

Diagnostic de l'état de santé du supercondensateur en phase de charge et d'autodécharge

Amrane OUKAOUR

Université de Caen Normandie - Laboratoire Universitaire des Sciences Appliquées de Cherbourg

RESUME - Les composants de stockage de l'énergie électrique, destinés pour des applications comme le véhicule électrique ou le micro-réseau de distribution, subissent des contraintes le long de leur durée de fonctionnement (durée de vie). Celles-ci altèrent leurs qualités et leurs aptitudes à assurer les fonctions pour lesquelles ils sont destinés. Les critères de performances et de fiabilité d'un composant de stockage dépendent essentiellement de son architecture lors de sa conception. Cette dernière ne pouvant atteindre la perfection, alors les vulnérabilités et les faiblesses qu'il contient entraînent des dysfonctionnements lors de sa vie opérationnelle. Les dégradations engendrées sont souvent liées à l'état de vieillissement du composant considéré.

La stratégie souvent utilisée pour améliorer la sûreté de fonctionnement est celle qui intègre la notion de fiabilité. Cette dernière repose sur des essais de vieillissement accélérés obtenus par l'augmentation des niveaux de contraintes dans des limites admissibles jusqu'à obtenir les seuils escomptés. La capitalisation des données obtenues lors de ces essais, permet d'établir des modèles de dégradations (lois d'accélération) dont nous pouvons nous servir pour la mise en œuvre de la maintenance prédictive de ces systèmes. C'est dans ce contexte qu'une idée originale consistant à exploiter les données obtenues lors des essais de vieillissement et relatives à la phase d'autodécharge du supercondensateur nous a permis d'étudier et de diagnostiquer son état de santé (SoH). En effet, la phase d'autodécharge utilise une seule mesure, en l'occurrence la tension aux bornes du composant, et s'affranchit donc de la mesure du courant de charge/décharge, comme c'est le cas dans la plupart des méthodes répertoriées dans la littérature.

Mots-clés—*Supercondensateur (SC), système de stockage, vieillissement, dégradation, diagnostic, base de données, apprentissage artificiel.*

1. INTRODUCTION

Les composants de stockage de l'énergie électrique jouent un rôle prometteur dans les applications industrielles actuelles et futures. En effet, l'électromobilité est devenue un véritable enjeu de société qui nécessite des moyens technologiques importants permettant d'assurer la sécurité et l'autonomie. Afin d'atteindre ces objectifs, il est nécessaire de disposer de sources d'énergie embarquées répondant aux besoins de la chaîne de conversion et de son système intelligent de contrôle et de gestion.

Ces dispositifs de stockage doivent avoir l'aptitude à accomplir des fonctions requises dans certaines conditions et pour une période de temps. Ils doivent donc garantir la sécurité et la fiabilité du système qu'ils alimentent.

Les batteries Li-ion sont aujourd'hui une option la plus répandue en raison de leur haute densité d'énergie et de leur cycle de vie convenable. Néanmoins, ces dernières sont très sensibles aux courants de décharges très élevés, qui altèrent

sensiblement leur durée de vie. En effet, leur densité de puissance est limitée [1].

Pour pallier cet inconvénient, les supercondensateurs en raison de leur forte densité de puissance et de leur degré de cyclabilité élevé représentent une technologie très prometteuse pour des applications nécessitant des appels de puissance importants pendant des durées courtes [2-3].

Pour tous ces avantages, les SC lorsqu'ils sont associés aux batteries de stockage, sont les mieux adaptés pour les besoins dans les applications d'électromobilité [4].

Pour faire fonctionner ces sources de stockage d'énergie dans un environnement sécurisé et pour leur permettre d'avoir une meilleure durée de vie, un système de contrôle associé à un système de gestion sont nécessaires. Ils permettent de contrôler les flux d'énergie et de superviser la sécurité de l'ensemble de la chaîne tant sur le plan électrique que thermique [5].

Les stratégies de contrôle et de gestion d'énergie nécessitent souvent une modélisation fiable et efficace la plus proche possible du fonctionnement réel. En effet les algorithmes de contrôle se basent souvent sur des modèles pour élaborer des lois de commande [6]. La modélisation est parfois essentielle pour le suivi de l'état de fonctionnement d'un système de stockage afin d'en déduire son état de santé.

La modélisation à l'aide de circuits équivalents offre une certaine souplesse dans son utilisation pour des besoins de contrôle/commande mais ne tient pas compte du phénomène de vieillissement, qui est difficilement modélisable [7]. Les différents modèles établis dans la littérature offrent des précisions plus ou moins différentes selon leur degré de complexité [8-9].

Dans le cadre de la sûreté de fonctionnement, différentes approches ont été mises en œuvre pour étudier l'état de santé des systèmes de stockage d'énergie :

- *Approche basée sur le modèle seul* : cette approche est limitée car il est difficile d'intégrer la dynamique de dégradation dans le modèle [10].
- *Approche hybride* : Cette approche est basée sur le modèle associé à un observateur pour estimer les paramètres indicateurs de l'état de santé du composant. Les plus répandus sont : l'observateur de Kalman étendu, l'observateur de Lyapunov et celui à modes glissants [11-17].
- *Approche basée sur les données* : Cette approche utilise des méthodes d'intelligence artificielle et des méthodes statistiques. Les méthodes d'intelligence artificielle s'appuient sur l'analyse des données et sont basées sur l'apprentissage automatique de façon à acquérir une forme d'autonomie. Les plus utilisées dans la littérature sont les

réseaux de neurones ou les méthodes à base d'instance [18-21]. Les méthodes statistiques utilisent les modèles bayésiens ou ceux de Markov et les modèle de régression [22-25].

Le suivi de l'état de santé (SOH) des systèmes de stockage (SC) est fondamental de manière à garantir la sécurité et la durée de vie. Dans la littérature, il est indiqué que la résistance série ESR et la capacité C sont les indicateurs principaux de l'état de vieillissement des SC. Il a été convenu que l'augmentation de 100% pour la résistance ESR et la diminution de 20 % pour la capacité sont les seuils annonciateurs de la fin de vie [26].

Les facteurs aggravants qui contribuent considérablement à la diminution ou l'augmentation de l'un ou de l'autre indicateur sont la température et la tension de polarisation du SC. Ces deux facteurs accélèrent significativement la décomposition de l'électrolyte et provoquent des réactions secondaires qui génèrent des résidus endommageant gravement le composant.

En effet, les électrodes de ce composant sont en charbon actif, connu pour sa forte teneur en eau. Celle-ci, lorsque le potentiel dépasse la limite de 1,23 V, subit le phénomène d'électrolyse qui s'accompagne d'un dégagement gazeux, en oxygène et en hydrogène. Les gaz ainsi produits, ont pour effet de boucher les pores du matériau actif et du séparateur. Ils font aussi augmenter la pression à l'intérieur du boîtier, pouvant engendrer des étirements jusqu'à la fissuration de l'électrode et la détérioration des contacts électriques. Ces mécanismes de vieillissement se révèlent par l'accroissement de la résistance globale du composant et la diminution de sa capacité [27].

Dans cet article, pour évaluer l'état de santé des SC, nous nous sommes intéressés aux approches basées sur les données de mesures et particulièrement les réseaux de neurones représentés par le perceptron multicouche. La base de données est constituée par la mesure de la tension aux bornes du SC pendant la phase d'autodécharge. Le SC sous test a subi un vieillissement calendaire. Il est polarisé à l'aide d'une tension de valeur importante et porté à une température élevée de façon à pouvoir altérer ses propriétés physiques en un temps très court.

L'évaluation précise de l'état de santé du SC est effectuée en utilisant le réseau de neurones pour estimer la valeur de la capacité et permettant ainsi de suivre l'évolution de celle-ci dans le temps jusqu'à obtention du seuil toléré [28].

2. VIEILLISSEMENT CALENDRAIRE

Les supercondensateurs sont vieillis à température constante et en même temps polarisés à l'aide d'une tension constante. Ils sont placés dans une chambre climatique pendant le processus de vieillissement. La valeur de la température est choisie afin de permettre l'observation du vieillissement assez rapidement. Le vieillissement concerne le supercondensateur 350 F BCAP0350 de Maxwell Technologies.

2.1. Conditions de vieillissement calendaire

Le test de vieillissement calendaire a été effectué sur le composant. La tension de polarisation à laquelle ce dernier a été soumis est 3 V et il a été porté en même temps à la température de 70 °C, telles sont les conditions de stress imposées et subies par le composant. Plus les contraintes sont sévères en température et en tension, plus la cinétique de dégradation est élevée et la dégradation est plus accentuée. Le composant testé a atteint la limite de vieillissement au bout de 816 heures. Autrement dit, il a atteint les seuils de dégradation limites évoqués précédemment.

Une caractérisation du composant à température ambiante est effectuée à différentes étapes du processus de vieillissement. En effet, à chaque étape de vieillissement, le composant est mis hors de la chambre climatique pour des besoins de caractérisation. Dans notre cas, il est caractérisé quatre fois durant ce processus de vieillissement. La charge du SC s'est faite à courant constant de 10 A. Nous avons fait l'acquisition de données pendant la phase de charge et pendant la phase de d'autodécharge. L'ensemble des mesures correspondant aux deux phases charge-autodécharge est visible sur la Figure 1 :




Fig. 1. Phase de charge et d'autodécharge.

Nous avons constaté que la pente de charge augmente avec le temps de vieillissement, ce qui signifie que la capacité du SC diminue. En effet, la tension aux bornes du SC évolue en fonction du temps avec la pente ($\frac{I}{C}$). Ceci est visible sur la figure 2 suivante :




Fig. 2. Phase de charge et évolution de sa pente.

A l'instant de l'interruption du courant de charge (sommet de la charge), la hauteur du saut de tension (ΔV) qui représente la chute de tension aux bornes de la résistance série ESR, augmente à chaque étape. Ce qui peut être interprété par l'augmentation de la résistance avec le temps de vieillissement. Ce résultat est illustré sur la Figure 3.




Fig. 3. Interruption de la charge et evolution du saut de la tension

Sur la Figure 4, Nous pouvons voir la phase correspondant à l'autodécharge et pour différentes phases de vieillissement.

Comme nous pouvons le constater, la profondeur d'autodécharge devient de plus en plus importante avec le temps de vieillissement. En effet, il a été montré que le courant de fuite augmente considérablement sous l'effet de la température et de la tension [29].




Fig. 4. Phase d'autodécharge

3. DIAGNOSTIC DE L'ETAT DE SANTE DU SUPERCONDENSATEUR DURANT SON VIEILLISSEMENT

3.1. Méthodologie de diagnostic

Quatre classes sont constituées, correspondant aux quatre périodes de caractérisation, pendant la phase de charge. Chaque caractéristique est exploitée séparément pour établir la fonction d'évolution de la capacité en fonction de la tension de polarisation. Pour ce faire, nous avons subdivisé la courbe de charge en petits intervalles de 500 ms (la capacité est supposée constante dans cet intervalle), et nous avons calculé sa valeur simplement par la relation suivante :

$$C = I / (\Delta V / \Delta t) \quad (1)$$

La relation obtenue à l'aide de la fonction Matlab 'polyfit' est exprimée par :

$$C = C_0 + \alpha_1 \cdot V + \alpha_2 \cdot V^2 \quad (2)$$

Il faut noter que le paramètre α_2 de la dernière équation donné par l'interpolation polynomiale est très faible. C'est pour cette raison que dans la littérature, il est toujours fait référence que la capacité évolue linéairement en fonction de la tension de polarisation [29]. Ce dernier résultat est illustré par la figure 5 :




Fig. 5. Interpolation polynomiale.

L'interpolation est appliquée à la base de données choisie de telle sorte que la tension de polarisation se situe entre 0,7 V et 2,7 V (zone où l'effet de vieillissement est plus prononcé).

Ce résultat est corroboré à l'aide de l'évaluation de la capacité équivalente en utilisant les courbes de charges obtenues à diverses phases de vieillissement entre 1,3 V et 2,6 V par l'utilisation de la relation (1) :

$$C_{eq} = \frac{I}{\frac{\Delta V}{\Delta t}}, \Delta V = 1,3 V$$

La résistance série ESR est aussi évaluée à l'aide de la relation $R = \frac{\Delta V_R}{I}$ où ΔV_R représente le saut de tension à l'interruption du courant de charge.

L'évolution de ces deux indicateurs de vieillissement avec le temps de vieillissement est donnée sur la figure 6.




Fig. 6. Evolution de C_{eq} et de ESR en fonction du temps de vieillissement.

Sur la figure 7, nous pouvons voir l'évolution de ces deux paramètres en % de leurs valeurs initiales. La capacité équivalente C_{eq} a perdu 24% et la résistance ESR est augmentée de presque 200%.

A ce niveau de dégradation, le supercondensateur a dépassé le seuil défini pour la fin de vie.




Fig. 7. Evolution de C_{eq} et de ESR (en%) en fonction du temps de vieillissement.

3.2. Estimation de la capacité du SC par la méthode neuronale

Nous avons utilisé le Perceptron Multicouche (PMC) dont la structure est représentée sur la figure 8. Il est constitué d'une couche cachée (10 neurones) et d'une couche de sortie (1 neurone). Les fonctions d'activation 'g' et 'h' sont linéaires.




Fig. 8. Perceptron multicouche.

Dans notre cas :

$S^1 = s$ (s : nombre de neurones de la couche cachée).

$R = 2$ (Entrées) et $S^2 = 1$.

W^1 : Matrice des poids pour la couche cachée.

W^2 : Matrice des poids pour la couche de sortie.

$$W^1 = \begin{pmatrix} w_{1,1}^{(1)} & w_{1,2}^{(1)} \\ w_{2,1}^{(1)} & w_{2,2}^{(1)} \\ \vdots & \vdots \\ w_{s,1}^{(1)} & w_{s,2}^{(1)} \end{pmatrix}; W^2 = \begin{pmatrix} w_{1,1}^{(2)} & \Lambda & \Lambda & w_{1,s}^{(2)} \end{pmatrix}$$

La sortie de la couche cachée est exprimée par :

$$n_i^{(1)} = \sum_{j=1}^2 W_{i,j}^{(1)} \cdot x_j + b^{(1)} \cdot 1 \quad (3)$$

$$a_i^{(1)} = g(n_i^{(1)}) \quad (4)$$

La sortie du réseau est donnée par :

$$n^{(2)} = \sum_{i=1}^s W_{1,i}^{(2)} \cdot a_i^{(1)} + b^{(2)} \cdot 1 \quad (5)$$

$$y = a^{(2)} = h(n^{(2)}) \quad (6)$$

Avec : x_j le vecteur des entrées.

Le choix des entrées du réseau de neurones est fondamental. En effet, la pertinence des données d'apprentissage du réseau a un impact sur l'estimation des indicateurs de vieillissement du SC. Les valeurs estimées représentent la sortie du réseau, elles doivent tendre vers les valeurs cibles (état désiré) que nous souhaitons atteindre.

C'est dans ce cadre que nous avons choisi d'exprimer le vecteur d'entrée par les valeurs correspondant à la profondeur de décharge :

$$\Delta V_{self-discharge,j} = V_{self-discharge,j} - \min[V_{self-discharge}]$$

Dans notre cas le vecteur d'entrée:

$$x_j = \begin{pmatrix} \Delta V_{self-discharge,j} \\ \min[V_{self-discharge}] \end{pmatrix} \quad (7)$$

En effet la profondeur de décharge qui est liée à la valeur minimale de la tension d'autodécharge est un bon indicateur de l'état de dégradation du SC.

Du choix de ces entrées dépend aussi la vitesse de convergence de l'algorithme d'optimisation.

L'apprentissage se traduit par une modification de l'efficacité synaptique, c'est-à-dire par un changement dans la valeur des poids qui relient les neurones d'une couche à l'autre. Soit le poids $w_{i,j}$ qui relie le neurone i à son entrée j . Au temps t , un changement $\Delta w_{i,j}(t)$ peut s'exprimer par :

$$w_{i,j}(t+1) = w_{i,j}(t) + \Delta w_{i,j}(t) \quad (8)$$

Pour une entrée donnée (un exemple d'apprentissage), l'erreur de classification sera calculée de la façon suivante

$$e = y^d - y, \text{ avec } y^d : \text{ la sortie désirée.}$$

La fonction coût associée est donnée par la fonction $J = f(x)$. Elle est obtenue en utilisant la relation :

$$f(x) = J = \frac{1}{2} \cdot e^2 = \frac{1}{2} \cdot (y^d - y)^2 = \frac{1}{2} \cdot [y^d - h(n^{(2)})]^2 \quad (9)$$

La modification des poids passe par la minimisation de la fonction coût. L'obtention du minimum du critère aboutit au calcul des poids synaptiques optimaux du réseau de neurone. Dans notre cas, l'algorithme utilisé pour l'apprentissage et l'optimisation des paramètres du réseau est celui de **Levenberg-Marquardt**, connu pour sa rapidité de convergence et son implémentation n'est pas gourmande en termes de capacité de mémoire.

Si les données d'apprentissage sont pertinentes et suffisantes, l'estimation fournie par le réseau de neurones est non seulement fiable mais aussi, elle peut être généralisable à d'autres bases de test même plus complexes.

L'approche neuronique offre une grande souplesse concernant son application à de nouvelles données autres que celles de la base d'apprentissage. Cette faculté de généralisation est notamment caractérisé par l'absence de contraintes liées à la nécessité d'avoir un modèle précis du SC et à celles qui exigent les conditions initiales du SC pour démarrer l'algorithme, comme c'est le cas dans d'autres approches comme les régressions ou les observateurs [30].

3.3. Base d'apprentissage

L'apprentissage du réseau de neurones sur les données récoltées lors de la phase d'autodécharge du SC pour diverses étapes de vieillissement présentées sur la figure 4 a donné les résultats suivants quant à l'estimation de la valeur de la capacité et son évolution durant tout le processus de dégradation. Les valeurs estimées de la capacité et pour chaque étape de vieillissement sont comparées à celles obtenues par la méthode de l'interpolation polynomiale évoquée précédemment. Comme nous pouvons le constater l'écart maximal obtenu pour les quatre étapes de vieillissement ne dépasse pas 3%.




Fig. 9. Apprentissage du réseau de neurones en phase d'autodécharge.

La figure suivante (figure 10) montre la convergence de l'algorithme et le minimum global de l'erreur quadratique est atteint au bout de quelques boucles.




Fig. 10. Evolution de l'erreur quadratique.

3.4. Base de test

La base de test comme le montre la figure 11, est constituée par les données d'autodécharge d'un autre SC vieilli à la température de 65°C et sous la tension de polarisation de 3 V.

La durée du vieillissement accéléré est de 960 h. Les caractérisations effectuées à différentes étapes de ce processus sont réalisées à l'aide d'un courant de charge de 10 A.

Les données relatives à la partie de la charge du SC nous permettront d'identifier la fonction polynomiale pour chaque étape de vieillissement. Celles correspondant à l'autodécharge serviront de base de test pour la généralisation.




Fig. 11. Base de test.

Seules les données relatives à la partie d'autodécharge sont considérées pour la constitution de la base de test. La figure 12 montre les résultats de généralisation fournis par le réseau de neurones précédent optimisé suite au processus d'apprentissage.




Fig. 12. Résultats de la généralisation sur la base de test.

Comme nous pouvons le constater, la capacité estimée varie de 440 F à l'état initial jusqu'à 290 F après 960 h de vieillissement. Il est aisé de vérifier ce résultat en calculant la valeur de la capacité en utilisant les données de charge visibles sur la figure 11. Ce calcul utilise le même principe qu'au § 3.1 et a pour résultat celui de la figure 13.

Nous observons qu'autour de la valeur de 2.5 V, la capacité calculée varie de 425 F à l'état initial jusqu'à 320 F à la fin du processus de vieillissement.

Nous pouvons donc conclure que les résultats de l'estimation rejoignent ceux obtenus par calcul. Le réseau de neurones optimisé a pu être testé sur cette nouvelle base et les résultats sont très cohérents.




Fig. 13. Calcul de la capacité par la méthode de l'interpolation polynomiale.

4. CONCLUSIONS

Pour suivre et diagnostiquer l'état de vieillissement du SC, nous avons choisi d'exploiter un seul indicateur de cet état, en l'occurrence la valeur de la capacité connue pour sa dégradation avec le temps sous l'effet de contraintes subies pendant le fonctionnement.

Nous avons aussi choisi d'exploiter une seule mesure pour estimer la valeur de cet indicateur. Il s'agit de la tension de polarisation en phase d'autodécharge.

La caractéristique de charge à courant constant, obtenue à diverses périodes de vieillissement (niveaux de dégradation), a permis d'identifier la fonction $C(V)$ en utilisant la méthode de l'interpolation polynomiale. Nous nous sommes servis de cette fonction pour déterminer l'état désiré du réseau de neurones (cibles). Bien entendu cette fonction évolue selon l'état de vieillissement du SC.

Les cibles déterminées à l'aide de la fonction $C(V)$ a rendu possible le processus d'apprentissage du réseau de neurones.

L'utilisation d'une seule mesure (tension de polarisation) nous a semblé pertinente contrairement aux autres méthodes d'estimation utilisées dans la littérature pour évaluer les paramètres ou les indicateurs de vieillissement comme par exemple les observateurs ou les régressions. En effet, ces derniers nécessitent au moins deux mesures (tension et courant) pour produire un état de santé convenable du SC.

Les méthodes de régression et les observateurs nécessitent d'être initialisées. Elles s'appuient sur des modèles qui ne reproduisent pas toujours le fonctionnement réel et précis du SC.

Contrairement à ces méthodes, l'approche neuronique ne fait pas appel aux modèles et n'a pas besoin de l'état initial du SC pour le démarrage de l'algorithme à l'instant t . Cette approche exige néanmoins une bonne base de données comme entrées du réseau avec laquelle l'entraînement peut s'effectuer aisément et qui permet facilement une généralisation sur d'autres bases de test.

En outre, l'utilisation des données relatives à l'autodécharge, mérite d'être considérée du fait que nous nous sommes affranchis de l'influence du courant qui impacte directement le temps ou la vitesse de charge ou de décharge. Cette phase d'autodécharge nous révèle aussi bien les symptômes de vieillissement du SC. Une seule mesure de tension permet de déceler un état de dégradation de ce composant.

Les bases de données constituées à la phase d'autodécharge ayant servi aussi bien pour le processus d'apprentissage que pour la généralisation a fourni des résultats satisfaisants. En effet, nous avons eu une bonne convergence entre l'état désiré du réseau de neurones (la cible) et la sortie obtenue suite à

l'optimisation des poids synaptiques à l'aide de l'algorithme de Levenberg-Marquardt. Ce dernier a permis une convergence parfaite par l'obtention du minimum global de la fonction coût ou critère quadratique.

Le réseau de neurones utilisé et optimisé a été testé en phase de généralisation sur une base de test correspondant à un autre composant vieilli sous d'autres contraintes. Les résultats obtenus sont comparés à ceux obtenus par calcul en utilisant l'interpolation polynomiale et nous avons observé une parfaite cohérence.

5. REFERENCES

- [1] J. Wang, P. Liu, J. Hicks-Garner, E. Sherman, S. Soukiazian, M. Verbrugge, H. Tataria, J. Musser, P. Finamore, 'Cycle-life model for graphite-LiFePO₄ cells', *J Power Sources*, Vol. 196, issue 8, pp. 3942–3948, 2011.
- [2] G. Bullard, H. Sierra-Alcazar, H. Lee, J. Morris, 'Operating principles of the Ultracapacitor', *IEEE Transactions on Magnetics*, Vol. 25, Issue 1, pp. 102-126, 1989.
- [3] J. Dixon, I. Nakashima, EF. Arcos, M. Ortúzar, 'Electric vehicle using a combination of supercapacitors and ZEBRA battery', *IEEE Transactions on Industrial Electronics*, Vol. 57, Issue 3, pp. 943–949, 2010.
- [4] A. Santucci, A. Sornioti, C. Lekakou, 'Power split strategies for hybrid energy storage systems for vehicular applications', *Journal of Power Sources*, Vol. 258, pp. 395–407, 2014.
- [5] C. Pan, L. Chen, L. Chen, C. Huang, M. Xie, 'Research on energy management of dual energy storage system based on the simulation of urban driving schedules', *Electrical Power & Energy Systems*, Vol. 44, Issue 1, pp. 37–42, 2013.
- [6] I. Ike, I. Sigalas, S. Iyuke, K. Ozoemena, 'An overview of mathematical modeling of electrochemical supercapacitors/ultracapacitors', *Journal of Power Sources*, Vol. 273, pp. 264–77, 2015.
- [7] S. Kim, W. Choi, K. Lee, S. Choi, 'Advanced dynamic simulation of supercapacitors considering parameter variation and self-discharge', *IEEE Transactions on Power Electronics*, Vol. 26, Issue 11, 2011.
- [8] R. Faranda, 'A new parameters identification procedure for simplified double layer capacitor two-branch model', *Electric Power Systems Research*, Vol. 80, Issue 4, pp. 363–71, 2010.
- [9] Weddell A, Merrett G, Kazmierski T, Al-Hashimi B. 'Accurate supercapacitor modeling for energy harvesting wireless sensor nodes', *IEEE Transactions on Circuits and Systems II Exp Briefs*, Vol. 58, Issue 12, pp. 911–5, 2011.
- [10] [A. K. S. Jardine, D. Lin, D. Banjevic, 'A review on machinery diagnostics and prognostics implementing condition-based maintenance', *Journal of Mechanical Systems and Signal Processing*, Vol. 20, Issue 7, pp. 1483-1510, 2006.
- [11] M. St-Pierre, D. Gingras, 'Comparison between the unscented Kalman filter and the extended Kalman filter for the position estimation module of an integrated navigation information system', *IEEE Intelligent Vehicles Symposium*, pp. 831-835, 2004.
- [12] J. J. Laviola, 'A Comparison of Unscented and Extended Kalman Filtering for Estimating Quaternion Motion', *American control conference*, Vol. 3, pp. 2435-2440, 2003.
- [13] H. He, R. Xiong, X. Zhang, F. S. Amd et 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, Issue 14, pp. 1461-1469, 2011.
- [14] S. J. Julier, J. K. Uhlmann, 'New extension of the Kalman filter to nonlinear systems', *Signal Processing, Sensor Fusion, and Target Recognition VI*, Vol. 3068, Orlando, 1997.
- [15] H. Chaoui, N. Golbon, I. Hmouz, R. Souissi et S. Tahar, 'Lyapunov-Based Adaptive State of Charge and State of Health Estimation for Lithium-Ion Batteries', *IEEE Transactions on Industrial Electronics*, Vol. 62, pp. 1610-1618, 2015.
- [16] A. El Mejdoubi, A. Oukaour, H. Chaoui, Y. Slamani, J. Sabor, H. Gualous, 'Online Supercapacitor Diagnosis for Electric Vehicle Applications', *IEEE Transactions on Vehicular Technology*, Vol. 65, Issue 6, pp. 4241-4252, 2015.
- [17] Asmae El Mejdoubi, Amrane Oukaour, Hicham Chaoui, Hamid Gualous, Jalal Sabor, Youssef Slamani, 'State-of-Charge and State-of-Health Lithium-ion Batteries Diagnosis According to Surface Temperature Variation', *IEEE Transactions on Industrial Electronics*, Vol. 6, Issue 4, pp. 2391-2402, 2015.
- [18] A. Soualhi, M. Makdessi, R. German, F. Rivas, H. Razik, A. Sari, P. Venet, G. Clerc, 'Health Monitoring of Capacitors and Supercapacitors Using Neo Fuzzy Neural Approach', *IEEE Transactions on Industrial Informatics*, Vol. 14, Issue 1, pp. 24-34, 2018.
- [19] T. Weigert, Q. Tian, K. Lian, 'State-of-charge prediction of batteries and battery-supercapacitor hybrids using artificial neural networks', *Journal of Power Sources*, Vol. 196, Issue 8, pp. 4061–4066, 2011.
- [20] A. Soualhi, K. Medjaher, N. Zerhouni, 'Bearing health monitoring based on hilbert–huang transform, support vector machine, and regression', *IEEE Transactions on Instrumentation and Measurement*, Vol. 64, Issue 1, pp. 52-62, 2015.
- [21] N. Mengq, D. Jingjing, W. Tianzhen, G. Diju, H. Jingang, M.E.H. Benbouzid, 'A Hybrid Kernel PCA, Hypersphere SVM and Extreme Learning Machine Approach for Nonlinear Process Online Fault Detection', *IECON-Yokohama November 9-12*, pp. 2106-2111, 2015.
- [22] W. Rezgui, N. K. Mouss, L-H. Mouss, M. D. Mouss, M. Benbouzid, 'A Regression Algorithm for the Smart Prognosis of a Reversed Polarity Fault in a Photovoltaic Generator', *IEEE ICCE 2014*, pp. 134-138, 2014, Sfax, Tunisia, March 2014.
- [23] M. Dong, D. He, 'A segmental hidden semi-Markov model HSMM-based diagnostics and prognostics framework and methodology', *Journal of Mechanical Systems and Signal Processing*, Vol. 21, Issue 5, pp. 2248-2266, 2007.
- [24] M. Dong, D. He, 'Hidden semi-Markov model-based methodology for multi sensor equipment health diagnosis and prognosis', *European journal of Operational Research*, Vol. 178, pp. 858-878, 2007.
- [25] K. Medjaher, A. Mechraoui, N. Zerhouni, 'Diagnostic et pronostic de défaillances par réseaux Bayésiens', *4èmes Journées Francophones sur les Réseaux Bayésiens, JFRB'2008*, Lyon, France, pp. 80-93, 2008.
- [26] R. Köt, PW. Ruch, D. Cericola, 'Aging and failure mode of electrochemical double layer capacitors during accelerated constant load tests', *Journal of Power Sources*, Vol. 19, Issue 3, pp. 923–928, 2010.
- [27] P. Kreczanik, P. Venet P, A. Hijazi, G. Clerc, 'Study of supercapacitor ageing and lifetime estimation according to voltage temperature and RMS current', *IEEE Transactions on Industrial Electronics*, Vol. 61, Issue 9, pp. 4895–4902, 2014.
- [28] L. Zhang, Z. Wang, X. Hu, DG. Dorrell, 'Residual capacity estimation for ultracapacitors in electric vehicles using artificial neural network', In: *Proceedings of IFAC world congress*; vol. 19, pp. 3899–904, 2014.
- [29] P. Kurzweil, B. Frenzel, 'Capacitance Characterization Methods and Ageing Behaviour of Supercapacitors', *Proceedings: The 15th International Seminar On Double Layer Capacitors*, Deerfield Beach, FL., U.S.A., December 5-7, 2005.
- [30] A. El Mejdoubi, A. Oukaour, H. Chaoui, Y. Slamani, J. Sabor, H. Gualous, 'Online Supercapacitor Diagnosis for Electric Vehicle Applications', *IEEE Transactions on Vehicular Technology*, Vol. 65, Issue 6, pp. 4241-4252, 2015.