négligeable/élevé
CEC à base du convertisseur Boost (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Vitesse d'égalisation très élevée</li> <li>✓ Exécution simple</li> <li>✓ Perte négligeable</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe et intelligent requis</li> <li>• Coûteux</li> </ul>	Très élevé /Complexe / Négligeable/Moyen



CEC à base du convertisseur Buck-Boost (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Vitesse d'égalisation très élevée</li> <li>✓ Exécution simple</li> <li>✓ Perte négligeable</li> <li>✓ Excellente efficacité.</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe et intelligent requis</li> <li>• Coûteux</li> <li>• Nombre important d'interrupteurs est nécessaire</li> </ul>	Très élevé /Complexe / Négligeable/Moyen
CEC à base du convertisseur Cûk (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Haute efficacité</li> <li>✓ Vitesse d'égalisation</li> <li>✓ Faible perte</li> </ul>	<ul style="list-style-type: none"> <li>• Contrôle complexe et intelligent requis</li> <li>• Coûteux</li> <li>• Nécessite d'énormes commutateurs</li> </ul>	Élevé/Complexe /Négligeable /Moyen
CEC à ramp (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Faible perte</li> <li>✓ Commutation douce</li> <li>✓ Vitesse et efficacité moyennes</li> </ul>	<ul style="list-style-type: none"> <li>• Complexités d'exécution et de contrôle</li> <li>• Coûteux</li> <li>• Encombrant</li> </ul>	Moyen/Complexe /Négligeable /élevé
CEC à base e pont complet (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Vitesse d'égalisation rapide</li> <li>✓ Perte négligeable</li> <li>✓ Excellente efficacité.</li> </ul>	<ul style="list-style-type: none"> <li>• Complexités d'exécution et de contrôle</li> <li>• Coûteux</li> <li>• Encombrant</li> </ul>	Très élevé /Moyen /Négligeable /Moyen
CEC résonant (Active)	<ul style="list-style-type: none"> <li>✓ Bidirectionnel</li> <li>✓ Haut rendement</li> <li>✓ Faible perte de puissance</li> <li>✓ Vitesse moyenne.</li> </ul>	<ul style="list-style-type: none"> <li>• Complexités d'exécution et de contrôle</li> <li>• Coûteux</li> <li>• Encombrant</li> </ul>	Moyen/Très Complexe /Négligeable /élevé

## 1.6 Revue des algorithmes d'estimation de l'état de charge SOC

Cette partie décrit les diverses approches utilisées pour l'estimation de l'état de charge SOC des batteries. Ces dernières peuvent être résumées en deux grandes catégories, à savoir les méthodes directes et indirectes. Les méthodes directes comprennent la méthode de comptage coulomb, facilement applicable, et les méthodes OCV. Alors que la première méthode souffre du bruit des capteurs et des décalages induits par le processus d'initialisation, la deuxième nécessite une très longue période pour établir une mesure précise de l'OCV de la batterie. Par conséquent, ces deux méthodes sont souvent combinées en pratique pour former la base des techniques d'estimation indirecte de l'état de charge basées sur modèle.

### 1.6.1 Méthode de comptage coulomb

La technique de comptage coulomb est une solution facile à mettre en œuvre pour l'estimation du SOC, en donnant une valeur initiale SOC ( $t_0$ ), l'intégrale temporelle du courant aux bornes peut être considérée comme un indicateur de la charge disponible de la batterie.

$$SOC(t_2) = SOC(t_1) + \frac{1}{Q} \int_{t_1}^{t_2} \eta i(t) dt \quad (1.41)$$

Q est la capacité totale de la batterie, SOC est l'état de charge,  $\eta$  est le coefficient de coulomb, le courant  $i(t)$  étant considéré comme négatif pendant la charge de la batterie et positif pendant la décharge. En raison de la nature en boucle ouverte de cette méthode (1.41), le SOC prévu est

sujet à des erreurs de décalage et de dérive du capteur. De plus, en utilisant la capacité nominale comme dénominateur, le SOC résultant peut être sous-estimé ou surestimé.

### 1.6.2 Estimation basée sur l'OCV

L'état de charge peut être estimé sur la base d'une relation prédéfinie avec la tension de circuit ouvert (OCV), comme illustre la figure 1.27. Toutefois, cette technique nécessite une longue période de relaxation (sans charge) pour établir une mesure exacte de l'OCV, ce qui la rend peu pratique pour les applications en ligne. Il est également confirmé que pour les piles dont les courbes de OCV sont plates (par exemple, lithium-fer-phosphate), les techniques basées sur l'OCV peuvent produire des estimations instables de l'état de charge. Cela donne lieu à des estimateurs basés sur des modèles plus avancés. Ces méthodes utilisent souvent une représentation modélisée de la dynamique de la batterie dont les paramètres peuvent être utilisés comme de bons indicateurs pour différents états de la batterie, y compris le SOC et le SOH. Dans ces techniques, les avantages du comptage coulomb sont combinés avec une méthode basée sur l'OCV pour réaliser une approche simple, mais efficace pour l'estimation du SOC de diverses technologies de batteries, y compris le lithium-ion.




Figure 1.27 : Relation OCV-SOC pour une batterie lithium-ion

La relaxation de la batterie est principalement dominée par les processus électrochimiques et thermodynamiques internes qui se produisent à l'intérieur de celle-ci. Selon les conditions de la batterie, la relaxation peut prendre jusqu'à plusieurs heures, en particulier lorsque la batterie est exposée à des niveaux de courant de charge/décharge élevés et lorsqu'elle fonctionne à basse température.

Il existe plusieurs méthodes proposées dans la littérature pour estimer l'OCV en ne considérant que la partie initiale de la courbe de relaxation de l'OCV après une déconnexion de la charge. Dans [70], les auteurs ont utilisé une échelle semi-logarithmique pour tracer la courbe de relaxation de l'OCV en fonction du temps. Ensuite, en considérant deux asymptotes, l'OCV est estimée en fonction de  $\log(t)$ . Les paramètres du modèle sont trouvés à l'aide d'expériences en laboratoire sur des batteries neuves. Le principal inconvénient de cette méthode est qu'au fur et à mesure que la batterie vieillit, les paramètres utilisés pour modéliser la trajectoire de relaxation de la tension deviennent de moins en moins fiables.

Alternativement, des techniques adaptatives sont développées pour tenir compte des variations des paramètres du modèle avec le vieillissement de la batterie. L'hypothèse est d'utiliser les premières minutes de relaxation de la OCV après une déconnexion de la charge pour déterminer les paramètres du modèle de OCV ; ainsi, la FEM de la batterie peut être obtenue et utilisée pour une estimation précise du SOC. Par exemple, dans [71], les auteurs ont proposé une fonction exponentielle pour exprimer la FEM de la batterie en fonction de l'OCV :

$$V_{oc}(t) = FEM - (FEM - V_{oc}(t)) \cdot e^{-t/\tau} \quad (1.42)$$

Pour améliorer davantage la performance de la fonction exponentielle donnée dans (1.42), les auteurs [72] ont développé un modèle empirique plus complexe pour décrire la relaxation de l'OCV dans les batteries lithium-ion. Le modèle proposé est défini comme suit :

$$V_{oc}(t) = EMF - \frac{\gamma}{t^\alpha \cdot (\log(t))^\beta} \quad (1.43)$$

Où EMF,  $\gamma$ ,  $\alpha$  et  $\beta$  sont les paramètres du modèle et sont identifiés en ligne à l'aide de la méthode des moindres carrés. La performance du modèle OCV représenté par (1.43) a été testée sur des cellules lithium-ion de 1,1Ah.

### 1.6.3 Méthodes à base de table de recherche

Les méthodes de consultation des tables utilisent des tables pour établir un lien entre les différentes caractéristiques des batteries et l'état de charge SOC. Par exemple, dans [73-74], il est proposé d'estimer l'état de charge en mesurant la tension, le courant, et la température de la batterie, et en le rapportant à une fonction prédéfinie  $SOC = f(V, I, T)$ . Bien que simples à mettre en œuvre, ces méthodes d'estimation du SOC ne sont pas adaptées aux applications de puissance dynamique. De plus, les fonctions stockées ne sont valables que pour des batteries déterminées et l'effet du vieillissement n'est pas pris en compte.

### 1.6.4 Estimation basée sur l'impédance.

Cette approche d'estimation du SOC est similaire à la méthode basée sur l'OCV, sauf que dans ce cas, la fonction OCV-SOC (tableau de correspondance) est remplacée par une relation impédance-SOC. Cependant, comme indiqué dans [75], l'impédance de la batterie est fortement influencée par le SOC, le SOH et d'autres conditions de fonctionnement telles que la température et le courant. Ainsi, les paramètres d'impédances seules ne peuvent pas fournir une estimation précise du SOC au fur et à mesure que la batterie vieillit. De plus, la sensibilité de l'impédance au SOC est beaucoup plus faible que celle à la température. Par conséquent, un système de mesures très précis de la température est nécessaire pour compenser les effets de la température sur l'impédance. En outre, en raison des variations rapides de température et de la distribution thermique inégale dans les gros blocs de batteries, il est impossible d'obtenir une grande précision avec les méthodes d'estimation de l'état de charge des batteries basées sur l'impédance.

### 1.6.5 Estimation basée sur les modèles

Ces méthodes utilisent des représentations déterministes [76-78] du système de batterie dans le but de mettre en relation les signaux aux bornes (tension, courant et température) avec le SOC de la batterie. Essentiellement, les mesures sont considérées comme des entrées de modèle pour calculer l'OCV de la batterie. Ensuite, la relation SOC-OCV est utilisée pour fournir une estimation du SOC en temps réel. Les paramètres des modèles utilisés dans les algorithmes d'estimation du SOC en ligne varient considérablement tout au long de la durée de vie de la batterie. En revanche, l'adaptation des paramètres du modèle en fonction des conditions de fonctionnement et du vieillissement de la batterie n'est pratiquée que pour des structures de modèle relativement simples.

### 1.6.6 Méthodes basées sur les observateurs

Par ailleurs, des observateurs adaptatifs peuvent être soigneusement conçus pour estimer en temps réel divers états et paramètres de la batterie. Les auteurs [79] ont examiné les non-linéarités et les incertitudes de la relation OCV-SOC afin de développer un meilleur estimateur du SOC basé sur un observateur. D'autres exemples d'estimateurs SOC basés sur des observateurs et leur utilité dans les applications de batteries lithium-ion sont présentés dans [79-83]. Ces méthodes bénéficient de la simplicité et d'un niveau de précision raisonnablement élevés. Cependant, l'adaptation des paramètres des batteries en raison de leur vieillissement reste un problème. Pour résoudre ce problème, Rahimi-Eichi et ses collaborateurs [84] ont proposé une cartographie linéaire par morceaux de la relation OCV-SOC et une méthode des moindres carrés à fenêtre mobile pour estimer le SOC, ainsi que les paramètres d'impédance de la batterie en temps réel.

### 1.6.7 Estimateurs basés sur le filtre de Kalman

Le filtre de Kalman (KF) est un ensemble récursif d'équations qui permet une identification stochastique des systèmes dynamiques [85]. Il trouve des applications dans un large éventail de disciplines, notamment la gestion de l'énergie. Le KF ordinaire est surtout utilisé avec des structures de modèles de batteries plutôt simples et linéaires. Par exemple, dans [86-87], les auteurs appliquent l'algorithme KF pour trouver l'OCV de la batterie, qui est ensuite utilisée pour estimer l'état de charge. Pour compenser les non-linéarités inhérentes aux dispositifs électrochimiques et aux modèles de batterie complexes, des extensions de l'algorithme KF ordinaire sont également utilisées.

Le filtre de Kalman étendu (EKF) est la version la plus populaire du KF non linéaire, où les états et les paramètres du modèle sont linéarisés sur la trajectoire actuelle du filtre. Parmi les exemples de surveillance des états de la batterie à l'aide de l'EKF, on peut citer [88-93]. L'EKF souffre d'imprécisions de linéarisation et que les caractéristiques stochastiques du bruit de mesure peuvent varier en fonction du vieillissement de la batterie et du capteur. Par conséquent, d'autres versions avancées de l'algorithme KF, telles que le filtre de Kalman à points sigma (SPKF), ont été introduites à des fins d'identification. Parmi les exemples de SPKF, on peut citer le KF non parfumé (UKF) et le KF par différence centrale (CDKF), dont l'applicabilité à l'estimation de l'état des batteries a été validée dans [94-99].

L'inconvénient de tous les estimateurs basés sur le filtre KF est que, pour une mise en œuvre correcte, une connaissance a priori raisonnable des paramètres du modèle et de la covariance du bruit de mesure et de processus est nécessaire. Un réglage inexact des conditions initiales du filtre peut entraîner soit une divergence, soit une convergence extrêmement lente. Pour résoudre ce problème, les chercheurs ont utilisé le filtre de Kalman adaptatif (AKF) [88], filtre de Kalman étendu adaptatif (AEKF) [100-104] ou le SPKF adaptative (ASPKF) [105] pour estimer les paramètres du modèle non linéaire et la covariance du bruit de mesure en temps réel, au détriment d'une puissance de calcul supplémentaire.

Un autre handicap associé aux estimateurs KF est que les bruits de processus et de mesure sont supposés suivre une distribution gaussienne avec une valeur moyenne de zéro. Cependant, cette hypothèse peut ne pas être valable dans la plupart des applications réelles, ce qui entraîne une exacerbation supplémentaire du comportement de convergence du filtre et de la précision globale. En conséquence, les filtres de particules (PF) et les filtres de particules non parfumées (UPF) sont utilisés dans [106-108] pour obtenir des meilleurs résultats que les KF, au prix d'une augmentation significative de la puissance de calcul et de la consommation de mémoire.

### **1.6.8 Méthodes à bases des données**

Les réseaux de neurones artificiels (ANN) [109-111], la logique floue (FL) [112-113] et les machines à vecteurs de support (SVM) [114-116] ont également trouvé une place dans les applications de gestion BMS. L'avantage de ces approches est que la connaissance a priori des paramètres de la batterie n'est plus nécessaire. Toutefois, en raison de la nécessité de disposer d'un grand ensemble de données, ces approches pour l'estimation du SOC sont souvent exclues des applications de BMS en ligne.

Dans les approches d'apprentissage machine plus récentes, le SOC estimé est utilisé comme l'une des entrées du système et la sortie, qui est la tension aux bornes, est comparée à la tension réelle de la batterie pour produire un indicateur d'erreur. Ensuite, en utilisant un observateur approprié ou l'une des variantes KF, l'estimation du SOC en boucle fermée peut être réalisée comme dans [117-118], qui peut s'adapter aux variations des paramètres de la batterie dues au vieillissement et aux conditions de fonctionnement variables ; ainsi, l'apprentissage en ligne des modèles sous-jacents devient possible. Toutefois, cela entraîne des problèmes supplémentaires tels que des besoins énormes en puissance de calcul et un suréquipement, ce qui empêche ces techniques d'être utilisées dans les applications de gestion des batteries en ligne destinées à être mises en œuvre sur des microcontrôleurs à faible coût.

### **1.6.9 Conclusion sur l'estimation de l'état de charge**

On recense dans le tableau 1.2 les avantages et les inconvénients des différentes méthodes d'estimation de l'état de charge d'une batterie Li-ion. L'objectif principal d'un estimateur d'état de charge est d'assurer à la fois une bonne robustesse ainsi qu'une précision accrue et une charge de calcul faible.

**Tableau 1.2 : Méthodes d'estimation du SOC**

Méthodes	Avantages	Désavantages	Précision /Robustesse
Comptage coulomb	<ul style="list-style-type: none"> <li>✓ Implémentation facile</li> <li>✓ Implémentation à faible coût</li> <li>✓ Adaptée au temps réel</li> </ul>	<ul style="list-style-type: none"> <li>• Accumulation d'erreurs</li> <li>• Dépendant des conditions initiales</li> <li>• Non adaptative</li> </ul>	Très bonne / Acceptable
Table de correspondance OCV	<ul style="list-style-type: none"> <li>✓ Simple à mettre en œuvre</li> <li>✓ Faible complexité</li> <li>✓ Adaptée au temps réel</li> </ul>	<ul style="list-style-type: none"> <li>• Précision faible</li> <li>• Non adaptative</li> </ul>	Faible/Bonne
Basées sur modèle	<ul style="list-style-type: none"> <li>✓ Bonne précision</li> <li>✓ Adaptée au temps réel</li> <li>✓ Adaptative</li> <li>✓</li> </ul>	<ul style="list-style-type: none"> <li>• Ne considère pas le vieillissement</li> </ul>	Bonne /Bonne
Basées observateur	<ul style="list-style-type: none"> <li>✓ Simplicité de mise en œuvre</li> <li>✓ Précision raisonnablement élevée.</li> </ul>	<ul style="list-style-type: none"> <li>• Non adaptative</li> </ul>	Bonne /Faible
Kalman filtre (EKF, SPKF, AEKF, ASPKF)	<ul style="list-style-type: none"> <li>✓ Bonne précision</li> <li>✓ Adaptée au temps réel</li> <li>✓ Adaptative</li> </ul>	<ul style="list-style-type: none"> <li>• Complexité au niveau des calculs</li> </ul>	Bonne / Bonne
À base des données (NN, KNN, FL, SVM)	<ul style="list-style-type: none"> <li>✓ Très bonne précision</li> <li>✓ Adaptative</li> <li>✓ Indépendante de la chimie</li> </ul>	<ul style="list-style-type: none"> <li>• Grande complexité algorithmique</li> <li>• Dépendant de la quantité de données d'entraînement</li> </ul>	Très bonne / Bonne

## 1.7 Revue des méthodes d'estimation de la capacité des batteries (utilisées pour l'estimation de l'état de santé SOH)

Comme nous l'avons évoqué précédemment, un système de gestion de batterie (BMS) efficace est indispensable pour assurer le bon fonctionnement de la batterie pendant sa durée de vie. L'une des tâches fondamentales d'un BMS est l'estimation de l'état de santé (SOH). Pour garantir la fiabilité et la sécurité d'une batterie, une estimation précise du SOH en temps réel est obligatoire. Le SOH est un indicateur qui reflète la capacité d'une batterie à fournir des performances spécifiques par rapport à son état initial. Bien qu'il ne soit pas défini physiquement, la résistance interne et la capacité totale sont reconnues comme des indicateurs pour décrire le SOH d'une batterie. Les méthodes d'estimation du SOH basées sur la résistance interne sont plus rapides et plus simples, mais tendent à être moins précises que les méthodes utilisant la capacité totale [119]. La connaissance de la valeur de la capacité est utilisée aussi pour calculer la capacité maximale de stockage d'énergie, et l'énergie restante dans un bloc de batteries. Lorsque la capacité totale est utilisée pour indiquer l'état de santé, le SOH est décrit comme le rapport entre la capacité totale de la cellule actuelle et sa capacité initiale ou sa capacité nominale fournie par le fabricant. La capacité totale est définie comme la charge maximale qui peut être tirée d'une cellule de batterie entièrement chargée. La capacité totale d'une batterie diminue au cours de sa durée de vie en raison du vieillissement. Le vieillissement peut être causé par une perte de stock de lithium disponible en raison d'une utilisation prolongée [120], et par le développement de la couche d'interphase d'électrolyte solide (SEI) pendant les premiers cycles [121-122]. Il est donc important de pouvoir prévoir et surveiller ces variations, ce qui peut aider à prévenir les défaillances dans les applications électriques dont la sécurité est

plus critique. Dans la littérature, on trouve plusieurs techniques pour évaluer la capacité totale d'une batterie. En général, ces techniques peuvent être regroupées en cinq catégories (figure 1.28).

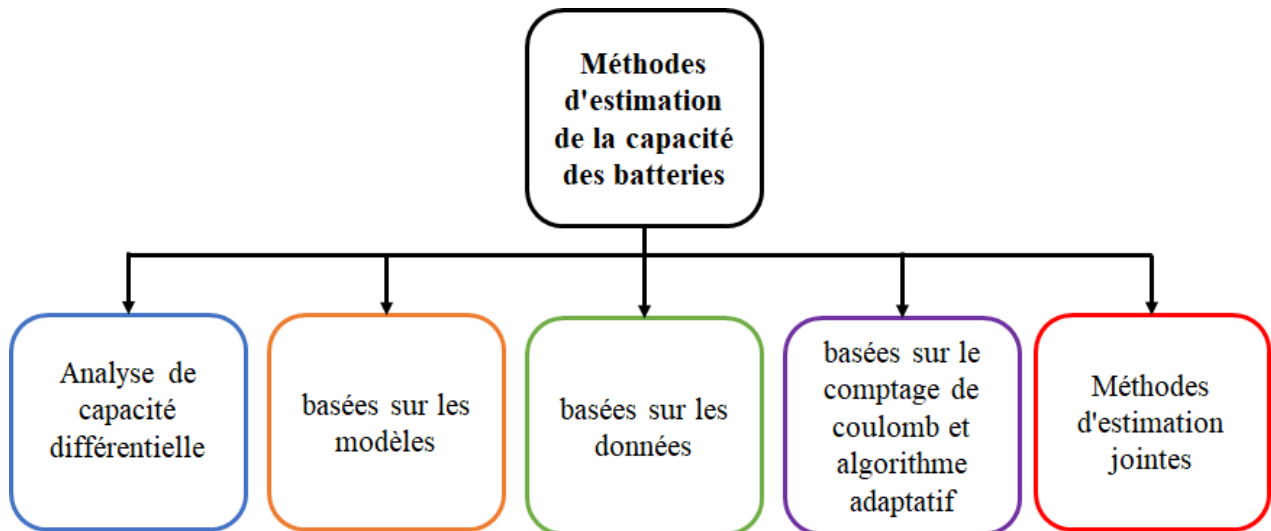


Figure 1.28 : Méthodes utilisées pour l'estimation de la capacité des batteries

### 1.7.1 Méthodes basées sur l'extraction des paramètres (Analyse de capacité différentielle)

La première catégorie est basée sur l'extraction des paramètres de la batterie. L'une des méthodes les plus couramment utilisées est l'analyse de la tension différentielle (DVA) et l'analyse de la capacité incrémentale (ICA). Dans la DVA, les données sont utilisées pour calculer le rapport ( $dV/dQ$ ) tracé en fonction de la capacité ( $dV/dQ$  en fonction de  $Q$ ), la caractéristique générée contient des pics (figure 1.29) qui indiquent un changement rapide de la tension. La localisation de ces pics est étudiée dans [123-128] pendant la durée de vie de la batterie. Les pics représentent les réactions chimiques qui se produisent dans la cellule, la distance entre ces pics représente une partie de la capacité de la batterie [129]. Pour détecter ces pics avec précision, la cellule doit être chargée et déchargée complètement en utilisant un faible courant.

D'autre part, dans la méthode ICA, on trace  $dQ/dV$  en fonction de la tension (figure 1.30). Le calcul de la dérivée permet de convertir les plateaux de tension de la transition à deux phases en pics distincts. L'emplacement des pics permet d'étudier le comportement de la batterie en matière de perte de capacité pendant sa durée de vie. Le décalage, l'atténuation ou l'affaiblissement des pics sont utilisés pour obtenir plus d'informations sur le vieillissement, comme cela a été fait pour de nombreuses technologies de batteries [131-137]. Un faible courant de charge/décharge est également requis (le même cas que le DVA) afin de ne pas déformer les courbes ICA [134].




Figure 1.29 : Courbe DVA [130]




Figure 1.30 : Courbe ICA [138]

Ces méthodes ont pour principale limite d'exiger que la batterie soit chargée ou déchargée avec un faible courant afin de simuler un fonctionnement à l'équilibre, ce qui n'est pas réalisable dans des scénarios en temps réel. En outre, le calcul de la tension différentielle ( $dV$ ) et de la capacité ( $dQ$ ) peut conduire à un bruit élevé, en particulier lorsque la batterie présente une courbe plate, c'est pourquoi un filtre approprié est généralement associé à ces méthodes.

### 1.7.2 Méthodes basées sur les modèles

La deuxième catégorie combine des modèles empiriques/électrochimiques et des données expérimentales pour cibler le problème de l'estimation de la capacité des batteries [139-145]. Les modèles les plus utilisés sont les modèles de circuit équivalent ECM [139-141] et les modèles électrochimiques EM [142-145]. Les modèles de circuit équivalent sont construits en utilisant des composants de circuits électriques pour modéliser la dynamique d'une batterie, tandis que dans les modèles EM, une série d'équations (équations différentielles partielles) est utilisée pour décrire la distribution de la concentration et du potentiel des ions lithium dans une batterie. L'inconvénient de ces méthodes est qu'elles nécessitent un volume important de données dans des conditions bien définies et/ou un modèle précis, ce qui n'est pas une tâche facile à réaliser.



### 1.7.3 Méthodes basées sur les données

La troisième catégorie, connue sous le nom de méthode axée sur les données, est un substitut de l'approche basée sur les modèles, dans laquelle des méthodes d'apprentissage automatique sont mises en œuvre pour cartographier la relation complexe entre la capacité de la cellule et les mesures (courant et tension). Dans ce cas, aucune connaissance des principes de fonctionnement de la batterie n'est requise. Cela peut être réalisé grâce à diverses méthodes d'apprentissage automatique qui peuvent être classées en techniques de régression par noyau (kernel regression) [146-148] et en techniques de réseaux neurones (NN) [149-150].

Dans les méthodes régression par noyau, les fonctions de noyau sont utilisées pour modéliser la relation non linéaire entre la capacité de la cellule et les caractéristiques mesurables. Par exemple, dans l'article [147], la méthode k-nearest neighbor kNN est utilisée pour trouver la relation entre la capacité de la batterie et les caractéristiques liées à la charge (courbes de tension et de courant de charge). Une optimisation par PSO (particle swarm optimization) est ensuite utilisée pour améliorer les coefficients de pondération du modèle de régression. Dans un travail récent [148], une combinaison de l'approche MKRVM (multiple kernel relevance vector machine) et de la méthode de débruitage EMD (empirical mode decomposition) est utilisée pour estimer la capacité de la batterie. Le modèle d'estimation de la capacité de la batterie utilisant MKRVM est construit sur la base de données de capacité, qui sont maintenues exemptes de bruit par la méthode de suppression du bruit EMD.

La deuxième approche de la catégorie "axée sur les données" utilise le réseau neuronal NN et le réseau neuronal profond DNN (Apprentissage profond). Le réseau neuronal est un cadre composé de nombreux éléments connectés appelés neurones qui relient l'entrée (tension de sortie de la batterie, courant de la batterie, température) à la sortie (capacité totale de la batterie). Les techniques d'apprentissage DNN basées sur les NN ont attiré l'attention ces derniers temps en raison de leurs bonnes performances de généralisation et de leurs puissantes caractéristiques. S. Shen et al ont présenté un modèle de réseau de neurones à convolution profonde (DCNN) pour estimer la capacité de la batterie en utilisant le courant et la tension, ainsi que les mesures de la capacité de charge sur un cycle de charge partiel [149]. Dans une étude récente [150], un DCNN avec des concepts d'apprentissage d'ensemble et d'apprentissage par transfert est proposé. L'apprentissage par transfert permet de transmettre les connaissances acquises dans une tâche source pour améliorer la formation dans une tâche correspondante mais distincte. L'apprentissage d'ensemble assure la robustesse en termes de performance en fusionnant les résultats de divers algorithmes d'apprentissage.

Le besoin d'une grande quantité de données fiables et le temps d'apprentissage sont les principaux inconvénients des approches basées sur les données.

### 1.7.4 Méthodes basées sur le comptage de coulomb et algorithme adaptatif

La quatrième classe combine l'équation de comptage de coulomb et des algorithmes d'estimation. À partir de l'équation (1.44), la capacité de la batterie ( $Q$ ) peut être extraite. Cette méthode nécessite la connaissance de l'évolution de l'état de charge (SOC) entre  $t_1$  et  $t_2$ .

$$SOC(t_2) = SOC(t_1) + \frac{1}{Q} \int_{t_1}^{t_2} \eta i(t) dt \quad (1.44)$$

Q est la capacité totale, SOC représente l'état de charge,  $\eta$  est le coefficient de coulomb, avec le courant  $i(t)$  considéré comme négatif pendant la charge et positif pendant la décharge.

Le filtre de Kalman étendu (EKF) est avancé dans [29-31] pour estimer la capacité de la batterie. Bien qu'il fonctionne bien dans les modèles linéaires et non linéaires du premier ordre, cette méthode n'est pas efficace pour les modèles hautement non linéaires. Le filtre de Kalman à points sigma (SPKF) [96-97] peut résoudre le problème de la robustesse des modèles non linéaires, mais le problème du SPKF est qu'il ne peut pas estimer les bruits de mesure.

Dérivé des techniques des moindres carrés totaux (TLS), Plett dans [12-13] a extrait plusieurs variations de TLS pour prédire la capacité totale de la batterie, avec la version ultime : moindres carrés pondérés approximatifs totaux (AWTLS) capable d'évaluer la capacité totale de la batterie avec une bonne précision et un calcul minimum. L'AWTLS prend en considération l'impact du bruit de l'état de charge.

### 1.7.5 Méthodes d'estimation jointes

Des méthodes d'estimation jointes ont également été utilisées pour l'estimation de la capacité des cellules. Bien qu'elles puissent donner une bonne estimation, elles dépendent fortement de la précision du modèle de batterie ; de plus, l'estimation de la capacité et de l'état de charge étant couplés, un manque de convergence ou un problème d'instabilité peut survenir. Nous énumérons ici les études les plus récentes :

C. Chen, et al ont proposé un double  $H_\infty$  multi-échelle (filtres H infini) dans [151] pour traiter l'impact de l'erreur du modèle et du bruit sur la précision de l'estimation, tandis que dans [152], les auteurs ont combiné le RLS et le filtre  $H_\infty$  adaptatif, la méthode RLS est employée pour identifier le paramètre de la batterie et le filtre H infini adaptatif effectue l'estimation de la capacité. La référence [153] présente une nouvelle estimation jointe du SOC et de la capacité de la batterie. La technique d'identification TSRLS (two stage recursive least squares) est proposée pour identifier les paramètres du modèle de batterie et pour estimer le décalage de la mesure du courant. Étant donné l'impact de l'erreur d'estimation du SOC sur l'estimation de la capacité de la batterie, l'AEKF est introduit pour obtenir une meilleure précision d'estimation du SOC. Dans [154], un modèle de circuit équivalent ECM de second ordre est mis en œuvre pour l'estimation du SOC à l'aide de l'algorithme SRCKF (square root cubature Kalman filter) en tenant compte de la dégradation de la capacité et de la variation des paramètres. La capacité de la batterie étant l'un des paramètres du modèle, elle est identifiée par l'algorithme génétique (GA). La référence [155] présente un nouvel algorithme conjoint pour l'estimation de la capacité et du SOC basé sur les techniques de Kalman et RLS afin de traiter les différentes variations des paramètres du modèle.

### 1.7.6 Conclusion sur l'estimation de la capacité

On recense dans le tableau 1.3 les avantages et les inconvénients des différentes méthodes d'estimation de la capacité d'une batterie Li-ion. L'objectif principal d'un estimateur de la

capacité est d'assurer à la fois une bonne robustesse ainsi qu'une précision accrue et une charge de calcul faible.

**Tableau 1.3 : Méthodes d'estimation de la capacité**

Méthodes	Avantages	Désavantages	Précision /Robustesse
Comptage coulombique seul (Ampère- heures)	<ul style="list-style-type: none"> <li>✓ Disponible dans presque tous les BMSs</li> <li>✓ Facile à implanter améliorée à l'aide de la courbe OCV-SoC</li> </ul>	<ul style="list-style-type: none"> <li>• Cumul de l'erreur de mesure de courant surtout en présence de biais de mesure</li> </ul>	Faible/ Faible
Analyse différentielle DVA	<ul style="list-style-type: none"> <li>✓ Implémentation simple</li> <li>✓ Bonne compréhension du vieillissement, de la dégradation et du déséquilibre des électrodes</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessite un courant de charge et de décharge faible</li> <li>• Erreurs dues aux calculs de dérivé</li> <li>• N'est pas adapté aux applications temps réel</li> </ul>	Faible/ Faible
Analyse différentielle ICA	<ul style="list-style-type: none"> <li>✓ Implémentation simple</li> <li>✓ Bonne compréhension du vieillissement, de la dégradation et du déséquilibre des électrodes</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessite un courant de charge et de décharge faible</li> <li>• Erreur du aux calcul de dérivé</li> <li>• N'est pas adapté aux applications temps réel</li> </ul>	Faible/ Faible
À base des données (NN, KNN, DCNN)	<ul style="list-style-type: none"> <li>✓ Adapté aux différentes chimies</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessité une grande quantité de données fiables</li> <li>• Temps d'apprentissage</li> </ul>	Bonne /Bonne
Méthode coulombique +algorithmes (EKF, SPKF, AFFRLS)	<ul style="list-style-type: none"> <li>✓ Adaptatif</li> </ul>	<ul style="list-style-type: none"> <li>• Dépend des états initiaux</li> <li>•</li> </ul>	Bonne /Faible
Méthodes d'estimation jointes	<ul style="list-style-type: none"> <li>✓ Bonne estimation</li> </ul>	<ul style="list-style-type: none"> <li>• Problème de convergence</li> </ul>	Bonne /Bonne

## 1.8 Conclusion

Ce chapitre a décrit l'état de l'art des systèmes de gestion des batteries. Il a été démontré qu'en raison de leur capacité énergétique et de leurs puissances accrues, les batteries lithium-ion sont devenues la solution préférée de stockage et d'approvisionnement en énergie pour différentes applications notamment les véhicules électriques. Nous avons également discuté le fait que sans optimisation des algorithmes de surveillance des batteries, l'adoption future des batteries lithium-ion dans les applications de sécurité critique resterait un défi. Ce chapitre présente donc un examen complet des techniques de modélisation de la batterie et d'équilibrage des cellules et les algorithmes actuels d'estimation de l'état de charge, et la capacité de la batterie.

Les états opérationnels de la batterie qui présentent un intérêt dans les applications BMS, et dans cette thèse, ont été identifiés : L'état de charge SOC, et l'état de santé SOH (par estimation de la capacité). En général, les états de la batterie et les méthodes d'estimation des paramètres peuvent être classés dans les groupes suivants : basé sur modèle et basé sur un filtre ou un observateur etc. Les techniques basées sur un modèle sont très populaires pour les applications de BMS en ligne. Cela est dû à la relation physique qui existe entre les différents paramètres du modèle et les conditions de fonctionnement de la batterie, qui peuvent servir de bons indicateurs non seulement pour le SOC, mais aussi pour le SOH.

# Chapitre

# 2

---

## **Comparaison des algorithmes d'estimation de l'état de charge des batteries lithium-ion pour les véhicules électriques**

---

## 2.1 Introduction

Dans le premier chapitre, nous avons démontré que pour assurer le bon fonctionnement d'une batterie lithium, un système de gestion (BMS) fiable est indispensable. Ce dernier permet non seulement la surveillance de la batterie via les différents indicateurs (SOC, SOH, SOP...), mais aussi d'assurer la sécurité et l'équilibrage des cellules. Une des fonctions essentielles d'un BMS est l'estimation de l'état de charge (SOC). L'estimation du SOC pour toutes les cellules est une donnée importante pour l'équilibrage des cellules, le calcul d'énergie et de puissance, et l'estimation de l'état de santé (SOH) [156], etc. Plusieurs méthodes ont été développées pour l'estimation du SOC, allant de modèles très simples traitant les batteries comme une boîte noire, à des modèles électrochimiques très détaillés utilisés pour capturer le comportement physique interne de la batterie [157]. La capacité d'un algorithme d'estimation de l'état de charge (SOC) à être utilisé avec succès dans une application réelle est fortement déterminée par sa robustesse, car diverses erreurs, y compris les erreurs de capteurs, les erreurs de données initiales, les erreurs de paramètres de modèle perturbent le calcul, ce qui entraîne une diminution significative de la précision de l'estimation, voire l'obtention d'un SOC erroné. Dans une publication [15], nous avons présenté une étude comparative entre quatre algorithmes utilisés pour estimer l'état de charge des batteries. Nous exposons dans cette partie cette comparaison ainsi que les résultats des simulations des algorithmes du filtre de Kalman étendu EKF (Extended Kalman Filter) et du filtre de Kalman à points sigma SPKF (Sigma Point Kalman Filter) pour le test de stress dynamique (DST).

## 2.2 État de charge SOC

Essentiellement, l'état de charge SOC est un peu comme une jauge de carburant sur le tableau de bord qui indique une valeur allant de 0% à 100% (la figure 2.31 montre l'état de charge de la batterie d'un véhicule Tesla). Alors qu'il existe des capteurs pour mesurer avec précision le niveau d'essence dans un réservoir, il n'y a actuellement aucun capteur capable de mesurer le SOC, alors un bon estimateur est essentiel pour prédire avec précision le niveau de SOC. Le comptage de coulomb est le moyen le plus simple pour estimer l'état de charge [156].




Figure 2.31 : État de charge de la batterie d'un véhicule Tesla [193]

L'équation (1.44) fonctionne en intégrant le courant dans le temps pour obtenir la somme totale de l'énergie entrante ou sortante de la batterie, permettant ainsi de suivre l'évolution de l'état de charge d'une batterie. Le problème est que cette équation n'est pas autocorrective, et sujette à une dérive due à la fluctuation du capteur de courant. De plus, cette méthode nécessite une connaissance précise de l'état initial du SOC.

Une alternative pour estimer le SOC consiste à utiliser des approches basées sur des modèles et/ou des données. Ces méthodes mettent en œuvre des algorithmes qui utilisent un modèle et/ou des mesures détectées (courant, tension) pour évaluer l'état caché (SOC), les algorithmes basés sur un modèle supposent un modèle mathématique connu de la cellule.

## 2.3 Modèle utilisé

Les modèles de batterie sont classés en cinq catégories : modèle empirique, modèle électrochimique, modèle de circuit électrique équivalent ECM, modèle d'impédance électrochimique EM et modèle basé sur les données [158]. Nous nous sommes concentrés sur le modèle électrique qui convient à l'estimation en ligne en raison de sa simplicité, de ses faibles exigences de calcul, et de sa grande compatibilité avec les applications de systèmes embarqués. Les modèles Rint et Thévenin sont les plus utilisés [158].

### 2.3.1 Modèle Rint

Le modèle Rint est le plus simple (Figure 2.32), il contient une source de tension OCV en série avec une résistance qui modélise la réponse instantanée de la batterie à une entrée de courant donnée (la résistance interne de la batterie). L'inconvénient de ce modèle est sa précision faible due au fait qu'il néglige l'effet d'hystérésis et les phénomènes de diffusion.




Figure 2.32 : Modèle Rint

### 2.3.2 Modèle Thévenin

Comme nous avons discuté dans le premier chapitre, le modèle de Thévenin est un modèle amélioré qui prend en compte non seulement l'effet de polarisation, mais aussi les phénomènes d'hystérésis et de diffusion. La précision du modèle dépend du nombre de branches RC parallèles (Figure 2.33). Un nombre  $n$  de branches parallèles peuvent être ajoutées au modèle original (modèle Rint) pour analyser la réponse la plus transitoire. D'après la littérature, un modèle de Thévenin avec trois branches RC décrit avec précision le comportement d'une batterie lithium [158]. Par la suite, le modèle adopté est le modèle Thévenin avec une seule branche parallèle RC.

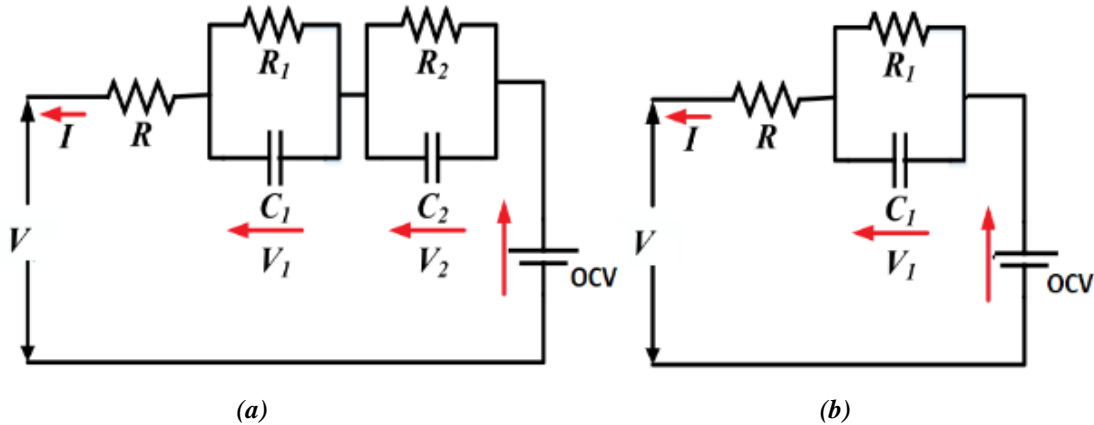


Figure 2.33 : Modèle de circuit équivalent nRC (Modèle Thévenin) : deux branches (a), une branche (b)

## 2.3. Algorithmes d'estimation SOC

Plusieurs algorithmes sont utilisés pour estimer le niveau du SOC, nous discuterons ici de quatre algorithmes.

### 2.3.1 Filtre de Kalman linéaire

Toute application utilisant un modèle est plus ou moins imprécise, car les modèles peuvent rarement tenir compte du bruit des mesures et s'adapter dynamiquement à des mesures variables ou à d'autres changements extérieurs. L'utilisation d'un filtre de Kalman linéaire présente l'avantage de générer des prédictions de l'état suivant en pondérant soigneusement l'état actuel du système avec la prédiction, au lieu de s'appuyer sur un modèle statique. Les poids placés sur l'état actuel et la prédiction peuvent être ajustés en ajustant le "gain" du filtre ( $K = 0$  utilise uniquement les prédictions, et  $K = 1$  utilise uniquement l'état actuel pour faire les prédictions). Un autre avantage de l'utilisation du filtre de Kalman est qu'il n'est pas nécessaire de connaître l'historique complet de l'état du système pour générer une prédiction (seuls l'état actuel et la prédiction actuelle sont nécessaires pour prédire le comportement du système dans l'état suivant comme indiqué dans les équations (2.45-46)).

$$x_k = Ax_{k-1} + w_{k-1} \quad (2.45)$$

Où  $x_k$  est l'état suivant estimé,  $x_{k-1}$  est l'état actuel du système,  $A$  est une matrice, et  $w_{k-1}$  est le bruit de processus.

$$z_k = Hx_k + v_k \quad (2.46)$$

$v_k$  est le le bruit de mesure,  $H$  est une matrice, et  $z_k$  est la sortie.

Le filtre de Kalman est un ensemble d'équations mathématiques utilisées récursivement avec des données de mesure pour estimer l'état caché d'un système donné. Le filtre de Kalman comporte deux étapes : la prédiction et la mise à jour (Figure 2.34).

**1- Prédiction :** la prédiction de l'état estimé évolue à partir de la mise à jour de l'état estimé précédent. Le terme P est appelé covariance d'erreur d'état. Il chiffre la covariance d'erreur que pense le filtre de l'erreur d'estimation.

**2- Mise à jour (correction) :** dans l'étape de mise à jour, le résidu de mesure est calculé en premier lieu. Le résidu de mesure, également appelé innovation, est la différence entre la mesure réelle  $z_k$  et la mesure estimée  $A * \hat{x}_{k-1}$ . Le résidu est ensuite multiplié par le gain de Kalman  $K_k$ . Après avoir obtenu l'estimation de l'état actualisé, le filtre de Kalman calcule la covariance d'erreur actualisée  $P_k$ , qui sera utilisée dans le cycle suivant.

La mise en œuvre du filtre de Kalman nécessite une étape d'initialisation. Comme valeurs initiales, le filtre de Kalman a besoin de la valeur initiale de l'état, et de la matrice de covariance des erreurs P0. À partir de ce moment, le filtre de Kalman alterne entre les états de prédiction et de correction (mise à jour). Les prédictions pour l'état du système et la covariance des erreurs d'estimation sont générées au temps k-1 (avant que les mesures réelles ne soient connues, d'où l'utilisation du signe moins en exposant). Le gain K du filtre de Kalman est calculé, après quoi l'état du système et la covariance de l'erreur d'estimation Pk sont mis à jour avec les valeurs de mesure. La pondération de la prédiction par rapport à la mesure est choisie en fonction de la valeur calculée du gain K, qui s'ajuste dynamiquement pour une performance optimale.

On note que le filtre de Kalman linéaire est dérivé en supposant que les modèles de processus et de mesure sont linéaires, et que les bruits de processus et de mesure sont des bruits gaussiens additifs. Par conséquent, un filtre de Kalman ne fournit une estimation optimale que si les hypothèses sont satisfaites. Dans ce sens, le filtre de Kalman linéaire n'est pas efficace, surtout lorsqu'il est utilisé pour estimer le SOC d'une batterie, ce qui est normal car le modèle de la batterie et la batterie elle-même sont fortement non linéaires.

La figure suivante résume les opérations de la boucle de Kalman.

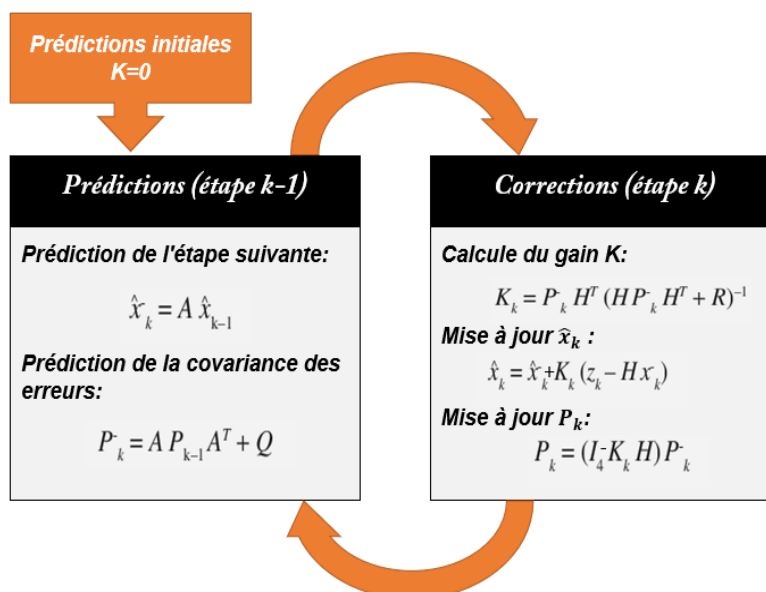


Figure 2.34 : Les étapes d'un filtre Kalman linéaire



### 2.3.2 Filtre de Kalman étendu (EKF)

Le filtre de Kalman étendu (EKF) est le plus préféré pour l'estimation des paramètres/états de la batterie et est une version non-linéaire du filtre de Kalman linéaire. Le filtre de Kalman étendu est une version améliorée du filtre de Kalman linéaire [159], l'EKF utilise le développement en série de Taylor du premier ordre pour linéariser les équations du système. Le calcul de la matrice jacobienne est nécessaire lors de l'estimation par l'algorithme EKF, ce qui affecte inversement la précision du SOC. Une des limites de l'algorithme EKF est que seule une précision du premier ordre peut être obtenue en utilisant le développement en série de Taylor du premier ordre dans la linéarisation.

Le système et les équations de mesure dans la forme discrète peuvent être décrits de la manière suivante :

$$\hat{x}_k = f_{k-1}(x_{k-1}, u_{k-1}) + w_{k-1} \quad (2.47)$$

$$y_k = h_k(x_k) + v_k \quad (2.48)$$

Où  $f(x)$  et  $h(x)$  sont des fonctions non-linéaires du modèle de système et de mesure,  $w_k$  et  $v_k$  sont des bruits gaussiens pour le modèle de processus et le modèle de mesure avec une covariance  $Q$  et  $R$  respectivement. Dans l'algorithme EKF, les fonctions non-linéaires des modèles de système et de mesure sont utilisées pour calculer les états estimés à priori et les mesures prédites. Dans l'EKF, le modèle doit être linéarisé autour de son estimation préalable comme suit :

$$F_k = \left. \frac{\partial f(x, u)}{\partial x} \right|_{x = \hat{x}_{k|k}, u_k} \quad (2.49)$$

$$H_{k+1} = \left. \frac{\partial h(x)}{\partial x} \right|_{x = \hat{x}_{k+1|k}} \quad (2.50)$$

Ci-dessous, un organigramme montrant les principales étapes du filtre de Kalman étendu :

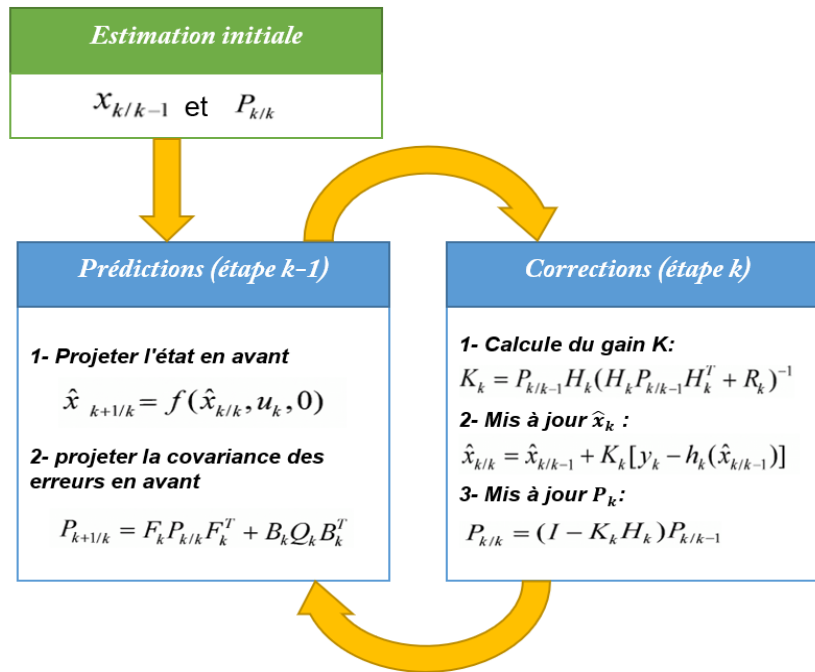


Figure 2.35 : Filtre de Kalman étendu EKF

L'algorithme EKF comprend les étapes suivantes :

1. Initialisation du vecteur d'état estimé  $\hat{x}_{k/k-1}$  et de la matrice de covariance des erreurs  $P_{k/k}$ .
2. Prédiction du vecteur d'état  $\hat{x}_{k+1/k}$  et calcul de la matrice de covariance des erreurs de prédiction  $P_{k+1/k}$ .
3. Calcul de la matrice d'observation  $H_{k+1}$ .
4. Acquisition d'un nouveau vecteur de mesure  $z_{k+1}$ .
5. Calcul de la matrice de gains de Kalman  $K_k$  et correction des résultats de la prédiction, c'est-à-dire calcul du vecteur d'état actualisé  $P_{k+1/k}$ ,  $\hat{x}_{k+1/k}$  et de la matrice de covariance des erreurs.
6. Déclaration de l'estimation du vecteur d'état  $\hat{x}_{k/k}$ .

Plett a expliqué dans trois publications [29-31] la théorie du filtre de Kalman étendu (EKF) et son adaptation à l'estimation de l'état de charge des batteries Li-ion. L'EKF a été utilisé pour l'identification des paramètres du modèle de batterie et l'estimation de l'état. Le calcul de la matrice jacobienne est nécessaire pendant l'estimation par l'algorithme EKF, ce qui a un effet inverse sur la précision du SOC estimé. Une limitation de l'algorithme EKF est que seule la précision du premier ordre peut être obtenue en utilisant l'expression de Taylor du premier ordre dans la linéarisation. La précision de l'algorithme EKF dépend des paramètres du modèle de batterie et de la connaissance préalable des signaux de bruit du système. Par exemple, si la connaissance préalable n'est pas correcte, l'erreur du processus d'estimation peut conduire à une divergence. Ainsi, plusieurs modifications ont été apportées au cours des décennies précédentes

pour améliorer les performances de l'algorithme EKF. Dans la Réf. [160], l'EKF amélioré a été proposé pour l'estimation en ligne du SOC en tenant compte du facteur de vieillissement pour actualiser en ligne de manière adaptative les paramètres du modèle de batterie. Le SOC estimé par la méthode d'une seule cellule peut être utilisé avec précision pour présenter le SOC de la batterie d'un véhicule électrique. Dans la Réf. [161], l'estimation du SOC a été réalisée à l'aide d'un EKF robuste, et les cinq modèles RC ont été pris en compte pour évaluer les performances. La sensibilité de l'algorithme d'estimation avec différentes valeurs initiales a été examinée. Les résultats ont montré que l'estimation du SOC à l'aide d'un EKF robuste pouvait réduire efficacement l'erreur résultant des valeurs initiales incorrectes du SOC.

D'autre part, un filtre Kalman étendu adaptatif (AEKF) est proposé dans [162] pour obtenir un état de charge correct et robuste en utilisant un modèle de batterie Thevenin amélioré. La méthode EKF est utilisée pour estimer les paramètres du modèle proposé. Les performances sont évaluées à l'aide de programmes fédéraux de conduite urbaine. Les résultats de la simulation indiquent que la méthode AEKF est meilleure que la méthode EKF en termes de précision et de fiabilité. L'étude comparative montre que l'erreur d'estimation du SOC est réduite de 3,16 % à 1,06 %. Dans [96], l'algorithme AEKF est mis en œuvre dans un modèle de Thevenin en ligne pour surveiller le SOC par le biais d'une table de consultation SOC-OCV. La performance du modèle est validée par un test UDDS (Urban Dynamometer Driving Schedule) dans lequel AEKF montre une performance satisfaisante avec une erreur inférieure à 2%. Dans [98], l'algorithme AEKF est appliqué pour obtenir les paramètres en ligne du modèle de batterie LiFePO<sub>4</sub> et pour estimer le SOC basé sur l'OCV. Une étude comparative entre la tension terminale hors ligne et en ligne est réalisée sous les tests HPPC (Hybrid Pulse Power Characterization) et UDDS. Les résultats expérimentaux montrent que l'estimation en ligne du SOC peut réduire l'erreur à 4%.

Ci-dessous les limites du filtre EKF :

- Nécessite une connaissance préalable des bruits de mesure et d'état ( $R, Q$ ) ;
- Nécessite une connaissance de la variance de l'état initial :  $P(t_0)$  ;
- La non-corrélation entre les bruits d'état et de mesure  $v(t)$  et  $w(t)$  à tout instant ;
- La non-corrélation entre les bruits d'état et de mesure  $v(t)$  et  $w(t)$  et l'état initial  $x(t_0)$ .

L'EKF permet d'estimer de manière satisfaisante les états non mesurables. Il y a également des techniques de réglage des paramètres qui permettent de faire converger les résultats du filtre. Cependant il se trouve que dans certains cas, le filtre est très instable et les variables estimées divergent de la réalité. D'autre part, pour la transition vers le filtre EKF, la technique de linéarisation génère des erreurs qui peuvent, selon les degrés de non-linéarité des fonctions  $f$  et  $h$ , devenir très limitantes pour la convergence du filtre d'estimation. Le filtre Kalman à point sigma SPKF permet de surmonter les limitations mentionnées ci-dessus.

### 2.3.3 Filtre de Kalman à point Sigma (SPKF)

L'EKF utilise la linéarisation analytique qui conduit à des erreurs, en particulier pour les systèmes hautement non-linéaires. L'approche Sigma-point utilise la linéarisation statistique, en sélectionnant des points d'échantillonnage déterministes appelés points sigma pour trouver la moyenne et la covariance.

L'introduction de points sigma dans l'EKF est la principale différence entre l'EKF et la SPKF. La figure 2.36 montre que la covariance moyenne des points sigma de sortie correspond bien aux valeurs réelles de la moyenne et de la covariance.

Plett a mis en évidence dans [96-97], la plus forte supériorité du SPKF sur l'EKF au niveau de la précision. Le SPKF évite également les calculs des dérivées qui constituent souvent des sources d'erreurs et de complexité en termes de calcul en particulier lorsque les fonctions en question ne sont pas dérivables. Cette méthode permet d'atteindre une précision de Taylor du second ordre. En plus d'une linéarisation locale, l'approche de distribution statistiques avec l'utilisation de points d'échantillonnage déterministes appelés points sigma a été utilisée pour la linéarisation dans SPKF. La sélection des points sigma est généralement effectuée de telle sorte que la moyenne pondérée et la covariance de la variable aléatoire postérieure doivent correspondre à la moyenne antérieure et à la covariance des variables aléatoires modélisées [158]. Sur la base du facteur de pondération, l'algorithme SPKF est classé en deux catégories : le filtre de Kalman non parfumé (UKF) et le filtre de Kalman à différence centrale (CDFK).




Figure 2.36 : Linéarisation dans les algorithmes EKF et UKF (SPKF) [158]

Dans [76], l'estimation du SOC pour les batteries LiFePO4 est comparée entre trois algorithmes basés sur des modèles tels que SPKF, EKF et l'observateur de Luenberger. Les résultats expérimentaux indiquent que SPKF améliore la précision de l'estimation du SOC. Le SPKF est également stable dans les calculs numériques puisqu'il n'est pas besoin de calculer les matrices jacobiniennes. Dans [97], l'estimation de l'état de charge basée sur SPKF est présentée. Le SOC de la batterie est évalué en tenant compte de la relation entre SOC et OCV. Les rapports indiquent que la méthode proposée nécessite très peu de calcul et moins de mémoire pour obtenir des résultats efficaces.

### 2.3.4 Réseau de neurones

Le réseau de neurones est une branche de l'intelligence artificielle. Il repose sur une simple abstraction et simulation du cerveau humain et accepte la formation correspondante principalement par l'échantillon d'entrée et de sortie afin qu'il puisse répondre aux relations de la fonction de mappage. Il améliore la précision du modèle grâce à l'ajustement du poids et de la déviation du modèle. Ce processus peut être divisé en deux étapes.

La première est le processus de calcul direct, qui consiste principalement à compléter le calcul de chaque unité de la couche d'entrée à la couche de sortie. La seconde est le processus de propagation de l'écho d'erreur.

Dans la figure 2.37, la couche d'entrée est principalement constituée des paramètres de la batterie telle que le courant, la tension, la température et la résistance interne. La couche de sortie est la valeur estimée du SOC de la batterie. La couche cachée est la fonction d'activation du système.




Figure 2.37 : Estimation de l'état de charge par réseau de neurones

Les avantages de cette méthode résident dans le fait qu'elle permet d'estimer précisément le SOC sans nécessité de connaître le modèle de la batterie. Dans le même temps, les méthodes de recherche parallèle et globale sont rapides et l'expérience présente une meilleure vitesse de

convergence et une grande précision. Les inconvénients de cette méthode sont également évidents, principalement parce qu'elle nécessite une grande quantité de données.

Récemment, avec l'augmentation constante de la puissance de calcul fournie par les processeurs graphiques (GPU), les méthodes basées sur les NN artificiels ont suscité de plus en plus d'intérêt dans le monde de la recherche. D'énormes quantités de données d'entraînement peuvent être stockées et collectées soit en transférant continuellement des données de terrain de la batterie à partir de BMS en ligne vers des serveurs de données hors ligne, soit par des tests de simulation de la batterie en utilisant des profils de conduite dynamiques. En ce qui concerne le processus de formation, dans un environnement GPU, le processus de formation sur de grandes quantités de données est réduit à quelques minutes. Une fois le modèle formé, l'estimation peut être calculée en quelques millisecondes, répondant ainsi aux besoins des applications embarquées des véhicules électriques. He et al. [8] ont développé une estimation de l'état de charge des batteries Li-Ion à l'aide d'un réseau neuronal et d'un filtre de Kalman non parfumé (UKF) pour l'annulation des erreurs. Pour estimer l'état de charge des batteries, les entrées du réseau neurones étaient la tension, le courant et la température, et la sortie était l'état de charge, les résultats ont montré une bonne estimation de l'état de charge avec une erreur inférieure à 2,5%. Sahinoglu et al. [163] ont développé un réseau de neurones récurrent (RNN) pour estimer le SOC des batteries lithium-ion. Chaoui et al. [164] ont appliqué le RNN pour estimer l'état de santé des batteries au lithium-ion et ont évalué ses performances en utilisant deux types différents de batteries. Les résultats expérimentaux ont montré que le RNN est robuste au vieillissement de la batterie, à l'hystérésis, au profil de courant dynamique, et aux incertitudes paramétriques.

### **2.3.5 Logique floue**

La logique floue (FL) est un autre algorithme puissant permettant de présenter un modèle complexe et non linéaire à l'aide d'un ensemble de données d'apprentissage approprié. Cette approche facilite le concept de vérité partielle, où la valeur de vérité peut aller de complètement vrai, partiellement vrai, jusqu'à complètement faux selon la valeur qu'elle prend entre 0 et 1. Au lieu de la logique classique à deux valeurs (vrai ou faux), FL introduit le concept de logique à plusieurs valeurs. Le système d'interface FL est structuré en utilisant la fuzzification, la base de règles floues, le mécanisme d'inférence et la défuzzification [165].

Il existe quelques études impliquant la FL pour estimer le SOC. Salkind et al. [165] ont déterminé le SOC en utilisant la logique floue avec des données de spectroscopie d'impédance. Le modèle développé est exécuté en utilisant un microcontrôleur Motorola, un capteur de température, un capteur de courant et un convertisseur analogique-numérique. La plage d'erreur est limitée à moins de 5%. Dans [166], les auteurs ont proposé l'utilisation de FL avec SVM (machine à vecteur de support) pour prédire le SOC d'un pack utilisé dans un VE. Les auteurs ont signalé une amélioration de la précision de l'estimation du SOC et de l'immunité au bruit par rapport aux modèles NN et aux machines à vecteur de support (SVR) courants. Li et al. [167] ont développé un algorithme de filtre de Kalman adaptatif non parfumé basé sur un facteur d'oubli adaptatif flou pour estimer le SOC. Le facteur d'oubli adaptatif flou est utilisé pour mettre à jour les paramètres du modèle de la batterie. Le modèle proposé montre une

performance supérieure contre le SOC initial inconnu et la dérive du capteur de tension et peut fournir de meilleurs résultats par rapport à la méthode UKF traditionnelle en ce qui concerne la précision, la robustesse et la vitesse de convergence.

Le système adaptatif d'inférence neuro-floue (ANFIS) est un algorithme amélioré qui combine la méthode d'apprentissage NN et le système d'inférence floue sans la nécessité d'un modèle de batterie détaillé. L'ANFIS est très puissant pour la mise en correspondance, la modélisation, la prise de décision, le traitement du signal et l'optimisation. Dans la publication [168], les auteurs ont développé un modèle d'estimation du SOC basé sur ANFIS en utilisant six entrées (courant, température, perte de puissance réelle, puissance disponible et demandée, température de l'air de refroidissement et le facteur thermique de la batterie). Les résultats démontrent que le modèle est efficace avec une erreur SOC inférieure à 1% dans des 10 cycles de conduite diversifiés. Dans [169], le modèle ANFIS est construit avec le courant, la tension, la capacité et la température pour déterminer le SOC. L'erreur moyenne en pourcentage rapportée est de 0,53 %. La structure ANFIS pour l'estimation du SOC en utilisant deux entrées est illustrée dans la figure 2.38.




Figure 2.38 : Structure ANFIS avec deux entrées [169]

Bien que la logique floue ait une fonction puissante pour prédire un modèle non linéaire, il nécessite une grande unité de mémoire et des calculs complexes ainsi qu'une unité de traitement coûteuse.

## 2.4 Simulation, résultats et discussion

Afin de tester les performances des algorithmes (EKF, SPKF), nous avons utilisé des données réelles de la cellule INR 18650-20R fournies par le groupe de recherche sur les batteries CALCE. Le tableau ci-dessous reprend les paramètres de cette cellule [8-10].

Tableau 2.4 : Paramètres batterie

INR 18650-20R Batterie	
Batterie (Paramètres)	Spécifications (valeur)
Capacité nominale	2000mAh
Chimie	LNMC/Graphite
Dimensions	18.3+-0.07mm
Longueur	64.5+- 0.15mm

La configuration de l'expérience est présentée à la figure 2.39. Il se compose : (1) des cellules lithium-ion (LiFePO<sub>4</sub>) de type cylindrique 18650 (les principales spécifications sont indiquées dans le tableau 2.4) ; (2) d'une chambre d'essai de température Vötsch (les batteries ont été placées dans des supports de cellule dans la chambre) ; (3) d'un câble d'échantillonnage de courant et de tension pour le chargement et l'échantillonnage ; (4) d'un système d'essai de batterie (testeur BT2000 d'Arbin) ; (5) d'un PC avec le logiciel Mits Pro d'Arbins (v4. 27) pour le contrôle de la charge/décharge de la batterie ; (6) Matlab R2009b pour l'analyse des données. Pendant le fonctionnement de la batterie, le temps d'échantillonnage du courant et de la tension était de 1 s.

La première étape consiste à établir un tableau de référence OCV/SOC en utilisant le test OCV à faible courant [8-10]. Comme les courbes de charge et de décharge du SOC sont différentes en raison de l'effet d'hystérésis, une courbe combinée doit être tracée. La figure 2.40 montre séparément les trois courbes de charge, de décharge et la courbe mixte. Nous avons utilisé pour notre cas le modèle de Thévenin avec une branche parallèle RC (figure 2.33) comme modèle de la cellule.

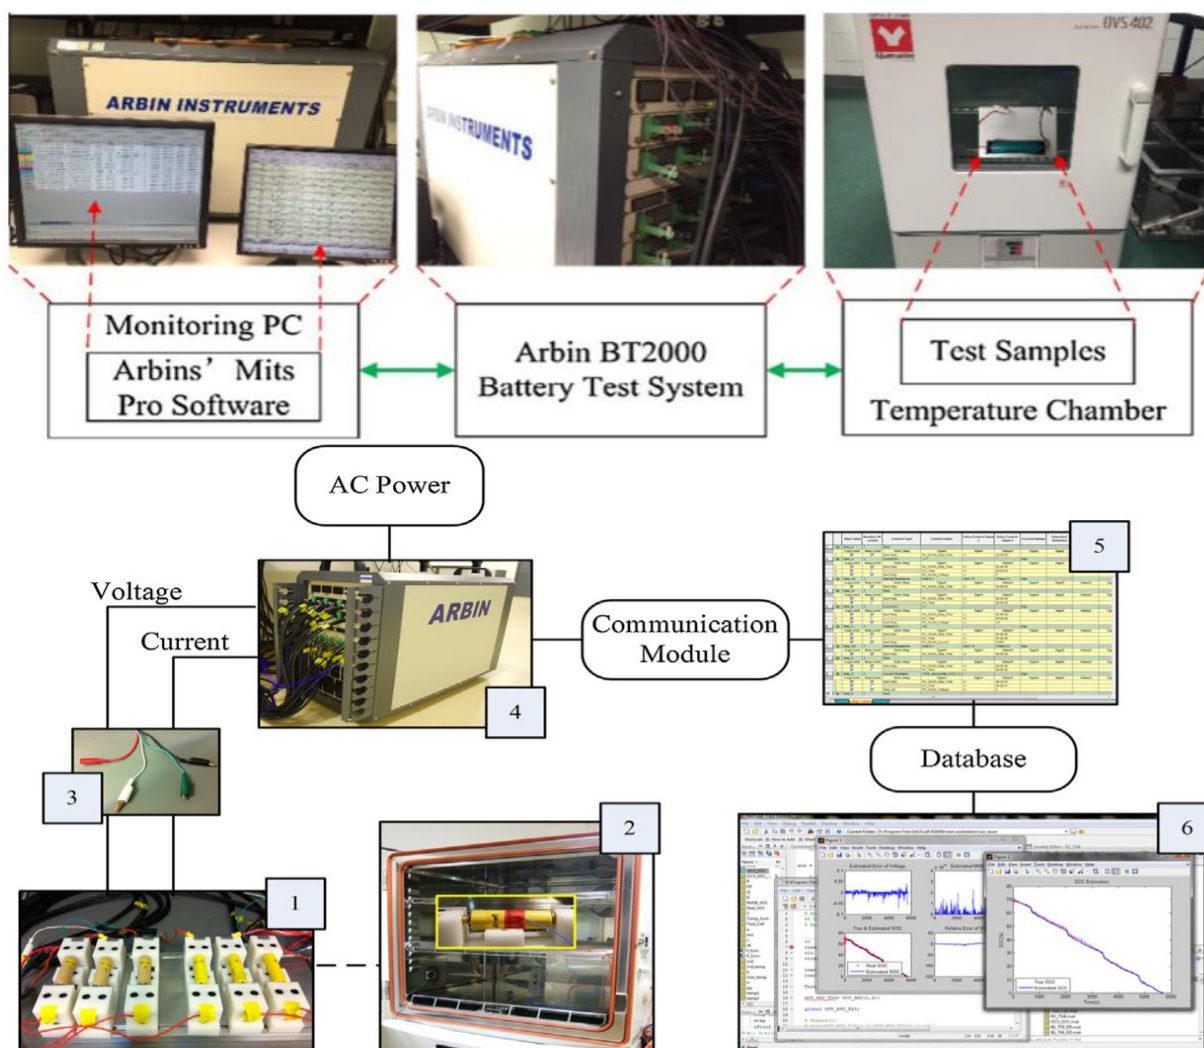


Figure 2.39 : Plate-forme de test des batteries [8-10]






Figure 2.40 : Courbe OCV SOC pour la charge, la décharge et la courbe mixte

La deuxième étape consiste à sélectionner un modèle. Nous avons utilisé pour notre cas le modèle Thévenin avec une seule branche parallèle RC. Le modèle doit être paramétré pour simuler le comportement de la batterie dans des conditions spécifiques. Comme nous travaillons sur l'estimation du SOC de la batterie pour les véhicules électriques, nous avons utilisé le profil dynamique DST premièrement pour identifier les paramètres du modèle, puis pour valider la performance des algorithmes. Le test de stress dynamique (DST) est un test de décharge de puissance variable qui est mis à l'échelle d'un pourcentage de la puissance nominale maximale des véhicules d'essai. C'est un cycle de décharge de puissance variable simplifié avec les mêmes caractéristiques moyennes que le régime FUDS. C'est un cycle de conduite commun qui est souvent utilisé pour évaluer divers modèles de batterie et des algorithmes d'estimation de l'état de charge. La figure 2.41 illustre le profil du courant, on peut voir que la cellule est fortement stressée avec un courant qui varie entre +2A (charge) et -4A (décharge).





Figure 2.41 : Courant test DST


La Figure 2.42 montre que les tensions terminales estimées et réelles sont très proches l'une de l'autre malgré la variation agressive du courant dans le test DST, l'erreur d'estimation est tracée dans la Figure 2.43, le tableau ci-dessous résume les différentes erreurs.

**Tableau 2.5 : RMSE, Erreur Moyenne et Max**

RMSE (V)	Erreur Moyenne (V)	Erreur Max (V)
0.0124845	-0.005	0.0698



**Figure 2.42 : Tension terminale réelle et estimée**



**Figure 2.43 : Erreur d'estimation du modèle**

Le modèle et le tableau de référence OCV/SOC sont des ingrédients essentiels pour les deux algorithmes (EKF, SPKF). Nous pouvons maintenant appliquer les algorithmes pour estimer le SOC. Les résultats montrent que malgré l'erreur de modélisation et l'agressivité du test DST, les algorithmes ont pu suivre les variations de l'état de charge.

Les figures 2.44, 2.46 montrent respectivement l'estimation du SOC par les algorithmes EKF et SPKF par rapport à la valeur réelle. Dans les figures 2.45, 2.47, nous exposons une section

agrandie de l'estimation du SOC. Nous pouvons observer que l'état de charge estimé par les deux filtres de Kalman sont proches de la réalité malgré la variation agressive du courant.

L'EKF et SPKF ont pu obtenir des résultats satisfaisants, en effet, l'erreur d'estimation maximale de l'état de charge (SOC) était de 2% pour l'EKF et de 1.01% pour le SPKF (figure 2.48). Le tableau 2.6 résume les erreurs des deux algorithmes pour chaque test (RMSE, l'erreur maximale, et l'erreur dehors des limites).

Tableau 2.6 : Erreurs d'estimation du SOC des deux algorithmes pour le test DST

Algorithmes	RMSE (%)	Max (%)	Erreur en dehors des limites (%)
EKF	1.071	2.01	0
SPKF	0.292	1.01	0

Les deux algorithmes étaient très proches de l'état réel, bien que le SPKF a montré des erreurs faibles par rapport à l'EKF. D'après l'erreur calculée en dehors des limites, nous pouvons conclure que ces algorithmes sont fiables pour estimer le SOC dans des applications réelles.




Figure 2.44 : Estimation du SOC par EKF




Figure 2.45 : Section agrandie de l'estimation du SOC par EKF




Figure 2.46 Estimation du SOC par SPKF




Figure 2.47 : Section agrandie de l'estimation du SOC par SPKF.




Figure 2.48 : Erreur d'estimation par EKF et SPKF

## 2.5 Résultats de la comparaison

La batterie lithium est un système fortement non linéaire ; par conséquent, le filtrage Kalman standard (KF) ne peut pas être utilisé comme algorithme pour estimer avec précision l'état de charge, car ce dernier ne peut être appliqué qu'à un modèle linéaire.

Le filtre de Kalman étendu (EKF), de l'autre côté, peut traiter la non-linéarité de la cellule, mais avec un coût de calcul élevé. L'EKF étudié nous a donné une erreur Max de 2%, ce qui est assez bien, mais une erreur élevée peut se produire lorsque le système est fortement non linéaire, en raison de son approximation d'une variable aléatoire gaussienne distribuée et de l'ignorance des termes d'ordre supérieur.

Le filtre de Kalman à point de Sigma est une alternative intéressante. La SPKF a une complexité de calcul identique à celle de l'EKF, mais sans tenir compte des matrices jacobiniennes. Basé sur une linéarisation statistique, le SPKF peut traiter des systèmes hautement non linéaires, l'erreur max enregistrée pour le test DST est de 1.07%.

Les réseaux de neurones (NN) et la logique floue sont très utilisés dans la littérature pour estimer le niveau du SOC. Les NN et la logique floue fonctionnent bien même si le système est fortement non linéaire : c'est le cas de la batterie. Le tableau 2.7 représente un récapitulatif des avantages et des inconvénients des algorithmes d'estimation du SOC étudiés dans ce chapitre.

**Tableau 2.7 : Comparaison entre les quatre algorithmes.**

Algorithme	Avantages	Inconvénients	Précision /Robustesse
Comptage de coulomb	<ul style="list-style-type: none"> <li>✓ Facile à mettre en œuvre</li> <li>✓ Faible consommation d'énergie</li> </ul>	<ul style="list-style-type: none"> <li>• Produit des résultats imprécis en raison des perturbations</li> <li>• Difficultés à déterminer la valeur initiale de la SOC, ce qui entraîne un effet cumulatif.</li> </ul>	Acceptable/ Faible
KF	<ul style="list-style-type: none"> <li>✓ Estime avec précision les états affectés par des perturbations externes.</li> </ul>	<ul style="list-style-type: none"> <li>• Ne fonctionne pas sur un système non linéaire.</li> <li>• La divergence du modèle est inexacte.</li> </ul>	Faible/Faible
EKF	<ul style="list-style-type: none"> <li>✓ Prévoit un état dynamique non linéaire avec une bonne précision.</li> </ul>	<ul style="list-style-type: none"> <li>• Robustesse limitée.</li> <li>• Une erreur peut se produire si le système est fortement non linéaire.</li> </ul>	Bonne/Bonne
SPKF	<ul style="list-style-type: none"> <li>✓ Pas de calcul de matrices jacobiniennes.</li> </ul>	<ul style="list-style-type: none"> <li>• Complexe.</li> </ul>	Bonne/Bonne
NN	<ul style="list-style-type: none"> <li>✓ Fonctionne bien dans la modélisation d'un système dynamique non linéaire.</li> </ul>	<ul style="list-style-type: none"> <li>• Calcul complexe.</li> <li>• Nécessite une unité de traitement coûteuse.</li> </ul>	Très Bonne/Faible
Logique floue	<ul style="list-style-type: none"> <li>✓ Performant dans la modélisation d'un système dynamique non linéaire.</li> <li>✓ Efficace dans la prédiction de tout degré de précision approprié en considérant l'état de charge, le vieillissement et la température.</li> </ul>	<ul style="list-style-type: none"> <li>• Le calcul est complexe.</li> <li>• Nécessite une grande unité de mémoire.</li> <li>• Nécessite une unité de traitement coûteuse</li> </ul>	Très Bonne/Faible

## 2.6 Conclusion

Dans cette section, une simulation du filtre de Kalman EKF et SPKF sur un modèle de premier ordre RC est présentée pour l'estimation du SOC pour les véhicules électriques.

Tout d'abord, une recherche du tableau de référence SOC/OCV est réalisée en utilisant un test d'OCV à faible courant. Ensuite, un modèle a été choisi puis paramétré avant d'appliquer le profil dynamique DST.

Les résultats ont montré une légère supériorité du SPKF par rapport à l'EKF pour l'estimation du niveau du SOC. Cependant, les deux algorithmes étaient suffisamment robustes pour traiter la non-linéarité élevée de la batterie lithium. En fait, l'EKF et le SPKF ont pu obtenir des bons résultats avec une erreur max de 2.01% et de 1.01% respectivement.

Le principal défi pour l'estimation SOC est d'améliorer l'exactitude, l'efficacité et la robustesse de l'algorithme avec une faible complexité de calcul, afin que la méthode puisse être implémentée dans un BMS à faible coût. L'objectif est de trouver un algorithme SOC efficace qui pourrait agir comme un compromis entre la précision et la complexité du calcul.

Habituellement, les erreurs de l'état de charge proviennent de plusieurs sources, notamment les capteurs de courant et de tension, un modèle de batterie inexact, un SOC initial erroné, ou une sélection inexacte des paramètres lors de l'optimisation. Il est donc nécessaire de développer une technique avec des sources d'erreurs de SOC faibles.

L'étude d'autres algorithmes est nécessaire afin de choisir le meilleur candidat pour estimer l'état de charge avec une grande précision et un faible coût de calcul. Le réseau neuronal (NN) et la logique floue [165-169] sont des algorithmes puissants, peut-être que par une combinaison entre ces algorithmes et le filtrage de Kalman (SPKF, EKF), nous pouvons obtenir de meilleurs résultats.

## **Chapitre**

# **3**

---

## **Estimation en ligne des paramètres de la batterie lithium-ion pour les véhicules électriques**

---

### 3.1 Introduction

En raison des problèmes environnementaux mondiaux croissants, les véhicules électriques (VE) gagnent en popularité et finiront par remplacer les véhicules à moteur à combustion interne. Les VE obtiennent leur énergie des batteries. Les batteries sont des éléments de stockage hautement non linéaires utilisés dans un environnement en constante évolution, ce qui les rend très dynamiques et mathématiquement complexes. Afin d'estimer l'autonomie d'un VE, l'état de charge (SOC) de la batterie, qui ne peut être mesuré directement, doit être estimé avec précision. Les techniques les plus couramment utilisées pour estimer l'état de charge d'une batterie s'appuient sur l'utilisation des modèles à base de circuit électrique, le problème est que les paramètres de ces modèles sont affectés par des facteurs tels que la température, le vieillissement de la batterie, l'état de charge, entraînant une erreur d'estimation de l'état de charge SOC. Il est donc essentiel d'identifier avec précision ces paramètres. La mise à jour constante des paramètres du modèle, également appelée identification des paramètres en ligne, peut résoudre ce problème pour le BMS. Dans le cadre de cette thèse, nous avons proposé deux nouveaux algorithmes pour l'estimation des paramètres en ligne :

1-L'algorithme AFFRLS (*Adaptive Forgetting Factor Recursive Least Square*).

2-L'algorithme Sunflower (*SFO : Sunflower Optimization Algorithm*).

### 3.2 L'algorithme AFFRLS

#### 3.2.1 Introduction

La prédiction de l'état de charge (SOC) est l'une des principales fonctions d'un BMS. Une prédiction précise de l'état de charge peut réduire les interruptions imprévues du système et protéger la batterie contre le danger de surcharge ou de décharge excessive. Une mesure directe du SOC n'est pas possible. Par conséquent, Les BMS doivent donc utiliser des méthodes précises pour estimer l'état de charge. Les techniques d'estimation du SOC peuvent être divisées en deux groupes : les approches basées sur un modèle et les approches qui ne le sont pas.

Les algorithmes basés sur les modèles ont de meilleures performances. Les exemples des modèles incluent le modèle de Thevenin, le modèle général non linéaire (GNL), le modèle Rint, le modèle PNGV (Partnership for a New Generation of Vehicles), et ainsi de suite [170].

Différentes techniques d'estimation ont été employées pour estimer l'état de charge de la batterie, telles que : les observateurs à mode glissant [171-172], les filtres de Kalman [173-174], le filtre de  $H_\infty$  [175], le filtre de particules (PF) [176-177].

Lorsque la batterie est utilisée, certains paramètres du modèle équivalent de la batterie changent lorsque les conditions de travail changent, affectées par des facteurs tels que la température ambiante, les conditions de fonctionnement et le degré de vieillissement de la batterie. Il est donc nécessaire d'identifier ces paramètres avec précision. Une solution efficace consiste à mettre à jour les paramètres de la batterie en permanence nommée : Estimation des paramètres en ligne.



Dans ce contexte, nous relevons différents travaux dans la littérature, nous mentionnons dans ici les plus récents : Dans [178], les paramètres d'un modèle de Thevenin sont extraits en utilisant les données de tension obtenues à partir d'une batterie soumise à une décharge à courant constant. Une analyse de la réponse en tension permet de vérifier l'identifiabilité des paramètres. Pour traiter le problème de l'identification, un processus d'optimisation basé sur les moindres carrés non linéaires est formulé, des bornes ont été imposées pour limiter l'espace de recherche. Le problème de l'identification est résolu par le biais d'algorithme à régions de confiance (Trust region method). Dans [179], l'algorithme CPSO (coevolutionary particle swarm optimization) est mis en œuvre pour identifier les paramètres d'un modèle de circuit équivalent de troisième ordre. Pour identifier le paramètre de la batterie, CPSO utilise une fenêtre d'identification des paramètres PIW (parameter identification window), qui contient un ensemble de données indiquant le fonctionnement de la batterie au moment présent. Chaque paramètre utilise un essaim de particules distinct et ne change qu'une étape dans chaque cycle. Dans [180], l'algorithme VFFRLS (Variable forgetting factor recursive least squares) est combiné avec un filtre de Kalman non linéaire pour estimer l'état de charge SOC. VFFRLS est appliqué pour mettre à jour les paramètres de la batterie d'un modèle de Thevenin, puis le filtre de Kalman est utilisé pour estimer en temps réel le SOC. Dans l'article [181], un algorithme d'estimation en ligne pour un modèle de circuit équivalent fractionnaire est proposé. L'algorithme utilise la méthodologie indirecte de Lyapunov combinée avec la théorie du calcul d'ordre fractionnaire. Dans l'article [182], les paramètres du modèle de batterie sont identifiés en temps réel par l'algorithme PF (filtre de particulaires) en tenant compte des états de la batterie. Parallèlement, l'estimation de l'état de charge (SOC) est assurée par un filtre Kalman à cubature (CKF).

Les algorithmes ci-dessus sont précis, mais à part RLS (recursive least squares), ils nécessitent un calcul important (CPSO, PF), ce qui implique que RLS est beaucoup plus rapide. De plus, l'implémentation de RLS est plus facile dans les puces à faible coût ce qui convient aux applications des véhicules électriques. En outre, certains des algorithmes mentionnés (PF, CPSO) nécessitent un modèle précis pour obtenir des résultats optimaux, ce qui n'est pas le cas pour RLS. C'est pourquoi, dans cet article, nous nous concentrons sur la méthode de la technique RLS qui est couramment utilisée pour l'identification des paramètres du système [183].

Le problème de RLS est le fait qu'il est affecté par les anciennes données, cela signifie que la génération de nouvelles données sera affectée par les anciennes données, ce qui mènera à de grandes erreurs. Comme le facteur d'oubli est constant, la capacité et la précision de l'identification des paramètres du circuit dynamique à l'aide de RLS seront affectées lorsque les courants de charge et de décharge changent fréquemment, en particulier lorsque les fluctuations sont vigoureuses, ce qui est le cas pour les applications des véhicules électriques. Ce problème est corrigé en introduisant un facteur d'oubli dans RLS, de sorte que la proportion d'anciennes données est réduite lorsque de nouvelles données sont disponibles, ainsi l'algorithme peut converger rapidement vers la valeur réelle [11].

Dans ce contexte, nous avons proposé un nouvel algorithme AFFRLS publié dans [16-17] pour extraire les paramètres du modèle Thévenin de la batterie lithium, puis estimer sa tension terminale. AFFRLS est une amélioration de l'algorithme RLS, le RLS souffre du fait que les anciennes données peuvent affecter sa précision, et donc conduire à des erreurs importantes

d'estimation. En plus de l'amélioration de l'algorithme RLS, nous avons proposé une nouvelle expression adaptative pour calculer le facteur d'oubli (forgetting factor  $\lambda$ ). L'algorithme développé est appliqué au modèle équivalent de Thévenin du premier ordre. La relation entre la tension de circuit ouvert (OCV) et l'état de charge (SOC) est décrite en utilisant une adaptation de l'équation de Nernst, le modèle utilise également le terme de correction hystérésis à l'état zéro (zero-state correction term) pour décrire le phénomène d'hystérésis. Dans cette partie, nous allons exposer les résultats des simulations effectuées pour vérifier les performances et la précision de l'algorithme AFFRLS par rapport à l'algorithme RLS dans les profils dynamiques suivants : DST (Dynamic Stress Test), FUDS (Federal Urban Driving Schedule), et le UDDS (Urban Dynamometer Driving Schedule).

### 3.2.2 Modèle utilisé

Le modèle de batterie est identique à celui utilisé dans [6]. Il contient une branche parallèle ( $R1$ ,  $C1$ ) pour simuler le régime transitoire, une résistance  $R2$  qui représente la résistance interne de la batterie. La tension de circuit ouvert OCV est exprimée par une adaptation de la formule de NERNST avec  $K2$ ,  $K1$  et  $K0$  comme paramètres à identifier. Pour l'effet d'hystérésis, il est exprimé par le terme ( $sM$ ).  $s$  désigne le signe du courant et  $M$  étant un paramètre à identifier.  $V$  est la tension de sortie (tension terminale). La figure 3.49 illustre le modèle utilisé :




Figure 3.49 : Modèle utilisé

Le signe  $s$  s'exprime selon :

$$s(k) = \begin{cases} 1 & \text{if } I(k) > \varepsilon \\ -1 & \text{if } I(k) < \varepsilon \\ s(k-1) & \text{if } |I(k)| < \varepsilon \end{cases} \quad (3.51)$$

$k$  est l'indice du temps, et  $\varepsilon$  est un petit nombre positif.

Dans [6], les auteurs ont utilisé les équations ci-dessous ainsi que la technique RLS pour identifier récursivement les paramètres du modèle ( $M$ ,  $C1$ ,  $R1$ ,  $R2$ ,  $K2$ ,  $K1$ ,  $K0$ ), la figure 3.50 illustre le schéma RLS utilisé pour identifier les paramètres de la batterie.

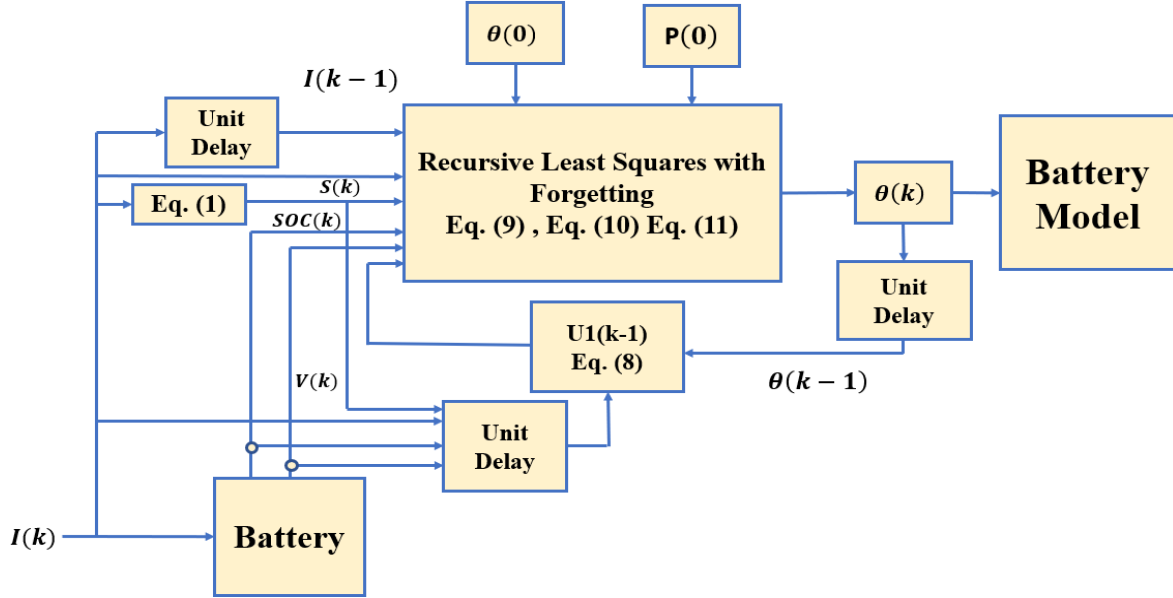


Figure 3.50 : Algorithme RLS [6]

$$SOC(k+1) = SOC(k) - \frac{\eta I(k)\Delta t}{Cn} \quad (3.52)$$

$Cn$  représente la capacité nominale,  $\eta$  est le coefficient de Coulomb qui varie entre 1 (100%) au moment de la décharge et de 0,98 (98%) lors de la charge.  $I(k)$  est le courant dans la batterie considéré positif lors de la décharge et négatif lors de la charge.  $\Delta t$  est le la durée de l'échantillonnage.

$$V(k) = K_0(k) + K_1(k)\ln(SOC(k)) + K_2(k)\ln(1 - SOC(k)) + I(k)R_2(k) + s(k)M(k) - A(k)U_1(k-1) - B(k)I(k-1) \quad (3.53)$$

$V(k)$  représente la tension aux bornes de la sortie, avec :

$$A(k) = \exp\left(\frac{-\Delta t}{R_1(k)C_1(k)}\right) \quad (3.54)$$

$$B(k) = R_1(k) \left[ 1 - \exp\left(\frac{-\Delta t}{R_1(k)C_1(k)}\right) \right] \quad (3.55)$$

$\theta(k)$  contient les paramètres du modèle à identifier ( $M, C_1, R_1, R_2, K_2, K_1, K_0$ ).

$$\theta(k) = [K_0(k), K_1(k), K_2(k), M(k), R_2(k), A(k), B(k)]^T \quad (3.56)$$

$$\varphi(k) = [1, \ln(SOC(k)), \ln(1 - SOC(k)), s(k), -I(k), -U_1(k-1), -I(k-1)] \quad (3.57)$$

$$U_1(k-1) = K_0(k-1) + K_1(k-1)\ln(SOC(k-1)) + K_2(k)\ln(1 - SOC(k-1)) + I(k-1)R_2(k-1) + s(k-1)M(k) - U_1(k) \quad (3.58)$$

$U_1(k-1)$  est la chute de tension aux bornes de la résistance  $R_1$ .

$$P(k) = \frac{P(k-1)G(k)\varphi^T(k)P(k-1)}{\lambda} \quad (3.59)$$

$$G(k) = \frac{P(k-1)\varphi(k)}{\lambda + \varphi^T(k)P(k-1)\varphi(k)} \quad (3.60)$$

$P(k)$ ,  $G(k)$  sont respectivement les matrices de covariance du gain et de l'erreur.  $\lambda$  est le facteur d'oubli.

Le facteur d'oubli ( $\lambda$ ) attribue des poids aux nouvelles et anciennes données et prend généralement une valeur comprise entre 0,95 et 1 [11]. Dans [6], les auteurs ont utilisé un facteur d'oubli constant. Toutefois, pour accélérer le processus d'identification et pour réduire les erreurs, le facteur d'oubli doit être ajustable avec l'erreur d'identification, en particulier lorsque l'erreur est importante [11]. Nous avons proposé une nouvelle expression pour calculer le facteur d'oubli exprimée par :

$$\lambda(k) = \min(\lambda_{\min} + (1 - \lambda_{\min})h^{\varepsilon(k)}, 1) \quad (3.61)$$

$$\varepsilon(k) = \frac{e(k)}{e_{base}} \quad (3.62)$$

$\lambda_{\min}$  est la valeur minimale que le facteur d'oubli peut atteindre, pour donner un bon équilibre entre vitesse et précision, nous avons fixé  $\lambda_{\min}$  à 0,98.  $h$  est un coefficient constant, il indique la sensibilité du facteur d'oubli par rapport aux erreurs. Lorsque  $h$  s'approche de 1,  $\lambda$  tends à ralentir et entraîne une réponse lente. À l'inverse,  $\lambda$  oscille fortement lorsque  $h$  est proche de 0, le temps de réponse est rapide mais la précision est faible. Nous avons fixé le paramètre  $h$  à 0,9 comme dans [11].

$e(k)$  Indique l'erreur échantillonnée au moment  $k$ .  $e_{base}$  est déterminée en fonction de l'ampleur de l'erreur attendue.  $\lambda$  change en fonction de la valeur de  $e(k)$ , si  $e(k)$  dépasse  $e_{base}$ ,  $\lambda$  tend à diminuer afin de stabiliser le processus d'identification, en revanche le facteur d'oubli augmente lorsque  $e(k)$  est inférieur à l'erreur  $e_{base}$ . L'équation 3.61 explique la relation entre le facteur  $\lambda$  et  $e(k)$ , plus la valeur de l'erreur est faible plus  $\lambda$  se rapproche de 1, et inversement, le facteur d'oubli oscille entre 0,98 et 1.

### 3.2.3 Implémentation de l'algorithme AFFRLS

Le modèle traité dans la section 3.2.2 est choisi comme modèle de la batterie, ou les éléments stockés dans le vecteur  $\theta(k)$  (3.56) sont les paramètres du modèle à déterminer à chaque instant d'échantillonnage  $k$ . L'algorithme AFFRLS est appliqué de manière récursive pour calculer le vecteur  $\theta(k)$ . La figure 3.51 illustre le schéma de l'algorithme proposé.

L'algorithme commence par fixer les valeurs initiales du vecteur  $\theta(0)$  : les matrices  $P(0)$  et  $G(0)$ , la sensibilité ( $h$ ), et le facteur d'oubli  $\lambda$ . Ensuite, le vecteur  $\theta(k)$  est actualisé de façon récursive. À chaque cycle, l'algorithme calcule la tension précédente  $U_1(k-1)$  (3.58), puis réajuste le

SOC (3.52). La matrice de gain  $G(k)$  est calculée avant l'évaluation du vecteur  $\theta(k)$ . Les valeurs des paramètres ( $M, C1, R1, R2, K2, K1, K0$ ) sont obtenues à partir du vecteur  $\theta(k)$ . Ensuite, la covariance  $P(k)$  est adaptée pour chaque cycle à l'aide de la matrice  $G(k)$  et le facteur d'oubli. Enfin, la tension de sortie est estimée (3.53), et le facteur d'oubli est mis à jour en se basant sur l'erreur actuelle  $e(k)$  (3.62). Le même processus est répété jusqu'à la fin de l'estimation.

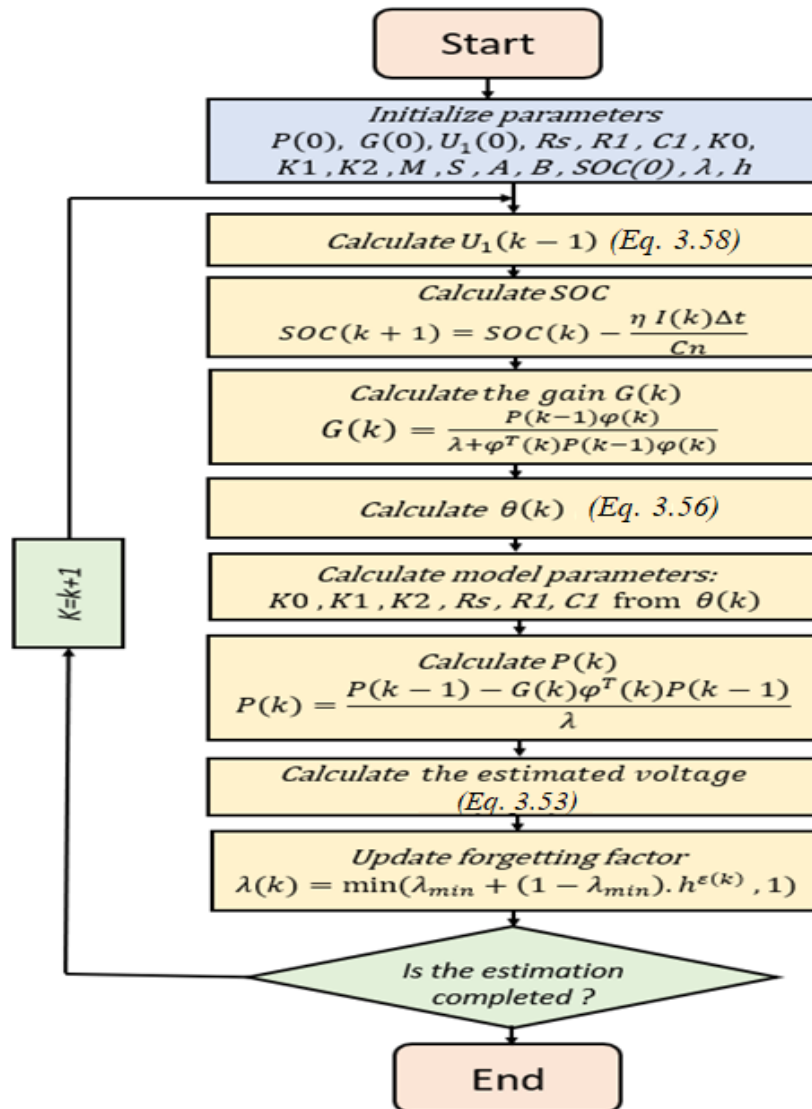


Figure 3.51 : Algorithme AFFRLS proposé

### 3.2.4 Résultats de la comparaison

Dans cette section, nous comparons l'AFFRLS proposé dans la figure 3.51 avec le RLS présenté dans l'article [6], nous appliquons les deux algorithmes au modèle abordé dans la section 3.2.2 pour estimer les paramètres de la batterie et la tension de sortie.

La performance des algorithmes est vérifiée à l'aide des données expérimentales fournies par l'Université McMaster de Hamilton, Ontario, Canada, réalisées sur la cellule de batterie Li-ion LG 18650HG2 dans le profil UDDS (Urban Dynamometer Driving Schedule) [7], en plus de deux ensembles de données fournis par le Groupe de recherche sur les batteries CALCE réalisés sur la batterie li-ion Samsung (INR 18650-20R) dans deux profils dynamiques : DST (Dynamic stress test) et FUDS (Federal urban driving schedule) [8-10].


### 3.2.4.1 UDDS test

L'UDDS est un cycle de conduite commun qui est souvent utilisé pour évaluer les modèles des batteries et les algorithmes d'estimation. L'UDDS représente les conditions de conduite en ville. Il est utilisé pour les essais de véhicules légers, créé à l'origine comme point de référence pour les véhicules à carburant fossile, il est également utilisé pour la voiture électrique afin de donner une approximation du kilométrage parcouru par le véhicule électrique sur une seule charge.

Une cellule LG 18650HG2 3Ah toute neuve a été testée dans une chambre thermique (tableau 3.8 et figure 3.52). Un testeur de batterie universel de 5 volts, 75 ampères (Digatron Firing Circuits) est utilisé avec une précision de tension et de courant de 0,1% figure 3.53. Les données ont été collectées pour différentes températures. Nous avons utilisé des données effectuées à température ambiante (25°C). La figure 3.54 illustre le courant dans le profil dynamique UDDS, le courant oscille vigoureusement comme on peut le voir, la cellule est soumise à un courant élevé qui varie entre +5A (charge) et -9A (décharge).

**Tableau 3.8 : Paramètres de la batterie**

Batterie LG 18650HG2	
Batterie (Paramètres)	Spécifications (valeur)
Capacité nominale	3000mAh
Chimie	Li [NiMnCo]O <sub>2</sub> (H-NMC) / Graphite + SiO
Tension nominale	3.6 V
Charge	4A, 4.2V, 100mA Courant de fin (CC-CV) Rapide 1,5A, 4,2, 50mA Courant de fin (CC-CV) Normal
Décharge	Tension de fin de décharge 2V, courant continu 20A MAX
Densité d'énergie	240 (Wh/Kg)



**Figure 3.52 : Batterie LG 18650HG2**

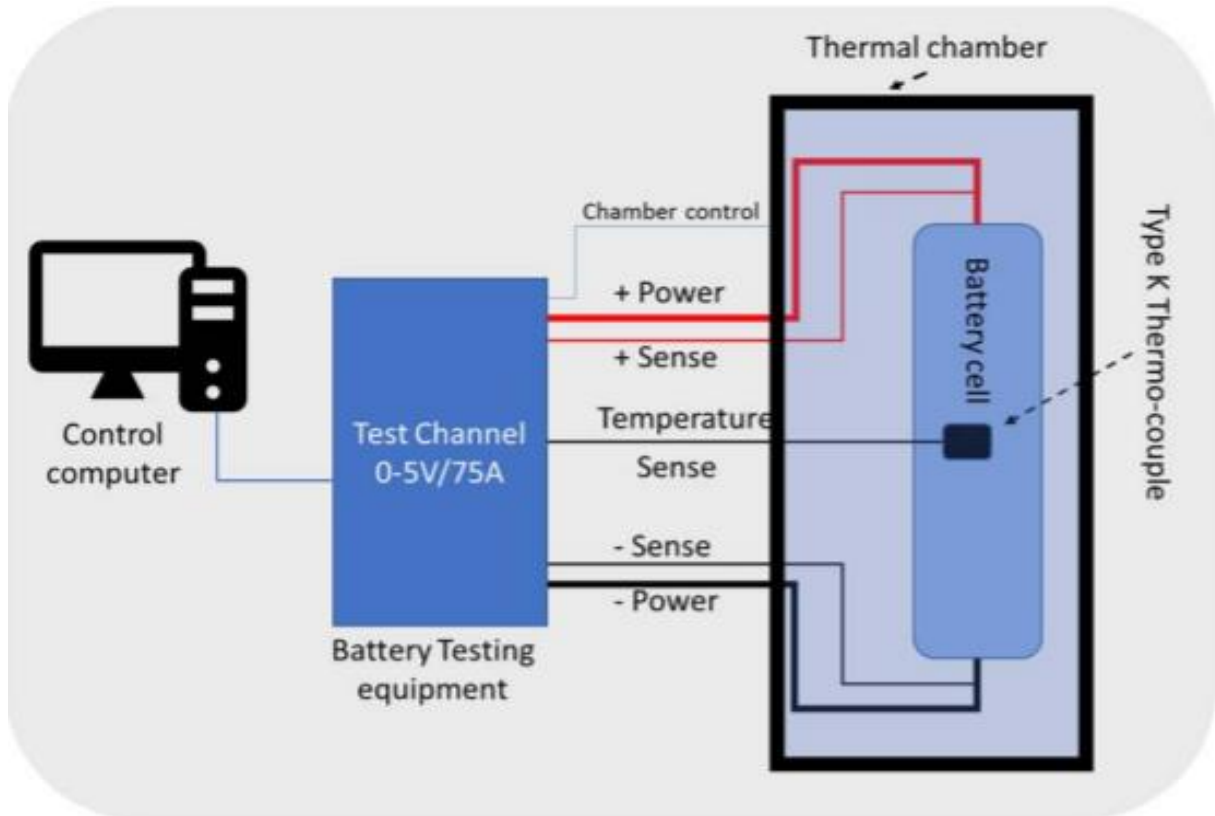


Figure 3.53 : Schéma du banc d'essai [184]


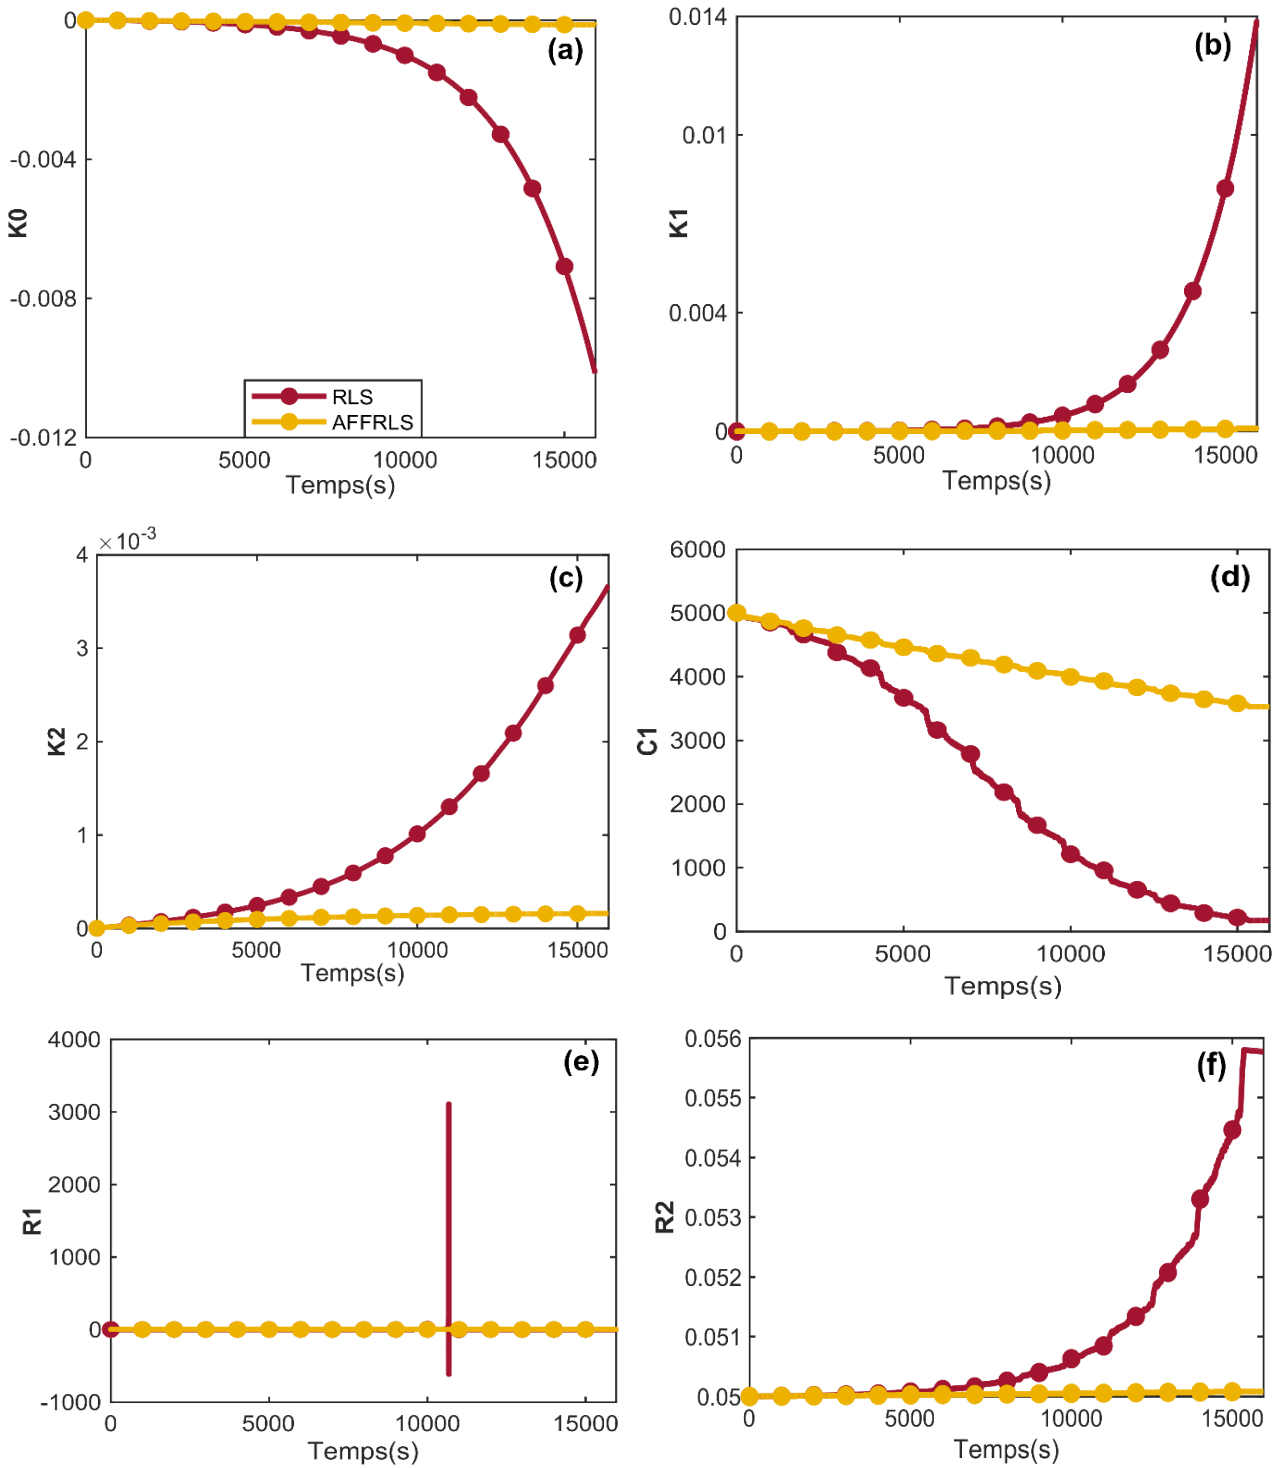


Figure 3.54 : Courant test UDDS

L'UDDS est utilisé afin de comparer les algorithmes. Le courant de ce profil est illustré à la figure 3.54. Le RLS et l'AFFRLS ont été initialisés avec les mêmes valeurs :  $\theta(0)$  : vecteur des paramètres de la batterie à identifier (3.56). La matrice de gain  $G(0)$  et la matrice de covariance des erreurs  $P(0)$ . La chute de tension initiale  $U_1(0)$  aux bornes de la résistance  $R_1$  (3.58). Nous avons également fourni le facteur d'oubli  $\lambda$  pour chacun des deux algorithmes. Le facteur d'oubli pour le RLS a été fixé à 0.9996, comme dans [6], pour AFFRLS, le facteur d'oubli a été initialisé comme précisé dans la section 3.2.2.

Ensuite, les deux algorithmes sont exécutés pour estimer les paramètres et la tension de sortie de la batterie. À chaque cycle, nous fournissons aux algorithmes les mesures (courant et tension) enregistrées dans l'ensemble de données pour ce test. Dans la figure 3.55, nous reportons les résultats de l'identification des paramètres. Dans la figure 3.56, nous avons tracé la tension estimée par les deux méthodes et l'avons comparé à la tension de sortie réelle (valeur mesurée enregistrée dans l'ensemble de données). L'erreur d'estimation de la tension de sortie est illustrée dans la figure 3.57.





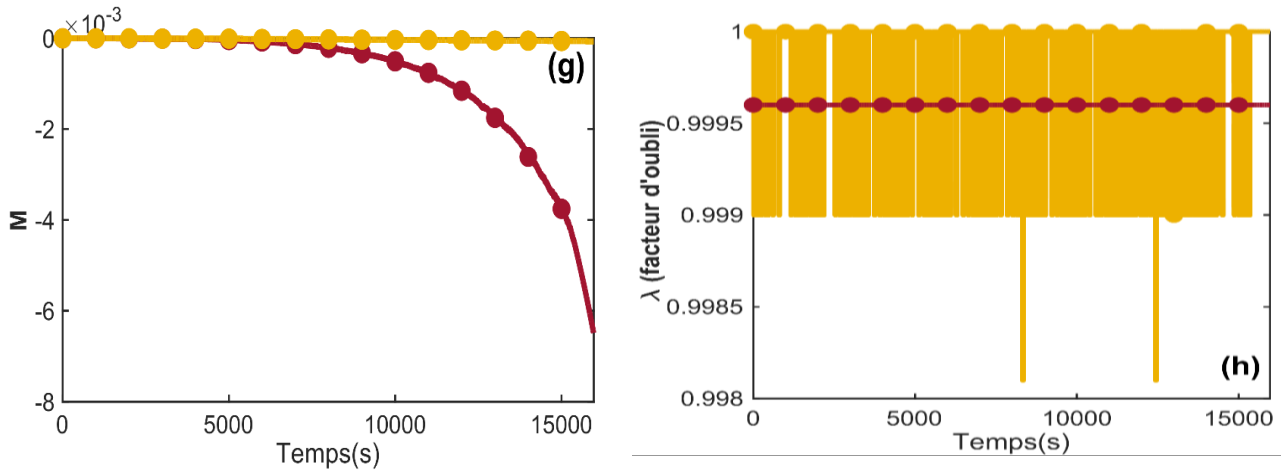


Figure 3.55 : Identification des paramètres par RLS et AFFRLS pour le test UDSS : (a), (b) et (c) Identification des paramètres de Nernst  $K_0$ ,  $K_1$  et  $K_2$  respectivement (d) Identification de  $C_1$  (e) Identification de  $R_1$  (f) Identification de  $R_2$  (g) Identification de  $M$  (h) Identification du facteur d'oubli.




Figure 3.56 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS




Figure 3.57 : Erreur d'estimation de la tension de sortie pour les deux algorithmes




Figure 3.58 : Proportion en pourcentage des points d'erreur relatifs absolus pour RLS et AFFRLS dans le test dynamique UDDS

La figure 3.58 est tracée en comptant les points d'erreurs relatifs absolus tombant dans chaque intervalle (0~0.5%, 0.5~1%...) puis en l'exprimant en pourcentage.

### 3.2.4.2 Test de stress dynamique (DST)

Le DST est un test de décharge à puissance variable qui est échelonné en fonction d'un pourcentage de la puissance nominale maximale des véhicules de test. C'est un cycle de conduite commun qui est souvent utilisé pour évaluer divers modèles de batterie et des algorithmes d'estimation de l'état de charge. Le test est mis à l'échelle en fonction de la puissance de pointe de la batterie. Nous l'avons utilisé ici pour comparer les deux algorithmes. Le profil de ce courant est illustré dans la figure 3.59, La configuration de l'expérience est présentée à la figure 2.39. La cellule lithium-ion (LiFePO4) de type cylindrique 18650 est utilisé.


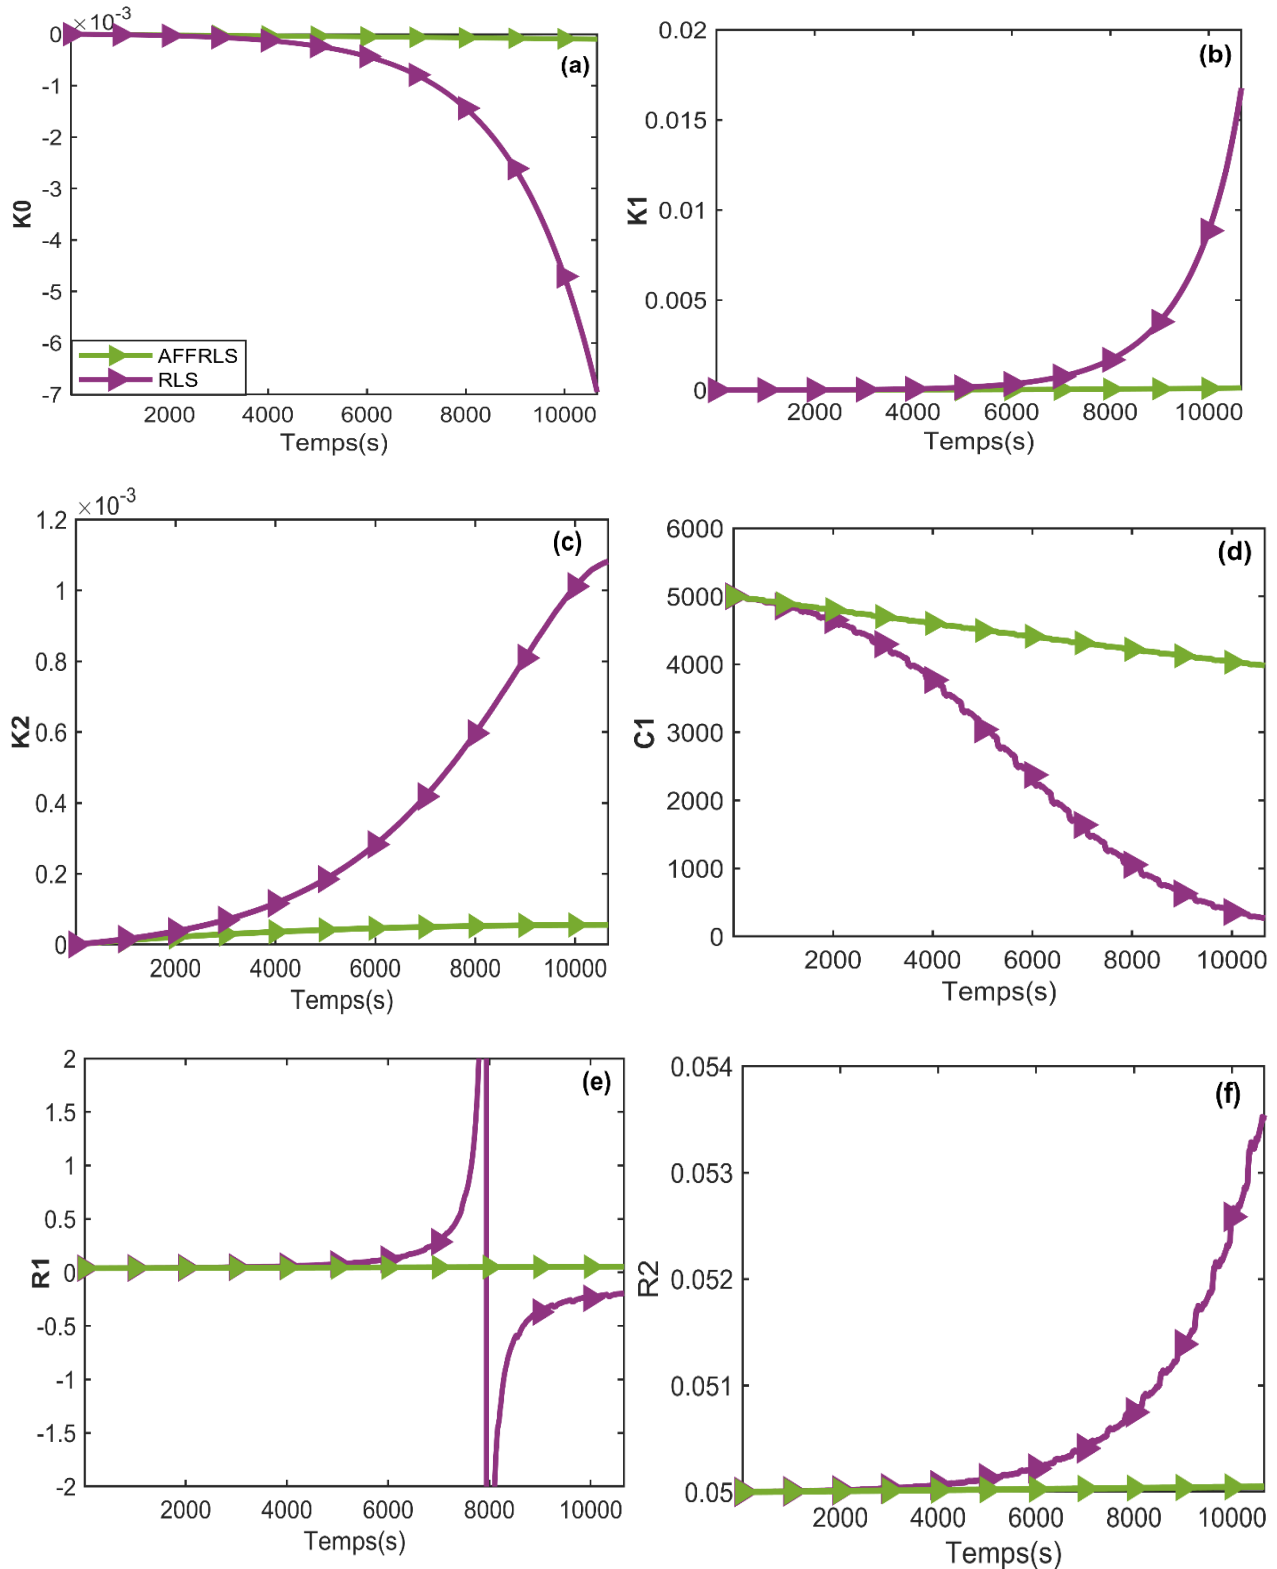


Figure 3.59 : Courant test DST

Nous avons fourni les mêmes valeurs initiales pour les deux algorithmes comme le cas pour le premier test (UDDS). Puis, nous avons exécuté ensuite dans MATLAB les algorithmes RLS et AFFRLS. À chaque itération, nous fournissons aux algorithmes le courant et la tension stockés dans les bases de données fournies par le groupe de recherche CALCE. Dans la figure 3.60, nous avons collecté les résultats de l'identification des paramètres pour les deux algorithmes. Sur les figures 3.61, 3.62, nous traçons respectivement la tension de sortie estimée par les deux algorithmes et l'erreur d'estimation.



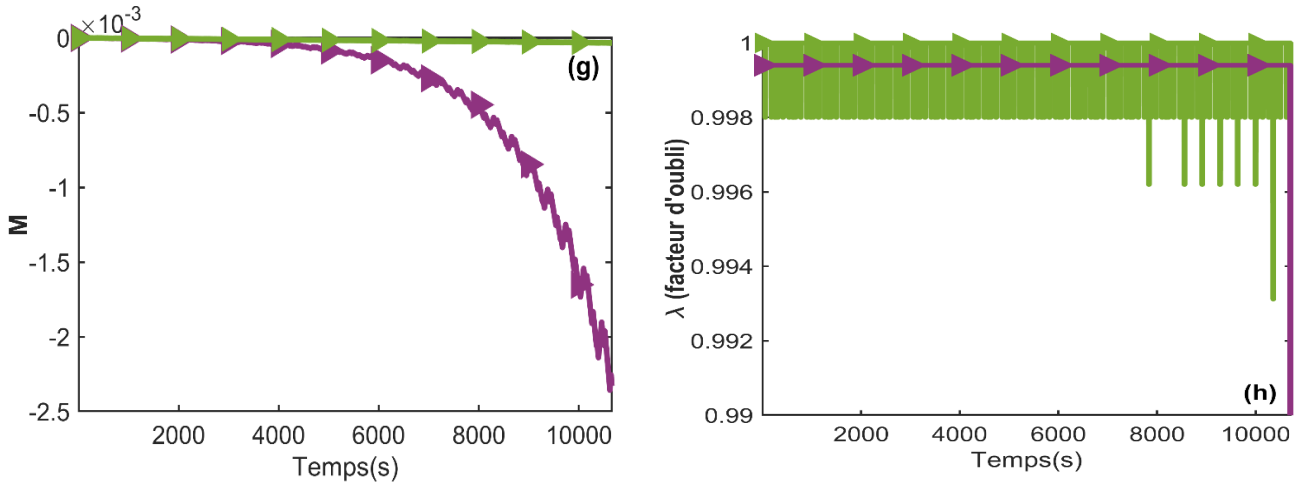


Figure 3.60 : Identification des paramètres par RLS et AFFRLS pour le test DST : (a), (b) et (c) Identification des paramètres de Nernst  $K_0$ ,  $K_1$  et  $K_2$  respectivement (d) Identification de  $C_1$  (e) Identification de  $R_1$  (f) Identification de  $R_2$  (g) Identification de  $M$  (h) Identification du facteur d'oubli




Figure 3.61 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS




Figure 3.62 : Erreur d'estimation de la tension de sortie pour les deux algorithmes




Figure 3.63 : Proportion en pourcentage des points d'erreurs relatifs absolues pour RLS et AFFRLS dans le test dynamique DST.

De même, on trace dans la figure 3.63 la proportion des points d'erreurs relatives absolues exprimer en pourcentage.

### 3.2.4.3 Test FUDS (Federal urban driving schedule)

FUDS représente un profil de conduite en ville pour les véhicules légers, avec des arrêts et des démarrages fréquents. Le courant de ce test peut être visualisé sur la figure 3.64. On peut voir que le profil actuel du FUDS est plus instable et présente plus d'oscillations que celui du DST et du UDDS.

Nous avons procédé de la même manière que dans le cas du DST et du UDDS. Nous avons initialisé les deux algorithmes avec les paramètres requis :  $(\theta(0), G(0), P(0), U_1(0))$ , et le facteur d'oubli  $\lambda$ .

Ensuite, les algorithmes sont exécutés de la même manière que dans les tests précédents. La Figure 3.64 illustre les résultats d'identification des paramètres du test RLS et AFFRLS pour le profil FUDS. La figure 3.65 montre la tension terminale réelle et les deux tensions identifiées par RLS et AFFRLS, l'erreur de tension estimée est tracée dans la figure 3.67.

La proportion en pourcentage des points d'erreur relatifs absolues est tracée (Figure 3.68) de la même manière que les figures 3.58 et 3.63.


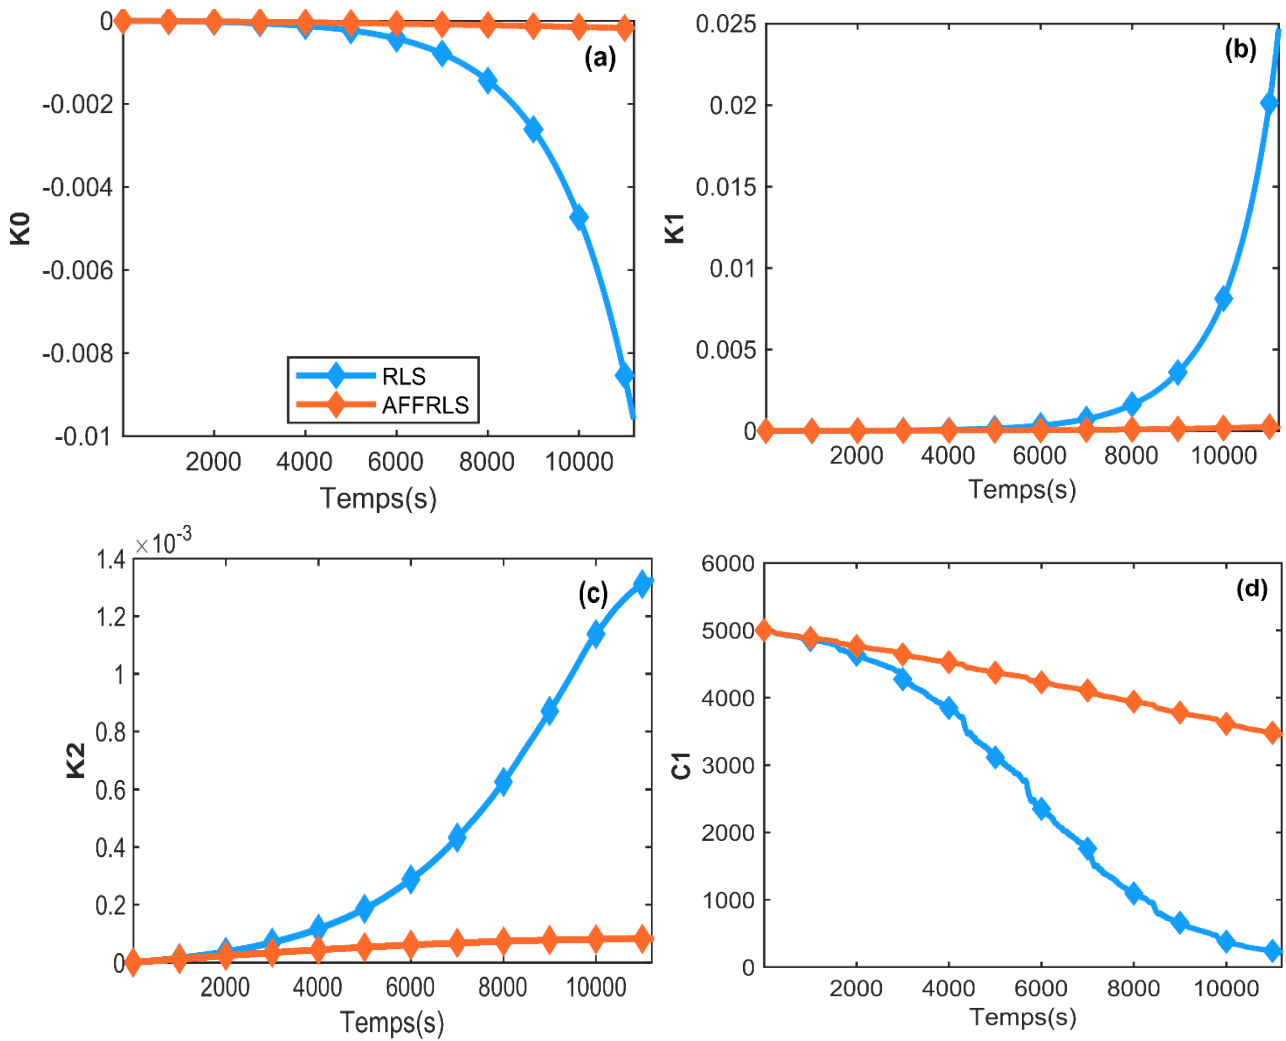


Figure 3.64 : Courant test FUDS



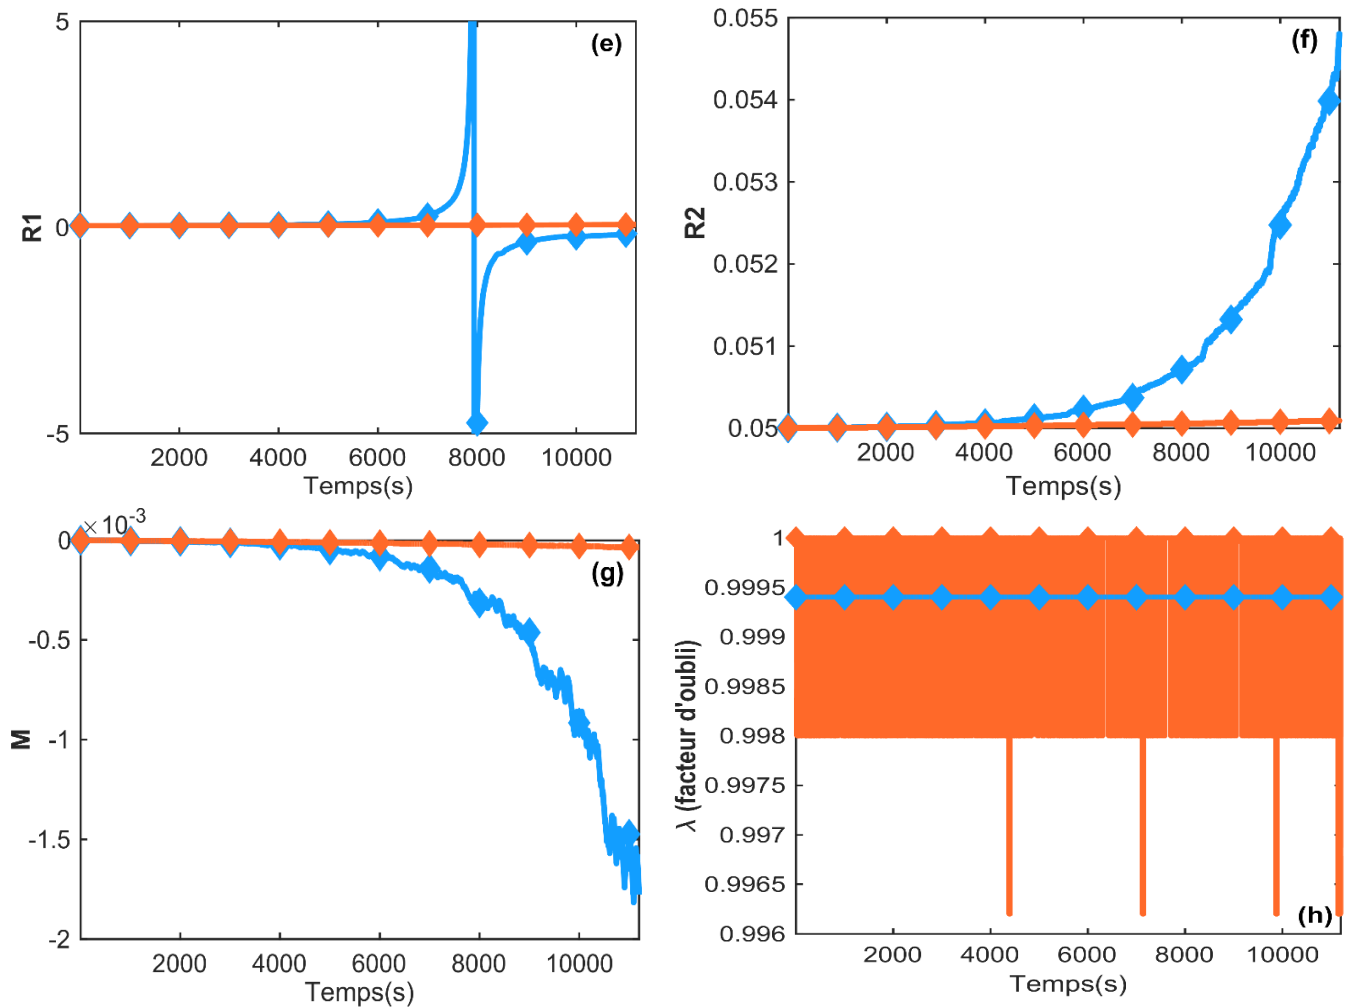


Figure 3.65 : Identification des paramètres par RLS et AFFRLS pour le test FUDS : (a), (b) et (c) Identification des paramètres de Nernst  $K0$ ,  $K1$  et  $K2$  respectivement (d) Identification de  $C1$  (e) Identification de  $R1$  (f) Identification de  $R2$  (g) Identification de  $M$  (h) Identification du facteur d'oubli




Figure 3.66 : Tension de sortie mesurée et estimée par les algorithmes RLS et AFFRLS




Figure 3.67 : Erreur d'estimation de la tension de sortie pour les deux algorithmes




Figure 3.68 : Proportion en pourcentage des points d'erreur relatifs absolus pour RLS et AFFRLS dans le test dynamique FUDS

### 3.2.5 Discussion

Les figures 3.55,3.60,3.65 montrent que les paramètres extraits par l'algorithme AFFRLS sont plus stables, les paramètres identifiés varient lentement avec la variation du courant. Ceci est attribué au fait que l'algorithme AFFRLS permet au facteur d'oubli ( $\lambda$ ) de changer afin de réduire l'erreur entre la tension de sortie réelle et estimée, ce qui permet une plus grande flexibilité pour identifier les paramètres du modèle de batterie. En revanche, le RLS a un facteur d'oubli constant  $\lambda$ , en conséquence pour minimiser l'erreur d'identification, le RLS fait osciller les paramètres dans le vecteur  $\theta(k)$ , de sorte que nous repérons plus de fluctuations et parfois des pics dans les paramètres de la batterie collectés par la méthode RLS.

La tension estimée par les deux algorithmes est proche de la tension réelle mesurée, bien que l'AFFRLS a montré une erreur faible par rapport à la méthode RLS (figure 3.56-3.57, 3.61-3.62, 3.66-3.67).



Si on regarde de plus près, on peut observer que l'AFFRLS est plus précis, comme le montre les figures 3.58,3.63,3.68 où nous exposons la distribution des erreurs relatives absolues pour chaque algorithme. Ces figures montrent que l'AFFRLS est plus précis en termes d'identification des paramètres que RLS. La répartition des erreurs relatives absolues du AFFRLS a une proportion plus élevée pour les erreurs faibles (<1%) que le RLS. La distribution diminue pour les intervalles élevés (supérieur à 2 %), jusqu'à 6,4 % de moins que le RLS. Cela signifie que l'AFFRLS est supérieur en termes de précision par rapport à la méthode RLS dans l'identification des paramètres du modèle de la batterie lithium.

### **3.3 Algorithme Sunflower**

#### **3.3.1 Introduction**

Dans le même cadre d'estimation des paramètres en ligne, nous avons proposé une nouvelle méthode basée sur l'algorithme SFO (Sunflower Optimization Algorithm) [18-19]. SFO est une des récentes métaheuristiques qui simule le mouvement du tournesol vers le soleil. SFO est appliqué pour extraire les paramètres du modèle Thévenin (premier ordre), puis estimer la tension terminale (de sortie). Le problème d'identification des paramètres est exprimé sous la forme d'une représentation d'état (state space model). Pour mesurer l'efficacité de la technique suggérée, nous avons utilisé des données expérimentales réalisées sur la cellule de la batterie lithium-ion A123 sous trois profils dynamiques : DST, US06 et FUDS. Les données utilisées ont été récupérées auprès du groupe de recherche sur les batteries CALCE. Une comparaison entre SFO et l'AFFRLS [11] est établie afin de prouver la capacité et la précision de l'algorithme présenté. Les résultats montrent que le modèle calibré utilisant SFO est supérieur à celui qui utilise l'algorithme AFFRLS pour simuler le comportement dynamique de la batterie lithium-ion. Au meilleur de notre connaissance, ce travail est l'une des premières tentatives d'utilisation du SFO pour estimer les paramètres de la batterie en temps réel.

#### **3.3.2 Modèle de la batterie**

Un modèle Thévenin est adopté avec un seul réseau RC ( $R_1, C_1$ ) figure 3.69. Le réseau RC décrit le régime transitoire,  $R_0$  simule la chute de tension instantanée. La tension de circuit ouvert OCV est représentée par une source de tension décrite par l'équation (3.63) avec deux paramètres  $K_0, K_1$  à identifier.

$$V_{ocv} = f(SOC) = K_0 + K_1 * SOC \quad (3.63)$$

Selon la loi de Kirchhoff, la tension terminale  $V$  est décrite comme :

$$V_{ocv} = V_{ocv} - R_0 * I + U_1 \quad (3.64)$$

Nous pouvons déduire l'équation ci-dessous entre le courant  $i$  et la tension  $U_1$  aux bornes du réseau  $R_1C_1$ .

$$C_1 \frac{dU_1}{dt} + \frac{U_1}{R_1} = i \quad (3.65)$$




Figure 3.69 : Modèle de la batterie adopté

Le problème d'identification des paramètres est exprimé sous la forme d'un modèle d'espace d'état. En utilisant le modèle figure 3.69 et les équations (3.63), (3.64) et (3.65), la représentation d'état du modèle de la batterie est formulée par les équations suivantes :

$$x(k) = A.x(k-1) + B.u \quad (3.66)$$

$$V(k) = y(k) = C.x(k) + D.u \quad (3.67)$$

Avec :

$$x(k) = \begin{bmatrix} SOC(k) \\ U_1(k) \end{bmatrix} \quad A = \begin{bmatrix} 1 & 0 \\ 0 & 1 - \frac{\Delta t}{R1 * C1} \end{bmatrix} \quad B = \begin{bmatrix} -\frac{\Delta t}{Q} \\ \frac{1}{C1} \end{bmatrix} \quad C = [K_1 \quad 1] \quad D = -R_0 \quad u = i(k)$$

$\Delta t$  représente la durée de l'échantillonnage.

### 3.3.3 Formulation du problème

L'algorithme SFO est utilisé pour identifier les paramètres ( $K_0$ ,  $K_1$ ,  $R_0$ ,  $R_1$ ,  $C_1$ ) du modèle d'espace d'état discuté dans la section précédente et pour estimer la tension de sortie de la batterie  $V(k)$ . Comme SFO est un algorithme d'optimisation, une fonction objective doit être définie pour mesurer l'écart entre la tension terminale estimée (par SFO) et la tension mesurée expérimentalement. La fonction objective utilisée est basée sur la minimisation de l'erreur quadratique entre les données expérimentales et le résultat de la simulation basée sur le modèle. Cette fonction est considérée comme fonction objective principale.

$$F = \left( \frac{V_{hat} - V_{ex}}{V_{ex}} \right)^2 \quad (3.68)$$

Où  $V_{hat}$  est la tension de sortie estimée et  $V_{ex}$  est la tension mesurée.

La fonction objective décrite à (3.68) est résolue par SFO soumis aux contraintes suivantes, min et max désignent les valeurs minimales et maximales des paramètres de la batterie :

$$\begin{cases} R_{0\min} < R_0 < R_{0\max} \\ R_{1\min} < R_1 < R_{1\max} \\ C_{1\min} < C_1 < C_{1\max} \\ K_{0\min} < K_0 < K_{0\max} \\ K_{1\min} < K_1 < K_{1\max} \end{cases} \quad (3.69)$$

### 3.3.4 Algorithme Sunflower

Inspiré de la nature. SFO est une nouvelle méthode qui repose sur la loi inverse du rayonnement [185-191], c'est une technique basée sur la population suggérée par G.F Gomes [191], SFO simule le mouvement des tournesols pour capter le rayonnement du soleil en tenant compte de la pollinisation entre les tournesols voisins. Les tournesols cherchent la meilleure orientation vers le soleil et se déplacent pour capter le maximum de rayonnement. L'intensité du rayonnement  $S_{rads}$  augmentera si la distance entre le soleil et les tournesols diminue et inversement selon l'équation ci-dessous :

$$S_{rads} = \frac{S_{pwr}}{4\pi r^2} \quad (3.70)$$

$S_{pwr}$  est la source d'énergie, et  $S_{rads}$  est l'intensité du rayonnement solaire reçue par les tournesols,  $r$  représente la distance du tournesol par rapport au soleil.

La direction  $S_i$  de chaque tournesol (plante) vers le soleil est exprimée par :

$$S_i = \frac{X^* - X_i}{\|X^* - X_i\|} \quad i = 1, 2, \dots, n \quad (3.71)$$

$n$  indique le nombre de population.  $X^*$  est la meilleure solution parmi les  $n$  tournesols, et  $X_i$  est la position actuelle du tournesol  $i$ .

Chaque plante est avancée vers la lumière du soleil par un pas  $d_i$ , exprimé par

$$d_i = \lambda * P_i(\|X_i + X_{i-1}\|) * \|X_i + X_{i-1}\| \quad (3.72)$$

$\lambda$  est une constante qui définit le déplacement inertiel des tournesols,  $P_i(\|X_i + X_{i-1}\|)$  indique la probabilité de pollinisation entre deux plantes voisines. Le pas d'une plante individuelle (tournesol) est limité comme indiqué dans l'équation ci-dessous :

$$d_{\max} = \frac{\|X_{\max} - X_{\min}\|}{2N_p} \quad (3.73)$$

Les positions des tournesols sont actualisées dans les limites  $X_{min}$  et  $X_{max}$ , où  $X_{min}$  et  $X_{max}$  sont respectivement les limites minimales et maximales.  $N_p$  est le nombre de population. L'équation suivante actualise la position actuelle de la population :

$$\overrightarrow{X}_{i+1} = \overrightarrow{X}_i + d_i * \overrightarrow{s}_i \quad (3.74)$$

Les étapes du SFO sont exposées ci-dessous :

1-Initialiser les positions des tournesols de façon arbitraire. Chaque plante représente les paramètres estimés dans leurs limites  $X_{min}$  et  $X_{max}$ .

2-Calculer la fonction objective pour chaque tournesol et trouver la meilleure valeur (3.68).

3-Diriger tous les tournesols vers la position du soleil (3.71).

4-Tant que ( $k < \text{Max\_iteration}$ )

4.1-Pour chaque plante (tournesol), calculer le vecteur de direction (3.71).

4.2-Réduire la population de  $m$  (%) : les plantes trop éloignées du soleil.

4.3-Calculer le pas pour chaque tournesol (3.72).

4.4-Fertiliser les meilleurs tournesols : tournesol proche du soleil.

4.5-évaluer la nouvelle position pour toutes les plantes (3.68).

4.6-Trouver le meilleur candidat et mettre à jour la nouvelle meilleure position.

5-Identifier la meilleure position.

Dans les publications [18-19], nous avons utilisé l'algorithme SFO pour extraire en temps réel les paramètres du modèle de la batterie ( $K_0$ ,  $K_1$ ,  $R_0$ ,  $R_1$ ,  $C_1$ ) discuté dans la section 3.3.2. L'organigramme de l'algorithme proposé est illustré à la figure 3.70. L'algorithme commence par la construction du modèle d'espace d'état et l'initialisation des paramètres SFO. Pour accélérer la convergence de l'algorithme, nous avons utilisé un nombre réduit de  $N_p$  (taille de la population,  $N_p = 5$ ) et fixé l'itération maximale à 10. Pour chaque nouvelle valeur échantillonnée du courant instantané  $i(k)$ , l'algorithme calcule la tension de sortie estimée en utilisant (3.66) et (3.67), puis déduit la fonction objective (3.68). Ensuite, SFO prend la relève pour estimer les paramètres dans le but de minimiser la fonction objective (l'écart entre la tension terminale expérimentale et la tension terminale estimée). L'algorithme ne s'arrête que lorsque la fonction objective est inférieure à un seuil défini. Nous permettons cependant à l'algorithme de quitter la fonction SFO lorsque la tension de sortie relative est inférieure à 1% dans le but d'accélérer le processus d'estimation.

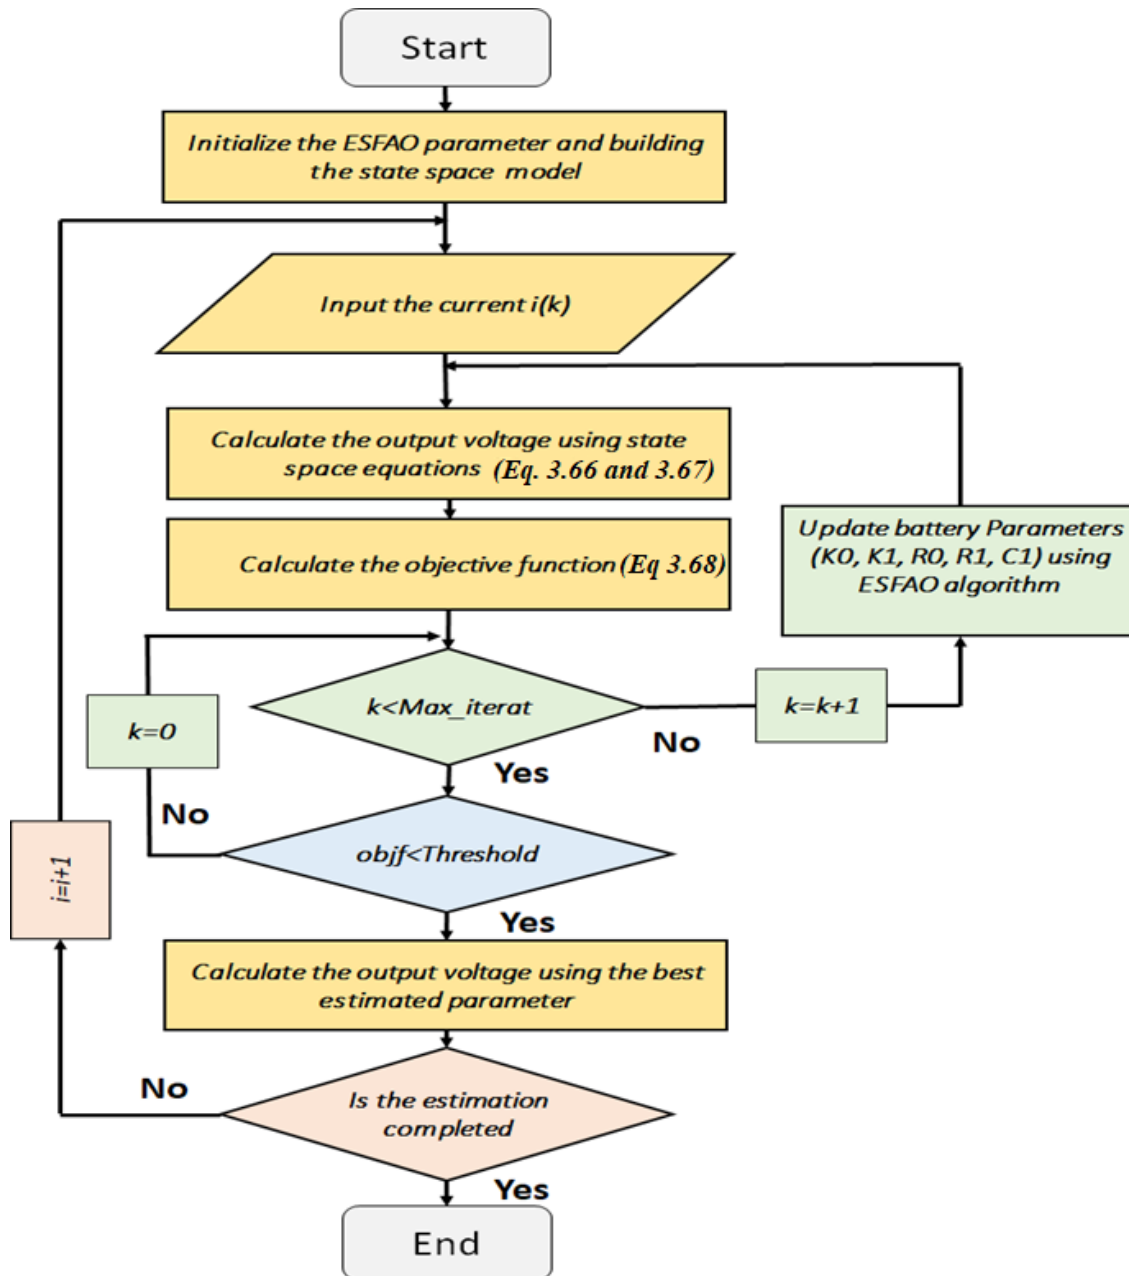


Figure 3.70 : Organigramme de l'algorithme proposé basé sur SFO

### 3.3.5 Résultat et discussion

Dans cette section, nous allons comparer l'algorithme SFO (figure 3.70) et l'AFFRLS proposé dans [11]. Nous insistons sur le fait que nous allons comparer les algorithmes et non pas les modèles. Les paramètres de l'AFFRLS sont extraits de [11]. Le tableau 3.9 montre les paramètres du SFO proposé, tandis que le tableau 3.10 définit les limites des paramètres estimés de la batterie.

Tableau 3.9 : Paramètres de l'algorithme SFO

Nombre de tournesols	Taux de pollinisation	Taux de mortalité	Taux de survie	Maximum d'itération	Seuil
5	0.1	0.005	0.9	20	$10^{-4}$

**Tableau 3.10 : Limites des paramètres de la batterie**


	R0( $\Omega$ )	R1( $\Omega$ )	C1(F)	K0	K1
Limite inférieure	0.01	100	40	0	2
Limite supérieure	0.06	1500	120	2.5	7

Pour évaluer la précision des algorithmes, nous avons utilisé des données réelles collectées par le groupe CALCE (Center for Advanced Life Cycle Engineering Battery) sur la batterie lithium-ion A123 (ANR26650M1-A). Nous avons employé un ensemble de données qui a été cyclée selon trois profils dynamiques nommés : DST (Dynamic stress Test), US06 (Supplemental Federal Test Procedure), et le protocole FUDS (Federal Urban Driving Schedule) à 25°C maintenu stable pendant l'expérience par une chambre de température [8,10].

L'ANR26650M1-A (figure 3.71) est la toute première génération de la cellule cylindrique 26650 d'A123 Systems. Cette cellule lithium-ion est généralement utilisée pour les véhicules électriques, mais convient à une grande variété d'applications et de conceptions de systèmes. Ayant fait ses preuves dans des conditions très difficiles, combinant durabilité, fiabilité et sécurité, la cellule ANR26650 offre une excellente combinaison qualité-prix.

Applications de la cellule :

- Appareils portables de haute puissance
- Systèmes de batterie de secours stationnaires
- Systèmes de stockage d'énergie pour la stabilisation du réseau
- Véhicules électriques hybrides (HEV) pour camions et bus commerciaux.



**Figure 3.71 : Batterie A123**

**Tableau 3.11 : Paramètres de la batterie**

Batterie A123	
Batterie (Paramètres)	Spécifications (valeur)
Capacité nominale	2230mAh
Chimie	LiFePO4
Tension nominale	3.6 V
Diamètre	25.4 mm
Longueur	65 mm
Poids	76 g

Pour obtenir ces données, CALCE a utilisé un banc d'essai (figure 3.72) qui comprend : Une chambre thermique pour réguler la température, un système de test de batterie Arbin BT2000 pour superviser la charge et la décharge de la batterie, un logiciel Arbin pour visualiser et contrôler les informations des données sur un ordinateur central, et des cellules de batterie au lithium [8,10]. Le profil de recharge en courant constant/tension constante (CCCV) a été utilisée pour charger la cellule de batterie Samsung A123. Les données ont été collectées pour différentes températures [8,10]. Nous avons exploité les données effectuées à 25°C.

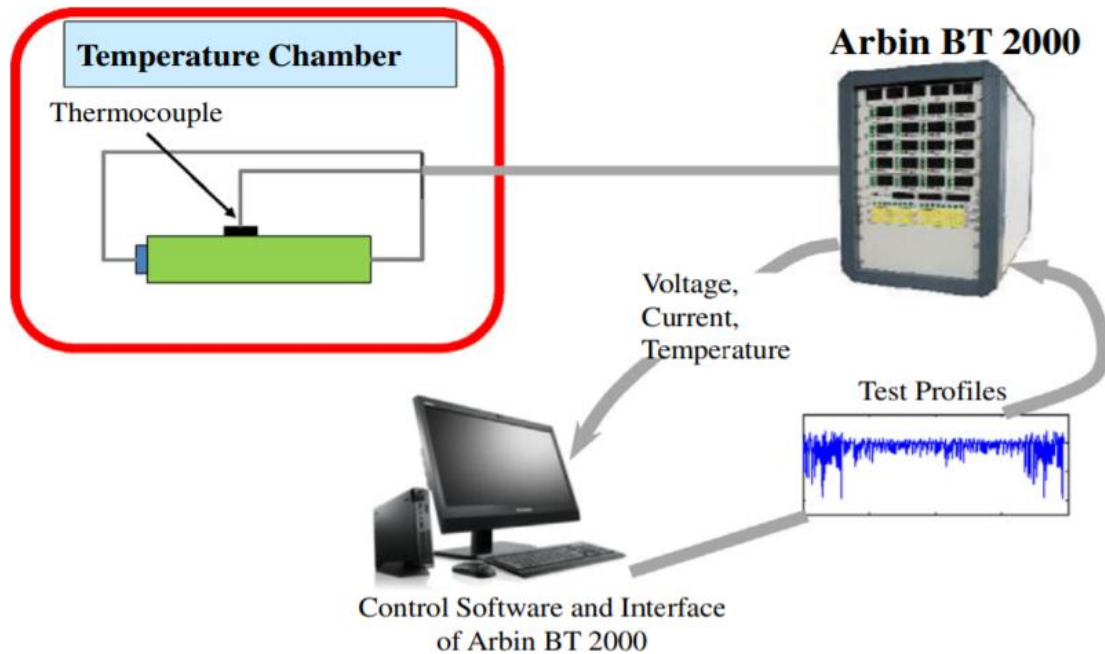


Figure 3.72 : Configuration expérimentale [8,10]

Le DST, l'US06, et le FUDS sont des cycles de conduite courants qui sont souvent utilisés pour évaluer les modèles de batterie et les algorithmes d'estimation. La cellule de la batterie A123 est soumise à ces trois profils dynamiques consécutivement, comme le montre la figure 3.73 où nous traçons le courant. Nous pouvons voir que le courant de la cellule varie entre -4A et +2A. Dans ces conditions, la validité des algorithmes étudiés peut être bien vérifiée.

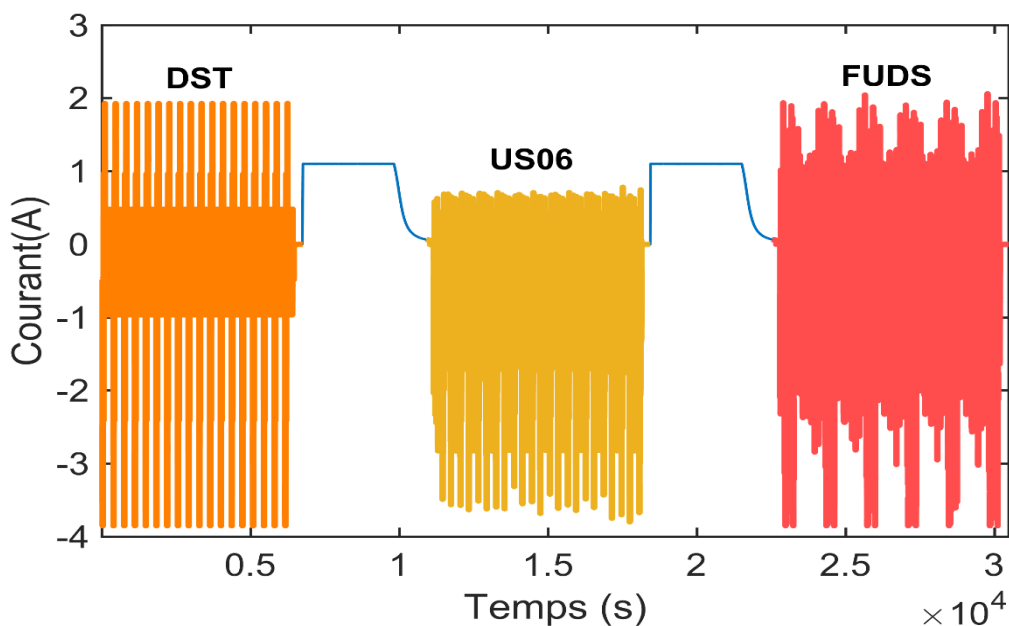
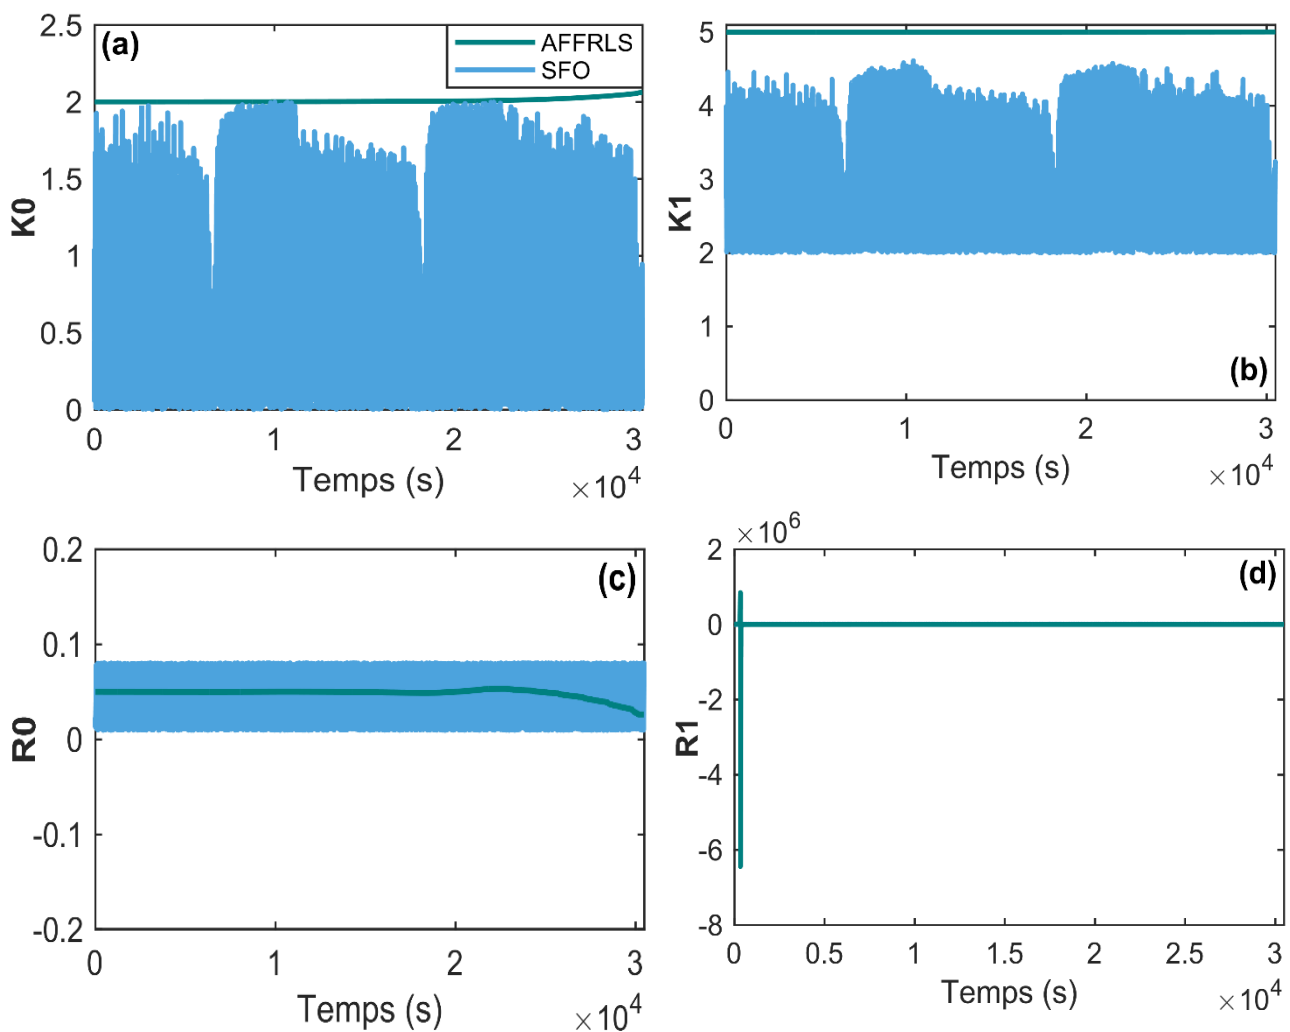


Figure 3.73 : Courant dans les cycles de conduite DST, US06 et FUDS à 25°C

Nous exécutons les algorithmes SFO et AFFRLS pour estimer les paramètres ( $K_0$ ,  $K_1$ ,  $R_0$ ,  $R_1$ ,  $C_1$ ) et la tension de sortie (tension aux bornes) de la batterie. À chaque cycle, nous fournissons aux deux algorithmes les mesures stockées dans l'ensemble de données (courant et tension). Dans la figure 3.74, nous traçons les paramètres de la batterie identifiés par AFFRLS et SFO. Sur la figure 3.75, nous relevons la tension mesurée de sortie et celle estimée par les deux algorithmes.

Comme montre la figure 3.74, les paramètres déterminés par SFO fluctuent davantage, ce qui est normal puisque la procédure d'identification de l'algorithme est basée sur une initialisation aléatoire des paramètres (dans des limites  $[X_{min}, X_{max}]$ ), qui se produit à chaque cycle.

Cependant, les paramètres décrits par l'AFFRLS sont plus stables à l'exception d'un pic rare dans  $R_1$ . Les paramètres de l'AFFRLS évoluent de façon fluide avec les oscillations du courant. Cela peut s'expliquer par le fait qu'AFFRLS repose sur les données précédentes pour déterminer les valeurs futures, d'où le caractère stable des paramètres prévus par rapport à l'algorithme SFO. Pour une meilleure évaluation des algorithmes, nous allons examiner de près la tension de sortie estimée. La tension terminale estimée à l'aide du SFO et d'AFFRLS et la tension de sortie réelle sont représentées sur la figure 3.75. L'erreur estimée pour les deux méthodes est montrée à la figure 3.76.








Figure 3.74 : Résultats de l'identification des paramètres  $K0$  (a),  $K1$  (b),  $R0$  (c),  $R1$  (d),  $C1$  (e)





Figure 3.75 : Tension de sortie estimée par les deux algorithmes ainsi que la tension réelle






Figure 3.76 : Sections zoomées de la tension de sortie réelle et estimée par les algorithmes AFFRLS et SFO

Les deux algorithmes sont capables d'estimer la tension de sortie, comme le montre la figure 3.75. Des portions agrandies de cette figure sont représentées dans la figure 3.76.

Un examen plus approfondi montre que SFO a une erreur de tension étroite par rapport à AFFRLS comme le montre la figure 3.77. L'erreur estimée par SFO varie entre  $-0,03V$  et  $+0,03V$ , cela résulte du fait que nous avons défini un seuil strict pour la fonction objective (3.68). Toutefois, l'AFFRLS a montré une erreur estimée qui dépasse dans la plupart du temps  $0,2V$ , le pic enregistré était de  $0,5V$ , ce qui signifie que SFO a une meilleure estimation des paramètres que la méthode AFFRLS.




Figure 3.77 : Erreur d'estimation par les algorithmes AFFRLS et SFO

### 3.4 CONCLUSION

Dans ce chapitre, nous avons présenté deux contributions réalisées dans le cadre de cette thèse au niveau de l'estimation en ligne des paramètres de la batterie lithium moyennant deux algorithmes : AFFRLS et SFO, les deux méthodes et les modèles développés sont adaptés pour les applications véhicules électriques.

Pour AFFRLS, un modèle de batterie Thévenin est étudié. La tension en circuit ouvert (OCV) est exprimée par une adaptation de l'équation Nernst. L'impact de l'hystérésis est décrit par un terme correcteur à l'état zéro. Les paramètres du modèle équivalent de Thévenin sont identifiés sur la base de la méthode proposée AFFRLS et comparés à celle de RLS proposée par X. Hu et al [6] (méthode originale). La tension de sortie estimée par les deux méthodes (AFFRLS et RLS) est comparée avec la tension mesurée. L'exactitude de l'identification des paramètres du modèle de circuit a été vérifiée à l'aide des données expérimentales pour trois profils dynamiques : DST (Dynamic Stress Test), FUDS (Federal Urban Driving Schedule), et le UDDS (Urban Dynamometer Driving Schedule).

Nous avons fourni les données aux algorithmes et comparé la tension estimée. Nous avons démontré que la distribution de l'erreur relative absolue d'AFFRLS est faible pour des erreurs supérieures à 2% jusqu'à 6,4% moins que RLS. Cela signifie que la méthode AFFRLS est supérieure en termes de précision à RLS dans l'identification des paramètres du modèle de la batterie.

Pour le deuxième algorithme (SFO), le modèle Thévenin est construit en utilisant une représentation d'état. L'identification des paramètres du modèle basé sur SFO est proposée et comparée à l'algorithme AFFRLS proposé par X.Sun, et al [11]. La tension de sortie estimée par ces algorithmes est comparée à la tension de sortie réelle mesurée. Pour comparer l'efficacité de l'identification des paramètres du modèle de circuit équivalent, les données effectuées sur la cellule lithium A123 par le groupe de recherche sur les batteries CALCE pour trois profils dynamiques nommés : DST, US06 et FUDS ont été utilisées.

Nous avons fourni les données (courant et tension) aux deux méthodes et comparé la tension terminale estimée. Les résultats montrent que SFO est supérieure à l'algorithme AFFRLS pour simuler le comportement dynamique de la tension d'une batterie lithium-ion. En effet, SFO a pu prédire la tension de sortie avec une erreur qui ne dépasse pas  $\pm 0,03V$  par rapport à l'algorithme AFFRLS qui a enregistré une pointe de 0,5V. Cela signifie que l'algorithme SFO est plus précis en termes d'identification des paramètres en ligne.

À notre connaissance, il s'agit de la première tentative d'utilisation du SFO pour estimer les paramètres d'une batterie en temps réel, nous pensons qu'il y a une grande marge d'amélioration pour obtenir de meilleurs résultats en termes de rapidité et de précision.

Dans la perspective de ces travaux. Les algorithmes proposés peuvent être adaptés et combinés avec des techniques telles que les observateurs en mode glissant, les filtres de Kalman, le filtre  $H_\infty$  ou le filtrage de particules (PF) pour estimer l'état de charge ou le l'état de santé d'une batterie lithium-ion.

## **Chapitre**

# **4**

---

## **Estimation de la capacité de la batterie lithium-ion pour les véhicules électriques (état de santé SOH) par SFO**

---

## 4.1 Introduction

Le développement des véhicules électriques est très rapide ces derniers temps. Les batteries sont parmi les éléments les plus critiques des VE et les batteries lithium-ion sont largement acceptées comme le meilleur choix. Ceci est dû aux améliorations continues en termes de cycle de vie, de densités d'énergie et de puissance, de stabilité thermique, et surtout la réduction continue de coût.

Du point de vue d'un ingénieur automobile, il est nécessaire de connaître deux éléments concernant les batteries : la puissance que le système de batterie peut fournir et la quantité d'énergie stockée dans la batterie. Il est plus simple d'estimer les résultats de ces deux questions pour une nouvelle cellule, mais pour une cellule âgée, une erreur d'estimation importante se produirait sans connaître la capacité de la batterie. Ainsi, l'estimation de la capacité totale de la batterie est fondamentale pour les systèmes de gestion des batteries (BMS). Une connaissance précise de la capacité totale permet non seulement au BMS de calculer avec une bonne approximation la capacité maximale de stockage d'énergie et l'énergie restante dans une batterie, mais surtout d'anticiper les risques de défaillance, grâce à des indicateurs tels que l'état de santé (SOH) et la durée de vie utile restante (RLU). Nous avons relevé dans la section 1.7 les méthodes utilisées pour l'estimation de la capacité d'une batterie. Dans le cadre de cette thèse, nous avons proposé un nouveau Framework basé sur l'algorithme SFO pour l'estimation de la capacité totale publié dans [20]. SFO est l'une des plus récentes métaheuristiques qui imite le mouvement du tournesol vers le soleil. L'algorithme SFO est appliqué pour identifier le meilleur candidat qui a enregistré la plus faible valeur d'une fonction objective dans une population de tournesols. Une stratégie de réduction de l'espace de recherche est utilisée pour améliorer la précision de la solution. Le meilleur candidat est ensuite employé via à un facteur d'oubli pour mettre à jour la capacité totale de la batterie. La précision de l'algorithme a été vérifiée à l'aide de l'ensemble de données sur le vieillissement des batteries de la NASA [14] (NASA Prognostic Data Repository), en plus de trois scénarios d'une batterie dans des applications de véhicules électriques et hybrides rechargeables. À notre connaissance, il s'agit de l'un des premiers efforts où SFO est utilisé pour estimer la capacité totale d'une batterie. SFO a montré une grande performance en termes de prédiction : SFO a enregistré une erreur maximale de 1,26 % dans le pire des cas. De plus, tous les indicateurs prédictifs de performance (RMSE, MAE, et MAPE) n'ont pas dépassé 0,4 % dans tous les tests.

Les principales contributions de ce travail peuvent être résumées dans les points suivants :

- Un nouveau Framework d'estimation de la capacité en ligne basé sur l'algorithme SFO. La méthode proposée est récursive, ce qui signifie qu'elle nécessite moins de calculs et de mémoire. Des données collectées à partir de la base de données sur le vieillissement des batteries de la NASA effectuée sur la batterie SAMSUNG (INR 18650) ont été utilisées, ainsi que trois scénarios d'une batterie dans des applications de véhicule électrique (EV) et de véhicule électrique hybride rechargeable (PHEV) pour évaluer la technique. Les résultats montrent que SFO est très fiable et précis. Au mieux de notre connaissance, il s'agit de l'une des premières tentatives d'estimation de la capacité d'une batterie à l'aide de la technique SFO.

- La technique présentée prend en compte les sources d'erreurs, notamment les bruits de mesure et d'estimation.
- Comparaison des résultats obtenus par l'approche suggérée avec les valeurs expérimentales et quatre méthodes récursives robustes (AWTLS, WTLS, WLS, TLS) publiées par Plett [12] :
  1. AWTLS : moindres carrés totaux pondérés approximatifs (approximate weighted total least squares).
  2. WTLS : moindres carrés totaux pondérés (weighted total least squares).
  3. WLS : moindres carrés pondérés (weighted least squares).
  4. TLS : moindres carrés totaux (total least squares).

## 4.2 Formulation du problème

L'état de charge (SOC) d'une cellule indique la capacité actuellement disponible en fonction de la capacité nominale. La valeur du SOC varie entre 0% et 100%. Si le SOC atteint 100 %, on dit que la cellule est entièrement chargée, tandis qu'un SOC de 0 % indique que la cellule est entièrement déchargée. L'état de charge est donné par l'équation suivante :

$$SOC(t_2) = SOC(t_1) + \frac{1}{Q} \int_{t_1}^{t_2} \eta i(t) dt \quad (4.75)$$

Q est la capacité totale, SOC représente l'état de charge,  $\eta$  est le coefficient de coulomb, le courant  $i(t)$  étant considéré comme négatif pendant la charge et positif pendant la décharge.

Si on réarrange l'équation (4.75), on obtient :

$$\underbrace{\int_{t_1}^{t_2} \eta i(t) dt}_y = Q \underbrace{(SOC(t_2) - SOC(t_1))}_x \quad (4.76)$$

La structure linéaire  $y = Q \cdot x$  devient apparente. En utilisant une technique de régression, par exemple, il est possible de déterminer Q. Il suffit de trouver les valeurs de "x" et "y". Le problème est que la valeur x (différence entre les valeurs de l'état de charge) et la valeur y (l'intégrale du courant) sont associées à des bruits (liés au capteur et à l'estimation de l'état de charge). Ainsi, l'équation (4.76) devient  $(y - \Delta y) = Q (x - \Delta x)$  [12].

Plett dans [12] a exploré la méthode des moindres carrés pour estimer la capacité totale de la batterie. Différentes versions sont exposées. Dans [12], la fonction objective suivante est utilisée pour dériver les équations utilisées dans ces méthodes :

$$\chi^2_{WLS} = \sum_{i=1}^N \frac{(y_i - Q_{hat} x_i)^2}{(Q_{hat})^2 \sigma_{xi}^2 + \sigma_{yi}^2} \quad (4.77)$$

Où  $Q_{hat}$  est la capacité estimée.  $y_i$  présente les ampères-heures accumulés sur l'intervalle  $[t_1, t_2]$  et  $x_i$  est l'état de charge estimé sur le même intervalle.  $(\sigma_{xi})^2$  et  $(\sigma_{yi})^2$  sont les variances sur les axes x et y respectivement.

À partir de l'équation ci-dessus, Plett a dérivé plusieurs variations de TLS pour estimer la capacité totale de la batterie, la version finale AWTLS considérée comme la meilleure est capable d'atteindre l'objectif avec des approximations (par exemple : faire en sorte que la ligne joignant les données  $(X_i, Y_i)$  et  $(x_i, y_i)$  soit à angle droit par rapport à la ligne  $Y_i = \hat{Q} * X_i$ , en plus de pondérer  $x_i$  et  $X_i$  différemment de  $y_i$  et  $Y_i$ ,  $Y_i$  et  $X_i$  sont des points sur la ligne  $Y_i = \hat{Q} * X_i$ ).

Dans l'article [20], nous avons implémenté l'algorithme SFO dans lequel nous tenons compte des bruits dans les axes  $x$  et  $y$  sans approximations (nous appliquons directement SFO pour minimiser la fonction de coût (4.77) sans dériver aucune équation).

Puisque SFO est un algorithme d'optimisation, une fonction objective doit être définie, nous avons utilisé la fonction objective (4.77). Cette fonction est la même que celle utilisée dans [12].

La fonction objective (4.77) est résolue par SFO en tenant compte des restrictions ci-dessous, avec  $\max$  et  $\min$  comme valeurs maximales et minimales de la capacité totale  $Q$  :

$$Q_{\min} < Q_{hat} < Q_{\max} \quad (4.78)$$

### 4.3 Algorithme SFO

Nous avons examiné l'algorithme SFO dans le chapitre 3 section 3.3.4 quand nous l'avons utilisé pour estimer les paramètres du modèle de batterie. Nous utilisons les mêmes équations (3.70 - 3.74). Nous avons cependant modifié l'algorithme. Les étapes du SFO sont illustrées dans la figure 4.78.

SFO commence par une initialisation aléatoire des positions des tournesols. Chaque position présente une valeur possible de la capacité de la batterie définie dans les limites  $X_{\min}$  et  $X_{\max}$  ( $X_{\min} = Q_{\min}$ ,  $X_{\max} = Q_{\max}$ ). Après le calcul de la fonction objective pour chaque tournesol (4.77), la plante avec l'évaluation la plus élevée est celle qui est transformée en soleil (le tournesol ayant la valeur la plus basse de la fonction objective). La population (tournesols) est ensuite dirigée vers la position du soleil et prend des actions définies pour se rapprocher de celle-ci. L'ensemble du processus est répété jusqu'à ce que la limite soit atteinte ( $Max\_iteration$ ). À chaque itération, l'algorithme trouve la meilleure solution et met à jour la nouvelle position. Nous avons ajouté une étape supplémentaire où nous gérons l'espace de recherche par une modification des limites des paramètres  $X_{\min}$  et  $X_{\max}$  lorsque l'erreur est supérieure à un seuil au moyen des deux équations suivantes :

$$X_{\min} = X_{\min} + \alpha(X_{\max} - X_{\min}) \quad (4.79)$$

$$X_{\max} = X_{\max} - \alpha(X_{\max} - X_{\min}) \quad (4.80)$$

Où  $\alpha$  est le facteur de réduction qui gère les limites supérieure et inférieure ( $X_{\min}$  et  $X_{\max}$ ).

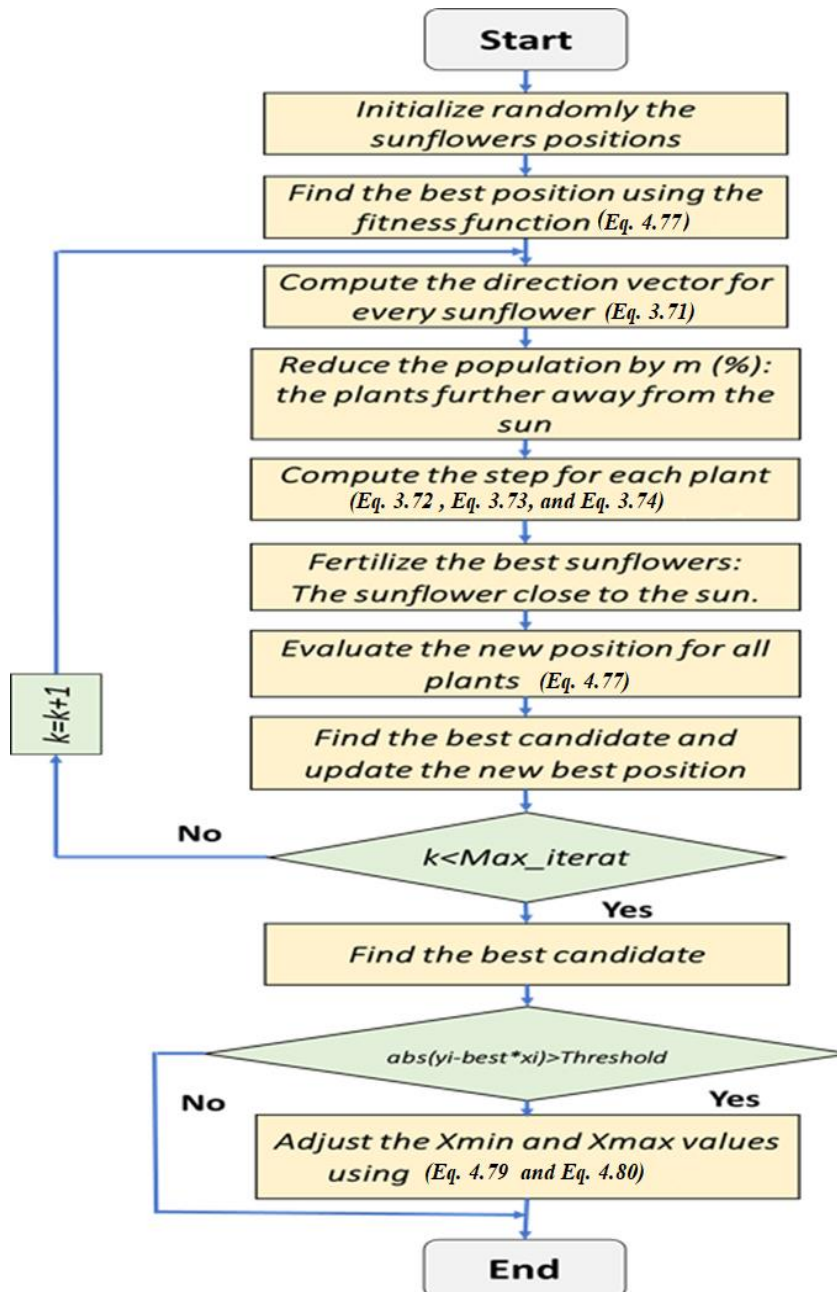


Figure 4.78 : Organigramme de l'algorithme SFO modifié

#### 4.4 Framework proposé

Le Framework proposé est illustré à la Figure 4.79. Il comprend deux étapes : un traitement préalable des données et une étape d'estimation.

**Dans l'étape 1 :** les données anormales sont éliminées à travers le nettoyage : le nettoyage des données est une étape importante. Elle consiste à nettoyer les données afin de les préparer à la phase de traitement. Ici, nous essayons de supprimer toutes les données potentiellement corrompues, incomplètes, mal formatées ou dupliquées de la base de données ; ensuite, les données extraites sont uniformément espacées avant l'estimation du SOC (utilisé pour calculer le vecteur  $x$ ). Enfin, les vecteurs  $x$  et  $y$  sont extraits.



**Dans l'étape 2 :** l'algorithme SFO prend la relève pour déterminer la capacité totale de la batterie. L'algorithme commence par initialiser les paramètres du SFO. Pour accélérer le processus d'estimation, nous avons utilisé une population de petite taille ( $N_p=20$ ), et fixé l'itération maximale à 20.

Pour chaque nouvelle valeur  $x$  et  $y$ , SFO essaie de repérer le meilleur candidat ( $Q_{hat}$ ) dans le but de minimiser la fonction objective (4.77). Nous avons introduit un facteur d'oubli (4.81) pour calculer la capacité estimée  $Q_{est}$ , ce qui permet à l'algorithme de converger rapidement vers la valeur réelle.

$$Q_{est}(k) = (1 - \lambda) * Q_{hat} + \lambda * Q_{est}(k - 1) \quad (4.81)$$

$Q_{est}(k)$ ,  $Q_{est}(k-1)$  sont la capacité totale estimée récente et précédente respectivement.  $Q_{hat}$  est la meilleure valeur prédite par SFO. Le facteur d'oubli  $\lambda$  attribue des poids aux données nouvelles et anciennes et est généralement une valeur fixe comprise entre 0,95 et 1 [11].

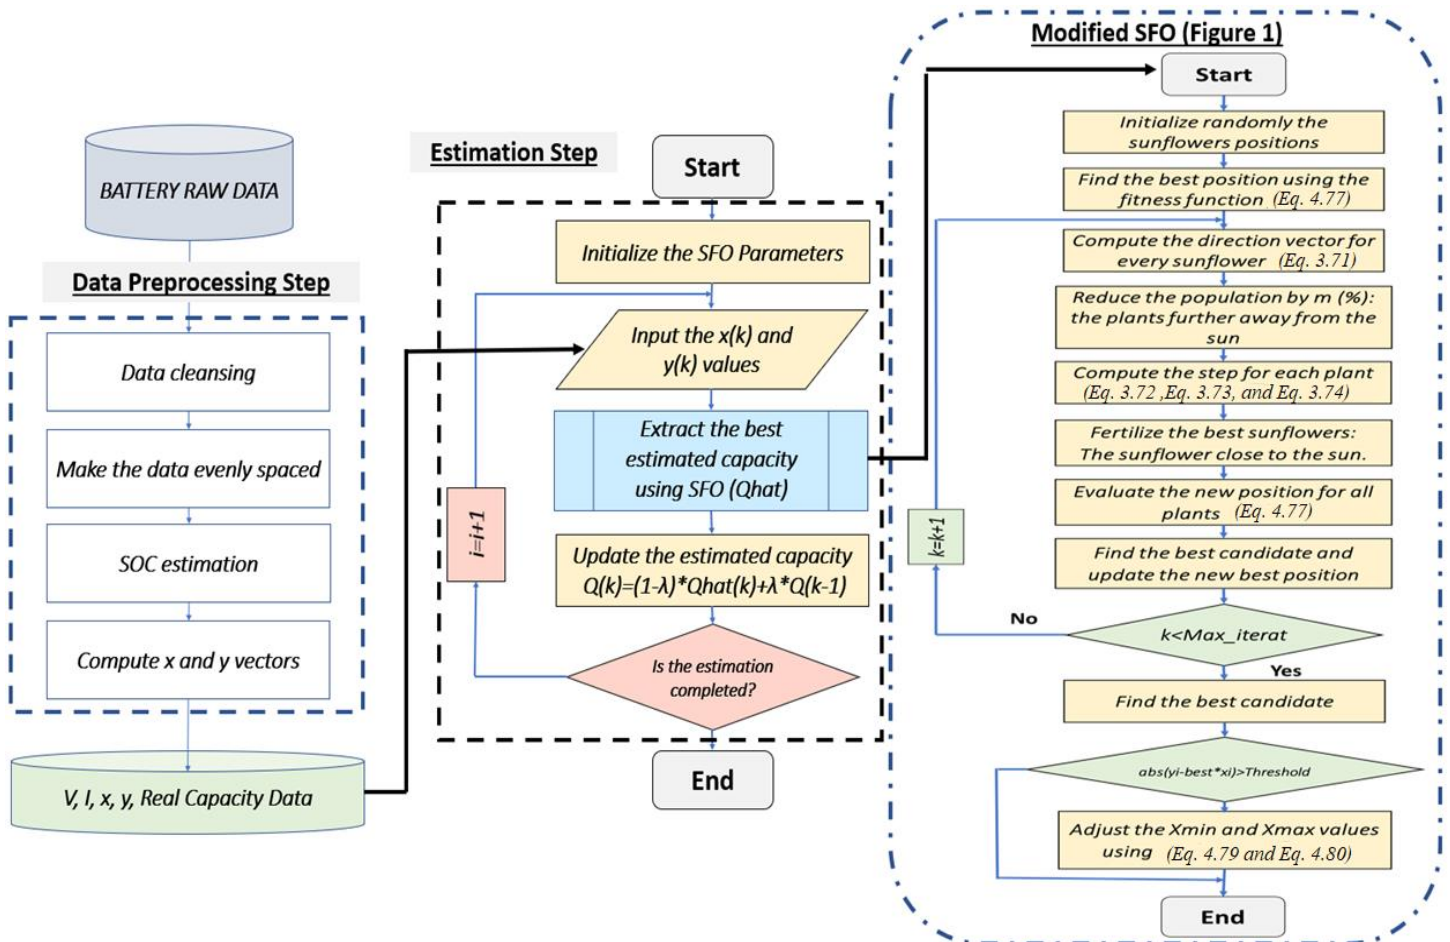


Figure 4.79 : Framework proposé pour l'estimation de la capacité totale

#### 4.5 Évaluation de l'ensemble des données de la batterie NASA

Nous comparons dans cette section la méthode SFO (Figure 4.79) et les méthodes des moindres carrés récursifs (AWTLS, WTLS, WLS et TLS) proposées dans la revue [12]. Les paramètres de ces méthodes sont empruntés de [12]. Le tableau 4.12 présente les paramètres du SFO. Les

limites des paramètres de la batterie (limite supérieure et inférieure de la capacité  $Q_{max}$  et  $Q_{min}$ ) ainsi que les constantes utilisées dans l'algorithme SFO (facteur d'oubli  $\lambda$ , seuil et le facteur de réduction  $\alpha$ ) sont énumérées dans le tableau 4.13.

**Tableau 4.12 : Paramètres de l'algorithme SFO**

Nombre de tournesols	Taux de pollinisation	Taux de mortalité	Taux de survie	Maximum d'itération
20	0.1	0.005	0.9	20

**Tableau 4.13 : Paramètres de la batterie et autres constantes**

Q (Ah)		$\lambda$	Seuil	$\alpha$
$Q_{min}$	$Q_{max}$			
0	5	0.999	0.1	0.01

### 4.5.1 Ensemble de données de la NASA

Pour évaluer les performances des algorithmes, nous avons utilisé en premier les données expérimentales recueillies par le centre d'excellence pour les pronostics (PCoE) de la NASA sur la batterie lithium-ion SAMSUNG INR 18650 (Figure 4.80). Le tableau 4.14 résume les caractéristiques de la batterie utilisée.

**Tableau 4.14 : Paramètres de la batterie**

Batterie SAMSUNG INR 18650-20R	
Batterie (Paramètres)	Spécifications (valeur)
Capacité nominale	2000mAh
Chimie	LiNiMnCo/Graphite
Tension nominale	3,6 V
Courant de décharge continu max	22 A
Tension de charge :	4,20 +/- 0,05 V
Diamètre	18.33 mm ± 0.07 mm
Longueur	64.85 mm ± 0.15 mm



**Figure 4.80 : SAMSUNG INR 18650-20R**

Le centre de données de pronostic est une collection d'ensembles de données. Le dépôt de données se concentre exclusivement sur les ensembles de données de prévision, c'est-à-dire les ensembles de données qui peuvent être utilisés pour le développement d'algorithmes de prévision. Il s'agit le plus souvent de séries chronologiques de données allant d'un état nominal à un état de défaillance.

La NASA a effectué une expérience de vie accélérée par des cycles de charge et de décharge répétés (jusqu'à défaillance) sur la batterie mentionnée et a obtenu une série de données.

Un ensemble de quatre batteries Li-ion (No.5, No.6, No.7 et No.18) a été soumis à 3 profils opérationnels différents (charge, décharge et impédance) à température ambiante. La charge a été effectuée en mode courant constant (CC) à 1,5 A jusqu'à ce que la tension de la batterie atteigne 4,2 V, puis a continué en mode tension constante (CV) jusqu'à ce que le courant de charge atteigne une valeur de 20 mA. La décharge a été effectuée à un niveau de courant constant (CC) de 2A jusqu'à ce que la tension de la batterie baisse à 2,7V, 2,5V, 2,2V et 2,5V pour les batteries No.5 No.6 No.7 et No.18 respectivement.

Les figures (de 4.81 à 4.86) montrent respectivement : le courant mesuré pendant la charge/décharge, la tension mesurée pendant la charge/décharge, la température mesurée pendant la charge/décharge de la batterie No.18 pour les différents cycles.

La mesure de l'impédance a été effectuée par un balayage de fréquence de la spectroscopie d'impédance électrochimique (EIS) de 0,1Hz à 5kHz. On relève sur la Figure 4.87 l'impédance mesurée de la batterie No.18 pour les différents cycles.

Les cycles de charge et de décharge répétés entraînent un vieillissement accéléré des batteries, tandis que les mesures d'impédance donnent un aperçu des paramètres internes des batteries qui changent au fur et à mesure du vieillissement. Les expériences ont été arrêtées lorsque les batteries ont atteint 70% de la capacité initiale, soit une diminution de 30% de la capacité nominale (de 2Ahr à 1,4Ahr). La Figure 4.88 montre la dégradation de la capacité des quatre batteries et le tableau 4.15 reprend les caractéristiques des quatre batteries.




Figure 4.81 : Courant mesuré pendant les différents cycles de charge (Batterie No.18)




Figure 4.82 : Courant mesuré pendant les différents cycles de décharge (Batterie No.18)




Figure 4.83 : Tension mesurée pendant les différents cycles de charge (Batterie No.18)




Figure 4.84 : Tension mesurée pendant les différents cycles de décharge (Batterie No.18)




Figure 4.85 : Température mesurée pendant les différents cycles de charge (Batterie No.18)




Figure 4.86 : Température mesurée pendant les différents cycles de décharge (Batterie No.18)




Figure 4.87 : Impédance mesurée (Batterie No.18)




Figure 4.88 : Trajectoires de dégradation de la capacité des quatre batteries

Tableau 4.15 : Spécifications des quatre batteries

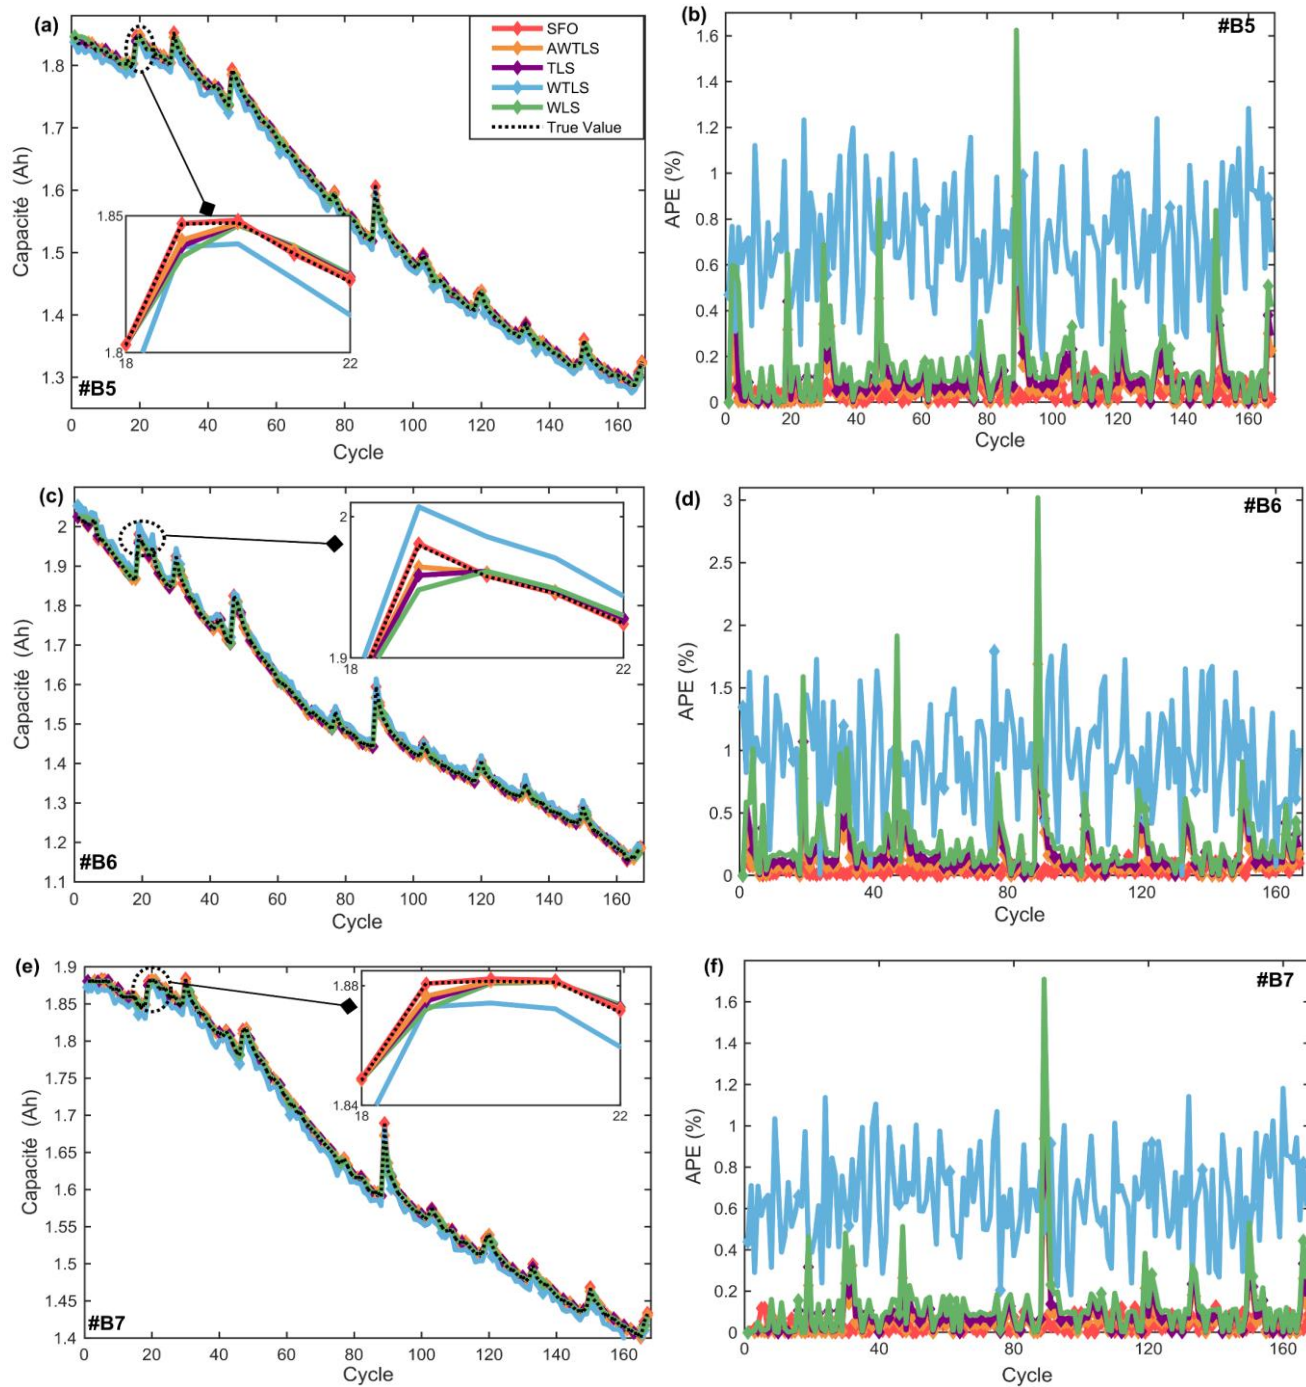
#### 4.5.2 Résultats et discussion

Nous exécutons SFO et les algorithmes des moindres carrés pour estimer la capacité totale des batteries. Les tests sont effectués sur un ordinateur portable du type Asus équipé d'un processeur Intel Core i7 2,6 GHz, 8 Go de mémoire. La plate-forme utilisée est : MATLAB R2019a.

La Figure 4.89 montre les valeurs d'estimation de la capacité des algorithmes AWTLs, WTLS, TLS, WLS et SFO ainsi que la valeur réelle pour les quatre cas. Pour mettre en évidence la différence entre les algorithmes, des sections zoomées sont présentées dans les mêmes figures. Comme on peut le voir, la précision de l'estimation de SFO est légèrement meilleure.

Batterie	Pendant la charge			Pendant la décharge		Conditions		
	Courant constant (A)	Tension de limite supérieure (V)	Courant de coupure (mA)	Courant constant (A)	Tension de coupure (V)	Température	Capacité initiale (Ah)	Fin de vie (Ah)
No.5	1.5	4.2	20	2	2.7	Température amb	1.86	1.4
No.6	1.5	4.2	20	2	2.5	Température amb	2.04	1.4
No.7	1.5	4.2	20	2	2.2	Température amb	1.89	1.4
No.18	1.5	4.2	20	2	2.5	Température amb	1.86	1.4





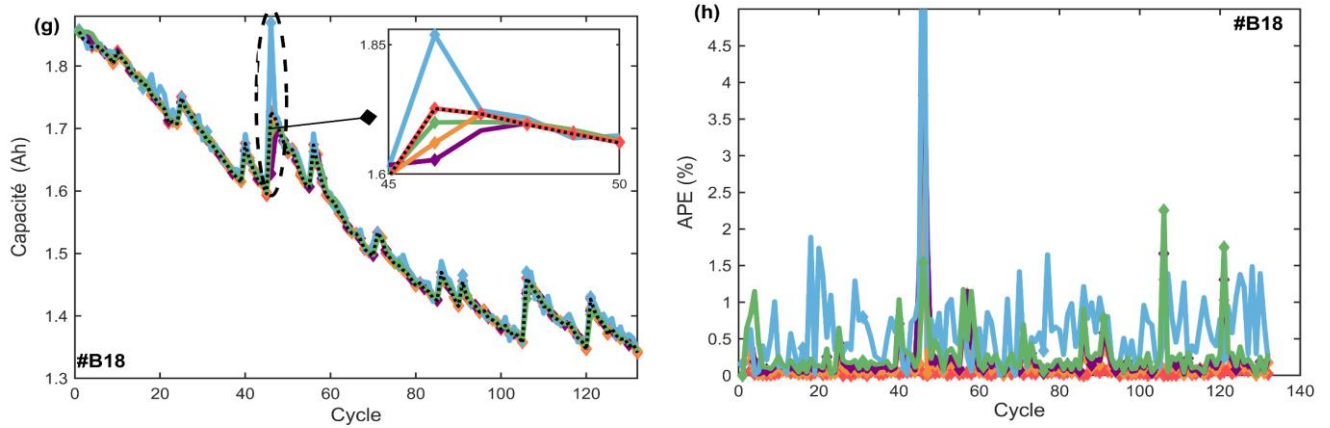


Figure 4.89 : Trajectoires de dégradation de la capacité des quatre batteries avec leur APE correspondant en (%) : (a, b) batterie n°5, (c, d) batterie n°6, (e, f) batterie n°7, (g, h) batterie n°18

Si on examine la valeur de l'erreur absolue en pourcentage (APE) (4.82) sur la même figure, on peut voir que, par rapport aux méthodes des moindres carrés, le SFO a une faible erreur dans tous les cas. L'erreur maximale enregistrée par SFO est de +0,16 % (n° 18). Pour les méthodes des moindres carrés, l'AWTLS a enregistré le pic le plus faible avec une valeur de +0,9 % (n°5). L'erreur moyenne était faible pour toutes les méthodes avec une valeur qui ne dépassait pas 1%, SFO a enregistré les valeurs les plus faibles parmi ces méthodes.

Le tableau 4.16 résume les valeurs d'erreur maximale et moyenne. Le tableau montre clairement que l'algorithme SFO a une meilleure capacité d'estimation et peut refléter précisément les caractéristiques complexes d'une variation en ligne pendant la charge/décharge de la batterie par rapport aux approches TLS.

$$APE = \left| \frac{Q_{true}(i) - Q_{est}(i)}{Q_{true}(i)} \right| * 100 \quad (4.82)$$

$Q_{true}$  est la valeur réelle de la capacité de la batterie, et  $Q_{est}$  est la valeur estimée.

Pour prouver davantage l'efficacité du SFO, nous avons calculé trois indicateurs prédictifs de performance qui mettent en évidence la qualité des algorithmes sur la durée de vie des quatre batteries : l'erreur moyenne absolue (MAE), l'erreur moyenne absolue en pourcentage (MAPE) et l'erreur quadratique moyenne (RMSE). Le MAE est une mesure simple de la performance pronostique. MAPE est une méthode d'évaluation des erreurs relatives qui prend en compte les erreurs absolues, en plus de la relation entre les erreurs et les valeurs réelles mesurées. Le RMSE est en mesure de fournir une évaluation pronostique complète des performances. Il est particulièrement sensible dans le cas où les valeurs sont anormales. Si une valeur pronostique diffère significativement de la valeur réelle, la valeur du RMSE sera plus élevée.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{true}(i) - Q_{est}(i))^2} \quad (4.83)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{true}(i) - Q_{est}(i)| \quad (4.84)$$



$$\text{MAPE}(\%) = \frac{100}{n} \sum_{i=1}^n \frac{|Q_{\text{true}}(i) - Q_{\text{est}}(i)|}{Q_{\text{true}}(i)} \quad (4.85)$$

$n$  représente le nombre de cycles,  $Q_{\text{true}}$  est la véritable pile et  $Q_{\text{est}}$  est la valeur estimée.

Dans la figure 4.90, nous indiquons le RMSE et le MAPE de tous les algorithmes pour les 4 batteries. Le tableau 4.17 résume les erreurs d'estimation de la capacité. Nous observons que toutes les valeurs RMSE pour la méthode SFO sont jusqu'à 20 fois inférieures (n°18) à celles enregistrées par les méthodes des moindres carrés. En outre, la MAE et la MAPE sont inférieures jusqu'à 13,9 et 0,9 (n° 6) respectivement pour notre méthode, ce qui indique une grande précision d'estimation dans l'ensemble du processus de prévision.

Les bonnes performances du SFO peuvent s'expliquer par le fait que la batterie n'est pas fortement stressée, le courant de la batterie est maintenu constant pendant la charge (1,5A) et la décharge (2A), ainsi le SOC de la batterie et les paramètres internes responsables du vieillissement de la batterie évoluent lentement dans le temps, ce qui donne aux algorithmes suffisamment de temps pour estimer la capacité de la batterie avec une grande précision. En outre, pour chaque cycle complet consistant en une charge et une décharge complète de la batterie (qui prend environ 3-4 heures), l'algorithme a suffisamment de temps et de données pour converger et suivre la valeur de la capacité de la batterie (qui change lentement) avec une grande précision. L'algorithme atteint cette haute précision sans avoir besoin de considérer toutes les données précédentes, seule la dernière valeur estimée est nécessaire (4.81) pour calculer la nouvelle valeur. Les résultats montrent clairement que SFO est capable de minimiser l'influence du bruit dans les axes  $x$  et  $y$ , qui sera toujours présent même en utilisant un capteur très stable et précis pour mesurer le courant (utilisé pour calculer la valeur  $x$ ) et/ou un algorithme robuste pour estimer le SOC (pour calculer la valeur  $y$ ).

Il convient de noter que les valeurs initiales des paramètres influent sur la précision des résultats du SOC, par exemple, la modification du nombre d'itérations et/ou le nombre de tournesols affectera la proximité entre la capacité estimée et la capacité réelle. Pour obtenir une grande précision, on peut fixer des valeurs élevées pour ces paramètres, mais au détriment du temps de calcul, la réduction de ces valeurs accélérera le temps de traitement mais affectera la précision d'autre part. Un autre acteur important est le facteur d'oubli  $\lambda$  qui aide l'algorithme à atteindre une convergence plus rapide, un changement de la valeur de ce paramètre conduit à un compromis entre un décalage et une consistance d'un côté et un degré de convergence rapide de l'autre côté, le réglage de ce paramètre affectera sensiblement les résultats. Nous avons utilisé une valeur fixe dans notre cas, mais un facteur d'oubli variable est une possibilité à étudier.

De l'autre côté, le facteur de réduction  $\alpha$  aide l'algorithme à trouver le bon chemin à travers les équations 4.79 et 4.80 chaque fois que l'erreur dépasse un seuil déterminé. Chaque fois que l'erreur est supérieure à ce seuil, ces équations sont utilisées pour réajuster les limites supérieure et inférieure ( $X_{\text{min}}=Q_{\text{min}}$  et  $X_{\text{max}}=Q_{\text{max}}$ ), permettant à l'algorithme de réajuster dynamiquement l'espace de recherche, et par conséquent de rechercher un nouvel intervalle  $[Q_{\text{min}}, Q_{\text{max}}]$  pour trouver le meilleur candidat  $Q_{\text{best}}$  utilisé pour calculer la capacité totale estimée, améliorant ainsi la précision et la stabilité de l'algorithme.

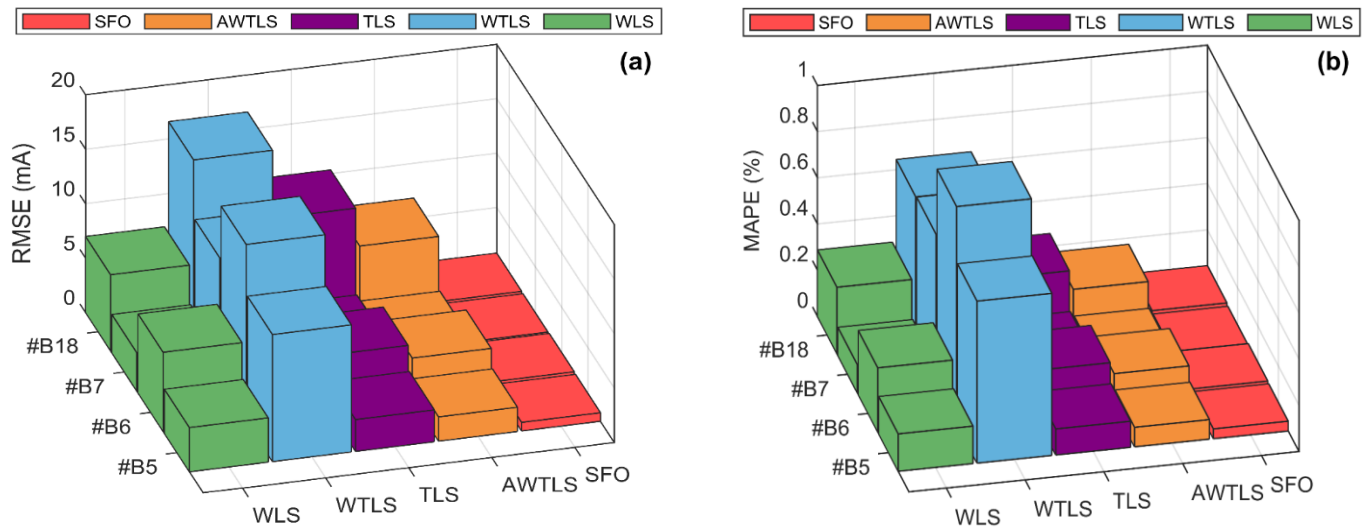


Figure 4.90 : RMSE (a) et MAPE (b) des algorithmes dans tous les tests

Tableau 4.16 : Erreur Max et Moyenne en (%)

Batterie	Erreur (%)	SFO	AWTLS	TLS	WTLS	WLS
No.5	Max	0.14	0.9	1.17	1.28	1.62
	Moyenne	0.04	0.084	0.11	0.7	0.16
No.6	Max	0.16	1.69	2.18	1.83	3.01
	Moyenne	0.046	0.14	0.19	0.94	0.28
No.7	Max	0.126	0.94	1.22	1.18	1.71
	Moyenne	0.038	0.06	0.09	0.65	0.12
No.18	Max	0.13	3.82	5.72	8.25	2.25
	Moyenne	0.04	0.17	0.25	0.64	0.28

Tableau 4.17 : Indicateurs de performance prédictifs

Batterie	Indicateurs de performance	SFO	AWTLS	TLS	WTLS	WLS
No.5	RMSE	0.78	2.22	2.92	11.66	4.06
	MAPE	0.04	0.08	0.11	0.7	0.16
	MAE	0.65	1.32	1.77	10.99	2.55
No.6	RMSE	0.84	3.92	5.14	16.24	7.27
	MAPE	0.04	0.14	0.19	0.94	0.27
	MAE	0.69	2.32	3.11	14.61	4.43
No.7	RMSE	0.78	1.95	2.55	11.28	3.52
	MAPE	0.03	0.06	0.08	0.50	0.12
	MAE	0.62	1.05	1.40	10.66	2.00
No.18	RMSE	0.82	6.80	10.33	16.59	6.98
	MAPE	0.04	0.17	0.25	0.64	0.28
	MAE	0.69	2.72	4.05	10.01	4.52

Nous n'avons pas expérimenté avec les autres paramètres (taux de pollinisation, de mortalité et de survie), nous avons conservé les mêmes valeurs dans tous les tests.

Dans la prochaine section, nous allons explorer trois tests agressifs, ces tests simulent une batterie dans des applications de véhicules électriques et électriques rechargeables. Les conditions des scénarios sont beaucoup plus rigoureuses : la capacité de la batterie est élevée, l'autonomie du SOC est beaucoup plus grande et la capacité de la batterie se dégrade plus rapidement (scénario 3).

## **4.6 Application véhicules électriques et hybrides :**

Dans cette section, nous utilisons trois scénarios d'une batterie dans des applications pour véhicules électriques et hybrides présentés dans [12].

Ces scénarios diffèrent de la première simulation par le fait que la capacité de la batterie est beaucoup plus importante, l'intervalle SOC est plus large, et la batterie est chargée jusqu'à un point précis. Dans tous les cas, une batterie de 100 Ah est considérée. Nous avons appliqué les méthodes des moindres carrés (AWTLS, WTLS, WLS, et TLS) proposées dans [12] telles quelles, nous avons maintenu les mêmes valeurs pour tous les paramètres. Pour le SFO, l'étape de prétraitement n'est pas nécessaire ; dans ce cas, l'algorithme SFO est directement appliqué (les vecteurs  $x$  et  $y$  sont directement fournis). Pour les paramètres du SFO, nous avons utilisé les mêmes valeurs que dans le tableau 4.12, cependant nous avons modifié le tableau 4.13 pour les paramètres et les constantes de la batterie, le tableau 4.18 reprend les valeurs appliquées pour chaque scénario.

**Tableau 4.18 : Paramètres de la batterie et autres constantes**

Scénarios	Q (Ah)		$\lambda$	Seuil	$\alpha$
	$Q_{\min}$	$Q_{\max}$			
Scénario 1	95	105	0.991	0.1	0.008
Scénario 2	95	105	0.97	0.1	0.02
Scénario 3	65	105	0.99	1	0.01

### **4.6.1 Premier scénario**

Pour le premier scénario, la capacité totale est actualisée régulièrement au fur et à mesure que le véhicule fonctionne, pour cela l'auteur a fixé la variable  $mi$  à 7200 s (toutes les 120 minutes de distance de conduite sur autoroute). L'état de charge de la batterie est censé changer entre +40% et -40%. Le bruit sur l'axe  $x$  (figure 4.91) est considéré comme un bruit gaussien avec une variance  $(\sigma_{xi})^2$  de  $2*(0.01)^2$ . La capacité totale est fixée à 99Ah dans la méthode AWTLs.




Figure 4.91 : Variable  $x$  #EV1

#### 4.6.2 Deuxième scénario

Ce scénario diffère du premier par le fait que les mises à jour se font de manière aléatoire. Par conséquent,  $m_i$  est traité comme une variable aléatoire. L'auteur a exprimé  $m_i$  comme une variable log-normale aléatoire [12]. Il en résulte une fonction de densité de probabilité du cycle de conduite (Figure 4.92) ; la fonction est sélectionnée pour fournir des cycles de conduite satisfaisants de durée incluant divers comportements de conduite et distances.




Figure 4.92 : Fonction de densité de probabilité pour les scénarios 2 et 3 [12]

En outre, comme une portion importante de la batterie est utilisée pour un cycle de conduite complet, contrairement à une mise à jour périodique programmée, un intervalle de 80 % de la SOC a été utilisé, donc  $x$  est calculé comme un nombre aléatoire compris entre -0,8 et +0,8 (Figure 4.93). La variance dans ce cas est fixée à la moitié de la valeur utilisée dans le scénario 1  $(\sigma_{xi})^2 = (0.01)^2$  [12].

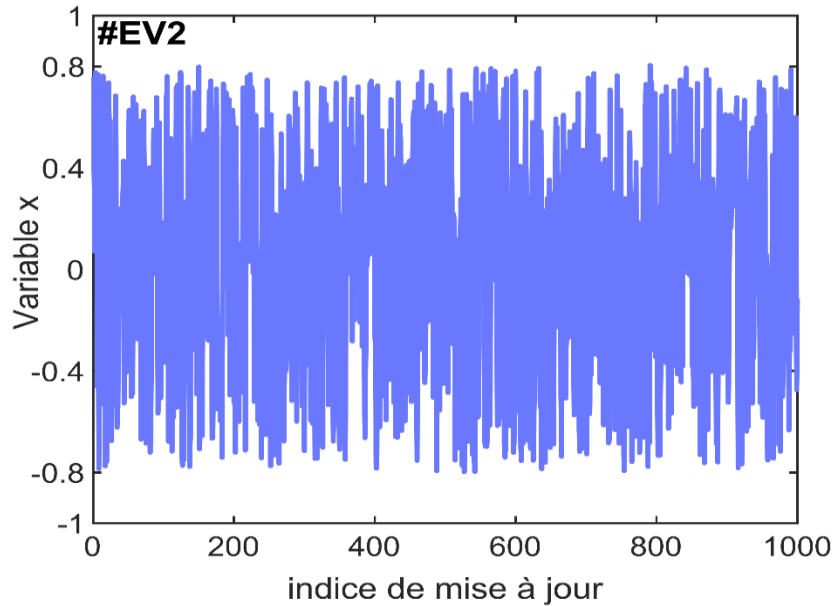


Figure 4.93 : Variable  $x$  #EV2

### 4.6.3 Troisième scénario

Le dernier scénario est similaire au précédent, sauf que l'auteur simule une capacité totale variable. La courbe de capacité est supposée avoir une pente de -0,01 Ah pour chaque cycle [12], de même  $x$  est une variable aléatoire qui oscille entre +0.8 et -0.8 (figure 4.94).


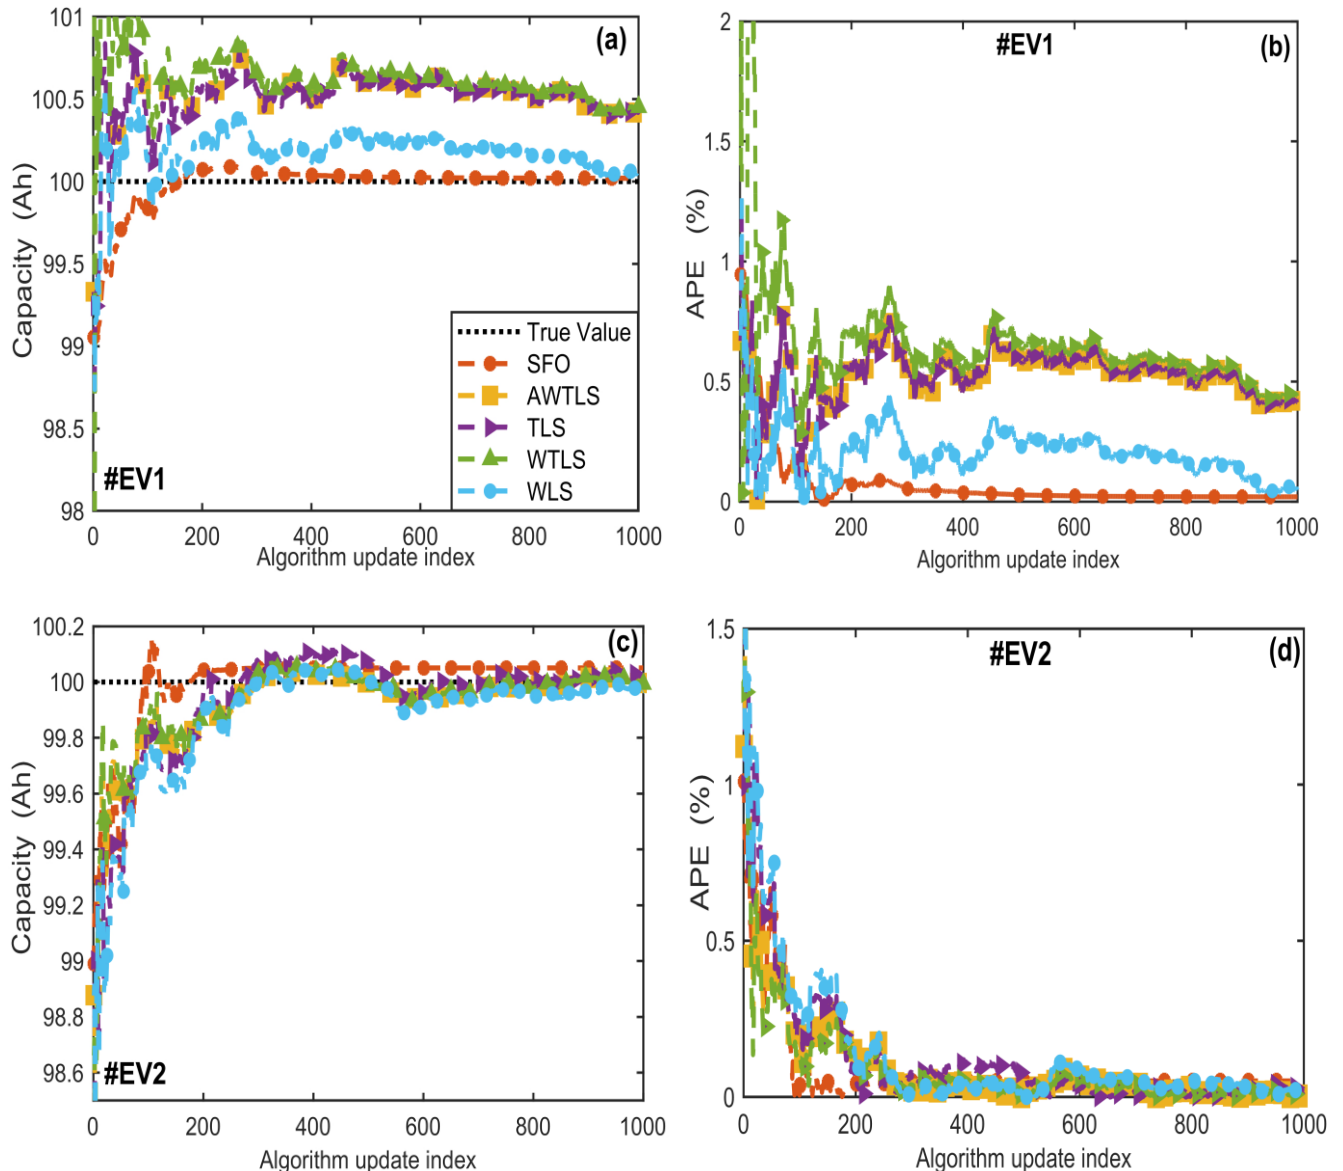


Figure 4.94 : Variable  $x$  #EV3

#### 4.6.4 Résultats et discussion

Les résultats représentatifs de l'estimation de la capacité pour tous les algorithmes dans les trois scénarios sont présentés dans la Figure 4.95, ainsi que l'erreur APE en pourcentage (%). La capacité totale réelle est représentée par une ligne noire en pointillés. Nous soulignons ici que la première valeur enregistrée (tracée) pour SFO est la première valeur de capacité totale estimée par l'algorithme.

Nous pouvons voir que SFO éprouve des difficultés au début dans les scénarios #EV1 et #EV2 mais se rattrape après l'itération 250 par rapport aux méthodes des moindres carrés qui ont pris plus de temps à se stabiliser, la capacité estimée par SFO commence à se rapprocher (après l'itération 250) de la valeur réelle et l'erreur de capacité diminue jusqu'à une faible valeur par rapport aux méthodes des moindres carrés. L'erreur initiale au début est essentiellement due au changement rapide de l'état de charge dans ces conditions de fonctionnement (le SOC de la batterie est censé changer entre +40% et -40% dans le premier #EV1 et entre +80% et -80% dans le #EV2), ce qui entraîne un retard de convergence pour toutes les méthodes.






Figure 4.95 : Estimation de la capacité et APE en (%) : (a, b) Scénario 1, (c, d) Scénario 2, (e, f) Scénario 3

Le troisième scénario #EV3 est un test exceptionnel. En effet, en plus d'un changement significatif de l'état de charge (supposé osciller entre +80 % et -80 % comme le scénario #EV2), la capacité de la batterie varie avec un gradient de -0,01Ah, ce qui implique que pour chaque 100 itérations, la capacité de la batterie diminue de 1Ah (1 % de la capacité nominale), ce qui simule une chute très rapide de la capacité de la batterie. On peut observer que SFO prend un certain temps pour suivre l'évolution de la capacité. Cependant, malgré l'agressivité de ce test, SFO a pu maintenir une erreur globale inférieure à 1,3 % par rapport aux méthodes TLS.

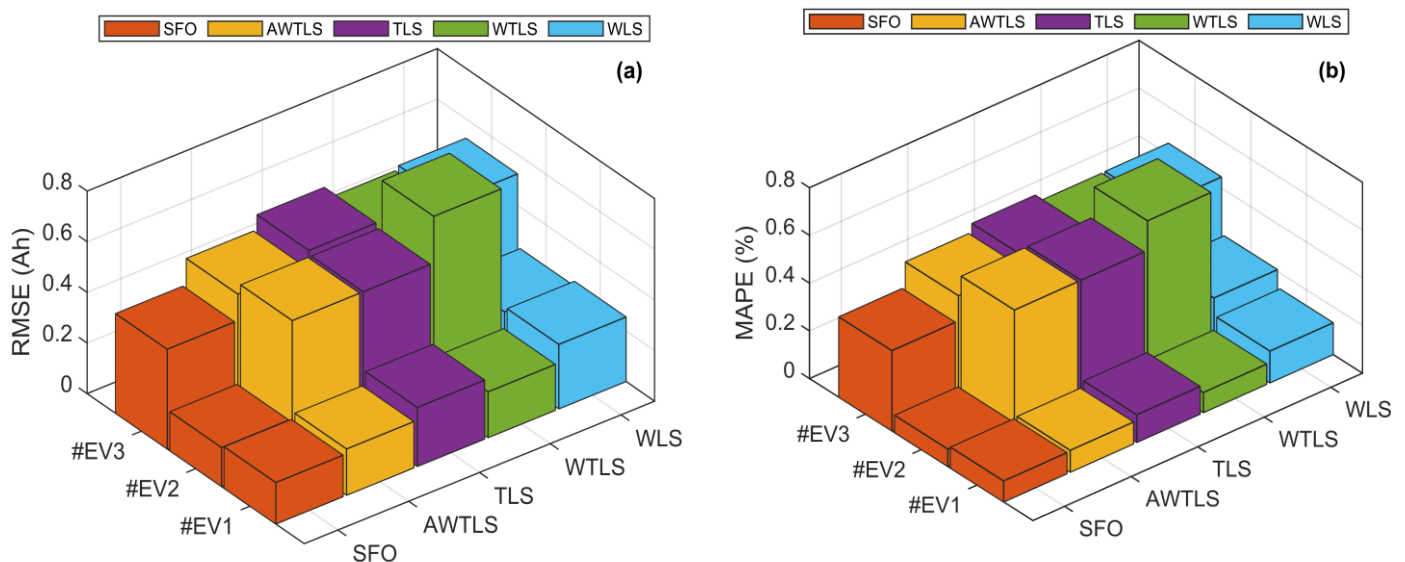


Figure 4.96 : RMSE (a) et MAPE (b) des algorithmes dans tous les scénarios

Dans tous les scénarios, le SFO a montré une faible erreur de prédiction relative par rapport aux méthodes des moindres carrés, comme montre le tableau 4.19. En effet, tous les indices d'erreur (max et moyenne) du SFO sont plus faibles dans tous les scénarios, avec 0,98% (scénario 1) et 1,26% (scénario 3) comme meilleure et pire valeur pour l'erreur maximale, et une valeur

d'erreur moyenne de 0,33% dans le scénario le plus agressif (scénario 3). D'autre part, les meilleures et les pires valeurs enregistrées par la méthode des moindres carrés pour l'erreur maximale sont : 1,19 % (scénario 1) et 6,36 % (scénario 3). L'erreur moyenne la plus élevée a été enregistrée par la méthode WTLS avec une valeur de 0,65 % (scénario 1).

**Tableau 4.19 : Valeur Min, Max et Moyenne de l'erreur de prédiction en (%)**

Scénarios	Erreur (%)	SFO	AWTLS	TLS	WTLS	WLS
Scénario 1	Max	0.98	1.19	1.196	6.36	1.26
	Moyenne	0.07	0.53	0.53	0.65	0.20
Scénario 2	Max	1.01	1.50	1.59	1.94	1.60
	Moyenne	0.08	0.09	0.11	0.08	0.13
Scénario 3	Max	1.26	1.32	1.42	2.80	1.36
	Moyenne	0.33	0.44	0.47	0.44	0.44

**Tableau 4.20 : Indicateurs de performance prédictifs**

Scénarios	Indicateurs de performance	SFO	AWTLS	TLS	WTLS	WLS
Scénario 1	RMSE	0.15	0.54	0.54	0.72	0.23
	MAPE	0.07	0.53	0.53	0.65	0.2
	MAE	0.072	0.53	0.53	0.65	0.20
Scénario 2	RMSE	0.16	0.18	0.23	0.18	0.25
	MAPE	0.08	0.09	0.11	0.08	0.13
	MAE	0.08	0.09	0.11	0.08	0.13
Scénario 3	RMSE	0.39	0.49	0.55	0.50	0.52
	MAPE	0.33	0.44	0.47	0.44	0.44
	MAE	0.32	0.41	0.45	0.42	0.42

Cela signifie que SFO est capable de suivre la valeur de la capacité totale de la batterie avec une grande précision même lorsque la valeur change rapidement (scénario 3), ce qui prouve la supériorité de notre méthode dans l'estimation de la capacité totale de la batterie.

Nous avons calculé également les trois indicateurs de performance prédictifs : RMSE, MAE et MAPE, comme évoqué dans la section 4.5. Le tableau 4.20 montre clairement que la méthode SFO est plus efficace que les méthodes TLS pour l'estimation de la capacité dans tous les scénarios. En réalité, les valeurs RMSE enregistrées par SFO sont inférieures jusqu'à 4,8 fois (scénario 1), les indices MAE et MAPE sont inférieurs dans tous les scénarios jusqu'à 9 fois (scénario 1). Dans la Figure 4.96, les valeurs de RMSE et MAPE de tous les algorithmes pour les trois scénarios sont indiquées.

Comme montre les résultats ci-dessus, la technique que nous présentons à une grande capacité de prédiction dans tous les scénarios, ce qui peut être expliqué en examinant le principe de fonctionnement du SFO.



Comme nous l'avons vu précédemment, SFO s'appuie sur une population de tournesols (définie dans les limites  $Q_{min}$  et  $Q_{max}$ ) qui est évaluée pour trouver le meilleur candidat le plus susceptible d'être proche de la valeur réelle de la capacité totale, l'évaluation est réalisée par la mesure de la fonction objective (le meilleur candidat est celui qui a la valeur la plus faible de la fonction objective), ce processus est répété plusieurs fois pour chaque nouvelle valeur échantillonnée de  $x$  et  $y$  jusqu'à ce que SFO atteigne la limite ( $Max\_iteration$ ), le nombre de tournesols et itérations permettent à l'algorithme de se rapprocher autant que possible de la solution optimale. La réduction de l'espace de recherche (lorsque l'erreur est supérieure à un seuil défini) ainsi que l'introduction du facteur d'oubli pour calculer la valeur estimée de la capacité totale aident l'algorithme à converger étroitement vers la valeur réelle. La précision peut encore être améliorée en augmentant le nombre de tournesols et/ou le nombre d'itérations, mais au détriment du temps de calcul, dans notre cas, nous avons utilisé un petit nombre de tournesols ( $N_p = 20$ ) dans tous les tests et fixé l'itération maximale à 20 ( $Max\_iteration = 20$ ) pour obtenir un équilibre entre précision et vitesse.

Les résultats des sections 4.5 et 4.6 prouvent que notre méthode reflète avec précision les caractéristiques complexes de la variation en temps réel lorsque la batterie est déchargée/chargée, nous avons démontré que SFO peut suivre la valeur de la capacité totale de la batterie avec une bonne précision, ce qui fait de l'algorithme un candidat attractif pour estimer la capacité de la batterie en temps réel.

#### 4.7 Temps de calcul et exigence de mémoire

Dans cette partie, les performances de SFO sont comparées à celles des algorithmes TLS en termes de vitesse de calcul et de besoin en mémoire. Nous avons utilisé MATLAB comme logiciel, exécuté sur un ordinateur portable Asus avec un CPU Intel Core i7 2.6 GHz, et 8 Go de mémoire.

Nous avons exécuté les algorithmes et calculé le temps d'exécution moyen pour un cycle, nous avons rassemblé les résultats dans le tableau 4.21.

Comme nous pouvons le constater, la méthode WTLS nécessite plus de temps pour estimer la capacité dans un cycle jusqu'à 13 secondes ( $n^{\circ}5$  et  $n^{\circ}18$ ), ceci est principalement dû au calcul lourd nécessaire pour calculer le Jacobien et le Hessien utilisés dans le processus d'estimation.

D'autre part, WLS et TLS sont les plus rapides, mais leur précision est moyenne. WLS a obtenu une erreur maximale de 3,01 % ( $n^{\circ}6$ ) et TLS une erreur maximale de 5,72 % ( $n^{\circ}18$ ). En outre, leurs indicateurs de performance (RMSE, MAPE, MAE) sont plus élevés que ceux de AWTLs et SFO (Tableau 4.16-4.17 et Tableau 4.19-4.20).

SFO et AWTLs étant les plus précis de tous, ils étaient proches en termes de temps de traitement. AWTLs était légèrement plus rapide dans les tests No.5 et No.6, et SFO était plus rapide dans les autres tests. En termes de précision, AWTLs a obtenu une erreur maximale de 3.82% (No.18) et SFO une erreur maximale de moins de 1%. Nous pouvons dire que SFO a un bon équilibre entre précision et rapidité, SFO a surpassé les méthodes TLS en termes de précision et de rapidité dans la plupart des tests.

**Tableau 4.21 : Temps moyen d'exécution d'un cycle en secondes**

TESTS	SFO	AWTLS	WTLS	TLS	WLS
No.5	0.34696	0.2800	13.2602	0.0035	0.0023
No.6	0.35067	0.2994	14.0824	0.0037	0.0026
No.7	0.36512	0.3673	12.4470	0.0034	0.0029
No.18	0.32832	0.3764	13.1446	0.0035	0.0029
Scénario 1	0.0081	0.01	3.2	0.009	0.007
Scénario 2	0.0036	0.004	1.8	0.0045	0.005
Scénario 3	0.0014	0.003	0.9	0.002	0.003

En ce qui concerne les besoins en mémoire, nous avons utilisé le profilage MATLAB pour collecter l'allocation de mémoire nécessaire à chaque algorithme (Tableau 4.22). Le profilage MATLAB est un outil utilisé pour optimiser et déboguer les codes M-file [192].

**Tableau 4.22 : Mémoire allouée en Kb**

Tests	SFO	AWTLS	WTLS	TLS	WLS
No.5	4,5	4,4	5,5	Faible	Faible
No.6	4,5	4,4	5,5	Faible	Faible
No.7	4,5	4,4	5,5	Faible	Faible
No.18	3,2	3,1	4,4	Faible	Faible
Scénario 1	3,2	3,2	4	Faible	Faible
Scénario 2	3,2	3,2	4	Faible	Faible
Scénario 3	3,2	3,2	4	Faible	Faible

**Faible** : l'allocation de mémoire est très faible, MATLAB n'affiche pas l'allocation de mémoire.

Les besoins en mémoire pour TLS et WLS sont très faibles, ce qui est attendu car ils ne stockent pas de grandes matrices, de tableaux et n'a pas besoin d'une grande quantité de données pour réaliser l'estimation. D'autre part, SFO, AWTLS, WTLS nécessitent une allocation de mémoire entre 3,2 et 5,5 kb, ce qui est encore très faible et reste dans la capacité de mémoire de la plupart des systèmes embarqués.

Comme il s'agit de la première implémentation de SFO, nous pensons que nous pouvons encore améliorer l'algorithme proposé à travers la vectorisation, en ajustant les paramètres de l'algorithme, et en utilisant le profilage MATLAB (utilisé pour l'optimisation).

## 4.8 CONCLUSION

Dans cette partie, on présente la troisième contribution réalisée dans le cadre de cette thèse qui consiste en une nouvelle approche pour évaluer la capacité totale d'une batterie, où les bruits dans les axes x et y sont correctement pris en compte. Cette stratégie est principalement basée sur l'algorithme SFO.

L'estimation de la capacité totale de la batterie à l'aide du SFO est présentée et comparée à quatre techniques récursives. Pour évaluer la précision des algorithmes ci-dessus, nous avons utilisé l'ensemble de données offert par « Pronostics Data Repository » de la NASA, en plus de trois scénarios de simulation d'une batterie dans des applications pour les véhicules électriques et électriques hybrides.

Au mieux de notre connaissance, le travail présenté est l'une des premières tentatives d'utilisation de l'algorithme SFO pour estimer la capacité totale d'une batterie. SFO a montré des résultats satisfaisants. En effet, dans tous les tests, SFO a enregistré des erreurs faibles de prédiction relatives (erreurs max et moyenne  $< 0,4\%$ ), ainsi que des faibles valeurs pour tous les indicateurs de performance prédictifs (RMSE, MAE et MPAE  $< 0,4\%$ ) par rapport aux méthodes des moindres carrés. L'erreur maximale enregistrée par SFO était de 1,26% dans le pire des cas.

# Conclusion générale :

Le cadre automobile actuel s'organise autour d'une augmentation de plus en plus importante de la part d'énergie électrique. Les véhicules électriques grâce à un système de stockage réversible ont un meilleur rendement énergétique que les véhicules qui utilisent une chaîne de traction non réversible. Pour le sujet de thèse « Estimation des paramètres, de l'état de charge et de l'état de santé de la batterie lithium pour les véhicules électriques », on s'intéresse essentiellement aux systèmes de stockage d'énergie pour les véhicules électriques. Le vrai problème pour les véhicules électriques est la batterie, la production des batteries n'est pas exempte de pollution et le recyclage n'est pas encore efficace. Il est donc important de veiller à une utilisation optimisée.

Le système de gestion d'énergie BMS est un système qui permet de sécuriser l'utilisation d'un module de stockage d'énergie en assurant la surveillance et/ou le contrôle des éléments individuels qui le constituent. Pour une exploitation optimale de la batterie, l'état de charge SOC (State of Charge), et la capacité totale (utilisée pour l'estimation de l'état de santé SOH) sont les variables qui doivent être connues le plus précisément possible. Par conséquent, cette thèse vise à étendre l'état actuel de l'art des algorithmes avancés ciblant l'estimation de ces variables.

Les contributions réalisées au cours de cette thèse peuvent être résumer comme suit :

Premièrement, une étude comparative est menée entre quatre algorithmes pour l'estimation de l'état de charge des batteries pour les véhicules électriques, ainsi que les résultats des simulations des algorithmes : Filtre de Kalman étendu EKF (Extended Kalman Filter), et du filtre de Kalman à points sigma SPKF (Sigma Point Kalman Filter) pour le test de stress dynamique DST (Dynamic stress test).

Deuxièmement, nous avons proposé deux nouveaux algorithmes pour l'estimation des paramètres en ligne du modèle d'une batterie lithium, L'estimation des paramètres est essentielle pour les algorithmes d'estimation de l'état de charge SOC se basant sur un modèle :

1-L'algorithme AFFRLS (Adaptive Forgetting Factor Recursive Least Square) :

Publié dans [16-17], la méthode est appliquée pour extraire les paramètres du modèle Thévenin du premier ordre de la batterie lithium, puis estimer sa tension terminale. La performance des algorithmes est vérifiée à l'aide des données expérimentales fournies par l'Université McMaster de Hamilton, Ontario, Canada, réalisées sur la cellule de batterie Li-ion LG 18650HG2 dans le profil UDDS (Urban Dynamometer Driving Schedule) [7], en plus de deux ensembles de données fournis par le Groupe de recherche sur les batteries CALCE réalisés sur la batterie Li-ion Samsung (INR 18650-20R) dans deux profils dynamiques : DST (Dynamic stress test) et FUDS (Federal urban driving schedule) [8-10].

2-L'algorithme SFO (Sunflower Optimization Algorithm). « *Meilleur article à la conférence IEEE GPECOM2020* »:

Dans le même cadre d'estimation des paramètres en ligne, nous avons proposé une nouvelle méthode basée sur l'algorithme SFO (Sunflower Optimization Algorithm) [18-19]. SFO est appliqué pour extraire les paramètres du modèle Thévenin (premier ordre), puis estimer la tension terminale. Pour mesurer l'efficacité de la technique suggérée, nous avons utilisé des données expérimentales réalisées sur la cellule de la batterie lithium-ion A123 sous trois profils dynamiques : DST, US06 et FUDS. Les données utilisées ont été récupérées auprès du groupe de recherche sur les batteries CALCE [8-10]. À notre connaissance, il s'agit de la première tentative d'utilisation du SFO pour estimer les paramètres d'une batterie en temps réel.

Dans la perspective de ces travaux. Les algorithmes d'estimation des paramètres proposés peuvent être adaptés et combinés avec des techniques telles que les observateurs en mode glissant, les filtres de Kalman, le filtre  $H_\infty$  ou le filtrage de particules (PF) pour estimer l'état de charge ou le l'état de santé d'une batterie lithium-ion.

Quant à l'estimation de la capacité totale de la batterie qui est une tâche essentielle pour le système de gestion de la batterie afin de maintenir les performances et la durée de vie de la batterie dans les véhicules électriques et d'anticiper les risques de défaillance, grâce à des indicateurs tels que l'état de santé (SOH) ; nous avons mis au point un nouveau Framework basé sur l'algorithme SFO pour l'estimation de la capacité totale, cet algorithme est validé et comparé à quatre algorithmes récursifs robustes [12-13] (AWTLS, WTLS, WLS, TLS) à l'aide de l'ensemble de données sur le vieillissement des batteries de la NASA [14], en plus de trois scénarios d'une batterie dans des applications de véhicules électriques et hybrides rechargeables [12-13]. À notre connaissance, il s'agit de la première tentative d'utilisation du SFO pour l'estimation de la capacité.

En perspective, la portée du Framework peut être élargi dans différentes directions, tout d'abord en validant la méthode à l'aide d'autres ensembles de données sur le vieillissement des batteries, les cycles de conduite des véhicules électriques, ainsi qu'en explorant d'autres types de batteries.

En outre, nous visons à tester l'habilité de l'algorithme à estimer la capacité de la batterie en tenant compte de l'influence d'autres facteurs externes tels que la température, la profondeur de décharge, l'équilibrage des cellules, etc. En plus, nous cherchons à examiner la robustesse de notre approche dans des cas spécifiques (données d'entrée bruyantes, entrées d'erreurs importantes dans un des axes).

Par ailleurs, la performance de l'algorithme peut être améliorée (en ajustant les paramètres du SFO pour obtenir des meilleurs résultats, accélérer le processus de prédiction, trouver les meilleures valeurs pour obtenir le meilleur compromis entre précision et vitesse de calcul, explorer d'autres fonctions objectives). La méthode peut être combinée par la suite avec d'autres algorithmes tels que le filtrage de Kalman ou le filtrage de particules pour construire un cadre global capable d'estimer en temps réel l'état de charge et l'état de santé de la batterie.

# Références :

- [1] Disponible en ligne <https://www.jato.com/q1-2021-ev-global-sales-at-the-same-level-as-2017-full-year-figures/>
- [2] A. Chachdi, B. Rahmouni, and G. Aniba, "Socio-economic analysis of electric vehicles in Morocco," *Energy Procedia*, vol. 141, pp. 644-653, 2017.
- [3] Disponible en ligne <https://www.tesla.com/compare>
- [4] Calce research group, "Battery Failure." [Online]. Disponible en ligne <https://web.calce.umd.edu/batteries/overview.html>
- [5] L. Lu, X. Han, J. Li, J. Hua, and M. Ouyang, "A review on the key issues for lithium-ion battery management in electric vehicles," *J. Power Sources*, vol.226, pp. 272–288, 2013.
- [6] X. Hu, F. Sun, Y. Zou, and H. Peng, "Online estimation of an electric vehicle lithium-ion battery using recursive least squares with forgetting," in *Proceedings of the 2011 American Control Conference*, 2011: IEEE, pp. 935-940.
- [7] K.Phillip, N. Mina, S.Michael, " LG 18650HG2 Li-ion Battery Data," Mendeley Data, v2 <http://dx.doi.org/10.17632/b5mj79w5w9.2> ,2020
- [8] W. He, N. Williard, C. Chen, and M. Pecht, "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*, vol. 62, pp. 783-791, 2014.
- [9] F. Zheng, Y. Xing, J. Jiang, B. Sun, J. Kim, and M. Pecht, "Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries," *Applied energy*, vol. 183, pp. 513-525, 2016.
- [10] Y. Xing, W. He, M. Pecht, and K. L. Tsui, "State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures," *Applied Energy*, vol. 113, pp. 106-115, 2014.
- [11] X. Sun, J. Ji, B. Ren, C. Xie, and D. Yan, "Adaptive Forgetting Factor Recursive Least Square Algorithm for Online Identification of Equivalent Circuit Model Parameters of a Lithium-Ion Battery," *Energies*, vol. 12, no. 12, p. 2242, 2019.
- [12] G. L. Plett, "Recursive approximate weighted total least squares estimation of battery cell total capacity," *Journal of Power Sources*, vol. 196, no. 4, pp. 2319-2331, 2011.
- [13] G.L. Plett, "Battery Health Estimation," in *Battery management systems, Volume II: Equivalent-circuit methods*, Artech House, 2015, pp. 220–228. Link for AWTLS method, EV and PHEV scenarios : <http://mocha-java.uccs.edu/BMS2/index.html>
- [14] B. Saha, K. Goebel, Battery Data Set, NASA Ames Prognostics Data Repository ; NASA Ames: Moffett Field, CA, USA, 2007, (2019). [Online] Available: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>
- [15] M. Elmarghichi, M. Bouzi, N. Ettalabi, and M. Derri, "Comparison of State of Charge Estimation Algorithms for Lithium Battery," in *International Conference on Electronic Engineering and Renewable Energy*, 2020: Springer, pp. 293-300.
- [16] M. Elmarghichi, M. B., Naoufl Ettalabi, "Robust Parameter Estimation of an Electric Vehicle Lithium-Ion Battery Using Adaptive Forgetting Factor Recursive Least Squares", <http://www.inass.org/2020/2020103108.pdf>, vol. 13, no. 5, pp. 75-84, 2020.
- [17] E. Mouncef, B. Mostafa, and E. Naoufl, "Online Parameter Estimation of an Electric Vehicle Lithium-Ion Battery Using AFFRLS," in *2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, 2020: IEEE, pp. 1-6.
- [18] E. Mouncef, B. Mostafa, and E. Naoufl, "Online Parameter Estimation of a Lithium-Ion Battery based on Sunflower Optimization Algorithm," in *2020 2nd Global Power, Energy and Communication Conference (GPECOM)*, 2020: IEEE, pp. 53-58.
- [19] M. Elmarghichi and N. Ettalabi, "Online parameter estimation of a lithium-ion battery based on sunflower optimization algorithm," *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 3, pp. 1505-1513, 2021.
- [20] E. Mouncef, B. Mostafa, Battery total capacity estimation based on the sunflower algorithm, *J. Energy Storage*. 48 (2022) 103900. <https://doi.org/10.1016/j.est.2021.103900>.
- [21] H. Budde-Meiwes et al., "A review of current automotive battery technology and future prospects," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 227, no. 5, pp. 761-776, 2013.
- [22] Source image : <https://energsoft.com/blog/f/the-strides-of-lithium-ion-battery>
- [23] M. S. Farag, R. Ahmed, S. Gadsden, S. Habibi, and J. Tjong, "A comparative study of Li-ion battery models and nonlinear dual estimation strategies," in *2012 IEEE Transportation electrification conference and expo (ITEC)*, 2012: IEEE, pp. 1-8.
- [24] M. Farag, M. Fleckenstein, and S. R. Habibi, "Li-ion battery SOC estimation using non-linear estimation strategies based on equivalent circuit models," *SAE Technical Paper*, 0148-7191, 2014.
- [25] D. Di Domenico, G. Fiengo, and A. Stefanopoulou, "Lithium-ion battery state of charge estimation with a kalman filter based on a electrochemical model," in *2008 IEEE International Conference on Control Applications*, 2008: Ieee, pp. 702-707.
- [26] D. Doerffel and S. A. Sharkh, "A critical review of using the Peukert equation for determining the remaining capacity of lead-acid and lithium-ion batteries," *Journal of power sources*, vol. 155, no. 2, pp. 395-400, 2006.
- [27] S. Buller, "Impedance-based simulation models for energy storage devices in advanced automotive applications," D]. Ph. D. Dissertation, RWTH Aachen, Aachen, Germany, 2003.
- [28] V. R. Subramanian, V. Boovaragavan, V. Ramadesigan, and M. Arabandi, "Mathematical model reformulation for lithium-ion battery simulations: Galvanostatic boundary conditions," *Journal of The Electrochemical Society*, vol. 156, no. 4, p. A260, 2009.

- [29] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background," *Journal of Power sources*, vol. 134, no. 2, pp. 252-261, 2004.
- [30] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs Part 2. Modeling and identification," *Journal of Power Sources*, vol. 134, no. 2, pp. 262-276, 2004.
- [31] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3. State and parameter estimation," *Journal of Power sources*, vol. 134, no. 2, pp. 277-292, 2004.
- [32] V. Pop, H. J. Bergveld, J. O. het Veld, P. Regtien, D. Danilov, and P. Notten, "Modeling battery behavior for accurate state-of-charge indication," *Journal of The Electrochemical Society*, vol. 153, no. 11, p. A2013, 2006.
- [33] H. E. Perez, J. B. Siegel, X. Lin, A. G. Stefanopoulou, Y. Ding, and M. P. Castanier, "Parameterization and validation of an integrated electro-thermal cylindrical lfp battery model," in *Dynamic Systems and Control Conference*, 2012, vol. 45318: American Society of Mechanical Engineers, pp. 41-50.
- [34] N. R. Council, *Review of the Research Program of the Partnership for a New Generation of Vehicles: Seventh Report*. National Academies Press, 2001.
- [35] M. Doyle, T. F. Fuller, and J. Newman, "Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell," *Journal of the Electrochemical society*, vol. 140, no. 6, p. 1526, 1993.
- [36] T. F. Fuller, M. Doyle, and J. Newman, "Simulation and optimization of the dual lithium ion insertion cell," *Journal of the Electrochemical Society*, vol. 141, no. 1, p. 1, 1994.
- [37] V. R. Subramanian, V. D. Diwakar, and D. Tapriyal, "Efficient macro-micro scale coupled modeling of batteries," *Journal of The Electrochemical Society*, vol. 152, no. 10, p. A2002, 2005.
- [38] V. R. Subramanian, V. Boovaragavan, and V. D. Diwakar, "Toward real-time simulation of physics based lithium-ion battery models," *Electrochemical and Solid State Letters*, vol. 10, no. 11, p. A255, 2007.
- [39] J. C. Forman, S. Bashash, J. L. Stein, and H. K. Fathy, "Reduction of an electrochemistry-based li-ion battery model via quasi-linearization and pade approximation," *Journal of the Electrochemical Society*, vol. 158, no. 2, p. A93, 2010.
- [40] K. A. Smith, C. D. Rahn, and C.-Y. Wang, "Model order reduction of 1D diffusion systems via residue grouping," 2008.
- [41] K. A. Smith, C. D. Rahn, and C.-Y. Wang, "Model-based electrochemical estimation and constraint management for pulse operation of lithium ion batteries," *IEEE Transactions on Control Systems Technology*, vol. 18, no. 3, pp. 654-663, 2009.
- [42] B. S. Haran, B. N. Popov, and R. E. White, "Determination of the hydrogen diffusion coefficient in metal hydrides by impedance spectroscopy," *Journal of Power Sources*, vol. 75, no. 1, pp. 56-63, 1998.
- [43] S. Santhanagopalan, Q. Guo, P. Ramadass, and R. E. White, "Review of models for predicting the cycling performance of lithium ion batteries," *Journal of power sources*, vol. 156, no. 2, pp. 620-628, 2006.
- [44] S. K. Rahimian, S. Rayman, and R. E. White, "Extension of physics-based single particle model for higher charge-discharge rates," *Journal of Power Sources*, vol. 224, pp. 180-194, 2013.
- [45] Y. Xiao, "Model-Based Virtual Thermal Sensors for Lithium-Ion Battery in EV Applications," *IEEE Trans. Ind. Electron.*, vol. 62, no. 5, pp. 3112-3122, May 2015.
- [46] Y. Wang, Z. Han, and J. Shi, "One cell Lithium-ion battery protection IC," in *2014 9th IEEE Conference on Industrial Electronics and Applications*, 2014, pp.1427-1432.
- [47] Z. Ye, X. Wu, Y. Sun, and J. Lu, "A Universal Protection Controller for Li-ion Battery Charger," in *2010 Asia-Pacific Power and Energy Engineering Conference*, 2010, pp. 1-4.
- [48] I. Aizpuru, U. Iraola, J. M. Canales, M. Echeverria, and I. Gil, "Passive balancing design for Li-ion battery packs based on single cell experimental tests for a CCCV charging mode," in *Clean Electrical Power (ICCEP), 2013 International Conference on*, 2013, pp. 93-98.
- [49] K. Vitols, "Design of an embedded battery management system with passive balancing," in *Education and Research Conference (EDERC), 2014 6th European Embedded Design in*, 2014, pp. 142-146
- [50] T. Morstyn, M. Momayyezani, B. Hredzak, and V. Agelidis, "Distributed Control for State of Charge Balancing Between the Modules of a Reconfigurable Battery Energy Storage System," *IEEE Trans. Power Electron.*, vol. PP, no. 99, p. 1, 2016.
- [51] W. Huang and J. A. A. Qahouq, "Energy Sharing Control Scheme for State-of-Charge Balancing of Distributed Battery Energy Storage System," *IEEE Trans.Ind. Electron.*, vol. 62, no. 5, pp. 2764-2776, May 2015
- [52] Source image : [https://plsadaptive.s3.amazonaws.com/eco/images/channel\\_content/images/btms-hdr.jpg](https://plsadaptive.s3.amazonaws.com/eco/images/channel_content/images/btms-hdr.jpg)
- [53] Z. Rao and S. Wang, "A review of power battery thermal energy management," *Renew. Sustain. Energy Rev.*, vol. 15, no. 9, pp. 4554-4571, 2011
- [54] C. Alaoui, "Solid-State Thermal Management for Lithium-Ion EV Batteries," *IEEE Trans. Veh. Technol.*, vol. 62, no. 1, pp. 98-107, Jan. 2013
- [55] R. Zhao, S. Zhang, J. Gu, J. Liu, S. Carkner, and E. Lanoue, "An experimental study of lithium ion battery thermal management using flexible hydrogel films," *J. Power Sources*, vol. 255, pp. 29-36, 2014
- [56] H. Zhou, T. Bhattacharya, D. Tran, T. S. T. Siew, and A. M. Khambadkone, "Composite Energy Storage System Involving Battery and Ultracapacitor With Dynamic Energy Management in Microgrid Applications," *IEEE Trans. Power Electron.*, vol. 26, no. 3, pp. 923-930, Mar. 2011.
- [57] A. Urtasun, E. L. Barrios, P. Sanchis, and L. Marroyo, "Frequency-Based Energy-Management Strategy for Stand-Alone Systems With Distributed Battery Storage," *IEEE Trans. Power Electron.*, vol. 30, no. 9, pp. 4794-4808, Sep. 2015.
- [58] C. Fleischer, W. Waag, H.-M. Heyn, and D. U. Sauer, "On-line adaptive battery impedance parameter and state estimation considering physical principles in reduced order equivalent circuit battery models: Part 1. Requirements, critical review of methods and modeling," *J. Power Sources*, vol. 260, pp. 276-291, 2014.
- [59] J. Baker and A. Collinson, "Electrical energy storage at the turn of the millennium," *Power Engineering Journal*, vol. 13, no. 3, pp. 107-112, 1999.
- [60] M. Uno and K. Tanaka, "Single-switch multioutput charger using voltage multiplier for series-connected lithium-ion battery/supercapacitor equalization," *IEEE Transactions on Industrial electronics*, vol. 60, no. 8, pp. 3227-3239, 2012.

- [61] A. C. Baughman and M. Ferdowsi, "Double-tiered switched-capacitor battery charge equalization technique," *IEEE Transactions on Industrial Electronics*, vol. 55, no. 6, pp. 2277-2285, 2008.
- [62] M.-Y. Kim, C.-H. Kim, J.-H. Kim, and G.-W. Moon, "A chain structure of switched capacitor for improved cell balancing speed of lithium-ion batteries," *IEEE Transactions on Industrial Electronics*, vol. 61, no. 8, pp. 3989-3999, 2013.
- [63] T. H. Phung, J.-C. Crebier, A. Chureau, A. Collet, and V. Nguyen, "Optimized structure for next-to-next balancing of series-connected lithium-ion cells," in 2011 Twenty-Sixth Annual IEEE Applied Power Electronics Conference and Exposition (APEC), 2011: IEEE, pp. 1374-1381.
- [64] R. Ling, Q. Dan, L. Wang, and D. Li, "Energy bus-based equalization scheme with bi-directional isolated Cuk equalizer for series connected battery strings," in 2015 IEEE Applied Power Electronics Conference and Exposition (APEC), 2015: IEEE, pp. 3335-3340.
- [65] T. Gottwald, Z. Ye, and T. Stuart, "Equalization of EV and HEV batteries with a ramp converter," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 33, no. 1, pp. 307-312, 1997.
- [66] J. Ewanchuk and J. Salmon, "A modular balancing bridge for series connected voltage sources," *IEEE transactions on power electronics*, vol. 29, no. 9, pp. 4712-4722, 2013.
- [67] K.-m. Lee, Y.-c. Chung, C.-H. Sung, and B. Kang, "Active cell balancing of li-ion batteries using  $\$ LC \$$  series resonant circuit," *IEEE Transactions on Industrial Electronics*, vol. 62, no. 9, pp. 5491-5501, 2015.
- [68] J.-W. Kim and J.-I. Ha, "Cell balancing control of single switch flyback converter using generalized filters," in 2014 IEEE Applied Power Electronics Conference and Exposition-APEC 2014, 2014: IEEE, pp. 3273-3277.
- [69] M. Simon, M. Mürken, C. Augustin, and J. Pforr, "Multi-Port Converter with bidirectional energy flow for automotive energy net applications," in 2014 16th European Conference on Power Electronics and Applications, 2014: IEEE, pp. 1-10.
- [70] J. H. Aylor, A. Thieme, and B. W. Johnso, "A battery state-of-charge indicator for electric wheelchairs," *IEEE Trans. Ind. Electron.*, vol. 39, no. 5, pp. 398-409, Oct. 1992.
- [71] Y. Yang, J. Liu, and C. Tsai, "Improved estimation of residual capacity of batteries for electric vehicles," *J. Chinese Inst. Eng.*, vol. 31, no. 2, pp. 313-322, 2008.
- [72] V. Pop, H. J. Bergveld, D. Danilov, P. P. L. Regtien, and P. H. L. Notten, *Battery management systems: Accurate state-of-charge indication for battery-powered applications*, vol. 9. Springer Science & Business Media, 2008.
- [73] H. J. Bergveld, V. Pop, and P. H. L. Notten, "Method of estimating the State-of Charge and of the use time left of a rechargeable battery, and apparatus for executing such a method." Google Patents, 2005.
- [74] V. Coroban, I. Boldea, and F. Blaabjerg, "A novel on-line state-of-charge estimation algorithm for valve regulated lead-acid batteries used in hybrid electric vehicles," in *Electrical Machines and Power Electronics, 2007. ACEMP '07. International Aegean Conference on*, 2007, pp. 39-46.
- [75] S. Nejad, D. T. Gladwin, and D. A. Stone, "Sensitivity of lumped parameter battery models to constituent parallel-RC element parameterisation error," in *Industrial Electronics Society, IECON 2014 - 40th Annual Conference of the IEEE*, 2014, pp. 5660-5665.
- [76] J. Li, J. Klee Barillas, C. Guenther, and M. A. Danzer, "A comparative study of state of charge estimation algorithms for LiFePO4 batteries used in electric vehicles," *J. Power Sources*, vol. 230, pp. 244-250, 2013.
- [77] F. Baronti et al., "State-of-charge estimation enhancing of lithium batteries through a temperature-dependent cell model," in *Applied Electronics (AE), 2011 International Conference on*, 2011, pp. 1-5.
- [78] R. Xiong, H. He, F. Sun, X. Liu, and Z. Liu, "Model-based state of charge and peak power capability joint estimation of lithium-ion battery in plug-in hybrid electric vehicles," *J. Power Sources*, vol. 229, pp. 159-169, 2013.
- [79] M. Gholizadeh and F. R. Salmasi, "Estimation of state of charge, unknown nonlinearities, and state of health of a lithium-ion battery based on a comprehensive unobservable model," *IEEE Trans. Ind. Electron.*, vol. 61, no. 3, pp. 1335-1344, 2014.
- [80] H. Chaoui, N. Golbon, I. Hmouz, R. Souissi, and S. Tahar, "Lyapunov-Based Adaptive State of Charge and State of Health Estimation for Lithium-Ion Batteries," *IEEE Trans. Ind. Electron.*, vol. 62, no. 3, pp. 1610-1618, Mar. 2015.
- [81] Y. Wang, H. Fang, Z. Sahinoglu, T. Wada, and S. Hara, "Adaptive Estimation of the State of Charge for Lithium-Ion Batteries: Nonlinear Geometric Observer Approach," *IEEE Trans. Control Syst. Technol.*, vol. 23, no. 3, pp. 948-962, May 2015.
- [82] C. Zhang, L. Y. Wang, X. Li, W. Chen, G. G. Yin, and J. Jiang, "Robust and Adaptive Estimation of State of Charge for Lithium-Ion Batteries," *IEEE Trans. Ind. Electron.*, vol. 62, no. 8, pp. 4948-4957, Aug. 2015.
- [83] X. Chen, W. Shen, Z. Cao, and A. Kapoor, "A novel approach for state of charge estimation based on adaptive switching gain sliding mode observer in electric vehicles," *J. Power Sources*, vol. 246, pp. 667-678, 2014.
- [84] H. Rahimi-Eichi, F. Baronti, and M.-Y. Chow, "Online Adaptive Parameter Identification and State-of-Charge Coestimation for Lithium-Polymer Battery Cells," *Ind. Electron. IEEE Trans.*, vol. 61, no. 4, pp. 2053-2061, Apr. 2014.
- [85] F. Auger, M. Hilairat, J. M. Guerrero, E. Monmasson, T. Orłowska-Kowalska, and S. Katsura, "Industrial Applications of the Kalman Filter: A Review," *Ind. Electron. IEEE Trans.*, vol. 60, no. 12, pp. 5458-5471, Dec. 2013.
- [86] A. El Mejdoubi, A. Oukaour, H. Chaoui, H. Gualous, J. Sabor, and Y. Slamani, "State-of-Charge and State-of-Health Lithium-Ion Batteries' Diagnosis According to Surface Temperature Variation," *IEEE Trans. Ind. Electron.*, vol. 63, no. 4, pp. 2391-2402, Apr. 2016.
- [87] C. R. Gould, C. M. Bingham, D. A. Stone, and P. Bentley, "New battery model and state-of-health determination through subspace parameter estimation and state-observer techniques," *IEEE Trans. Veh. Technol.*, vol. 58, no. 8, pp. 3905-3916, Oct. 2009.
- [88] Z. Chen, Y. Fu, and C. C. Mi, "State of Charge Estimation of Lithium-Ion Batteries in Electric Drive Vehicles Using Extended Kalman Filtering," *IEEE Trans. Veh. Technol.*, vol. 62, no. 3, pp. 1020-1030, Mar. 2013.
- [89] C. Hu, B. D. Youn, and J. Chung, "A multiscale framework with extended Kalman filter for lithium-ion battery SOC and capacity estimation," *Appl. Energy*, vol. 92, pp. 694-704, Apr. 2012.



- [90] J. Kim and B.-H. Cho, "State-of-Charge Estimation and State-of-Health Prediction of a Li-Ion Degraded Battery Based on an EKF Combined With a Per-Unit System," *Veh. Technol. IEEE Trans.*, vol. 60, no. 9, pp. 4249–4260, Nov. 2011.
- [91] S. Yuan, H. Wu, and C. Yin, "State of Charge Estimation Using the Extended Kalman Filter for Battery Management Systems Based on the ARX Battery Model," *Energies*, vol. 6, no. 1, p. 444, 2013.
- [92] X. Hu, S. Li, H. Peng, and F. Sun, "Robustness analysis of State-of-Charge estimation methods for two types of Li-ion batteries," *J. Power Sources*, vol. 217, pp. 209–219, 2012.
- [93] R. Xiong, F. Sun, Z. Chen, and H. He, "A data-driven multi-scale extended Kalman filtering based parameter and state estimation approach of lithium-ion polymer battery in electric vehicles," *Applied Energy*, vol. 113, pp. 463–476, 2014.
- [94] H. Aung, K. S. Low, and S. T. Goh, "State-of-Charge Estimation of Lithium-Ion Battery Using Square Root Spherical Unscented Kalman Filter (Sqrt-UKFST) in Nanosatellite," *IEEE Trans. Power Electron.*, vol. 30, no. 9, pp. 4774–4783, Sep. 2015.
- [95] J. Meng, G. Luo, and F. Gao, "Lithium Polymer Battery State-of-Charge Estimation Based on Adaptive Unscented Kalman Filter and Support Vector Machine," *IEEE Trans. Power Electron.*, vol. 31, no. 3, pp. 2226–2238, Mar. 2016.
- [96] G. L. Plett, "Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs," *J. Power Sources*, vol. 161, no. 2, pp. 1369–1384, Oct. 2006.
- [97] G. L. Plett, "Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs. Part 1: Introduction and state estimation," *J. Power Sources*, vol. 161, no. 2, pp. 1356–1368, 2006.
- [98] Z. He, M. Gao, C. Wang, L. Wang, and Y. Liu, "Adaptive State of Charge Estimation for Li-Ion Batteries Based on an Unscented Kalman Filter with an Enhanced Battery Model," *Energies*, vol. 6, no. 8, p. 4134, 2013.
- [99] Liye Wang, Lifang Wang, Chenglin Liao, and Jun Liu, "Sigma-point Kalman filter application on estimating battery SOC," in *2009 IEEE Vehicle Power and Propulsion Conference*, 2009, pp. 1592–1595.
- [100] R. Xiong, H. He, F. Sun, and K. Zhao, "Evaluation on state of charge estimation of batteries with adaptive extended Kalman filter by experiment approach," *IEEE Transactions on Vehicular Technology*, vol. 62, no. 1, pp. 108–117, 2012.
- [101] S. Sepasi, R. Ghorbani, and B. Y. Liaw, "A novel on-board state-of-charge estimation method for aged Li-ion batteries based on model adaptive extended Kalman filter," *Journal of Power Sources*, vol. 245, pp. 337–344, 2014.
- [102] H. He, R. Xiong, and H. Guo, "Online estimation of model parameters and state-of-charge of LiFePO<sub>4</sub> batteries in electric vehicles," *Applied Energy*, vol. 89, no. 1, pp. 413–420, 2012.
- [103] R. Xiong, F. Sun, X. Gong, and H. He, "Adaptive state of charge estimator for lithium-ion cells series battery pack in electric vehicles," *Journal of power sources*, vol. 242, pp. 699–713, 2013.
- [104] R. Xiong, F. Sun, X. Gong, and C. Gao, "A data-driven based adaptive state of charge estimator of lithium-ion polymer battery used in electric vehicles," *Applied Energy*, vol. 113, pp. 1421–1433, 2014.
- [105] F. Sun, X. Hu, Y. Zou, and S. Li, "Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles," *Energy*, vol. 36, no. 5, pp. 3531–3540, 2011.
- [106] M. E. Orchard, P. Hevia-Koch, B. Zhang, and L. Tang, "Risk measures for particle-filtering-based state-of-charge prognosis in lithium-ion batteries," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 11, pp. 5260–5269, 2012.
- [107] Y. He, X. Liu, C. Zhang, and Z. Chen, "A new model for State-of-Charge (SOC) estimation for high-power Li-ion batteries," *Applied Energy*, vol. 101, pp. 808–814, 2013.
- [108] S. Schwunk, N. Armbruster, S. Straub, J. Kehl, and M. Vetter, "Particle filter for state of charge and state of health estimation for lithium-iron phosphate batteries," *Journal of Power Sources*, vol. 239, pp. 705–710, 2013.
- [109] X. Chen, W. Shen, M. Dai, Z. Cao, J. Jin, and A. Kapoor, "Robust adaptive sliding-mode observer using RBF neural network for lithium-ion battery state of charge estimation in electric vehicles," *IEEE Transactions on Vehicular Technology*, vol. 65, no. 4, pp. 1936–1947, 2015.
- [110] M. Landi and G. Gross, "Measurement techniques for online battery state of health estimation in vehicle-to-grid applications," *IEEE Transactions on Instrumentation and Measurement*, vol. 63, no. 5, pp. 1224–1234, 2014.
- [111] W.-Y. Chang, "Estimation of the state of charge for a LFP battery using a hybrid method that combines a RBF neural network, an OLS algorithm and AGA," *International Journal of Electrical Power & Energy Systems*, vol. 53, pp. 603–611, 2013.
- [112] C. Hametner and S. Jakubek, "State of charge estimation for Lithium Ion cells: Design of experiments, nonlinear identification and fuzzy observer design," *Journal of Power Sources*, vol. 238, pp. 413–421, 2013.
- [113] A. Zenati, P. Desprez, and H. Razik, "Estimation of the SOC and the SOH of li-ion batteries, by combining impedance measurements with the fuzzy logic inference," in *IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society*, 2010: IEEE, pp. 1773–1778.
- [114] T. Kim et al., "Model-based condition monitoring for lithium-ion batteries," *Journal of Power Sources*, vol. 295, pp. 16–27, 2015.
- [115] J. C. A. Anton, P. J. G. Nieto, C. B. Viejo, and J. A. V. Vilán, "Support vector machines used to estimate the battery state of charge," *IEEE Transactions on power electronics*, vol. 28, no. 12, pp. 5919–5926, 2013.
- [116] B. Pattipati, C. Sankavaram, and K. Pattipati, "System identification and estimation framework for pivotal automotive battery management system characteristics," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 41, no. 6, pp. 869–884, 2011.
- [117] P.-H. Michel and V. Heiries, "An adaptive sigma point kalman filter hybridized by support vector machine algorithm for battery SoC and SoH estimation," in *2015 IEEE 81st Vehicular Technology Conference (VTC Spring)*, 2015: IEEE, pp. 1–7.
- [118] M. Shahriari and M. Farrokhi, "Online state-of-health estimation of VRLA batteries using state of charge," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 1, pp. 191–202, 2012.
- [119] M.N. Ramadan, B.A. Pramana, S.A. Widayat, L.K. Amifia, A. Cahyadi, O. Wahyunggoro, Comparative Study Between Internal Ohmic Resistance and Capacity for Battery State of Health Estimation, *J. Mechatronics, Electr. Power, Veh. Technol.* 6 (2015) 113–122.

- [120] M. Ouyang, X. Feng, X. Han, L. Lu, Z. Li, X. He, A dynamic capacity degradation model and its applications considering varying load for a large format Li-ion battery, *Appl. Energy*. 165 (2016) 48–59.
- [121] L. Liu, J. Park, X. Lin, A.M. Sastry, W. Lu, A thermal-electrochemical model that gives spatial-dependent growth of solid electrolyte interphase in a Li-ion battery, *J. Power Sources*. 268 (2014) 482–490.
- [122] P. Guan, L. Liu, X. Lin, Simulation and experiment on solid electrolyte interphase (SEI) morphology evolution and lithium-ion diffusion, *J. Electrochem. Soc.* 162 (2015) A1798.
- [123] I. Bloom, A.N. Jansen, D.P. Abraham, J. Knuth, S.A. Jones, V.S. Battaglia, G.L. Henriksen, Differential voltage analyses of high-power, lithium-ion cells: 1. Technique and application, *J. Power Sources*. 139 (2005) 295–303.
- [124] I. Bloom, J. Christophersen, K. Gering, Differential voltage analyses of high-power lithium-ion cells: 2. Applications, *J. Power Sources*. 139 (2005) 304–313.
- [125] I. Bloom, J.P. Christophersen, D.P. Abraham, K.L. Gering, Differential voltage analyses of high-power lithium-ion cells: 3. Another anode phenomenon, *J. Power Sources*. 157 (2006) 537–542.
- [126] I. Bloom, L.K. Walker, J.K. Basco, D.P. Abraham, J.P. Christophersen, C.D. Ho, Differential voltage analyses of high-power lithium-ion cells. 4. Cells containing NMC, *J. Power Sources*. 195 (2010) 877–882.
- [127] K. Honkura, H. Honbo, Y. Koishikawa, T. Horiba, State analysis of lithium-ion batteries using discharge curves, *ECS Trans.* 13 (2008) 61.
- [128] K. Honkura, K. Takahashi, T. Horiba, Capacity-fading prediction of lithium-ion batteries based on discharge curves analysis, *J. Power Sources*. 196 (2011) 10141–10147.
- [129] R. Xiong, L. Li, J. Tian, Towards a smarter battery management system: A critical review on battery state of health monitoring methods, *J. Power Sources*. 405 (2018) 18–29.
- [130] P. Keil and A. Jossen, "Calendar aging of NCA lithium-ion batteries investigated by differential voltage analysis and coulomb tracking," *Journal of The Electrochemical Society*, vol. 164, no. 1, p. A6066, 2016.
- [131] M. Dubarry, V. Svoboda, R. Hwu, B.Y. Liaw, Incremental capacity analysis and close-to-equilibrium OCV measurements to quantify capacity fade in commercial rechargeable lithium batteries, *Electrochem. Solid State Lett.* 9 (2006) A454.
- [132] D. Anseán, V.M. García, M. González, C. Blanco-Viejo, J.C. Viera, Y.F. Pulido, L. Sánchez, Lithium-ion battery degradation indicators via incremental capacity analysis, *IEEE Trans. Ind. Appl.* 55 (2019) 2992–3002.
- [133] M. Dubarry, C. Truchot, B.Y. Liaw, Synthesize battery degradation modes via a diagnostic and prognostic model, *J. Power Sources*. 219 (2012) 204–216.
- [134] C. Pastor-Fernández, K. Uddin, G.H. Chouchelamane, W.D. Widanage, J. Marco, A comparison between electrochemical impedance spectroscopy and incremental capacity-differential voltage as Li-ion diagnostic techniques to identify and quantify the effects of degradation modes within battery management systems, *J. Power Sources*. 360 (2017) 301–318.
- [135] Y. Li, M. Abdel-Monem, R. Gopalakrishnan, M. Berecibar, E. Nanini-Maury, N. Omar, P. van den Bossche, J. Van Mierlo, A quick on-line state of health estimation method for Li-ion battery with incremental capacity curves processed by Gaussian filter, *J. Power Sources*. 373 (2018) 40–53.
- [136] J. Tian, R. Xiong, Q. Yu, Fractional-order model-based incremental capacity analysis for degradation state recognition of lithium-ion batteries, *IEEE Trans. Ind. Electron.* 66 (2018) 1576–1584.
- [137] Z. Ma, R. Yang, Z. Wang, A novel data-model fusion state-of-health estimation approach for lithium-ion batteries, *Appl. Energy*. 237 (2019) 836–847.
- [138] B. Jiang, H. Dai, and X. Wei, "Incremental capacity analysis based adaptive capacity estimation for lithium-ion battery considering charging condition," *Applied Energy*, vol. 269, p. 115074, 2020.
- [139] W. Li, M. Rentemeister, J. Badeda, D. Jöst, D. Schulte, D.U. Sauer, Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation, *J. Energy Storage*. 30 (2020) 101557.
- [140] Y. Zou, X. Hu, H. Ma, S.E. Li, Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles, *J. Power Sources*. 273 (2015) 793–803.
- [141] J. Wu, Z. Wei, W. Li, Y. Wang, Y. Li, D. Sauer, Battery thermal-and health-constrained energy management for hybrid electric bus based on soft actor-critic DRL algorithm, *IEEE Trans. Ind. Informatics*. (2020).
- [142] W. Li, D. Cao, D. Jöst, F. Ringbeck, M. Kuipers, F. Frie, D.U. Sauer, Parameter sensitivity analysis of electrochemical model-based battery management systems for lithium-ion batteries, *Appl. Energy*. 269 (2020) 115104.
- [143] W. Li, Y. Fan, F. Ringbeck, D. Jöst, X. Han, M. Ouyang, D.U. Sauer, Electrochemical model-based state estimation for lithium-ion batteries with adaptive unscented Kalman filter, *J. Power Sources*. 476 (2020) 228534.
- [144] B. Jenkins, A. Krupadanam, A.M. Annaswamy, Fast adaptive observers for battery management systems, *IEEE Trans. Control Syst. Technol.* 28 (2019) 776–789.
- [145] L. Zheng, L. Zhang, J. Zhu, G. Wang, J. Jiang, Co-estimation of state-of-charge, capacity and resistance for lithium-ion batteries based on a high-fidelity electrochemical model, *Appl. Energy*. 180 (2016) 424–434.
- [146] C. Hu, G. Jain, C. Schmidt, C. Strief, M. Sullivan, Online estimation of lithium-ion battery capacity using sparse Bayesian learning, *J. Power Sources*. 289 (2015) 105–113.
- [147] C. Hu, G. Jain, P. Zhang, C. Schmidt, P. Gomadam, T. Gorka, Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery, *Appl. Energy*. 129 (2014) 49–55.
- [148] C. Zhang, Y. He, L. Yuan, S. Xiang, Capacity prognostics of lithium-ion batteries using EMD denoising and multiple kernel RVM, *IEEE Access*. 5 (2017) 12061–12070.
- [149] S. Shen, M. Sadoughi, X. Chen, M. Hong, C. Hu, A deep learning method for online capacity estimation of lithium-ion batteries, *J. Energy Storage*. 25 (2019) 100817.
- [150] S. Shen, M. Sadoughi, M. Li, Z. Wang, C. Hu, Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of lithium-ion batteries, *Appl. Energy*. 260 (2020) 114296.

- [151] C. Chen, R. Xiong and W. Shen, "A Lithium-Ion Battery-in-the-Loop Approach to Test and Validate Multiscale Dual H Infinity Filters for State-of-Charge and Capacity Estimation," in *IEEE Transactions on Power Electronics*, vol. 33, no. 1, pp. 332-342, Jan. 2018, doi: 10.1109/TPEL.2017.2670081.
- [152] Q. Yu, R. Xiong, R. Yang, and M. G. Pecht, "Online capacity estimation for lithium-ion batteries through joint estimation method," *Applied Energy*, vol. 255, p. 113817, 2019.
- [153] B. Jiang, H. Dai, X. Wei, and T. Xu, "Joint estimation of lithium-ion battery state of charge and capacity within an adaptive variable multi-timescale framework considering current measurement offset," *Applied Energy*, vol. 253, p. 113619, 2019.
- [154] Z. Chen, J. Xiao, X. Shu, S. Shen, J. Shen, and Y. Liu, "Model-based adaptive joint estimation of the state of charge and capacity for lithium-ion batteries in their entire lifespan," *Energies*, vol. 13, no. 6, p. 1410, 2020.
- [155] Z. Wei, J. Zhao, D. Ji, and K. J. Tseng, "A multi-timescale estimator for battery state of charge and capacity dual estimation based on an online identified model," *Applied energy*, vol. 204, pp. 1264-1274, 2017.
- [156] M.A. Hannan, M.S.H. Lipu, A. Hussain, A. Mohamed, A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations, *Renew. Sustain. Energy Rev.* 78 (2017) 834–854.
- [157] M. Farag, M. Fleckenstein, and S. Habibi, "Continuous piecewise-linear, reduced-order electrochemical model for lithium-ion batteries in real-time applications," *Journal of Power Sources*, vol. 342, pp. 351-362, 2017.
- [158] P. Shrivastava, T.K. Soon, M.Y.I. Bin Idris, S. Mekhilef, Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries, *Renew. Sustain. Energy Rev.* 113 (2019) 109233.
- [159] R. Xiong, J. Cao, Q. Yu, H. He, and F. Sun, "Critical review on the battery state of charge estimation methods for electric vehicles," *Ieee Access*, vol. 6, pp. 1832-1843, 2017.
- [160] S. Sepasi, R. Ghorbani, and B. Y. Liaw, "Improved extended Kalman filter for state of charge estimation of battery pack," *Journal of Power Sources*, vol. 255, pp. 368-376, 2014.
- [161] H. He, R. Xiong, and J. Fan, "Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach," *energies*, vol. 4, no. 4, pp. 582-598, 2011.
- [162] H. He, R. Xiong, X. Zhang, F. Sun, and J. Fan, "State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved Thevenin model," *IEEE Transactions on vehicular technology*, vol. 60, no. 4, pp. 1461-1469, 2011.
- [163] G. O. Sahinoglu, M. Pajovic, Z. Sahinoglu, Y. Wang, P. V. Orlik, and T. Wada, "Battery state-of-charge estimation based on regular/recurrent Gaussian process regression," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 5, pp. 4311-4321, 2017.
- [164] H. Chaoui and C. C. Ibe-Ekeocha, "State of charge and state of health estimation for lithium batteries using recurrent neural networks," *IEEE Transactions on vehicular technology*, vol. 66, no. 10, pp. 8773-8783, 2017.
- [165] A. J. Salkind, C. Fennie, P. Singh, T. Atwater, and D. E. Reisner, "Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology," *Journal of Power sources*, vol. 80, no. 1-2, pp. 293-300, 1999.
- [166] H. Sheng and J. Xiao, "Electric vehicle state of charge estimation: Nonlinear correlation and fuzzy support vector machine," *Journal of Power sources*, vol. 281, pp. 131-137, 2015.
- [167] Y. Li, C. Wang, and J. Gong, "A combination Kalman filter approach for State of Charge estimation of lithium-ion battery considering model uncertainty," *Energy*, vol. 109, pp. 933-946, 2016.
- [168] T. Zahid, K. Xu, W. Li, C. Li, and H. Li, "State of charge estimation for electric vehicle power battery using advanced machine learning algorithm under diversified drive cycles," *Energy*, vol. 162, pp. 871-882, 2018.
- [169] W. Shen, C. C. Chan, E. W. Lo, and K. Chau, "Adaptive neuro-fuzzy modeling of battery residual capacity for electric vehicles," *IEEE Transactions on Industrial Electronics*, vol. 49, no. 3, pp. 677-684, 2002.
- [170] X. Zhang, W. Zhang, and G. Lei, "A review of li-ion battery equivalent circuit models," *Trans. Electr. Electron. Mater.(TEEM)*, vol. 17, no. 6, pp. 311-316, 2016.
- [171] B. Ning, B. Cao, B. Wang, and Z. Zou, "Adaptive sliding mode observers for lithium-ion battery state estimation based on parameters identified online," *Energy*, vol. 153, pp. 732-742, 2018.
- [172] Y. Feng, C. Xue, Q.-L. Han, F. Han, and J. Du, "Robust Estimation for State-of-Charge and State-of-Health of Lithium-ion Batteries Using Integral-Type Terminal Sliding-Mode Observers," *IEEE Transactions on Industrial Electronics*, 2019.
- [173] D.-W. Chung and S.-H. Yang, "SOC estimation of lithium-ion battery based on kalman filter algorithm for energy storage system in microgrids," in *E3S Web of Conferences*, 2018, vol. 57: EDP Sciences, p. 02006.
- [174] H. Ramadan, M. Becherif, and F. Claude, "Extended kalman filter for accurate state of charge estimation of lithium-based batteries: a comparative analysis," *International Journal of Hydrogen Energy*, vol. 42, no. 48, pp. 29033-29046, 2017.
- [175] B. Xia, Z. Zhang, Z. Lao, W. Wang, W. Sun, Y. Lai, M. Wang, "Strong tracking of a h-infinity filter in lithium-ion battery state of charge estimation," *Energies*, vol. 11, no. 6, p. 1481, 2018.
- [176] B. Xia, Z. Sun, R. Zhang, and Z. Lao, "A cubature particle filter algorithm to estimate the state of the charge of lithium-ion batteries based on a second-order equivalent circuit model," *Energies*, vol. 10, no. 4, p. 457, 2017.
- [177] B. Xia, Z. Zhang, Z. Lao, W. Wang, W. Sun, Y. Lai, M. Wang, "A comparative study of three improved algorithms based on particle filter algorithms in soc estimation of lithium ion batteries," *Energies*, vol. 10, no. 8, p. 1149, 2017.
- [178] N. Tian, Y. Wang, J. Chen, and H. Fang, "On parameter identification of an equivalent circuit model for lithium-ion batteries," In : 2017 IEEE Conference on Control Technology and Applications (CCTA): IEEE, Hawaii, USA, pp. 187-192, 2017
- [179] Z. Yu, L. Xiao, H. Li, X. Zhu, and R. Huai, "Model parameter identification for lithium batteries using the coevolutionary particle swarm optimization method", *IEEE Transactions on Industrial Electronics*, Vol. 64, No. 7, pp. 5690-5700, 2017.
- [180] Z. Lao, B. Xia, W. Wang, W. Sun, Y. Lai, and M. Wang, "A novel method for lithium-ion battery online parameter identification based on variable forgetting factor recursive least squares", *Energies*, Vol. 11, No. 6, pp. 1358, 2018.

- [181] J. Wang, L. Zhang, D. Xu, P. Zhang, and G. Zhang, "A simplified fractional order equivalent circuit model and adaptive online parameter identification method for lithium-ion batteries", *Mathematical Problems in Engineering*, Vol. 2019, 2019.
- [182] W. Xu, J. Xu, and X. Yan, "Lithium-ion battery state of charge and parameters joint estimation using cubature Kalman filter and particle filter", *Journal of Power Electronics*, Vol. 20, No. 1, pp. 292-307, 2020.
- [183] P. S. Diniz, *Adaptive Filtering Algorithms and Practical Implementation*, Vol. 694, Springer, Switzerland, 2020.
- [184] C. Vidal, P. Kollmeyer, E. Chemali, and A. Emadi, "Li-ion battery state of charge estimation using long short-term memory recurrent neural network with transfer learning," in *2019 IEEE Transportation Electrification Conference and Expo (ITEC)*,
- [185] R.A. El-Sehiemy, M.A. Hamida, T. Mesbahi, Parameter identification and state-of-charge estimation for lithium-polymer battery cells using enhanced sunflower optimization algorithm, *Int. J. Hydrogen Energy*. 45 (2020) 8833–8842.
- [186] M.H. Qais, H.M. Hasanien, S. Alghuwainem, Identification of electrical parameters for three-diode photovoltaic model using analytical and sunflower optimization algorithm, *Appl. Energy*. 250 (2019) 109–117.
- [187] Z. Yuan, W. Wang, H. Wang, N. Razmjoo, A new technique for optimal estimation of the circuit-based PEMFCs using developed Sunflower Optimization Algorithm, *Energy Reports*. 6 (2020) 662–671.
- [188] M.A.M. Shaheen, H.M. Hasanien, S.F. Mekhamer, H.E.A. Talaat, Optimal power flow of power systems including distributed generation units using sunflower optimization algorithm, *IEEE Access*. 7 (2019) 109289–109300.
- [189] G.F. Gomes, R.S. Giovani, An efficient two-step damage identification method using sunflower optimization algorithm and mode shape curvature (MSDBI-SFO), *Eng. Comput.* (2020) 1–20.
- [190] B.M. Alshammari, T. Guesmi, New chaotic sunflower optimization algorithm for optimal tuning of power system stabilizers, *J. Electr. Eng. Technol.* 15 (2020) 1985–1997.
- [191] G.F. Gomes, S.S. da Cunha, A.C. Ancelotti, A sunflower optimization (SFO) algorithm applied to damage identification on laminated composite plates, *Eng. Comput.* 35 (2019) 619–626.
- [192] MATLAB PROFILING: <https://www.mathworks.com/help/slrealtime/profiling.html>
- [193] Tesla SOC : <https://www.teslarati.com/tesla-caps-superchargers-at-80-percent-to-raise-throughput/>