UNIVERSITÉ SIDI MOHAMED BEN ABDELLAH

FACULTÉ DES SCIENCES ET TECHNIQUES

FÈS

Thèse de Doctorat

Spécialité : Génie Electrique et Énergies Renouvelables.

Sujet :

MODÉLISATION DE LA BATTERIE LITHIUM POUR LES MICROGRIDS EN UTILISANT LES RÉSEAUX DE NEURONES ARTIFICIELS

Présentée par

BOUJOUDAR YOUNES

Thèse présentée et soutenue le: 28-07-2021 :

Dédicaces

A MA TRÈS CHÈRE MÈRE ET PÈRE

Sources inépuisables de tendresse, de patience et de sacrifice. vos prières et vos bénédictions m'ont été d'un grand secours tout au long de ma vie. Quoique je puisse dire et écrire, je ne pourrais exprimer ma grande affection et ma profonde reconnaissance. J'espère ne jamais vous décevoir, ni trahir votre confiance et vos sacrifices. Puisse Dieu tout puissant, vous protéger et vous accorder santé, longue vie et bonheur.

À MON FRÈRE ET MES PRINCESSES SOEURS

Je vous remercie pour votre soutien inconditionnel durant toutes ces longues années d'études. Votre amour remplit mes jours de bonheur.

A MES AMIS ET MES COLLÈGUES

Je vous remercie pour votre amitié chère à mon coeur, et je vous souhaite tout le bonheur du monde.

Remerciements

En tout premier lieu, je remercie le bon Dieu, tout puissant, de m'avoir donné la force pour survivre, ainsi que l'audace pour dépasser toutes les difficultés. Les paragraphes suivants rendent hommage à plusieurs personnes, sans lesquelles ce travail n'aurait jamais abouti.

Les premiéres personnes que je tiens à remercier sont mes directeurs de thèse, professeur **Hassan El MOUSSAOUI**, professeur **Tijani LAMHAMDI**, Professeurs de l'enseignement supérieur à la FST de FES, pour leur hautes qualités humaines et professionnelles et pour tout le temps qu'ils m'ont consacré et leurs efforts inconditionnels pour mener à bien cette thèse, j'ai beaucoup appris de ces Grands Messieurs, peu importe combien je les remercie, je ne serai pas en mesure de remplir leur droit comme ils le doivent.

Je remercie profondément le professeur **Hassane ELMARKHI** , Professeur de l'enseignement supérieur à la FST de FES pour son soutien tout au long de mon travail de recherche, ses encouragements étaient pour moi une locomotive pour avancer dans ce travail.

Je remercie profondément le directeur du laboratoire LSSC, professeur **Mhammed Lahbabi**, et le directeur du laboratoire SIGER professeur **Ali Ahaitouf**, et à travers eux tous le Staff et les membres des deux laboratoires pour leur rigueur scientifique et leurs

conseils judicieux.

Mes remerciements s'adressent également à tous les enseignants du département Génie électrique de la FST de Fès.

J'exprime également toute ma gratitude et mes remerciements aux **Pr. El OUTASSI Omar**, **Pr. SAADANI Rachid** et **Pr. MECHAQRANE Abdellah** de m'avoir honoré en acceptant la charge d'être rapporteurs de cette thèse et en me faisant part de leurs remarques constructives. De même j'adresse mes remerciements au **Pr. EL HAMMOUMI Karima** et au **Pr. EL HASSANI Hind** de m'avoir honoré en acceptant d'être membres du jury afin d'examiner ce modeste travail.

Je remercie chaleureusement mes ami(e)s Docteurs : **Ghizlane Aamoum**, **Azeroual Mohamed**,**Lahcen El Iysaouy**, **Massaab elydrissi**, **Ismail Mahdi** ,**Boujoudar Mohamed**, pour leurs encouragements, et pour leurs soutiens énormes, ainsi que toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce présent travail.

Je remercie chaleureusement aussi mes collègues enseignants au **collège Maghraoua** à Taza, et tous les habitants de ce village étonnant.

Je ne peux pas finir mes remerciements sans rendre un grand hommage à mes **chers parents**, **mon Frère**, **mes princesses Soeurs** et tous les membres de ma famille, sans leurs soutiens, je ne peux aller de l'avant, toutes mes actions sont guidées par l'objectif de les honorer.

Production scientifique

Publications :

(1) **BOUJOUDAR Y**, Azeroual M, El Moussaoui H, Lamhamdi T. **Intelligent controller based energy management for stand-alone power système using artificial neural network**. Int Trans Electr Energ Syst. 2020;e12579.(**SCOPUS indexed Journal**) https ://doi.org/10.1002/2050-7038.12579(SCOPUS indexed Journal)

(2) **BOUJOUDAR, Younes**, ELMOUSSAOUI, Hassan, et LAMHAMDI, Tijani. **Lithium-ion batteries modeling and state of charge estimation using artificial neural network**. International Journal of Electrical and Computer Engineering (2088-8708), 2019, vol. 9. (**SCOPUS indexed Journal**)

(3) **BOUJOUDAR, Younes**, Azeroual Mohamed, ELMOUSSAOUI, Hassan, et LAMHAMDI, Tijani. **Intelligent Control of Battery Energy Storage for Microgrid Energy Management Using ANN**. International Journal of Electrical and Computer Engineering (2088-8708), 2021, vol.4. (**SCOPUS indexed Journal**)

(4) **BOUJOUDAR, Y**., Elmoussaoui, H., and Lamhamdi, T. (2019, April). **Lithium-Ion batteries modeling using NARX Nonlinear model**. In 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systèmes (WITS) (pp. 1-6). IEEE. (**IEEE Explore publication**)

(5) **BOUJOUDAR, Y**., Elmoussaoui, H., and Lamhamdi, T. (2017, April). **Li-ion battery parameters estimation using neural networks**. In 2017 International Conference on Wireless Technologies, Embedded and Intelligent Systèmes (WITS) (pp.

1-4). IEEE. (**IEEE Explore publication**)

(6) MOHAMED, Azeroual, **YOUNES, BOUJOUDAR**, LAMHAMDI, Tijani, et al. **Fault Location and Isolation Technique in Smart Distribution Systèmes with Distributed Generation**. In : 2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET). IEEE, 2020. p. 1-5. (**IEEE Explore publication**)

(7) Mohamed Azeroual, **Younes Boujoudar,** Tijani Lamhamdi, Hassan El Moussaoui, Hassane El Markhi, **Fault location technique using Distributed Multi Agent systèmes in Smart Grids**, The 6thInternationl conference on Wireless Technologies, embedded and intelligent Systèmes October 14, 2020, Fez, Morocco, (**Springer proceeding publication**)

Communications :

(1) YOUNESS BOUJOUDAR, Hassan EL MOUSSAOUI,TIJANI LAMHMDI "Lithium-Ion batteries modeling using NARX Nonlinear model" The 5thInternationl conference on Wireless Technologies, embedded and intelligent Systèmes April 3-5, 2019, Fez, Morocco,

(2) YOUNESS BOUJOUDAR, HANANE HEMI, Hassan EL MOUSSAOUI, HASSANE EL MARKHI AND TIJANI LAMHMDI "Li-ion battery parameters estimation using neural networks" The 4thInternationl conference on Wireless Technologies, embedded and intelligent Systèmes April 19-20, 2017, Fez, Morocco,

(3) MOHAMED, Azeroual, YOUNES, BOUJOUDAR, LAMHAMDI, Tijani, et al. Fault Location and Isolation Technique in Smart Distribution Systèmes with Distributed Generation. In : 2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET). IEEE, 2020. p. 1-5

(4) Mohamed Azeroual, Younes Boujoudar, Tijani Lamhamdi, Hassan El Moussaoui, Hassane El Markhi, Fault location technique using Distributed Multi Agent systèmes

in Smart Grids, The 6thInternationl conference on Wireless Technologies, embedded and intelligent Systèmes October 14, 2020, Fez, Morocco,

(5) BOUJOUDAR Y, Azeroual M, El Moussaoui H, Lamhamdi T. Control of bidirectional DC-DC converter for Li-ion Battery in Microgrids système The International Conference on Power Engineering is to be held in Guangzhou, China during December 19-21, 2020. (under review)

(6) Younes BOUJOUDAR, Hanane HEMI, Hassan EL MOUSSAOUI, Hassane EL MARKHI, TIijani LAMHAMDI "Li-ion battery température and state of charge estimation using artificiel neural networks" .2éme Colloque Franco-Marocain sur les Energies Renouvelables et leur Intégration aux Réseaux de Transport et de Distribution, Fez, 11-13 Avril 2017.

(7) Younes BOUJOUDAR, Hassan EL MOUSSAOUI, TIijaniLAMHAMDI " Simulation of Stand-alone power systèmes and control of DC-DC bidirectional converter with Artificial neural network 4 ème Rencontre Nationale des Jeunes Chercheurs en Sciences de l'Ingénieur (RNJC'2018)

(8) Younes BOUJOUDAR, Hanane HEMI, Hassan EL MOUSSAOUI, Hassane EL MARKHI, TIijani LAMHAMDI " A review of lithium-ion battery state of charge estimation and equivalent circuit model" 3 ème rencontre nationale des jeunes chercheurs en sciences de l'ingénieur (RNJC'2017)

(9) Younes BOUJOUDAR, Hanane HEMI, Hassan EL MOUSSAOUI, Hassane EL MARKHI, TIijani LAMHAMDI '' Estimation d'etat de charge soc et identification des parametres interne de la batterie Li-ion par les reseaux de neurones '' workshop sur la gestion des energies renouvelables : enjeux et perspectives, 15 mai 2017.

(10) Younes BOUJOUDAR, Hanane HEMI, Hassan EL MOUSSAOUI, Hassane EL MARKHI, TIijani LAMHAMDI " Dynamic Modeling and Simulation of Lithium Ion Battery with Temperature effect " 4ème journée scientifique sur les énergies renouvelables à l'EST de Fès, le 2 Novembre 2017.

(11) Younes BOUJOUDAR, Hanane HEMI, Hassan EL MOUSSAOUI, Hassane EL MARKHI, TIijani LAMHAMDI ‘’MODELISATION DE L’EFFET DE LA TEMPERATURE SUR LE FONCTIONNEMENT DE LA BATTERIE LITHIUM-ION”2 ème Rencontre Nationale des Jeunes Chercheurs en Sciences de l’Ingénieur 6 ème édition de la Journée des Doctorants du LSSC (RNJC/JDLSSC’2016)

(12) Younes BOUJOUDAR, Hassan EL MOUSSAOUI, TIijani LAMHAMDI ,Neural Network based modeling and state of charge estimation : Article presented in the 1st Winter School on Complex Systèmes, Modeling andamp ; Simulation, February 13-15, UM6P Benguerir

Résumé

Le développement d'un système de stockage par batterie pour un microgrid représente l'objectif principal de cette thèse. Afin d'atteindre cet objectif, nous avons proposé d'une part, un modèle de la batterie, qui prend en considération l'effet d'état de charge et de température et d'autre part une méthode d'estimation d'état de charge SOC par utilisation de l'approche de modélisation par les réseaux de neurones. La comparaison des résultats de simulation des modèles proposés avec les résultats expérimentaux montrent les performances et l'efficacité de notre modèle de réponse dynamique stable et puissante.

Dans la suite, nous avons implémenté ce système de stockage dans plusieurs microgrids. Afin de gérer l'énergie au sein de ces microgrids et assurer un fonctionnement sécurisé de la batterie, nous avons proposé un contrôleur intelligent pour le convertisseur bidirectionnel, qui connecte la batterie au microgrid. Ensuite nous avons implémenté une stratégie de gestion décentralisée par l'utilisation de l'approche des systèmes multi agents.

Mots clés : Batterie, Li-ion, Système de gestion de batterie, SOC, Réseau de Neurone Artificial.

Abstract

The development of a battery storage systeme for a microgrid represent the main objective of this thesis. In order to achieve this objective first of all we have proposed a model of the battery, which takes into account the effect of state of charge and temperature, then a SOC state of charge estimation method using the neural network modeling approach. The comparison of the simulation results of the proposed models with the experimental results shows the performance and efficiency of our model in terms of precision, stability and response dynamics. We implemented this storage systeme in several microgrids. In order to manage the energy within these microgrids and ensure safe battery operation, we have proposed an intelligent controller for the bidirectional converter, which connects the battery to the microgrid. Then we considered a decentralized management strategy using the multi-agent systèmes approach.

Keywords : Battery, Lithium, SOC, Battery Management System, Artifical Neural Network, Microgrid, Energy

Liste des acronymes

ANN : Artificial Neural Network

ANNC : Artificial Neural Network Controler

BESS : Battery Energy Storage Système

BMS : Battery Management Systeme

BP : Back-Propagation

CCM : Continuous Conduction Mode

CEI : Cathode Electrolyte Interphase

DER : Distributed Energy Resources

EKF : Extended Kalman Filtre

EMS : Energy Management System

FFNN : Feed Forward Neural Network

FL : Fuzzy Logic

IC : Incremental Conductance

IGBT : Insulated Gate Bipolar Transistor

IPPC : Intergovernmental Panel on Climate Change

IRENA :International Renewable Energy Agency

JADE : Java Agent Development Framework

KF : Kalman Filtre

Li-ion : Lithium-ion Batterie

MAS : Multi Agent System

MPPT : Maximum Power Point Tracking

MSE : Mean squared Error

NARX : Nonlinear AutoRegressive network with eXogenous inputs

NiCd : Nickel-Cadmium

NiMH : Nickel-Métal Hydrure

OCV : Open Circuit Voltage

P and O : Perturb and Observe

PID : Proportional, Integral, Derivative

PMSG : Permanent Magnet Synchronous Generator

MPP : Maximum Power Point

PV : PhotoVoltaïc

PWM : Pulse Width Modulation

RNA : Réseaux de Neurones Artificiels

SECS : Solar Energy Conversion System

SEI : Solid Electrolyte Interphase

SER : Source Energie Renouvelable

SMC :Sliding Mode Controller

SMO :Sliding Mode Observer

SOC : State Of Charge

SVM : Support Victor Machine

UKF : Uncented Kalman Filtre

WECS : Wind Energy Conversion System

WNN : Wavelet Neural Network

Table des figures

Figure 1.1 Diagramme de Ragon [1]. 10
Figure 1.2 Cellule lithium déchargée. 14
Figure 1.3 Cellule lithium au début de la charge. 15
Figure 1.4 Cellule lithium après la formation de SEI et CEI. 16
Figure 1.5 Couleur au début de la charge 17
Figure 1.6 Couleur à la fin de la charge 17
Figure 1.7 Cellule lithium au début de la décharge. 18
Figure 1.8 Cellule lithium à la fin de la décharge 19
Figure 1.9 État de charge de la batterie 21
Figure 1.10 Zones de fonctionnement sécurisé de tension 22
Figure 1.11 Zones de fonctionnement sécurisé de courant 22
Figure 1.12 Dessin schématique simplifié d'un BMS 24
Figure 1.13 Architecture générale d'un micro réseau intelligent multi sources . 25
Figure 1.14 Structure d'un microgrid de type AC 26
Figure 1.15 Structure d'un microgrid de type DC 27
Figure 1.16 Système de stockage d'énergie par batterie pour microgrid 29
Figure 1.17 Représentation d'un neurone biologique 31
Figure 1.18 Représentation d'un neurone formel 31
Figure 1.19 Représentation d'analogie entre le neurone biologique/formel . . . 32
Figure 1.20 Schéma bloc d'apprentissage supervisé 34

Figure 2.1 Circuit électrique équivalent de modèle simple 40

Figure 2.2 Modèle résistif de Thevenin 41
Figure 2.3 Schéma électrique du modèle de Thevenin 42
Figure 2.4 Circuit électrique de modèle de double polarisation 43
Figure 2.5 Modèle de Chen et Mora pour la batterie 44
Figure 2.6 Modèle générique de la batterie. 45
Figure 2.7 Protocole expérimental des tests de la batterie 47
Figure 2.8 Courant de la batterie 47
Figure 2.9 Tension de la batterie 47
Figure 2.10 Température de la batterie 47
Figure 2.11 Résistance interne 47
Figure 2.12 Système proposé pour la modélisation de la batterie 48
Figure 2.13 Modèle NARX 49
Figure 2.14 Comparaison entre la température estimée et celle mesurée 51
Figure 2.15 Comparaison entre la résistance interne estimée et mesurée 51
Figure 2.16 Comparaison entre la tension en circuit ouvert estimée et calculée durant les tests expérimentaux 52
Figure 2.17 Comparaison entre la tension du modèle proposé et la tension mesurée expérimentalement 53
Figure 2.18 Modèle boîte noire de la batterie 54
Figure 2.19 Protocole expérimental des tests de batterie 55
Figure 2.20 Variation de courant 55
Figure 2.21 Variation de Tension 55
Figure 2.22 Variation de température de la batterie 56
Figure 2.23 Algorithme suivi durant l'optimisation de RNA 57
Figure 2.24 Modèle proposé de batterie 59
Figure 2.25 État de charge calculé 60

Figure 2.26 Comparaison entre la réponse de tension des données expérimentales, le modèle standard et le modèle RNA 61
Figure 2.27 Comparaison entre la réponse de tension des données expérimentales, le modèle standard et le modèle RNA, pour des données de validation. . . 62
Figure 2.28 Comparaison de l'erreur de tension entre le MS et RNA avec la tension mesurée 63
Figure 2.29 Principe d'un estimateur d'état pour la batterie 65
Figure 2.30 Modèle proposé de la batterie Li-ion 72
Figure 2.31 Comparaison entre le SOC expérimental et le SOC estimé 73
Figure 2.32 Comparaison entre la tension expérimentale et la tension estimée . 73

Figure 3.1 Système photovoltaïque 81
Figure 3.2 Schéma électrique équivalent d'une cellule photovoltaïque 81
Figure 3.3 Convertisseur boost 83
Figure 3.4 Caractéristiques de fonctionnement de la méthode P and O 85
Figure 3.5 Organigramme de l'algorithme P and O 86
Figure 3.6 Système de conversion éolienne 87
Figure 3.7 Système de conversion éolienne 89
Figure 3.8 Schéma du convertisseur DC-DC bidirectionnel 91
Figure 3.9 Convertisseur en mode de charge Step1.a 92
Figure 3.10 Convertisseur en mode de charge Step1.b 93
Figure 3.11 Convertisseur en mode de décharge Step2.a 94
Figure 3.12 Convertisseur en mode de décharge Step2.b 94
Figure 3.13 Représentation schématique du contrôleur ANNC 98
Figure 3.14 Microgrid proposé 99
Figure 3.15 Système de gestion de l'énergie appliqué au microgrid 100
Figure 3.16 L'organigramme de stratégie de gestion d'énergie 101
Figure 3.17 Scénario d'irradiation 102

Figure 3.18 Puissance du panneau PV 102
Figure 3.19 SOC de la batterie 102
Figure 3.20 Tension de la batterie 102
Figure 3.21 Comparaison entre la tension de DC bus et de référence 103
Figure 3.22 Comparaison entre la puissance demandée et la puissance produite 104
Figure 3.23 Comparaison entre la tension de DC bus et de référence 105
Figure 3.24 Comparaison entre la puissance demandée et la puissance produite 106
Figure 3.25 Le microgrid proposé 107
Figure 3.26 La stratégie de gestion d'énergie 109
Figure 3.27 Scénario d'irradiation 110
Figure 3.28 Puissance du panneau PV 110
Figure 3.29 Etat de charge 111
Figure 3.30 Puissance du réseau 111
Figure 3.31 Comparaison entre la tension de référence et la tension mesurée au DC bus 111

Figure 4.1 Système de gestion de l'énergie proposé 118
Figure 4.2 Système de stockage d'énergie par batterie pour microgrid 120
Figure 4.3 Stratégie de contrôle du système d'énergie de batterie 121
Figure 4.4 L'interface MacsimJX de co-simulation 122
Figure 4.5 Scénario d'irradiation 124
Figure 4.6 Scénario de vitesse de vent 124
Figure 4.7 La puissance de PV 125
Figure 4.8 La puissance d'éolienne 125
Figure 4.9 Etat de charge de la batterie 125
Figure 4.10 La puissance de la batterie 125
Figure 4.11 Comparaison entre la tension mesurée et la tension de référence . 126

Figure 4.12 Comparaison entre la puissance demandée et la puissance du système produite 127
Figure 4.13 Les fonctions d'activation 151
Figure 4.14 Modèle proposé pour la batterie 152
Figure 4.15 Le schéma de microgrid autonome sous Simulink 153
Figure 4.16 Le schéma de microgrid connecté au réseau sous Simulink 154

Liste des tableaux

Tableau 1.1 Comparaison des performances spécifiques de quelques accumulateurs commercialisés [22] 9
Tableau 1.2 Caractéristiques des matériaux utilisés pour l'électrode positive . 12
Tableau 2.1 Résultats d'optimisation de RNA 58
Tableau 4.1 Description des tâches de chaque agent du microgrid 123
Tableau 4.2 Description du microgrid 124

Table des matières

Résume viii

Abstract ix

Table des Figures xvii

Table des tableaux xvii

INTRODUCTION GÉNÉRALE 1

1

Chapitre1: Étude bibliographique 5

1.1 Introduction 6

1.2 Système de stockage d'énergie par batterie 7

1.2.1 Historique des batteries 7

1.2.2 Les accumulateurs lithiums 10

1.2.2.1 Electrode négative 11

1.2.2.2 Electrode positive 11

1.2.2.3 Electrolyte 12

1.2.3 Le principe de fonctionnement des batteries lithium 13

1.2.4 Grandeurs caractéristiques des batteries 19

1.2.5 Les challenges des batteries Lithium 21

1.2.6 Les systèmes de gestion de la batterie 23
1.3 Les Microgrids 24
1.3.1 Le concept de microgrids 25
1.3.2 Classification des microgrids 26
1.3.2.1 Microgrid de type AC 26
1.3.2.2 Microgrid de type DC 27
1.3.3 La gestion d'énergie au sein de microgrid EMS 28
1.4 Théorie des réseaux de neurones artificiels 30
1.4.1 Neurone biologique 30
1.4.2 Neurone formel 31
1.4.3 Analogie entre neurone biologique et neurone formel 32
1.4.4 L'apprentissage des réseaux de neurones 33
1.4.4.1 Apprentissage non supervisé 33
1.4.4.2 Apprentissage supervisé 34
1.4.4.3 Algorithme d'apprentissage (Rétropropagation du gradient) 34
1.5 Conclusion 35

Chapitre2: Modélisation de la batterie Li-ion et l'estimation de l'état de charge (SOC) 37

2.1 Introduction 38
2.2 Modélisation de la batterie au lithium 38
2.2.1 Modélisation électrochimique de la batterie 38
2.2.2 Modélisation circuits équivalents 39
2.2.2.1 Le modèle simple de la batterie 40
2.2.2.2 Le modèle résistif de Thevenin 40
2.2.2.3 Le modèle de Thevenin 41
2.2.2.4 Le modèle de double polarisation 42

2.2.2.5 Le Modèle de batterie de (CHEN AND MORA) 43
2.2.2.6 Le modèle générique de la batterie 44
2.2.3 Développement de modèle standard de la batterie lithium en utilisant les réseaux de neurones artificiels 46
2.2.3.1 La base de données expérimentales utilisée 46
2.2.3.2 Description du système proposé 48
2.2.3.3 Simulation et discussion des résultats 50
2.2.4 Modélisation boîte noire de la batterie lithium 54
2.2.4.1 La base de données expérimentales utilisée 54
2.2.4.2 Description du modèle proposé 58
2.2.4.3 Simulation et discussion des résultats 61
2.3 Estimation de l'état de charge (SOC) de la batterie 63
2.3.1 La méthode d'intégration de courant 64
2.3.2 La méthode de tension en circuit ouvert 64
2.3.3 Les méthodes basées sur des modèles circuit équivalent 65
2.3.3.1 L'observateur mode glissant 65
2.3.3.2 Filtre de Kalman 66
2.3.4 Les méthodes d'intelligence artificielle 68
2.3.4.1 Estimation de l'état de charge par SVM 68
2.3.4.2 Estimation de l'état de charge par Logique de Flou (FL) 69
2.3.4.3 Estimation de l'état de charge par les réseaux de neurones artificials (RNA) 69
2.3.5 Modélisation de la batterie et estimation de l'état de charge . . . 71
2.3.5.1 La description du modèle proposé 71
2.3.6 Simulation et discussion des résultats 72
2.4 Conclusion 74

Chapitre3: Contrôle intelligent de convertisseur DC/DC bidirectionnel 76

3.1 Introduction 77
3.2 Contrôle de convertisseur bidirectionnel 77
3.3 Modélisation des composants du microgrid 80
3.3.1 Le système photovoltaïques PV 80
3.3.1.1 Cellule photovoltaïques 81
3.3.1.2 Convertiseur DC/DC de type boost 82
3.3.1.3 La commande MPPT 84
3.3.2 Le générateur éolienne 86
3.3.2.1 Turbine éolienne 87
3.3.2.2 Génératrice synchrone à aimant permanent (PMSG) . . 89
3.3.3 Le système de stockage d'energie 90
3.3.3.1 Batterie Li-ion 90
3.3.3.2 Convertisseur DC/DC Bidirectionnel 91
3.4 Contrôle de convertisseur bidirectionnel pour un microgrid autonome . . . 95
3.4.1 Contrôleur de Réseau de Neurone Artificial ANNC 95
3.4.2 Simulation et discussions des résultats 98
3.5 Contrôle de convertisseur bidirectionnel pour un microgrid connecté au réseau électrique 107
3.5.1 Simulation et discussion des résultats 108
3.6 Conclusion 112

Chapitre4: La gestion d'énergie dans un microgrid 114

4.1 Introduction 115
4.2 La gesion d'energie au sein du microgrid 115
4.2.1 Système de gestion d'énergie centralisé 116
4.2.2 Système de gestion d'énergie décentralisé 117
4.3 Gestion de l'énergie en temps réel pour DC Microgrid en utilisant les multi agents. 118

4.3.1 Système de stockage de batterie 119
4.3.2 Multi-Agent Système MAS 121
4.3.3 Simulation et discussion des résultats 122
4.4 Conclusion 127

CONCLUSION GÉNÉRALE **127**

BIBLIOGRAPHY **130**
4.5 Annex 1 146
4.6 Annex 2 148
4.7 Annex 3 151
4.8 Annex 4 152
4.9 Annex 5 153
4.10 Annex 6 153

INTRODUCTION GÉNÉRALE

Les changements climatiques mondiaux et la diminution d'approvisionnement énergétique posent un problème important. Pour faire face à ce problème, depuis 1995, chaque année, les pays qui ont signé la convention sur le climat du sommet de Rio, se réunissent lors de Conférence of Parties (COP) pour trouver des solutions concrètes afin de lutter contre les changements climatiques.

En 2015, la COP21 qui a eu lieu à Paris, a illustré un moment historique grâce à la signature de l'accord de Paris, où toutes la communauté internationale s'est mise d'accord sur l'obligation d'augmenter les efforts afin de limiter le réchauffement climatique bien en dessous de +2°C, de préférence à 1,5 °C, par rapport au niveau préindustriel.

Le plan d'action et d'application de l'accord de Paris a été défini en 2016 à Marrakech lors de la COP 22. Il a été confirmé dans le rapport de Intergovernmental Panel on Climate Change (IPCC) que les activités humaines, en particulier l'utilisation des énergies fossiles présentent la cause principale des changements climatiques. L'analyse effectuée par International Renewable ENergy Agency (IRENA) a montré qu'une combinaison entre les énergies renouvelables, et l'efficacité énergétique présente le choix le plus convenable permettant de réduire plus de 90% d'émissions de dioxyde de Carbone (CO_2).

Les énergies renouvelables sont des sources d'énergie propres provenant de la nature, sous forme d'un rayonnement solaire, du vent, des marées, et de la chaleur géothermique. La production mondiale d'électricité à base des sources d'énergie renouvelables a fortement augmenté ces dernières années à cause, d'une part de leur impact positif sur l'environnement qui se traduit par la diminution des émissions de gaz à effet de serre, ainsi

que les coûts bas de leurs composants électroniques, et d'autre part le développement continue des microgrids. Ces derniers sont apparus comme une architecture flexible pour déployer des sources d'énergies renouvelables distribuées, afin de combler le manque d'énergie des différentes communautés, surtout dans les zones rurales éloignées. Le plus grand défi de développement des microgrids et des systèmes qui utilisent les énergies renouvelables spécifiquement, l'énergie solaire et l'énergie éolienne, est le problème d'intermittence, c'est à dire son incapacité d'assurer une production constante d'électricité. L'utilisation de ces types d'énergie nécessite l'existence des systèmes de stockage pour stocker l'énergie en cas de surplus et en même temps de la réutiliser quand la production n'est pas suffisante. Par conséquent les énergies renouvelables ne pourront représenter une partie majoritaire du mix énergétique qu'à condition que leur stockage soit possible. En effet, plusieurs technologies de stockage peuvent être classifiées selon l'application visée (type d'application, taille, fréquence d'utilisation, etc).

Dans le contexte de cette thèse, notre attention s'est portée aux systèmes de stockage électrochimiques, plus particulièrement aux accumulateurs lithium-ion, qui représentent la technologie la plus récente dans le monde entier. Les batteries lithium-ion offrent un potentiel important, en terme d'énergie et de puissance par rapport aux autres types de batteries électrochimiques. En outre, ce type de batterie n'est pas affecté par l'effet-mémoire et son autodécharge est réduite. Toutefois, ils sont à l'origine d'un certain nombre d'accidents dans tous les secteurs d'application.

En janvier 2013, un incident a eu lieu dans l'aéroport de Boston (787 Japan airlin) sans dégâts humains, la batterie était la cause de cette explosion, ce qui a engendré la suspension de tous les vols.

En novembre 2016, un autre accident a été causé par un véhicule électrique qui s'est écrasé contre un arbre au centre-ville d'Indianapolis, l'impact de la collision a provoqué l'émission des cellules de la batterie dans toutes les directions.

En novembre 2017, une batterie de stockage d'énergie d'une station éolienne a explosé

en flammes dans une centrale électrique située près de la ville de Bruxelles. L'incendie a provoqué un nuage de fumée toxique qui a obligé des milliers de personnes à rester chez elles.

Donc, la sécurité des batteries au lithium présente un enjeu technique et sociétal très important, et nécessite une attention particulière lors de leurs applications.

Le système de stockage d'énergie par batterie est largement utilisé dans les Microgrid afin de compenser le déséquilibre d'énergie entre les sources d'énergies distribuées et la demande des charges électriques. Cet équilibre est assuré à travers les unités de stockage d'énergie en absorbant le surplus d'énergie des sources pendant les heures creuses. De plus, ils peuvent fonctionner comme une source de secours dans le microgrid autonome en fournissant l'énergie nécessaire pendant les heures de pointe.

Afin d'éviter les accidents liés à l'explosion des batteries lithium et d'assurer l'équilibre d'énergie pour les microgrids, la conception d'un modèle de batterie lithium est de grande nécessité.

De ce fait, l'objectif de notre travail consiste en la mise au point d'un modèle qui décrit le fonctionnement réel de la batterie, c'est à dire un modèle qui prend en considération l'effet d'état de charge et de température dans son comportement, suivi d'un développement d'une méthode intelligente pour l'estimation d'état de charge de la batterie. Le contrôle intelligent de convertisseur DC/DC bidirectionnel qui connecte la batterie avec le bus DC de Microgrid sera developpé. Le dernier objectif de notre travail est la mise en place d'une stratégie de gestion intelligente d'énergie pour un microgrid système.

Ce rapport, intitulé **Modélisation de la batterie lithium pour les microgrids en utilisant les réseaux de neurones artificiels** est organisé en quatre chapitres.

Le premier chapitre introduit le contexte général de la thèse. En un premier lieu, nous présentons les concepts de base et les caractéristiques des batteries au lithium, ainsi, nous présenterons le système de gestion de la batterie, ensuite nous définirons le concept

des microgrids et ses architectures. Et à la fin de ce chapitre, nous présenterons la théorie du réseau de neurones artificiel qui représente la principale technique utilisée pour l'ensemble des travaux.

Le deuxième chapitre est dévolu à la modélisation de la batterie et l'estimation de son état de charge. En premier lieu, nous introduirons un état d'art des grandes catégories de modélisation de la batterie, suivi de notre contribution au développement du modèle standard de la batterie, et le modèle boite noire que nous avons proposée. Ensuite nous présenterons un état d'art des méthodes d'estimation d'état de charge, avant de finir par présentation de notre modèle pour l'estimation d'état de charge.

Le troisième chapitre est consacré au contrôle de convertisseur bidirectionnel qui connecte la batterie avec le microgrid. En premier lieu, nous présenterons, les méthodes de contrôles existent dans la littérature, suivi de la description de modèle qui est utilisé pour chaque élément de microgrid. Ensuite nous présenterons le contrôleur proposé et son application dans les deux types de microgrid (isolé et connecté).

Dans **le quatrième chapitre**, une nouvelle approche de gestion d'énergie décentralisée par les multiagents est proposée pour la gestion d'énergie au sein de microgrid permettant de maximiser la production d'énergie de chaque source et de protéger la batterie Li-ion durant son fonctionnement. En premier lieu, nous présenterons les stratégies de gestion d'énergie qui existent dans la littérature, ensuite l'approche de multiagents système et à la fin nous présentons la stratégie de gestion d'énergie proposée.

CHAPITRE 1

ÉTUDE BIBLIOGRAPHIQUE

1.1 Introduction

Au cours des dernières années, les systèmes d'énergie électrique se sont forcés de remplacer les sources d'énergie principales et traditionnelles par des Sources d'Energie Renouvelables (SER) plus respectueuses de l'environnement et plus durables [2]. Cela est dû à plusieurs facteurs tels que l'augmentation de la demande d'électricité, la nécessité de réduire les émissions de gaz à effet de serre,les changements climatiques et la diminution des ressources énergétiques fossiles.

Les SER comme l'énergie solaire, éolienne, qui ont un potentiel considérable pour produire de l'électricité, jouent un rôle primordial dans les futurs systèmes de production d'électricité. Mais leur dépendance des conditions météorologiques représente le plus grand défi de ces sources d'énergie. Elles ne sont disponibles que lorsque le soleil et le vent sont suffisants. Puis, l'intégration des SER dans le réseau pose un problème en raison de leur nature variable et intermittente [3]. C'est pour cela le stockage d'énergie devient une technologie favorable et une solution appropriée pour intégrer les SER dans le réseau électrique.

Le stockage d'énergie désigne un processus de conversion de l'énergie électrique provenant d'une source électrique en une forme qui peut être stockée pour la reconvertir en énergie électrique en cas de besoin. Ensuite, ce type de processus dans le système de stockage d'énergie peut offrir une opportunité pour l'électricité d'être stockée à des moments de faible demande, et de forte production des sources d'énergie intermittentes et d'être utilisée en période de forte demande, de coût de production élevé, ou quand aucun autre moyen de génération n'est disponible. Il existe différentes technologies pour le stockage d'énergie, mais la forme la plus courante est la batterie, c'est un système modulaire, silencieux et non polluant [4].

Battery Energy Storage Système (BESS) est considérée comme une solution efficace pour les microgrids. La BESS permet d'augmenter la fiabilité et les performances globales

du système et de réduire le coût d'exploitation, car il minimise l'utilisation du réseau électrique, et maximise l'utilisation des SER.

Ce chapitre présente les concepts de base et les caractéristiques des systèmes de stockage d'énergie par batterie, des micro-réseaux et la théorie du réseau de neurone artificiel qui représentent la principale technique utilisée pour l'ensemble des travaux. Ce chapitre constitué de trois sections, est organisé comme suit :

— Système de stockage d'énergie par batterie ;

— Microgrid ;

— Théorie du réseau de neurone ;

1.2 Système de stockage d'énergie par batterie

Les batteries ou bien les accumulateurs constituaient la principale source d'électricité avant le développement des générateurs électriques et des réseaux électriques à la fin du 20ème siècle. Les améliorations successives de la technologie des batteries ont facilité le développement d'autres applications avancées, telles que les smartphones, ordinateurs portables et voitures électriques.

1.2.1 Historique des batteries

La première batterie qui pouvait fournir un courant électrique continu a été inventée par le physicien Italien Alessandro Volta en 1799. La pile de Volta utilisait du zinc et du cuivre pour les électrodes avec du papier imbibé de saumure pour un électrolyte. Son invention a réfuté la théorie courante selon laquelle l'électricité ne pouvait être créée que par des êtres vivants[5]. Environ 40 ans plus tard, le chimiste britannique John Fréderic Daniell créerait une nouvelle cellule qui résoudrait le problème de la ≪bulle d'hydrogène≫ de la pile voltaïque. Dans cette dernière, des bulles d'hydrogène accumulées au fond des électrodes en zinc limitaient la durée de vie et les utilisations de la pile. La cellule Da-

niell, inventée en 1836, utilisait un pot de cuivre rempli de solution de sulfate de cuivre, qui était ensuite immergé dans un récipient en terre cuite rempli d'acide sulfurique et d'une électrode de zinc. Le potentiel électrique de la cellule Daniell est devenu l'unité de base de la tension, égal à un volt [1]. En 1859, le physicien français Gaston Planté invente la première batterie au plomb rechargeable. Les batteries au plomb-acide ont deux avantages : le prix qui est raisonnable et la capacité à fournir des courants élevés. Cela les rend adaptées aux démarreurs automobiles, et cela fait partie de la raison pour laquelle 44,7 milliards de dollars de batteries au plomb ont été vendus dans le monde en 2014 [6].

Les batteries Nickel-Cadmium (NiCd) ont été inventées en 1899 par Waldemar Jünger en Suède. Les premieres étaient similaires aux batteries au plomb, utilisant un électrolyte liquide. Les piles au NiCd ont contribué à ouvrir la voie à la technologie moderne, mais elles sont de moins en moins utilisées en raison de la toxicité du cadmium. Pour cette raison, ces batteries ont perdu 80% de leur part de marché par rapport au autres batteries dans les années 90[7].

En 1950 les piles alcalines ont été inventées par l'ingénieur Canadien Lewis Urry en utilisant de l'oxyde de zinc et de manganèse dans les électrodes. Ce type de batterie tire son nom de l'électrolyte alcalin utilisé : l'hydroxyde de potassium. Ces piles sont très populaires dans des marques comme Duracell et Energizer et sont utilisées dans les appareils électroménagers ordinaires, des télécommandes aux lampes de poche. Elles sont peu coûteuses et généralement non rechargeables, bien qu'elles puissent être rendues rechargeables en utilisant une cellule spécialement conçue[8, 9].

De même, la batterie Nickel-Métal Hydrure (NiMH) utilise un alliage absorbant l'hydrogène au lieu du cadmium toxique. Cela le rend plus sécurisé pour l'environnement et contribue également à augmenter la densité énergétique. Les piles NiMH sont utilisées dans les outils électriques,les appareils photo numériques et certains appareils électroniques. Elles étaient également utilisées dans les premiers véhicules hybrides, tels que la Toyota Prius. Le développement du NiMH s'est étalé sur deux décennies et a été parrainé par

Daimler-Benz et Volkswagen AG. Les premières cellules disponibles dans le commerce datent de 1989[10, 11]. En ce qui concerne les batteries lithium, le marocain YAZAMI Rachid, avec les Japonais Akira Yoshino et Yoshio Nishi ainsi que l'Américain John Goodenough, ont joué un rôle essentiel dans le développement des premières batteries lithium. En 1991 Sony a lancé la première batterie lithium-ion commerciale.

Les batteries lithium-ion sont formées d'un certain nombre de cathodes spécifiques pour différentes applications. Par exemple, les cathodes au lithium-dioxyde de cobalt ($LiCoO_2$) sont utilisées dans les ordinateurs portables et les smartphones, tandis que les cathodes au Lithium-Nickel-Cobalt d'Aluminium ($LiNiCoAlO_2$), sont utilisées dans les batteries de véhicules tels que les vehicules de Tesla. Le graphite est un matériau commun pour l'utilisation dans l'anode[12, 13, 14].

Pour l'instant, les batteries lithium-ion sont très utilisées pour les appareils technologiques portables. La plupart des téléphones, ordinateur portable, les voitures électriques et les hybrides sont équipés de batterie au lithium. Le Tableau1.1 présente une comparaison entre plusieurs technologies des batteries commercialisées en termes de performances spécifiques de chaque batterie[15].

TABLEAU 1.1 – Comparaison des performances spécifiques de quelques accumulateurs commercialisés [22]

Technologie des batteries	f.é.m. à vide (V)	Énergie spécifique théorique (Wh/Kg)	Énergie spécifique pratique (Wh/Kg)	Énergie volumique pratique (Wh/dm3)	Nombre des cycles
Nickel cadmium	1,30	211	30-50	80	2000
Nickel hydrure métallique	1,32	216	65	200	500-1000
Nickel fer	1,41	268	40-60	60	Infinie
Plomb étanche	2,1	173	35	80	500-800
Lithium-ion	4,1	750	100-150	200-300	1000

En comparant les caractéristiques de chaque batterie de ce tableau, on remarque que la batterie lithium présente de meilleurs résultats en termes de performances. Pour cela cette technologie est préférentiellement choisie pour les microgrids ainsi que les téléphones mobiles et les ordinateurs portables.

La Figure 1.1 présente une comparaison entre les différentes technologies d'accumulateurs rechargeables, en termes de densités d'énergie et de puissance spécifique.

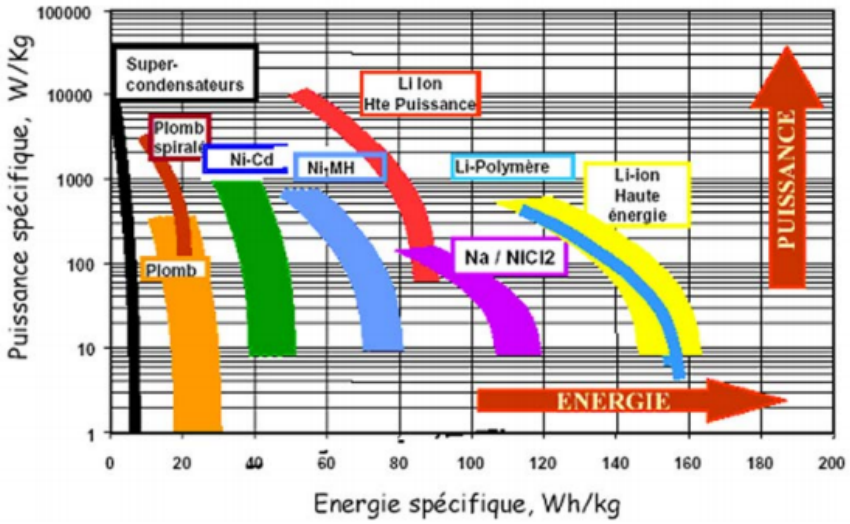


FIGURE 1.1 – Diagramme de Ragon [1].

Ce diagramme met le point sur l'intérêt des accumulateurs au lithium par rapport aux autres systèmes de stockage, expliquant la valeur de ces technologies. Celles-ci sont effectivement de plus en plus utilisées comme sources d'énergie autonomes en remplacement du Ni-Cd et du Ni-MH, en raison de leurs densités d'énergie très élevées .

1.2.2 Les accumulateurs lithiums

La différence entre les batteries lithiums se figure dans le choix des matériaux utilisés pour les électrodes. L'objectif principal des chercheurs électro chimistes est d'obtenir une différence de potentiel entre les électrodes de la batterie en utilisant pour l'anode

un matériau réducteur et pour la cathode un matériau oxydant. L'association de ces deux électrodes est effectuée par le biais de l'électrolyte qui assure le transport des charges entre les deux électrodes. Géneralment, il existe plusieurs choix d'électrodes dans la littérature[16] :

1.2.2.1 Electrode négative

Au début, les batteries au lithium sont présentées sous forme de lithium métal dont l'électrode négative est constituée de lithium sous forme métallique (réducteur). Ce choix d'électrode permet d'avoir une grande capacité massique grâce à son faible poids.

Les dépôts de lithium dans le électrolytes se forment des débris qui restent après chaque cycle de charge et de décharge. Ce qui représente un problème majeur pour ce type d'électrode, car ils peuvent provoquer des courts circuits internes en cas de formation d'un lien entre deux électrodes[17].

Pour conserver une excellente densité énergétique de la batterie lithium et éviter ces courts circuits internes, on peut utiliser un polymère conjointement au lithium métal qui joue le rôle d'électrolytes de séparateur[18].

1.2.2.2 Electrode positive

L'électrode positive est la principale variante entre les différentes techniques de cellules Lithium, car plusieurs matériaux peuvent être utilisés avec d'importantes variations au niveau de l'énergie spécifique, de la durée de vie, du coût et de la sécurité.

Les batteries Lithium les plus utilisées jusqu'au les années 2000 étaient composées de lithium et d'oxydes de cobalt (LiCoO2, LCO) qui présentent de hautes performances, mais ce type de batteries est connu par une forte toxicité. À cause de cette dernière, les chercheurs ont proposé d'autres matériaux pour l'électrode positive[19]. Les principaux matériaux utilisés sont :

$LiCoO_2$ **:** l'oxyde de cobalt offre une tension élevée et une forte capacité spécifique,

mais présente une certaine toxicité ainsi qu'un coût élevé.

$LiNiO_2$ **:** l'oxyde de nickel est parmi les matériaux les moins coûteux, mais il faut souvent l'associer à du cobalt afin d'avoir une forte capacité spécifique, c'est-à-dire une partie de l'oxyde de nickel est remplacée par le cobalt. Il faut également ajouter l'aluminium au sein des matériaux afin d'éviter les risques d'emballement thermique au-delà de 200°C. Cette combinaison permet de réduire le nombre d'ions Ni^{2+}, alors le matériau final de l'électrode devient : LiNi1-x-yCoxAlyO2[20].

$LiMn_2O_4$ **:** l'oxyde de manganèse est un matériau moins cher et non toxique, mais le plus grand avantage réside dans sa stabilité thermique, c'est-à-dire qu'il offre une meilleure sécurité. Mais ce matériau présente une capacité et une durée de vie réduite par rapport aux matériaux précédents [20].

$LiFePO_4$ **:** lithium fer phosphate est un matériau qui semble s'imposer dans les applications de puissance malgré sa faible tension par rapport aux autres matériaux. En effet ce matériau offre de nombreux avantages dont, le faible coût, une durée de vie importante, et non toxique et une capacité spécifique importante. Le Tableau1.2 présente une classification des principaux matériaux utilisés[21].

TABLEAU 1.2 – Caractéristiques des matériaux utilisés pour l'électrode positive

Matériau	Tension moyenne (V)	Capacité(Ah)	coût	Sécurité
$LiCoO_2$	3,7	180	Élevé	Sensible
$LiNiO_2$	3,5	220	moyenne	
$LiMn_2O_4$	3,8	140	faible	Stable
$LiFePO_4$	3,43	170	faible	Très stable

1.2.2.3 Electrolyte

L'électrolyte fonctionne comme un conducteur ionique, permettant aux ions lithium de migrer entre les électrodes positive et négative. Les électrolytes sont aujourd'hui utilisés sous deux formes principales [18, 19] :

— L'électrolyte liquide est constitué d'un solvant (tel que les carbonates d'alkyle) auquel du sel de lithium est ajouté (par exemple, $LiPF_6$ et $LiPF_4$).

— Le sel de lithium est incorporé dans les matrices polymères pour créer un électrolyte polymère.

1.2.3 Le principe de fonctionnement des batteries lithium

Le principe général de fonctionnement d'une batterie repose sur la conversion d'énergie chimique en énergie électrique via des réactions d'oxydoréduction réversible. Le principe sera présenté dans les différentes étapes de charge et de décharge de la batterie :

- Étape 1 : batterie déchargée (SOC=0%)

La Figure 1.2 présente une cellule de batterie Li-ion déchargée. L'électrode positive est la source des ions Li^+ nécessaire pour la conversion d'énergie électrique en énergie chimique. Le passage des ions Li^+ vers l'électrode négative est effectué à travers l'électrolyte qui contient aussi des ions Li^+.

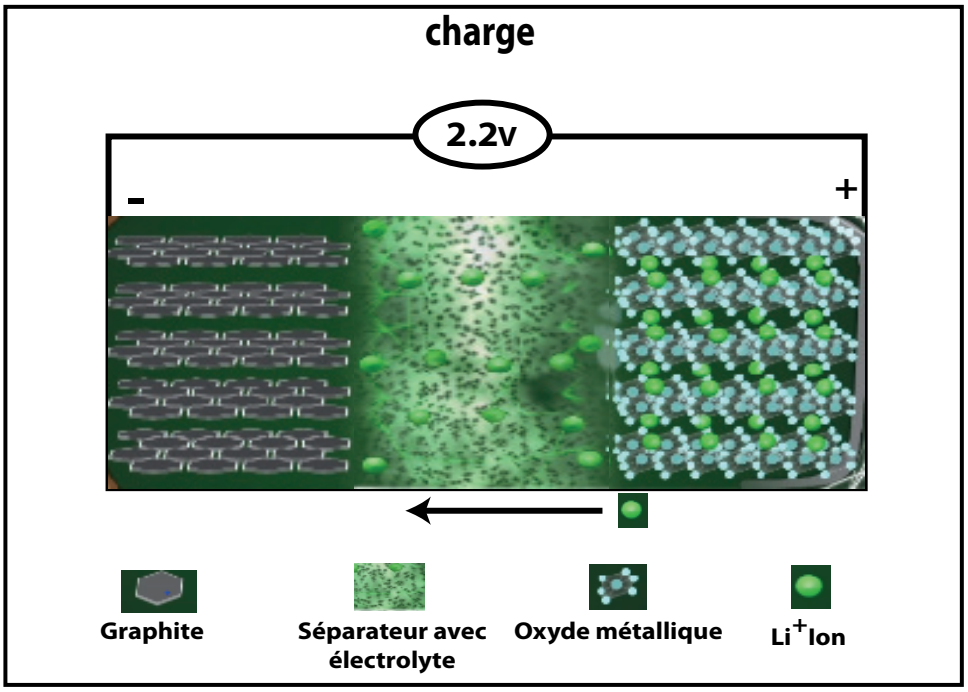


FIGURE 1.2 – Cellule lithium déchargée.

- Étape 2 : Formation des couches (SEI) et (CEI)

Au début du processus de charge de la batterie, les électrons se déplacent vers l'électrode négative, alors pour conserver la neutralité de charge les ions Li^+ émigrent vers l'électrode négative à travers l'électrolyte. Comme résultat de ce déplacement, deux couches sont créées Solid Electrolyte Interphase (SEI) et Cathode Electrolyte Interphase (CEI). Ces couches sont constituées par des composants électrolytiques et des ions Li^+ provenant de l'électrode positive, et représentent l'interface entre l'électrolyte et les deux électrodes de la cellule comme l'illustre la Figure 1.3.

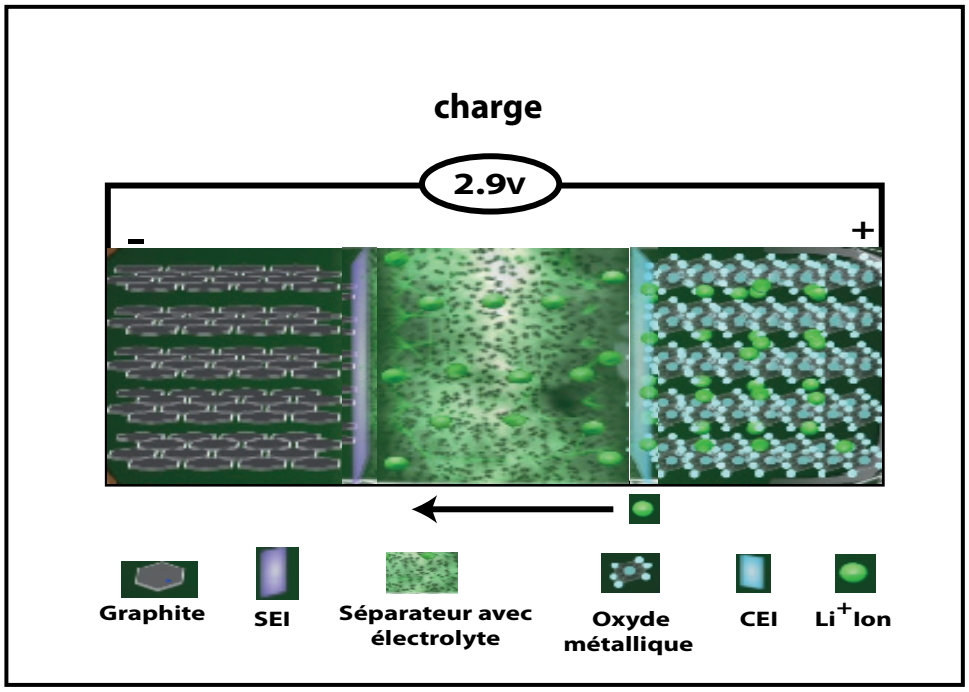


FIGURE 1.3 – Cellule lithium au début de la charge.

- Étape 3 : réactions des électrodes durant la charge

Après la formation des couches SEI et CEI, les autres ions Li^+ s'intercalent de l'électrode positive dans l'électrolyte et migrent, à travers celui-ci, vers le matériau de l'électrode négative pour être ensuite incorporés dans ce dernier comme l'illustre la Figure 1.4.

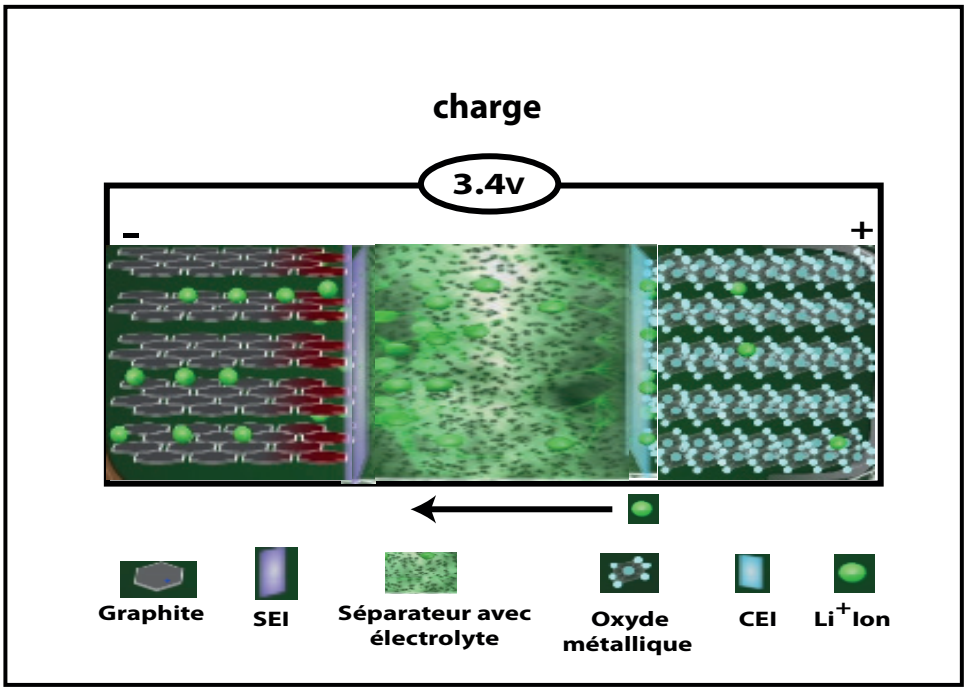


FIGURE 1.4 – Cellule lithium après la formation de SEI et CEI.

Les équations suivantes illustrent les réactions chimiques qui résultent au niveau de chaque électrode.

L'équation 1.1 pour l'électrode positive :

$$LiMO_2 \rightarrow Li_{(1-x)}MO_2 + xe^- + xLi^+ \tag{1.1}$$

l'équation1.2 pour l'électrode négative :

$$C_6 + xe^- + xLi^+ \rightarrow Li_xC_6 \tag{1.2}$$

L'équation 1.3 montre la réaction chimique globale de la cellule de Li-ion durant le process de charge.

$$C_6 + LiMO^2 \rightarrow Li_xC_6 + Li_{(1-x)}MO_2 \tag{1.3}$$

- Étape 4 : changement de couleur d'électrode négative

Le changement de couleur d'électrode négative dépend du nombre des ions Li^+ embarqué dans l'électrode négative et de l'état de charge de la cellule. Au début de charge de la batterie la couleur de l'électrode négative est rouge et à la fin de charge, la couleur devient or comme illustré sur les Figures 1.5 et 1.6.

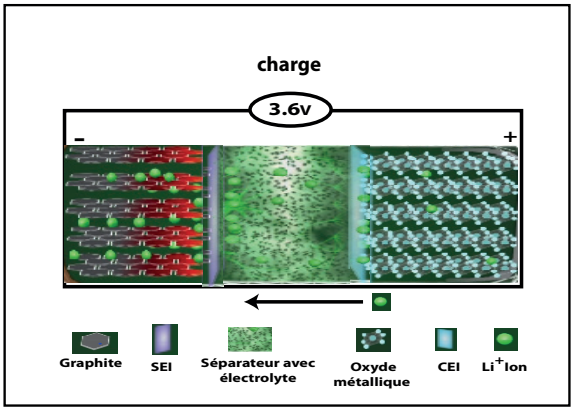


FIGURE 1.5 – Couleur au début de la charge

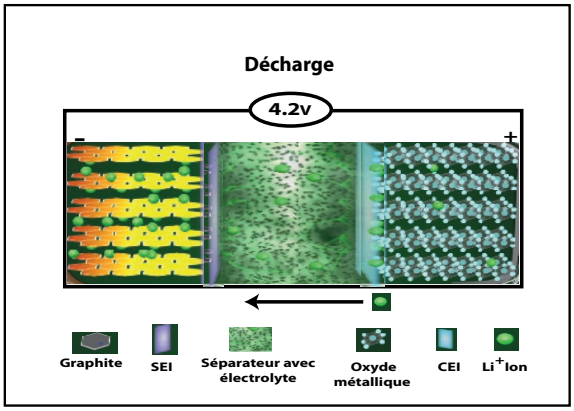


FIGURE 1.6 – Couleur à la fin de la charge

- Étape 5 : début de décharge de la batterie

Durant la décharge, le processus de transfert des électrons et des ions s'inverse entre l'électrode négative et positive. L'électrode négative devient la source des ions Li^+, alors pour conserver la neutralité électrique, les ions Li^+, se déplacent vers l'électrode positive à traves l'électrolyte. Il en résulte un changement de la couleur des deux électrodes comme le montre la figure1.7

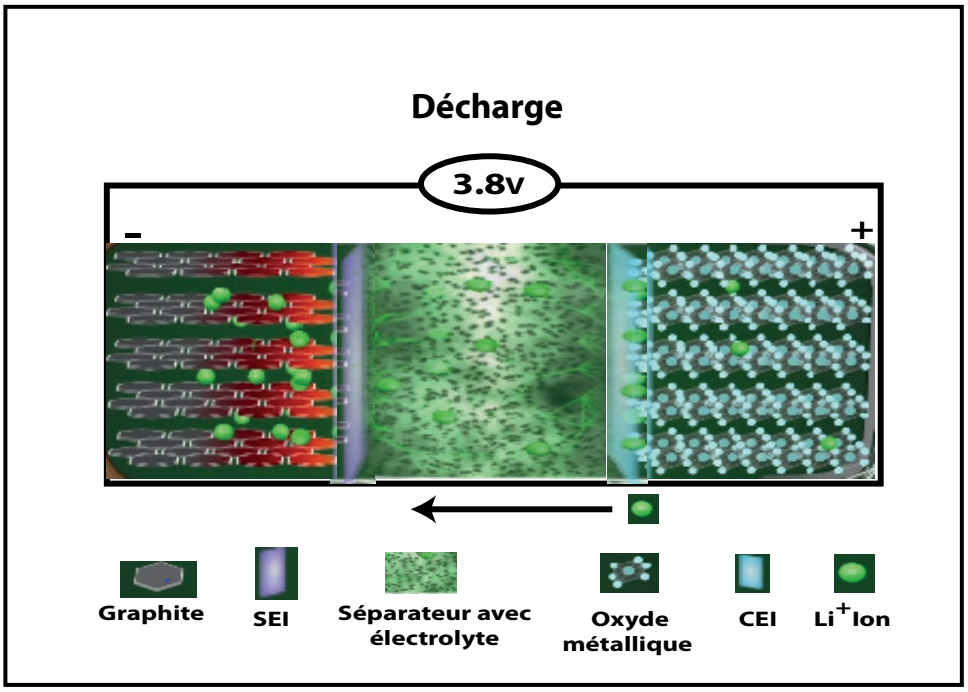


FIGURE 1.7 – Cellule lithium au début de la décharge.

Durant la décharge, le sens des réactions s'inversent dans les deux électrodes. Par conséquent les équations des réactions chimiques devient :

L'équation1.4 pour l'électrode positive

$$Li_{(1-x)}MO_2 + xe^- + xLi^+ \rightarrow LiMO_2 \tag{1.4}$$

l'équation1.5 pour l'électrode négative

$$Li_xC_6 \rightarrow C_6 + xe^- + xLi^+ \tag{1.5}$$

- Étape 6 : fin de décharge de la batterie(SOC=0%)

À la fin de décharge (SOC=0%), les ions Li^+ se retournent à l'électrode positive qui est l'origine de ces ions. Le premier cycle de charge/décharge engendre une perte irréversible des ions Li^+ à cause, d'une part de la création des deux couches SEI et CEI dans la cellule,

et d'autre part, des ions qui restent dans l'électrode négative et qui n'arrivent pas à joindre l'électrode positive comme illustré sur la Figure 1.8.

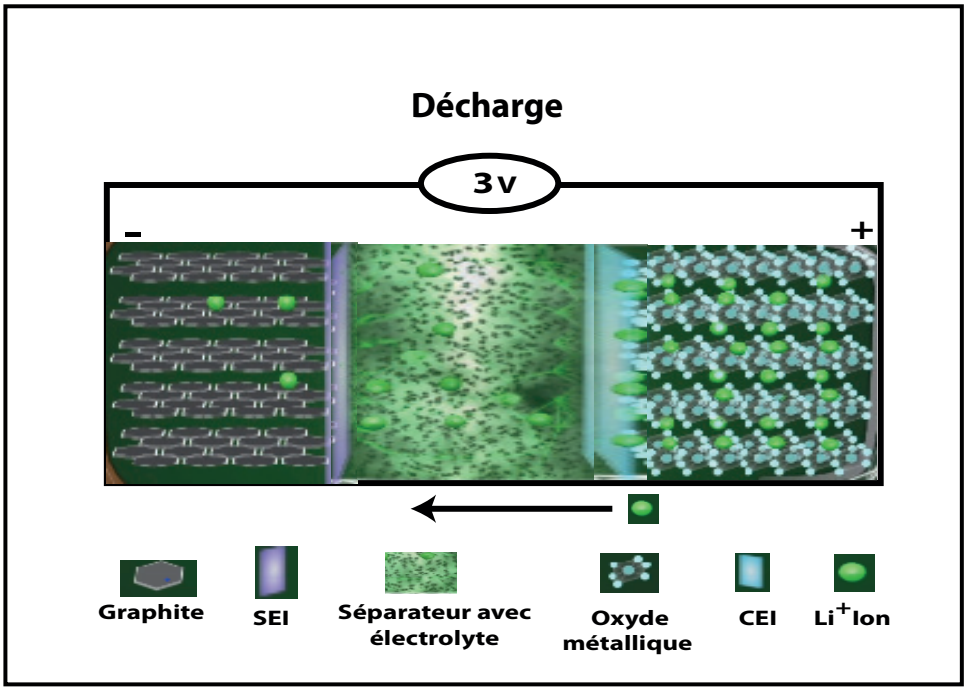


FIGURE 1.8 – Cellule lithium à la fin de la décharge

Par conséquent, moins des ions Li^+ sont stockés dans l'électrode négative pour les prochains cycles de charge, ce qui mène à réduire la capacité de la batterie.

1.2.4 Grandeurs caractéristiques des batteries

Dans cette section, les grandeurs caractéristiques de la batterie seront rappelées afin de se familiariser avec les différentes définitions et termes techniques qu'on utilisera dans la rédaction de cette thèse :

Tension

La tension de la batterie ou bien la tension en circuit ouvert est une grandeur qui caractérise la batterie, elle est définie comme la différence de potentiel entre les électrodes

de la batterie. Cette tension dépend du matériau utilisé pour l'électrode positive (voir le Tableau1.2).

Capacité

La capacité de la batterie exprimée en mAh représente la quantité de charges qu'il est possible d'obtenir lors d'une décharge complète à courant constant. En effet, la capacité de la batterie diminue à chaque fois qu'on augmente le courant de charge ou bien de décharge. L'une des explications de cette diminution en capacité est que sous l'effet des courants élevés, une partie de l'énergie est convertie en chaleur par Effet Joule [22]. C'est pour cette raison qu'on trouve toujours dans les fiches signalétiques des batteries, un courant recommandé pour la charge et la décharge, afin d'avoir 100% de la capacité de la batterie. Par exemple, dans le cas de la batterie lithium ions 24V- 180Ah, le courant recommandé est : 54A (0.3C).

État de santé

L'état de santé de la batterie est un paramètre qui prend en considération le vieillissement de la batterie dû à l'augmentation de la résistance interne. Il peut être défini comme le rapport entre la capacité totale actuelle et la capacité maximale obtenue lorsque la batterie était neuve[23]. Cependant, l'état de santé est un indicateur important pour suivre la dégradation des performances de la batterie et estimer sa durée de vie.

État de charge

L'état de charge de la batterie connu dans la literature par State Of Charge (SOC) est l'un des paramètres les plus importants pour la batterie [24]. En général, il est défini comme le rapport de sa capacité actuelle sur la capacité nominale. La Figure 1.9 montre le SOC en plusieurs état de la batterie.

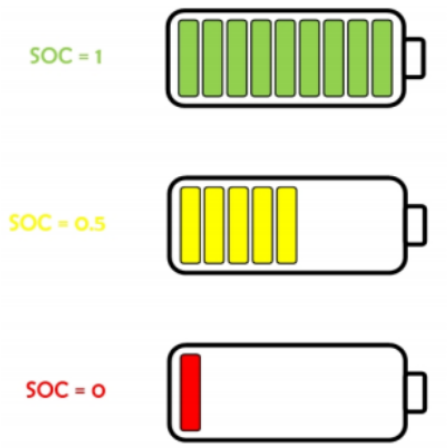


FIGURE 1.9 – État de charge de la batterie

La définition commune du SOC peut être donnée comme suit :

$$SOC(t) = SOC(t=0) + \frac{\int i(t) \times dt}{Q_n} \tag{1.6}$$

Avec

$SOC(t=0)$: l'état de charge initial

$i(t)$: le courant de la batterie

Q_n : la capacité nominale de la batterie

1.2.5 Les challenges des batteries Lithium

La température et la tension de fonctionnement sont les paramètres les plus importants qui déterminent les performances des cellules lithium-ion [25]. Les Figures 1.10 et 1.11 montrent que la tension, le courant et la température de fonctionnement de la cellule doivent être maintenus à tout moment dans la zone indiquée par la case verte intitulée " Zone d'opération sécurisée ". En dehors de cette zone, la cellule pourra être endommagée

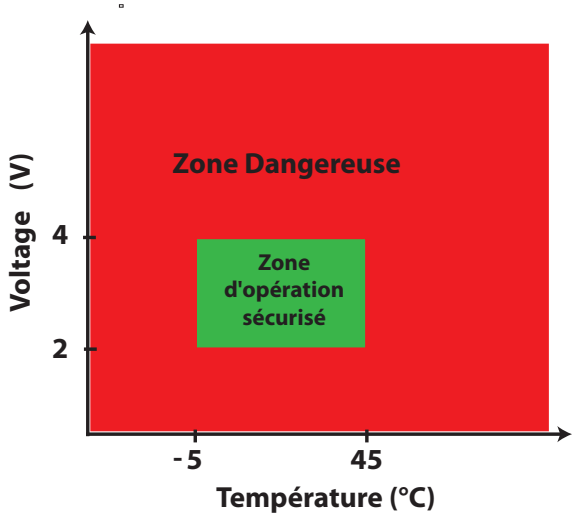


FIGURE 1.10 – Zones de fonctionnement sécurisé de tension

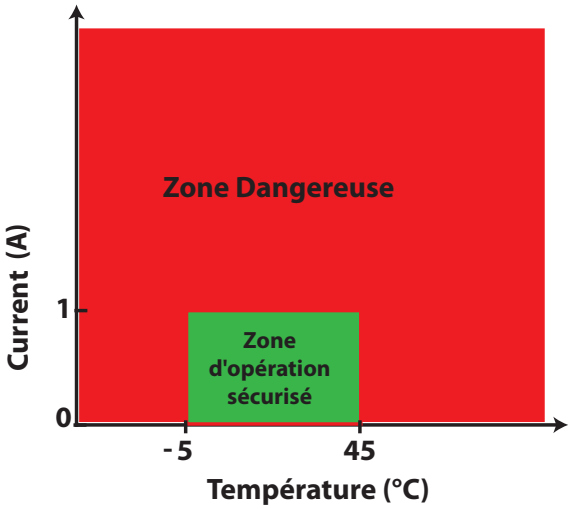


FIGURE 1.11 – Zones de fonctionnement sécurisé de courant

Les batteries peuvent être chargées au-dessus de leur tension nominale ou être déchargées sous une tension recommandée, mais cette opération peut endomager la batterie, surtout quand la tension de charge dépasse la limite supérieure recommandée de 4,2 V. D'autre part, la surdécharge ou bien la surcharge des cellules pendant des périodes prolongées entraînerait une chute de tension de la cellule en dessous de sa limite inférieure, typiquement vers 2,5 V. Cela pourra progressivement endommager l'électrode.

De même, la température de fonctionnement des piles au lithium-ion doit être rigoureusement contrôlée, car des températures trop élevées ou trop basses pourraient endommager la celllule de la batterieyuan2011development.

Il ressort clairement de la discussion, ci-dessus, qu'il n'est pas sécurisé d'utiliser la batterie directement avec des systèmes de charge ou de décharge. Par conséquent, des circuits électriques de protection sont nécessaires pour contrôler le fonctionnement du système de stockage de l'énergie.

1.2.6 Les systèmes de gestion de la batterie

Les systèmes de gestion de batterie, Battery Management Système (BMS) sont des systèmes en temps réel contrôlant de nombreuses fonctions vitales pour le fonctionnement correct et sécurisé de batterie. Ceci comprend la surveillance de la température, des tensions et des courants, la planification de la maintenance, l'optimisation des performances de la batterie, la prévision et / ou la prévention des pannes ainsi que la collecte de données sur la batterie. Il s'agit d'un dispositif électronique qui s'intercale entre la batterie et le système de charge ou bien de décharge pour gérer l'utilisation de la batterie[26].

Les systèmes de gestion de batterie sont largement répandus dans les véhicules électriq ues, mais sont également couramment utilisés dans d'autres applications de batterie comme les packs des batteries des avions, les microgirds, et tous les systèmes qui utilisent la batterie comme source d'energie. Les exigences du système de gestion de batterie pour ces applications sont souvent très similaires à celles du marché automobile, c'est-à-dire qu'il est toujours important de contrôler les cellules et de les emballer de manière robuste, fiable.

Afin d'obtenir un fonctionnement efficace de la batterie et de prolonger sa durée de vie, le système de gestion de batterie (BMS) doit inclure les fonctions suivantes montrées sur la Figure 1.12. En effet, le système de gestion de la batterie est un système qui englobe plusieurs fonctions de gestions, qui protègent le batterie de tous les dommages éventuels, et de veille à maintenir la batterie à un niveau de fonctionnement optimal.

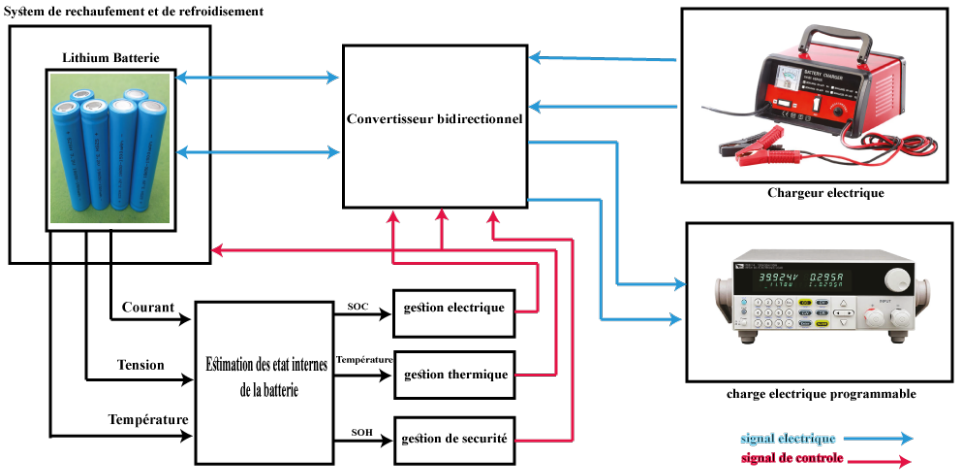


FIGURE 1.12 – Dessin schématique simplifié d'un BMS

À l'aide des capteurs installés dans la batterie, cette dernière devient supervisée durant son utilisation. Les données récupérées par les capteurs seront utilisées principalement pour l'estimation des états interne de la batterie (état de charge, état de santé et aussi la température interne, etc).

Les principales fonctions de BMS sont :

— Acquisition des données

— Gestion thermique ;

— Gestion de sécurité ;

— Gestion électrique ;

— Détermination de l'état de santé de la batterie ;

— Détermination de l'état de charge de la batterie ;

1.3 Les Microgrids

Dans cette partie, nous allons aborder le contexte d'application de notre système de gestion d'énergie de la batterie qui représente notre thème de recherche. En premier lieu, nous présenterons le concept d'un Microgrid, ses classifications, ensuite la gestion de

l'énergie au sein du microgrid.

1.3.1 Le concept de microgrids

Les microgrids ou bien les mini smart grids sont des petits systèmes d'alimentation électrique composés de charges électriques, de ressources énergétiques distribuées telles que des sources d'énergies renouvelables (panneaux photovoltaïques, mini éoliens, petite hydraulique) et des sources fossiles (micro turbines, piles à combustible, petits générateurs diesel), et de systèmes de stockage d'énergie comme illustré sur la Figure 1.13

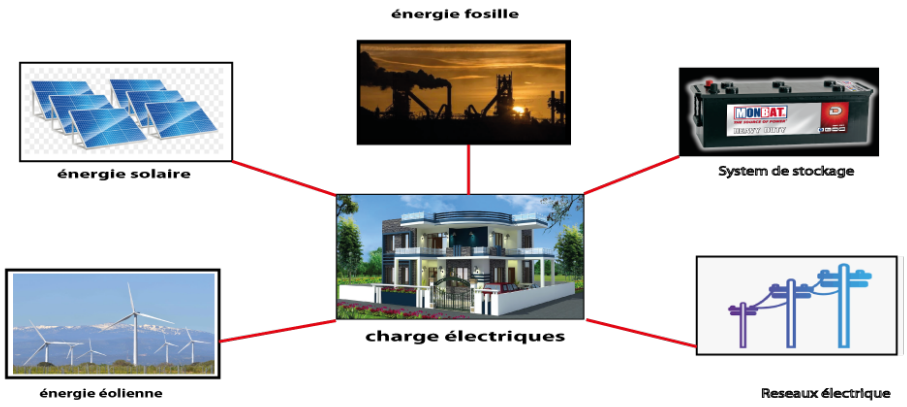


FIGURE 1.13 – Architecture générale d'un micro réseau intelligent multi sources

Le microgrid peut fonctionner en deux modes : mode isolé et mode connecté au réseau électrique. Pour le mode isolé, la production est nécessaire pour répondre à la demande de charges, par contre en mode connecté au réseau, la demande de charge peut être satisfaite à tout moment par le réseau électrique [27, 28].

1.3.2 Classification des microgrids

Les recherches sur les microgrids dans la littérature se concentrent principalement sur les microgrids de type DC et de type AC.

1.3.2.1 Microgrid de type AC

Les microgrids de type AC sont connectés au réseau électrique de distribution par l'intermédiaire d'un bus AC. La déconnexion du réseau de distribution se fait à travers le disjoncteur au Point de Couplage Commun (PCC), comme illustré sur la Figure 1.14. Toutes les unités de production distribuées qui produisent une puissance de sortie de type AC sont connectées directement avec le bus AC, c'est le cas des éoliennes et des biogaz. Tandis que les sources qui produisent une puissance DC sont connectées à l'aide d'un convertisseur DC/AC[29].

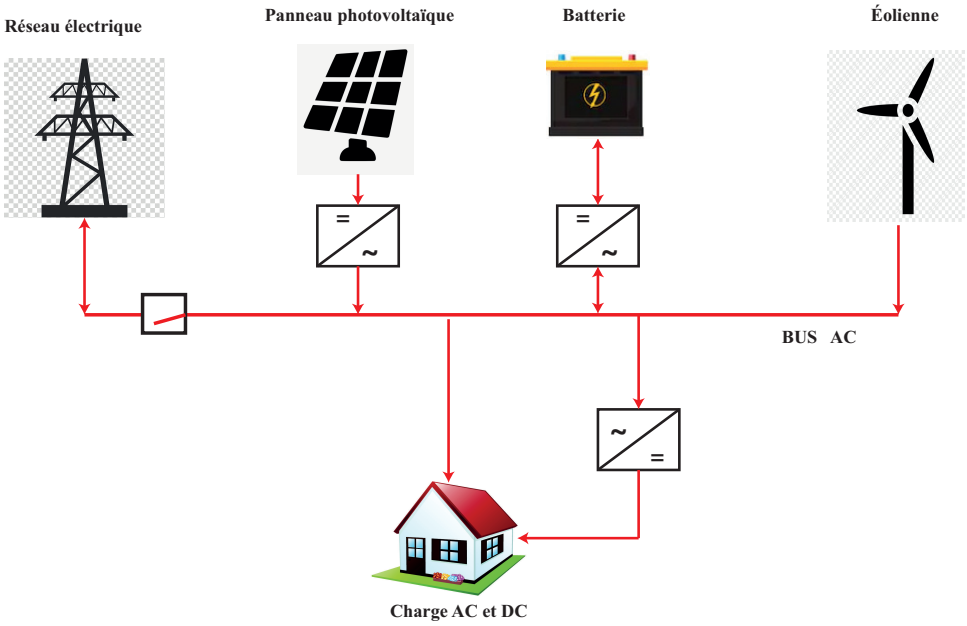


FIGURE 1.14 – Structure d'un microgrid de type AC

Le microgrid AC est un type dominant de microgrid en raison de la facilité de liaison avec le réseau électrique. Mais l'inconvénient majeur de ce type de microgrid est la

complexité de contrôle.

1.3.2.2 Microgrid de type DC

Le microgrid de type DC peut fonctionner soit en mode connecté au réseau principal, soit en mode isolé. Les composants constituant le microgrid DC sont tous reliés au bus DC comme illustré sur la Figure 1.15

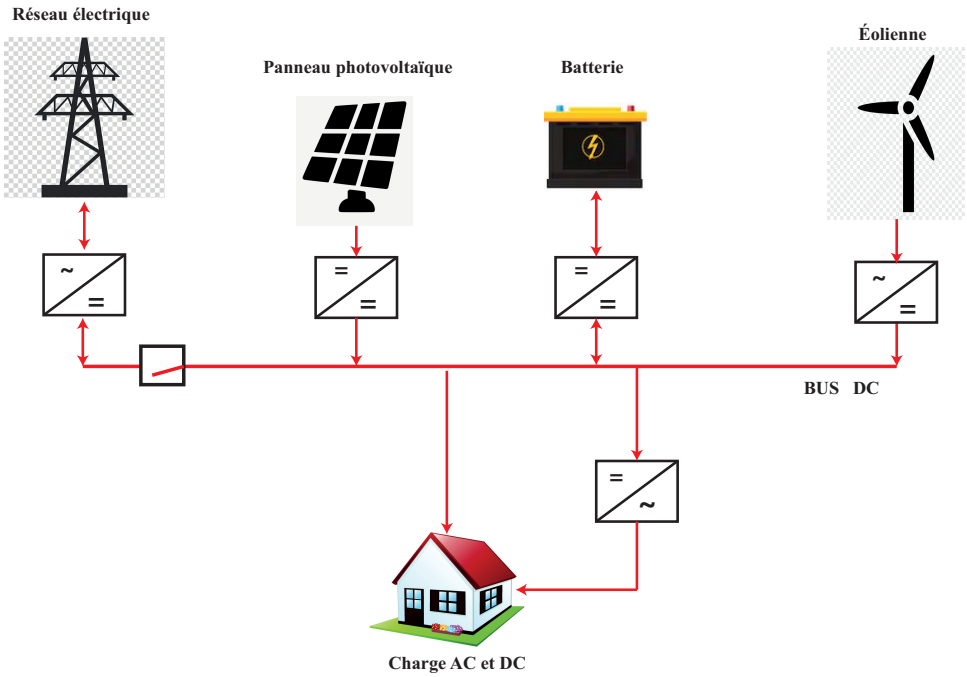


FIGURE 1.15 – Structure d'un microgrid de type DC

Le microgrid de type DC présente plusieurs avantages opérationnels. En effet, d'une part, la plupart des systèmes de production d'énergie utilisés dans un MG produisent une puissance de type DC, tels que des cellules photovoltaïques, des piles à combustible. . . etc, et d'autre part, les unités de stockage ont généralement une tension de sortie continue[30]. Donc la connexion avec le bus DC de microgrid est realisée uniquement par l'utilisation d'un régulateur de tension.

La plupart des charges électriques connectées au microgrid sont des charges classiques

de type DC, et ne nécessitent pas de multiples conversions des étages de puissance pour être connecté à un Microgrid DC. En plus, ces dernières n'utilisent pas de transformateurs, ce qui les rends plus efficaces, de plus de petite taille et fiables pour les systèmes DC.

Les microgrids hybrides

Un Microgrid hybride est constitué d'une combinaison de microgrid AC et DC. La plupart des convertisseurs de puissance utilisés dans les microgrids sont de type bidirectionnel. Les charges AC ou DC peuvent être alimentées sans avoir besoin d'une interface de conversion supplémentaire, ce qui augmente l'efficacité et la fiabilité du système. Ce dernier peut avoir besoin d'un algorithme de contrôle optimal pour assurer une performance stable.

1.3.3 La gestion d'énergie au sein de microgrid EMS

Un système de gestion de l'énergie (EMS) est défini comme un système d'information, qui fournit les fonctionnalités nécessaires lorsqu'il est pris en charge sur une plateforme, afin de garantir que la production, le transport et la distribution fournissent de l'énergie à un coût minimal[31]. La gestion de l'énergie dans un microgrid implique un système de contrôle qui permet d'avoir un fonctionnement optimal[32].

Les principales tâches pour la gestion de l'énergie au sien d'un microgrid sont : l'équilibre de puissance et de tension dans le bus de microgrid, en raison de la production instable de sources d'énergies renouvelables. Donc, un système de stockage d'énergie par batterie (BEES) jouera un rôle principal d'équilibre de la puissance dans le bus DC, en cas de besoin ou de surplus d'énergie.

Le système de stockage d'énergie par batterie représente une très bonne solution au problème d'intermittence des ressources d'énergie renouvelable. Généralement, le BESS est utilisé depuis longtemps dans les systèmes électriques, mais l'intégration des énergies renouvelables dans les microgrids et smart grids augmente la demande de BESS. La batterie de stockage d'énergie mondiale pour le marché des microgrids représentait 208,9

millions de dollars américains en 2019 est estimée à 556,1 millions de dollars américains d'ici 2029. Cette considération rend le BESS un élément essentiel des futurs microgrids. Le BESS peut être utilisé pour différents services et à différents niveaux de la chaîne du réseau électrique afin de relever les défis techniques et de fournir des avantages financiers.

Les BEES sont largement utilisés dans les MG dont l'objectif est de compenser le déséquilibre de puissance entre les sources d'alimentation et les charges. Pour atteindre cet objectif, les unités de stockage d'énergie sont chargées, d'une part d'absorber le surplus de puissance des sources d'énergie pendant les heures creuses, d'autre part, de fonctionner comme une source de secours dans le microgrid autonome en fournissant la puissance nécessaire pendant les heures de pointe de la forte demande. Comme le montre la Figure 1.16, le BESS se compose de trois éléments essentiels :

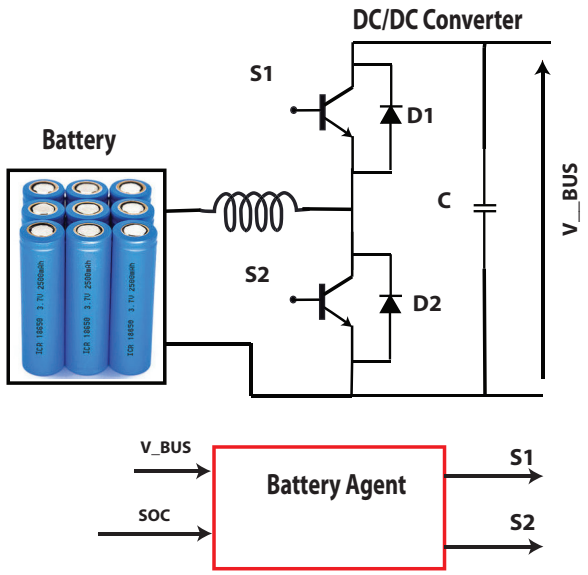


FIGURE 1.16 – Système de stockage d'énergie par batterie pour microgrid

Une batterie : c'est un assemblage de cellules électrochimiques montées en série et en parallèle.

BMS : c'est un système qui protège la batterie au cours de son utilisation.

Convertisseur DC / DC bidirectionnel : ce convertisseur est placé entre la batterie

et le bus de microgrid ce qui permet la circulation de la puissance de la batterie vers le bus DC ou inversement. Il représente le défi majeur d'intégration des batteries dans les microgrids à cause de la non linéarité de ce convertisseur, ce qui rend son contrôle difficile.

1.4 Théorie des réseaux de neurones artificiels

Les Réseaux de Neurones Artificiels RNA sont des systèmes informatiques, qui sont à l'origine des essais modélisant le cerveau humain d'une façon mathématique. Les premiers travaux datent de 1943 et sont l'oeuvre de MM. Mac Culloch et Pitts. Ce sont les premiers à proposer la notion de neurone formel et ils ont montré que les réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes [33]. L'idée principale des RNA est de donner à chaque objet, un neurone qui est capable de réaliser quelques calculs élémentaires. On associe ensuite entre les neurones pour d'obtenir un réseau de neurones.

1.4.1 Neurone biologique

Le neurone biologique est la cellule de base du cerveau humain, dont la fonction principale se situe dans le traitement de l'information. La Figure 1.17 illustre les éléments de base d'un neurone biologique. Ce dernier est composé d'un corps cellulaire dit Soma, de Dendrites, et d'Axones. Les dendrites représentent les pôles récepteurs par lesquels les cellules reçoivent les signaux provenant d'autres neurones à travers les synaps qui représentent la connexion entre les dendrites et les axons . Au niveau du soma, le neurone analyse et traite ces signaux en les sommant. Si le résultat obtenu est supérieur au seuil d'activation, il envoie une décharge alors nommée potentiel d'action le long de son axone vers d'autres neurones biologiques[34].

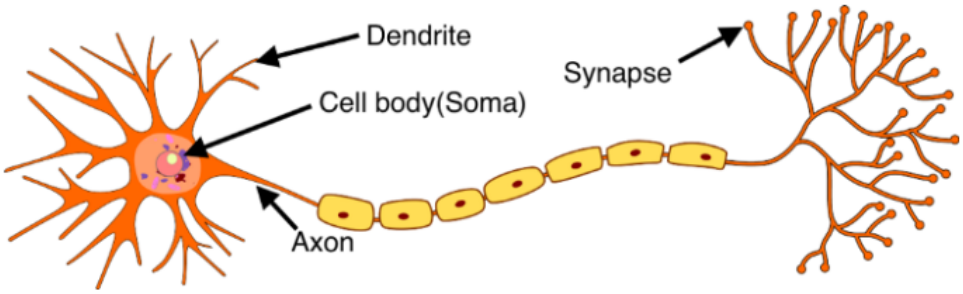


FIGURE 1.17 – Représentation d'un neurone biologique

1.4.2 Neurone formel

Un neurone formel est un élément élémentaire de traitement de l'information, il reçoit les entrées et produit un résultat à la sortie. La Figure 1.18 illustre la structure générale d'un neurone formel

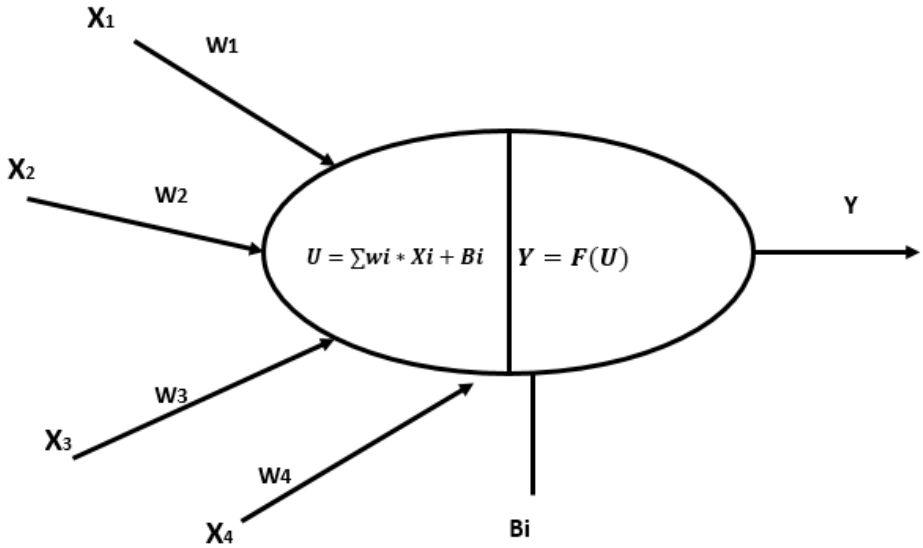


FIGURE 1.18 – Représentation d'un neurone formel

Avec :

Xi : les entrées de neurone ;

Wi : les poids de chaque entrée ;

Bi : le bias de neurone ;

F : la fonction d'activation ;

Chaque neurone formel a les fonctions principales suivantes [35] :

- Prendre les entrées de la couche d'entrée(Xi)

- Multiplier ces entrées séparément par les poids(Wi)

- Effectuer la somme de ces produits avec le bias (Bi)

- Passer cette somme à travers une fonction d'activation pour produire la sortie.

L'équation 1.7 présente le calcul effectué au niveau de neurone de la Figure 1.18 :

$$Y = F(X_1 * W_1 + X_2 * W_2 + X_3 * W_3 + X_4 * W_4 + B_1) \tag{1.7}$$

Avec

$X1, X2....X4$: les entrées de neurone

$B1$: le biais de neurone

$W1, W2.....W4$: les poids de connexion des entrées avec le neurone

1.4.3 Analogie entre neurone biologique et neurone formel

Un neurone formel est une modélisation mathématique et schématique d'un neurone biologique. La Figure 1.19 présente l'analogie entre le neurone biologique et formel.

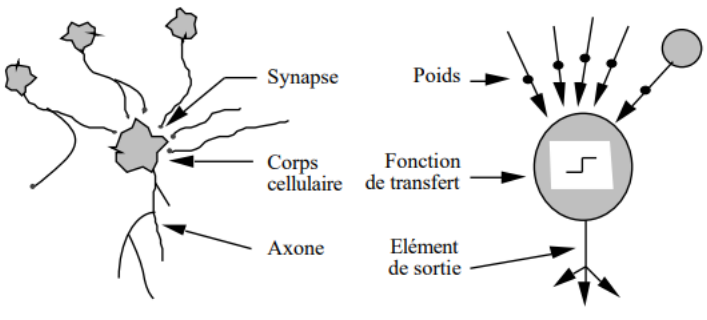


FIGURE 1.19 – Représentation d'analogie entre le neurone biologique/formel

On pourrait résumer l'analogie entre le neurone biologique et le neurone formel par les points suivants :

•Les Synapses sont modélisées par des poids ;

•Le Soma ou corps cellulaire est modélisé par la fonction de transfert, appelé aussi fonction d'activation ;

•Les Dendrites par les signaux d'entrées ;

•L'Axone par le signal de sortie ;

1.4.4 L'apprentissage des réseaux de neurones

L'apprentissage des réseaux de neurones se traduit par une modification de l'efficacité synaptique, c'est à dire par un changement dans les valeurs des poids qui relient les neurones d'une couche à l'autre, afin d'obtenir des valeurs optimales appropriées à ces poids. A la fin de cette opération, on obtient un système adapté au problème qu'on désire résoudre[36].

Généralement plusieurs algorithmes sont utilisés pour l'apprentissage, mais le plus utilisé est la rétro propagation de gradienne, qui un algorithme pour calculer le gradient de l'erreur pour chaque neurone d'un réseau de neurones, de la dernière couche vers la première de façon abusive[37].

Dans le domaine de l'intelligence artificielle, on distingue deux principaux types d'apprentissages : supervisé et non supervisé.

1.4.4.1 Apprentissage non supervisé

L'apprentissage non supervisé consiste à adapter les poids de réseau à partir d'une base d'apprentissage formée uniquement par des données d'entrées sans aucune information sur le résultat désiré. Dans ce cas, le réseau s'auto-organise de façon à optimiser une certaine fonction coût par la mise à jour des valeurs des poids et de biais, sans qu'on lui donne la réponse désirée. L'apprentissage consiste à déterminer les similarités et les

différences entre la base de données. L'avantage de ce type d'apprentissage réside dans sa grande capacité d'autoadaptation [38].

1.4.4.2 Apprentissage supervisé

On dit que l'apprentissage est supervisé lorsqu'on force le réseau de neurones à converger vers un état final connu à priori. Ce genre d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties comme illustrées sur la Figure 1.20.

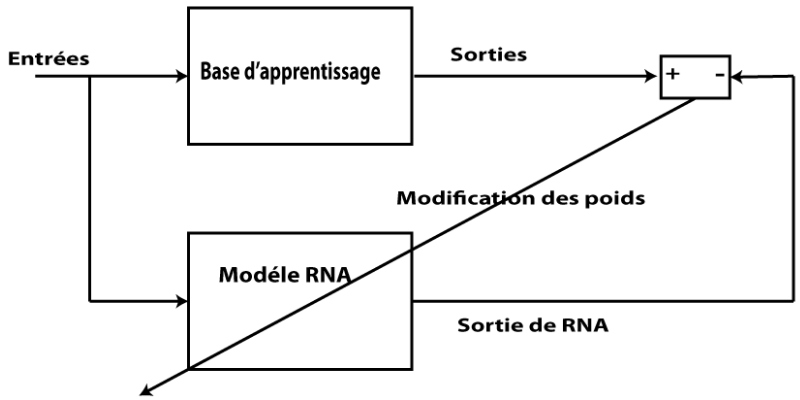


FIGURE 1.20 – Schéma bloc d'apprentissage supervisé

Ce type d'apprentissage est effectué de la façon suivante : on donne au modèle RNA les valeurs d'entrées et on calcule sa sortie actuelle correspondante, ensuite les poids sont ajustés de façon à réduire l'écart entre la réponse désirée et celle du réseau. Cette procédure est répétée itérativement jusqu'à l'obtention de résultats optimaux [39].

1.4.4.3 Algorithme d'apprentissage (Rétropropagation du gradient)

La rétropropagation de gradient, c'est l'algorithme le plus utilisé pour l'apprentissage des réseaux de neurones. Le principe de cet algorithme réside dans le calcul de gradient

de l'erreur pour chaque neurone du réseau de neurones, de la dernière couche vers la première [39].

L'algorithme fait la mise à jour des poids et de biais par la minimisation de l'écart entre les réponses réelles du réseau et ses réponses désirées par des méthodes d'optimisation non linéaire.

Donc, les différentes étapes à suivre durant l'entraînement d'un réseau de neurone avec l'algorithme de rétro propagation sont :

- Initialisation des poids par des valeurs aléatoires ;
- Application d'un vecteur entrées-sorties à apprendre ;
- Calcul des sorties du RNA à partir de vecteurs d'entrées appliquées et par la suite calcul de l'erreur entre la sortie de RNA et la sortie désirée ;
- Adaptation des valeurs des poids de liaison de la couche de sortie et la dernière couche cachée ;
- Propagation de l'erreur sur la couche précédente et correction des poids des liens entre les neurones de la couche cachée et ceux en entrée ;

1.5 Conclusion

Ce chapitre introduit le contexte général de notre thèse en s'appuyant sur les références bibliographiques. Dans un premier temps, nous dévoilons les systèmes de stockage d'énergie et spécifiquement les batteries au lithium, leur origine, principe de fonctionnement, les principaux challenges et le système de gestion de la batterie. Dans un second temps, nous présentons le concept d'un microgrid, ses types ainsi que le système de gestion de sa batterie.

Dans la dernière partie de ce chapitre, nous définissons la théorie des réseaux de neurones, leur origine, les réseaux de neurones artificiels et les algorithmes utilisés pour l'entrainement.

D'après cette étude bibliographique, nous avons trouvé plusieurs limitations liées à la sécurité de la batterie. Donc, notre travail consiste à proposer des solutions pour surmonter ces limitations et assurer la sécurité de la batterie durant son implémentation aux microgrids.

En utilisant l'approche importante d'intelligence artificielle, nous avons proposé un modèle de la batterie très proche au système réel. De même, nous avons estimé son état de charge.

Pour améliorer l'intégration de la batterie lithium dans les microgrids, nous avons proposé un contrôleur de réseau de neurones pour le convertisseur bidirectionnel qui connecte la batterie avec le microgrid, afin d'implémenter un système de gestion d'énergie.

CHAPITRE 2

MODÉLISATION DE LA BATTERIE LI-ION ET L'ESTIMATION DE L'ÉTAT DE CHARGE (SOC)

2.1 Introduction

Ce chapitre est consacré à un ensemble de travaux portant sur la modélisation et l'estimation de l'état de charge de la batterie.

Dans la première partie, nous présentons les grandes catégories de modélisation de la batterie. Par la suite, nous développons le modèle standard de la batterie, par intégration de l'effet de température dans ses paramètres internes. Ensuite, nous proposons un modèle boîte noire de la batterie qui prend en considération l'effet de température et d'état de charge. Ce modèle sera validé à l'aide de mesures réelles.

Finalement, nous présentons, les différentes méthodes d'estimation d'état de charge de la batterie, et en se basant sur le modèle boîte noire, un modèle hybride pour estimer l'état de charge sera détaillé.

2.2 Modélisation de la batterie au lithium

Les modèles de batteries les plus populaires dans la littérature sont généralement classés sous l'un des éléments suivants :

— Les modèles électrochimiques ;
— les modèles équivalents basés sur des circuits ;
— les modèles boîte noire ;

2.2.1 Modélisation électrochimique de la batterie

Les batteries au Li-ion sont des générateurs électrochimiques qui stockent l'énergie sous forme chimique et la restituent sous forme électrique. La cellule Li-ion est composée de deux électrodes (cathode et anodes), les deux électrodes séparées par un séparateur poreux permettent d'éviter le contact physique entre les deux électrodes, tout en laissant passer les ions porteurs de charges. Il s'agit donc d'une membrane perméable aux ions

et électriquement isolante[40]. Par conséquent, la modélisation électrochimique des batteries lithium présente un certain nombre de paramètres et de concepts qui permettent de comprendre le principe de fonctionnement de la batterie :

— Les modèles électrochimiques prennent en compte les phénomènes physiques et chimiques à l'intérieur de la cellule. Les modèles les plus cités dans le domaine de la modélisation électrochimique des batteries sont les Modèles de Marc Doyle et Thomas Fuller sous l'encadrement de John Newman [41, 42]. Ce type de modélisation combine le comportement chimique et physique, et offre également de très bonnes prédictions pour optimiser la conception de la batterie [43].

— La modélisation électrochimique représente généralement la modélisation des phé nomènes de masse, d'énergie et de transport dynamique de chaque espèce pour chaque phase et chaque composant de la cellule [43]. En raison de la structure composite des électrodes, les équations de transport sont souvent utilisées.

— La modélisation électrochimique prédit les changements des quantités macroscopiques comme la tension et le courant de la cellule Li-ion. Elle détermine aussi à une échelle microscopique la distribution locale en concentration, potentiel, courant et température à l'intérieur de la cellule. Cette modélisation nécessite l'acquisition des paramètres concernant la géométrie des électrodes, la concentration de l'électrolyte, le coefficient de diffusion, le coefficient de transfert, la constante de réaction... [44]

2.2.2 Modélisation circuits équivalents

Les modèles basés sur des circuits équivalents utilisent des composants simples tels que des résistances et des capacités pour modéliser le comportement de charge et de décharge des batteries Li-ion. Les modèles basés sur des circuits équivalents sont divisés en 7 catégories :

— Le modèle simple ;

— Le modèle résistif de Thevenin ;

— Le modèle de Thevenin ;

— Le modèle de Thevenin modifié ;

— Le modèle de double polarisation ;

— Le Modèle de batterie de (CHEN AND MORA) ;

— Le modèle générique de la batterie ;

2.2.2.1 Le modèle simple de la batterie

Le modèle le plus simple de la batterie se compose d'une résistance interne constante R_0 qui modélise l'électrolyte entre les électrodes de la batterie en série avec une tension de circuit ouvert idéal fixe V_0 (Figure 2.1) [44].

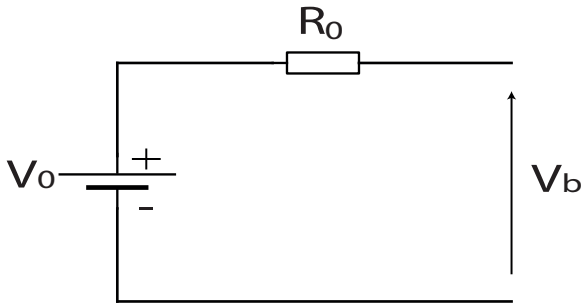


FIGURE 2.1 – Circuit électrique équivalent de modèle simple

Ce modèle représente la partie énergétique de la batterie[45], mais le comportement transitoire n'a pas été étudié. Par conséquent, ce modèle est inadapté à la précision de l'état de la batterie. Il a été développé par (Matthias D¨urr et HL Chan) [46, 47].

2.2.2.2 Le modèle résistif de Thevenin

Le modèle résistif de Thevenin illustré sur la Figure 2.2 se compose d'une source de tension V_0 et deux résistances : R_C est la résistance charge et R_d la résistance de décharge. Ce modèle suppose que :

— Les électrodes sont en matériaux poreux ;

— La résistance électrolytique est constante tout au long de la décharge ;

— La décharge se produit à courant constant ;

— La polarisation est une fonction linéaire du matériau actif ;

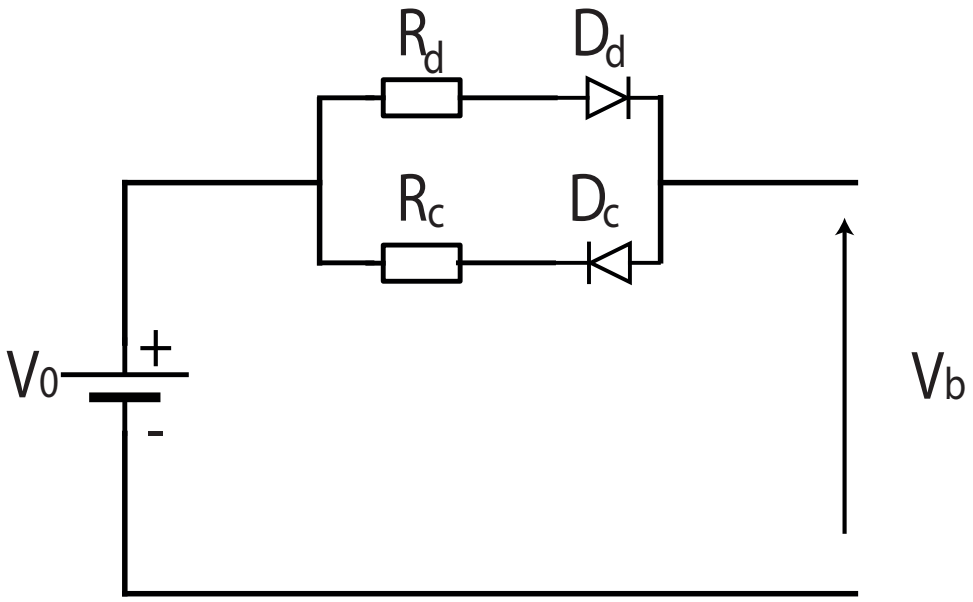


FIGURE 2.2 – Modèle résistif de Thevenin

Ce modèle est meilleur que le modèle simple car il modélise plus de phénomènes électrochimiques, mais il ne tient pas compte du comportement transitoire qui se produit dans la batterie [48].

2.2.2.3 Le modèle de Thevenin

Le modèle de Thevenin de la batterie prend la forme d'un arrangement série parallèle d'éléments à résistance et condensateur de valeurs constantes. Parmi les modèles de Thevenin qui existent dans la littérature, une des structures la plus utilisée est celle illustrée par la Figure 2.3.

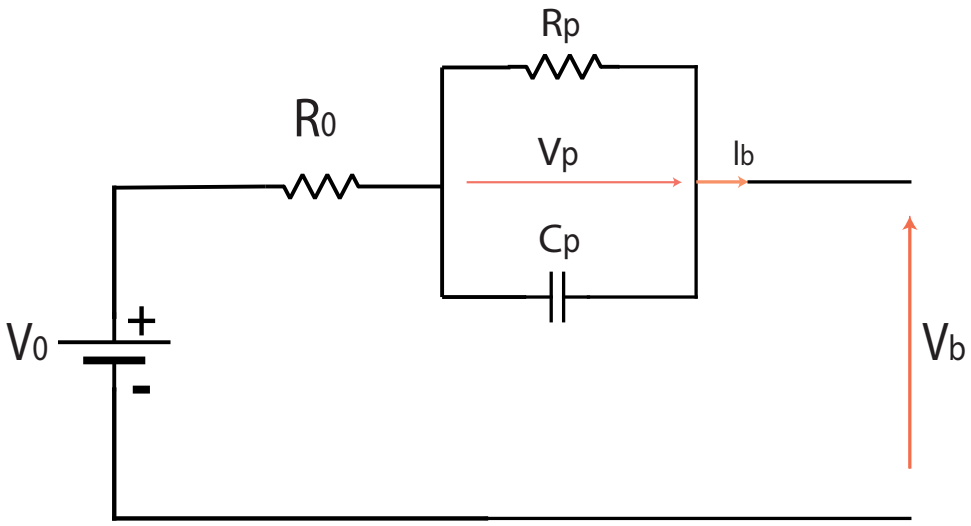


FIGURE 2.3 – Schéma électrique du modèle de Thevenin

Ce modèle est principalement composé de trois parties comprenant la tension en circuit ouvert V_0, la résistance ohmique R_0 qui modélise l'électrolyte entre les électrodes de la batterie et la branche R_pC_p parallèle, utilisée pour modéliser l'effet de polarisation de la batterie[49].

Le principal inconvénient de ce modèle est que toutes les valeurs des paramètres(V_0,R_p,C_p) sont supposées constantes[50].

2.2.2.4 Le modèle de double polarisation

Le phénomène de polarisation est modelisé par une seule branche RC (le cas de Thevenin), mais il devient moins précis à la fin de la charge ou de la décharge. Un modèle de circuit amélioré est défini comme un modèle à double polarisation comme le montre la Figure 2.4. Ce modèle améliore les caractéristiques de polarisation en simulant séparément les effets de concentration et de polarisation électrochimique[48] [51].

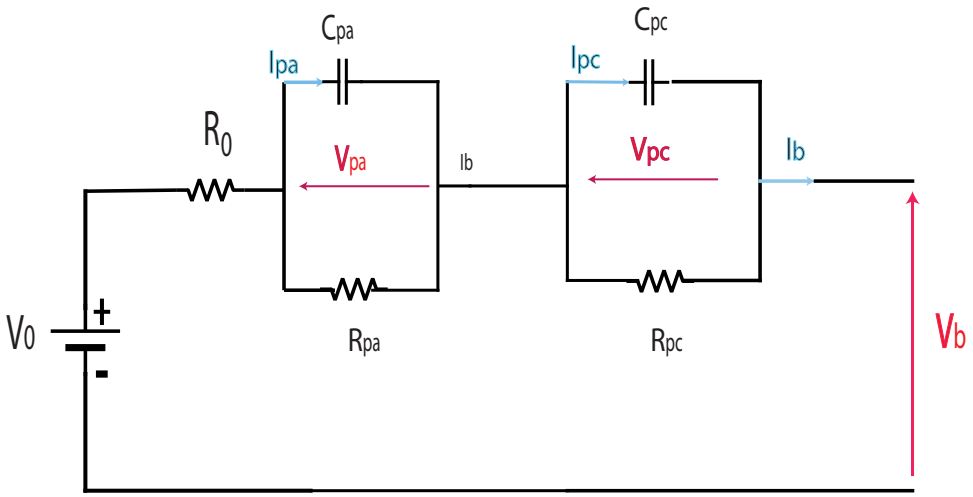


FIGURE 2.4 – Circuit électrique de modèle de double polarisation

Les résistances R_{pa} et R_{pc} représentent respectivement la polarisation électrochimique et la polarisation de concentration. Les condensateurs de capacité C_{pa} et C_{pc} caractérisent la réponse transitoire pendant le transfert de puissance pour la polarisation électrochimique et la concentration respectivement. Tous les paramètres de modèle sont supposés constants et ne tiennent pas en compte l'effet de température et de l'état de charge.

2.2.2.5 Le Modèle de batterie de (CHEN AND MORA)

Le modèle de Chen and Mora [52], illustré sur la Figure 2.5, est une combinaison de deux circuits couplés capable de prédir toutes les propriétés importantes des batteries électrochimiques. L'avantage de ce modèle est son comptabilité avec un large type de batteries (plomb, NiCd, NiMH, L2on, Li-ion polymère et autres batteries électrochimiques).

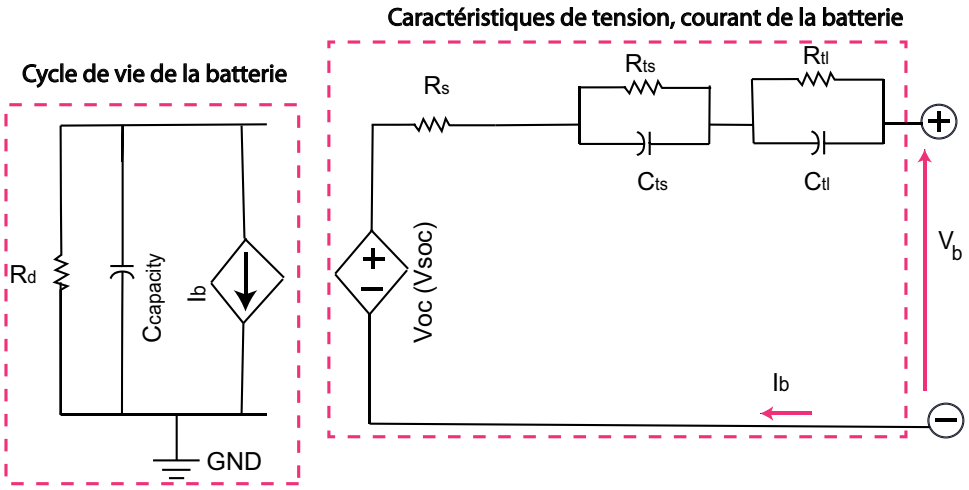


FIGURE 2.5 – Modèle de Chen et Mora pour la batterie

Avec $C_{capaicty}$ est la capacité de la batterie, I_b est le courant de la batterie, V_b est la tension de la batterie et R_d est la résistance d'autodécharge, elle est utilisée pour caractériser la perte d'énergie lorsque la batterie stocke l'énergie pendant une longue période. La résistance série R_s est responsable de la chute de tension dans les zones exponentielles de décharge. Les R_{ts}, C_{ts}, R_{tl} et C_{tl} sont responsables du comportement transitoire. R_{ts}, C_{ts} pour de courtes durées et R_{tl}, C_{tl} pour de longues durées.

Ce modèle offre aux concepteurs de circuits et de systèmes la possibilité d'améliorer l'efficacité du système et de prolonger l'autonomie de la batterie pour l'électronique portable. Mais l'inconvénient de ce modèle est la grand degré de complexité et la difficulté d'implémentation en un seul logiciel.

2.2.2.6 Le modèle générique de la batterie

Le modèle genérique, illustré sur la Figure 2.6 est proposé par C.M. Shepherd [53]. Il est basé sur une équation qui donne une excellente description d'une grande variété de décharges de cellules et de batteries. Les paramètres de cette équation sont calculés à partir d'un certain nombre de points discrétisés d'une courbe d'un manufacturier.

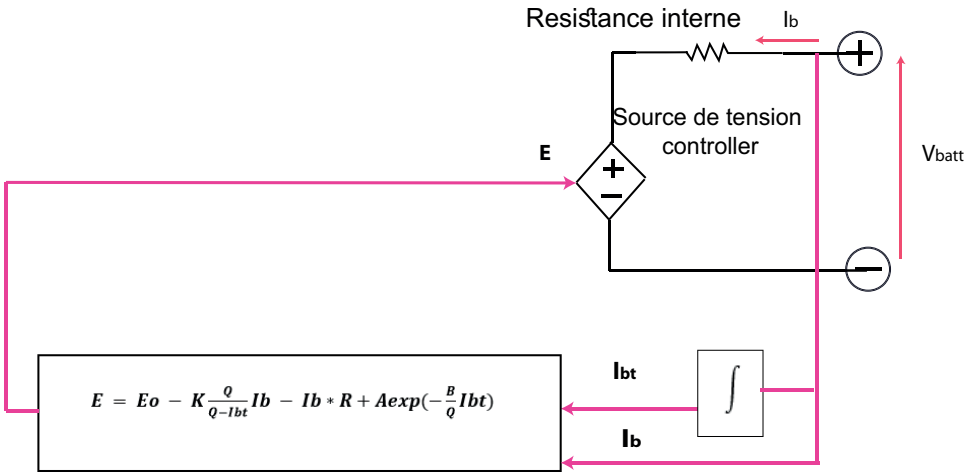


FIGURE 2.6 – Modèle générique de la batterie.

La tension en circuit ouvert aux bornes de la batterie dans ce modèle est exprimée par l'équation 2.1 :

$$E = E_0 - K\frac{Q}{Q - I_{bt}}I_b - I_bR + Aexp(\frac{-B}{Q}I_{bt}) \tag{2.1}$$

Où E_0, K, Q, R, A et B représentent des paramètres constants déterminés graphiquement à partir de la courbe de décharge de la batterie, ce qui nécessite plusieurs points de la courbe de décharge du fabricant . Shepherd utilise deux courbes de décharge pour déterminer les six paramètres [53].

Le modèle générique est largement utilisé et développé par plusieurs chercheurs dans la littérature surtout dans les travaux d'Olivier Tremblay [54, 55]. C'est le modèle implémenté sur Matlab/Simulink, et pour cette raison, il représente le modèle standard des batteries dans la littérature. Cependant, ce modèle ne prend pas en compte l'effet de l'état de charge et de température sur son comportement. Par conséquent, toutes nos contributions à la modélisation sont focalisées sur le développement de ce modèle.

2.2.3 Développement de modèle standard de la batterie lithium en utilisant les réseaux de neurones artificiels

Plusieurs modèles ont été développés pour décrire le comportement de la batterie Li-ion pendant ces deux modes de fonctionnement(charge et décharge). Cependant, la plupart de ces modèles ne prennent pas en compte l'effet de température sur le comportement de la batterie. Donc, notre contribution [56], consiste à développer le modèle générique de la batterie en intégrant l'effet de température dans les paramètres internes de ce modèle par l'utilisation des Réseaux de Neurones Artificials (RNA).

L'intérêt de ce modèle est la possibilité d'étudier le comportement de cette batterie et d'améliorer son cycle de vie. Le modèle est simple et peut-être implémenté dans n'importe quelle application.

Les résultats de la simulation [56], montrent que la modélisation de la température de la batterie est importante pour examiner la nature du courant et de la tension de la batterie dans différentes conditions.

2.2.3.1 La base de données expérimentales utilisée

Les données expérimentales des batteries Li-ion sont une collection d'ensembles de données publiques provenant de Prognostics Co de la National Aeronautics and Space Administration (NASA) des états-Unis [57]. La Figure 2.7 présente le protocole expérimental utilisé durant la collection de la base de données.

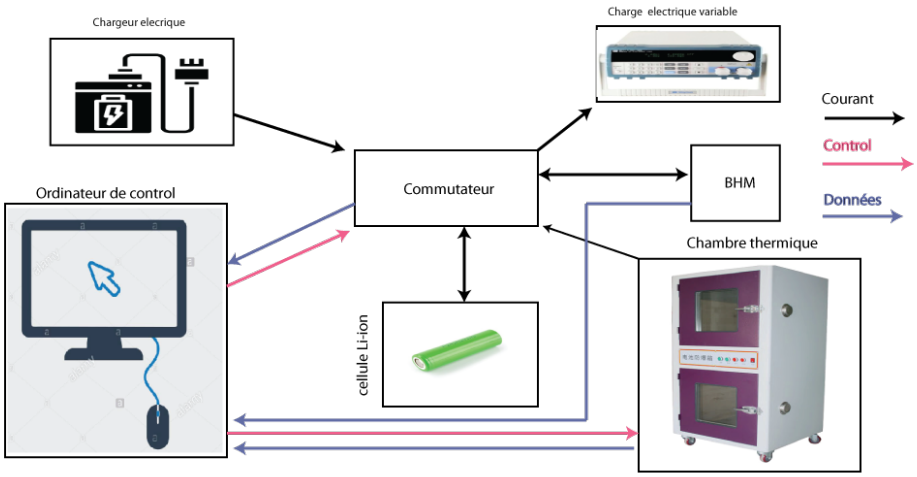


FIGURE 2.7 – Protocole expérimental des tests de la batterie

Les Figures 2.19, 2.20, 2.21, 2.11 illustrent la base de données utilisée (courant, tension, température et la résistance interne) pour la conception de notre modèle.

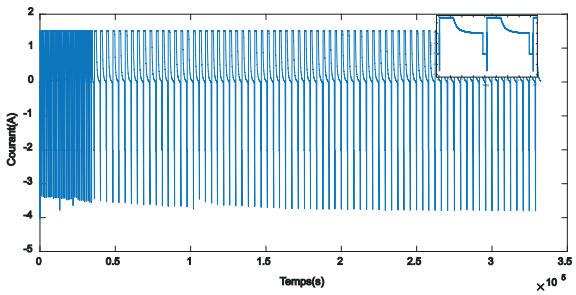


FIGURE 2.8 – Courant de la batterie

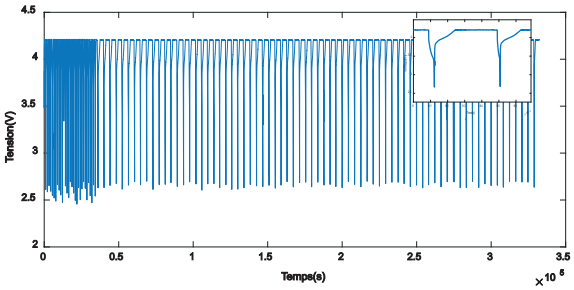


FIGURE 2.9 – Tension de la batterie

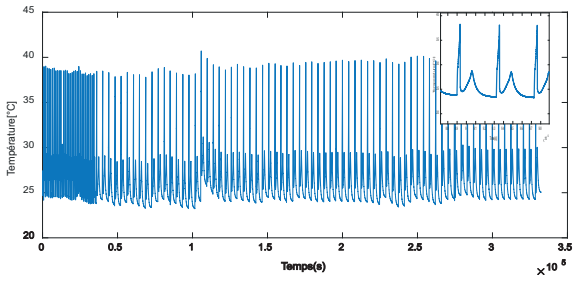


FIGURE 2.10 – Température de la batterie

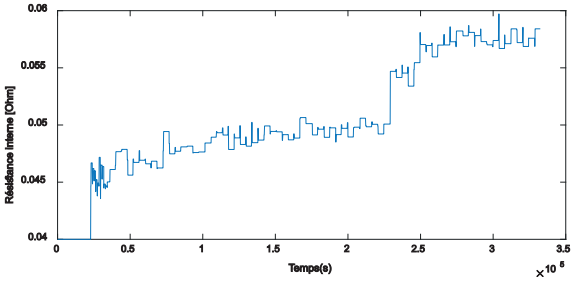


FIGURE 2.11 – Résistance interne

2.2.3.2 Description du système proposé

Le nouveau circuit équivalent de la batterie est composé également d'une résistance interne et d'une source de tension V_{oc}. Toutefois, ces paramètres sont estimés par deux réseaux de neurones. Afin d'intégrer les paramètres estimés dans les composants du modèle, nous avons créé de nouveaux composants personnalisés à travers l'extension Simscape de Matlab/Simulink $VC0(T,I,V)$ et $R_s(T,I,V)$. Chaque bloc contient trois ports : deux ports pour la connexion électrique et le troisieme pour intégrer la valeur estimée de chaque paramètre comme illustré sur la Figure 2.12.

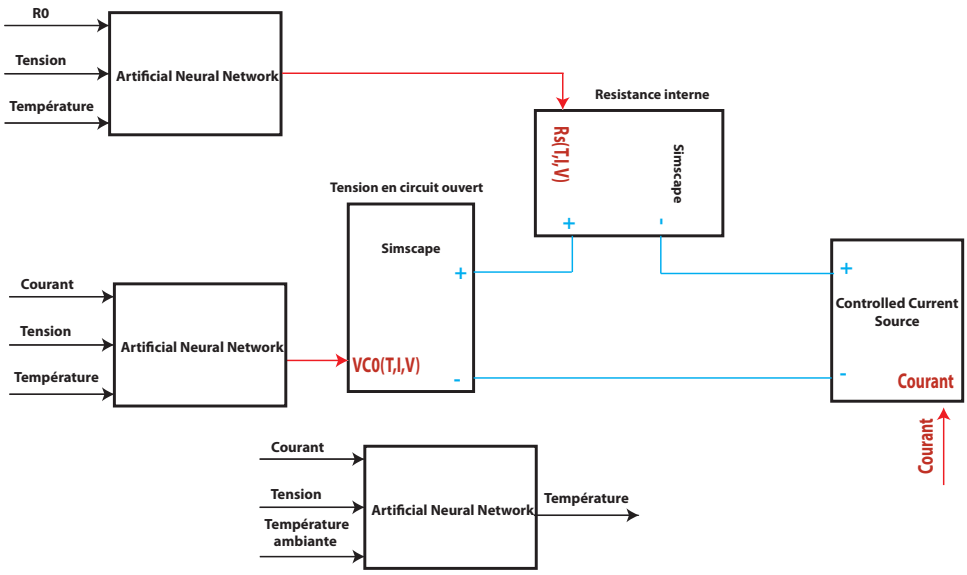


FIGURE 2.12 – Système proposé pour la modélisation de la batterie

Le modèle proposé est composé de trois réseaux de neurones :

Le premier réseau de neurones pour l'estimation de température surfacique de la batterie. Les entrées de ce modèle sont : la tension, le courant et la température ambiante, et la sortie est la température surfacique de la batterie.

Le deuxième réseau de neurones pour l'estimation de la résistance interne de la batterie. Les entrées de ce modèle sont la tension, le courant et la résistance interne initiale, et la sortie est la résistance interne $R_s(t)$.

Le troisième réseau de neurones pour l'estimation de tension V_{oc}. Les entrées de ce modèle sont la tension, le courant, et la température surfacique de la batterie, et la sortie est la tension $V_{oc}(t)$.

Les trois réseaux de neurones utilisés dans ce travail, sont de type Nonlinear AutoRegressive network with eXogenous inputs (NARX) (Figure 2.13).

Ce réseau utilise des délais pour stocker les valeurs précédentes de l'entrée U (k) et sortie Y(k).

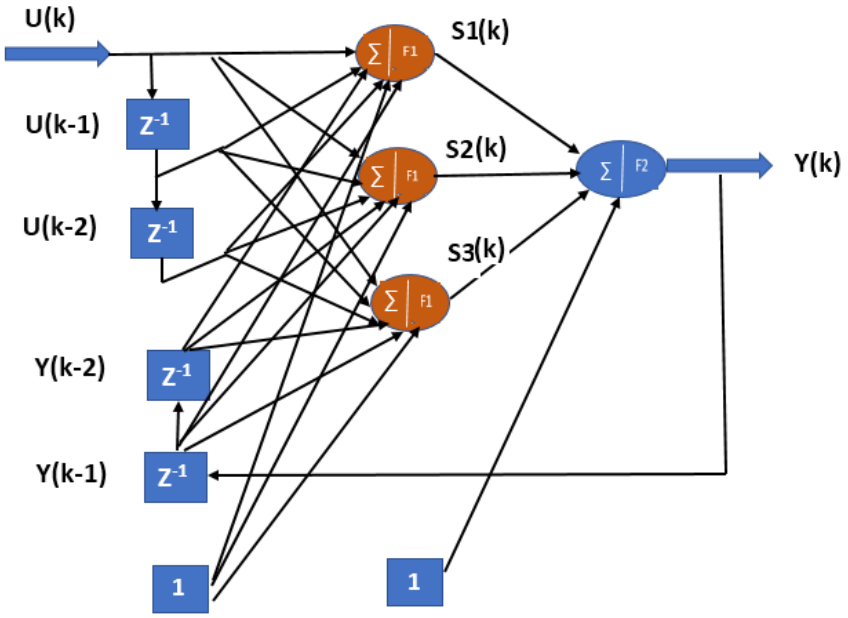


FIGURE 2.13 – Modèle NARX

À partir du modèle de la Figure 2.13, nous pouvons obtenir la relation de la sortie

Y(k) en fonction de l'entrée U (k) et les sorties précédentes Y (k-1) ; Y (k-2) :

$$\begin{aligned} S_1(k) &= F_1(U(k)*w_{11}+U(k-1)*w_{12}+U(k-2)*w_{13} \\ &\quad +Y(k-1)*w_{14}+Y(k-2)*w_{15}+b_1) \\ S_2(k) &= F_1(U(k)*w_{21}+U(k-1)*w_{22}+U(k-2)*w_{23} \\ &\quad +Y(k-1)*w_{24}+Y(k-2)*w_{25}+b_2) \\ S_3(k) &= F_1(U(k)*w_{31}+U(k-1)*w_{32}+U(k-2)*w_{33} \\ &\quad +Y(k-1)*w_{34}+Y(k-2)*w_{35}+b_3) \\ Y(k) &= F_2(S_1(k)*w_{41}+S_2(k)*w_{42}+S_3*w_{43}+b_4) \end{aligned} \tag{2.2}$$

Les variables (S_1,S_2, S_3) sont les sorties de couche cachées, F_1 (tangente hyperbolique) est la fonction d'activation de la couche cachée et F_2 (fonction linéaire) est la fonction d'activation de la couche de sortie. Les vecteurs W_{ij} et b_i sont les poids et le biais obtenus après l'étape d'apprentissage de réseau de neurones.

2.2.3.3 Simulation et discussion des résultats

La simulation de notre modèle est divisé en deux parties : la première partie de la simulation est dédiée à l'estimation de la température surfacique et aux paramètres internes de la batterie, en utilisant les trois réseaux de neurones de modèle précèdent.

Les résultats de simulation suivants présentent les sorties de chaque réseau de neurones.

La Figure 2.14 présente la comparaison de la température surfacique mesurée expérimentalement et celle estimée par le premier réseau de neurones.

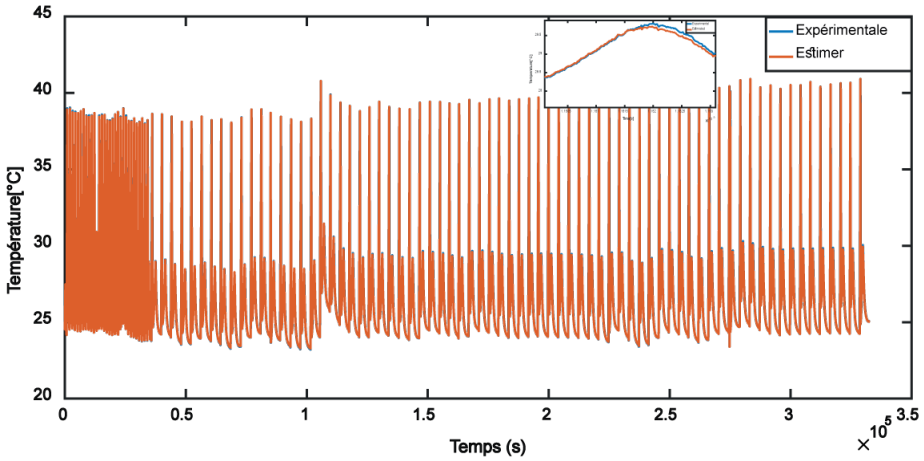


FIGURE 2.14 – Comparaison entre la température estimée et celle mesurée

La Figure 2.15 présente la comparaison de la résistance interne mesurée expérimentalement et celle estimée par le deuxième réseau de neurones.

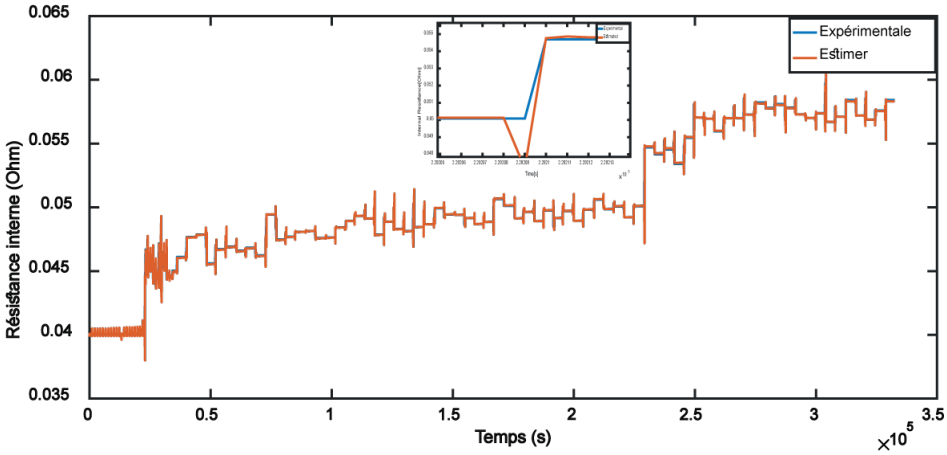


FIGURE 2.15 – Comparaison entre la résistance interne estimée et mesurée

La Figure 2.16 présente la comparaison de la tension en circuit ouvert mesurée expérimentalement et celle estimée par le troisième réseau de neurones.

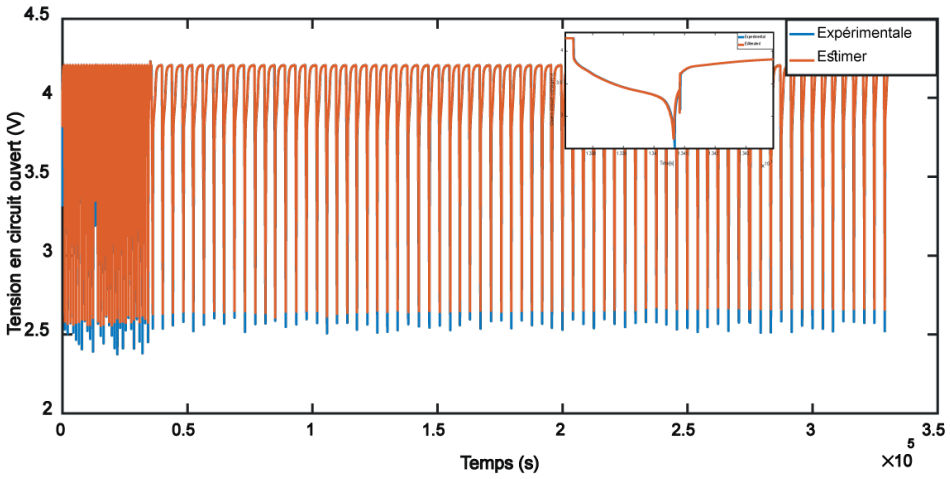


FIGURE 2.16 – Comparaison entre la tension en circuit ouvert estimée et calculée durant les tests expérimentaux

D'après les résultats de simulation, on constate que les paramètres de la batterie estimés par les trois réseaux de neurones sont très proches des paramètres expérimentaux, avec une erreur moyenne de 1%. Ce qui montre l'efficacité des réseaux de neurones dans l'estimation de ces paramètres.

La deuxième partie de simulation est dédiée à l'implémentation des paramètres estimés précédemment par chaque réseau de neurones dans le modèle proposé de la batterie (voir Figure 2.12).

La Figure 2.17 montre la comparaison entre les valeurs de la tension de la batterie mesurée expérimentalement et la tension de la batterie mesurée par le modèle proposé après la simulation sous Matlab Simulink.

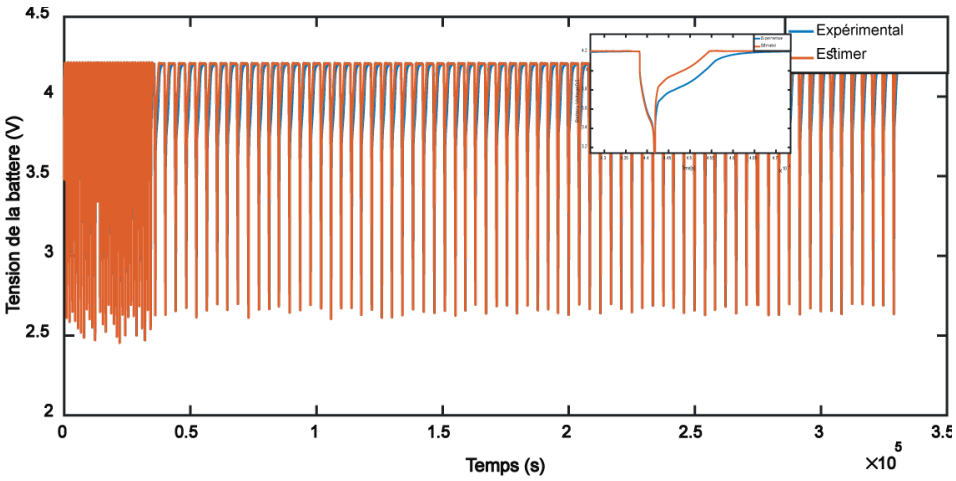


FIGURE 2.17 – Comparaison entre la tension du modèle proposé et la tension mesurée expérimentalement

D'après la comparaison des résultats de la Figure 2.17, on constate que les résultats de notre modèle sont identiques aux données expérimentales. Ce qui montre l'efficacité de la technique utilisée pour l'estimation des paramètres internes de la batterie.

Dans ce modèle[56], nous avons développé le modèle standard de la batterie par l'intégration de l'effet de température dans ces paramètres internes.

D'après les résultats de simulation, on remarque que les valeurs des paramètres estimées sont très proches des valeurs expérimentales, avec une erreur moyenne de 1%. De même, on constate que pour la courbe de tension de la batterie représentant la sortie de notre modèle converge rapidement vers la valeur expérimentale avec une erreur moyenne de 5% par rapport aux données expérimentales. Ces résultats confirment l'efficacité et la robustesse de notre modèle .

Malgré cette efficacité, ce modèle ne prend pas en considération l'effet de l'état de charge sur son comportement. Pour cette raison, dans la section suivante, nous proposons un autre modèle de type boîte noire, qui prend en considération l'effet de l'état de charge et de température.

2.2.4 Modélisation boîte noire de la batterie lithium

La modélisation boîte noire de la batterie cherche à reproduire le comportement interne de la batterie en se basant uniquement sur les mesures des données notamment : courant, tension et température[58].

Dans notre travail [59], nous allons proposé un nouveau modèle pour la batterie au lithium de type boîte noire comme illustré sur la Figure 2.18. Ce modèle prend en considération l'effet de la température de la cellule et l'état de charge de la batterie, ce qui nous donne un modèle très proche de la réalité. Le modèle boîte noire proposé, est conçu à l'aide d'un réseau de neuronnes récurrent de type NARX sur Matlab / Simulink et testé pour une cellule LiFePo4.

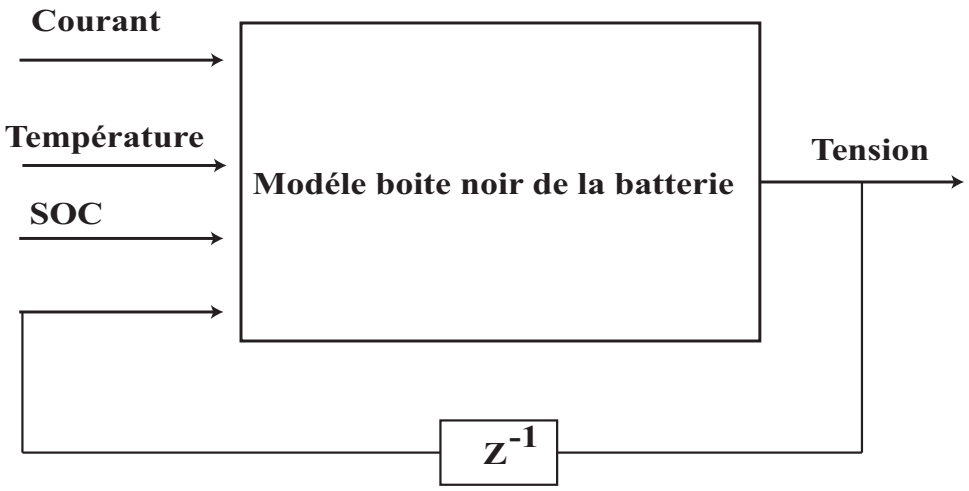


FIGURE 2.18 – Modèle boîte noire de la batterie

2.2.4.1 La base de données expérimentales utilisée

La base de données d'apprentissage utilisée dans cette contribution est collectée à l'aide d'un profil de test de contrainte dynamique (DST) avec une plage de température entre 10 °C et 50 °C à un intervalle de 10 °C comme il est spécifié dans les procédures de test des US Advanced Battery Consortium (USABC)[60].

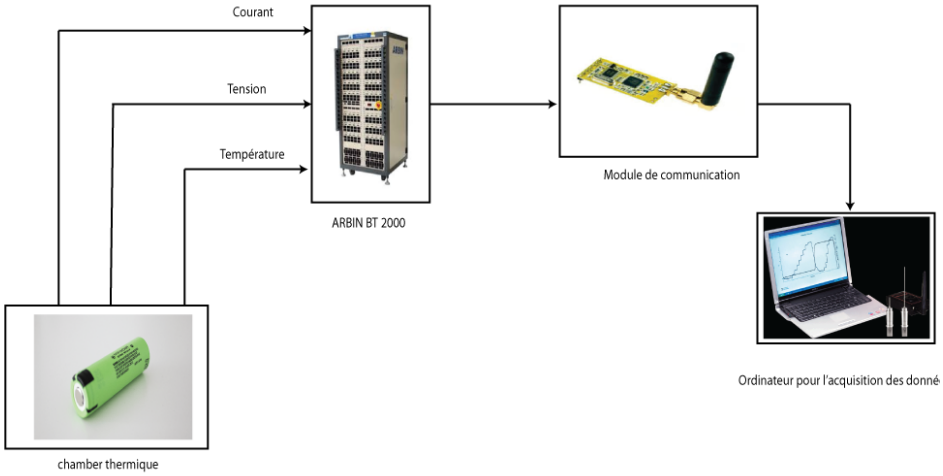


FIGURE 2.19 – Protocole expérimental des tests de batterie

Les Figures 2.20, 2.21, 2.22 illustrent les courbes de variation des données des grandeurs utilisées pour l'apprentissage (courant, tension, et la température) de la cellule à une température ambiante de 30 °C.

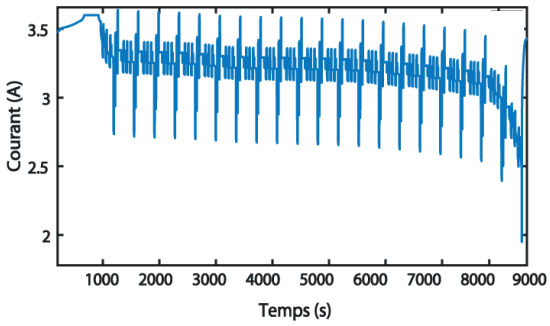


FIGURE 2.20 – Variation de courant

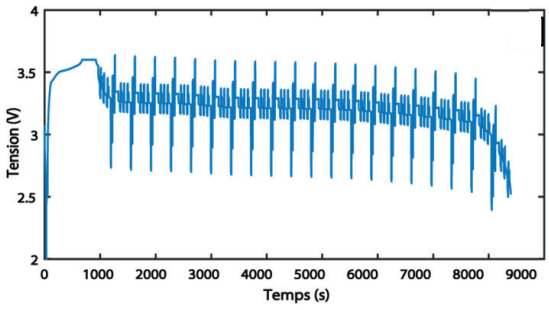


FIGURE 2.21 – Variation de Tension

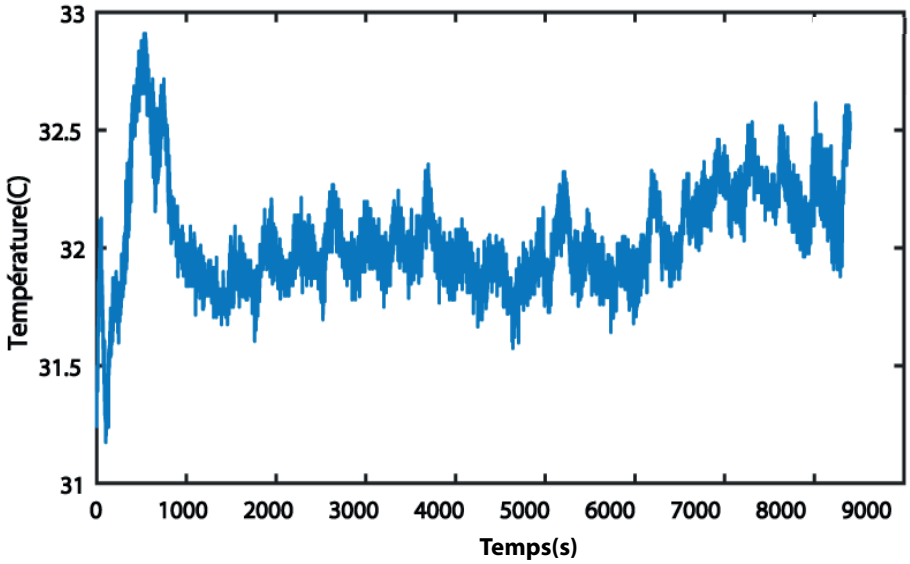


FIGURE 2.22 – Variation de température de la batterie

Les courbes précédentes représentent la variation des données de grandeurs caractéristiques de la batterie durant un cycle de décharge, ces données seront utilisées pour la conception de notre modèle de la batterie.

La normalisation des données, c'est à dire mettre toutes les données des entrées et de sorties dans l'intervalle [-1,1], rend l'apprentissage de réseaux de neurones plus efficace et robuste [61]. Par conséquent, avant l'entraînement, les entrées doivent être normalisées dans la plage [-1,1] à l'aide de l'équation 2.3 [62].

$$X_n = 2\frac{X - X_{min}}{X_{max} - X_{min}} - 1 \tag{2.3}$$

Avec, X_{min} et X_{max} représentent le minimum et le maximum respectivement du vecteur d'entrée X du RNA. Dans l'étape de test, les données de test sont normalisées en utilisant les mêmes Xmin et Xmax utilisés dans les données d'apprentissage. Après la construction de la base de données, une séparation de la base de données en deux bases : Base d'apprentissage et base de validation. Généralement, il n'y a pas de règle précise concernant

cette séparation, mais de manière générale, la base de validation représente 10 à 25% de la base générale. Après la séparation de la base de données, il faudra définir l'architecture du réseau de neurones. Nous utilisons le modèle NARX formé par l'algorithme d'apprentissage de rétro propagation de gradienne, grâce à sa capacité à résoudre des problèmes non linéaires [62, 63, 64]. Le risque de sur-apprentissage ou le sous-apprentissage existe durant l'apprentissage de RNA. Par conséquent, l'optimisation est une phase primaire dans la conception du réseau de neurones. L'objectif principal durant la phase d'optimisation est de trouver le nombre de couches cachées et celui des neurones pour chaque couche. L'algorithm de la Figure 2.23 montre le processus suivi durant la phase d'optimisation.

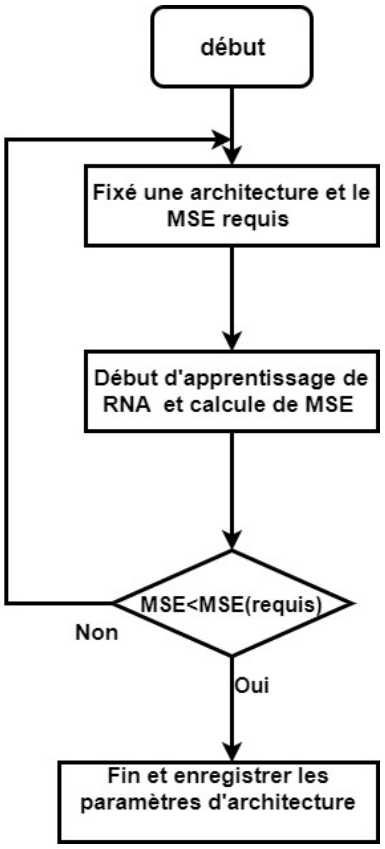


FIGURE 2.23 – Algorithme suivi durant l'optimisation de RNA

L'étape d'optimisation a pour objectif de trouver l'architecture optimale de RNA.

Nous avons effectué plusieurs tests pour trouver le nombre optimal de couches cachées et le nombre de neurones par couche. Ensuite, nous avons mesuré les performances de notre RNA en utilisant l'Erreur Quadratique Moyenne (MSE). Les résultats des performances des réseaux de neurones durant le processus d'optimisation sont présentés dans le Tableau 2.1.

TABLEAU 2.1 – Résultats d'optimisation de RNA

Architecture de RNA	**La performance (MSE)**	**Erreur maximale durant la validation**
[5,5]	1.564e-01	56%
[8,8]	6.954e-03	23%
[10,10]	2.2249e-04	10%
[12,12]	2.212e-04	12%
[12,14]	2.18749e-04	13.2%

Le tableau 2.1, présente quelques résultats des tests effectués durant la phase d'optimisation. D'après ces résultats, on remarque que l'erreur maximale diminue avec chaque augmentation de nombre de neurones, (c'est le cas de sous-apprentissage). Mais à partir de l'architecture [10 10], l'erreur maximale commence à augmenter (le cas de sur-apprentissage). Alors, l'architecture optimale est celle entre sous et sur apprentissage ([10 10]).

2.2.4.2 Description du modèle proposé

Nous avons considéré la batterie comme une boîte noire, avec le courant, la température, le SOC et les valeurs de la tension précédentes, représentent les entrées de cette boîte noire et la tension instantanée de la batterie, représente sa sortie. Le réseau de neurones récurrent de type NARX a été utilisé pour modéliser l'équation entre les entrées et la sortie (Figure 2.24).

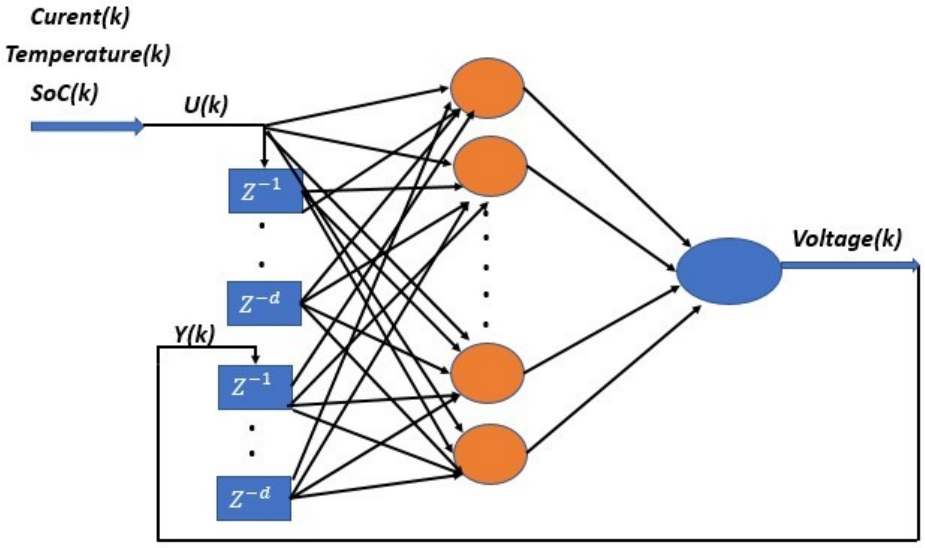


FIGURE 2.24 – Modèle proposé de batterie

À partir de ce modèle, nous pouvons obtenir la relation de la sortie $Y(k)$ en fonction de l'entrée $U(k)$ et de la sortie précédente $Y(k-1)$, $Y(k-2)$... comme le montre l'équation2.4 :

$$Y(k) = F(U(k), U(k-1)..., U(k-d), Y(k-1), ...Y(k-d)) \tag{2.4}$$

La fonction d'activation F utilisée dans ce modèle est (sigmoid function) donnée par l'équation 2.5, qui est souvent utilisée dans la couche cachée avec la fonction de transfert linéaire dans la couche de sortie.

$$F(u) = \frac{2}{1 + exp(-2.u)} - 1 \tag{2.5}$$

Tous les paramètres de RNA sont obtenus après l'étape d'apprentissage du RNA à l'aide d'algorithme de rétro propagation. Étant donné que le SOC de la batterie est l'une des entrées du RNA, il est nécessaire de mesurer le SOC en utilisant l'une des méthodes disponibles dans la littérature. Pour cette raison, la méthode d'intégration de courant [65],

est utilisée pour collecter les données d'entraînement. Cette méthode utilise l'intégration de courant de la batterie dans le temps pour calculer le SOC (l'équation2.6) :

$$SOC(t) = SOC(t=0) + \frac{\int i(t)dt}{Q(t)} \tag{2.6}$$

Avec Q est la capacité nominale de la batterie(Ah), i (t) le courant de la batterie(A), et SOC (t = 0) est l'état de charge initial. Ce dernier est inconnu et représente le problème principal de la méthode d'intégration de courant. Durant le processus de test expérimental, il est mentionné que la batterie se charge de 0 à 100% et se décharge de 100 à 0%, alors l'état de charge initial est toujours connu dans ce cas.

La Figure 2.25 illustre la variation de SOC calculé, durant un processus de décharge de la batterie. Cette courbe est considérée comme le SOC réel durant la conception de notre modèle de la batterie.

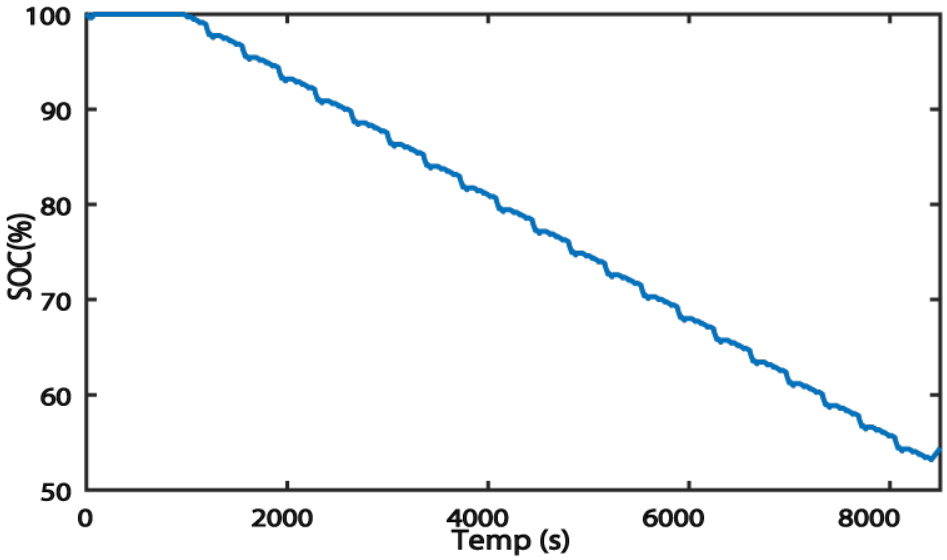


FIGURE 2.25 – État de charge calculé

2.2.4.3 Simulation et discussion des résultats

La simulation a été exécutée pendant 9000 secondes, pour comparer les résultats de modèle proposé par le réseau de neurones, avec le modèle standard implémenté sur Matlab/Simulink. Les données mesurées avec une température de 30°C ont été utilisées pour l'entraînement et les données collectées à une température de 10°C ont été utilisées pour la validation de modèle proposé.

la Figure 2.26 montre une comparaison de la tension entre le modèle de la batterie proposé, le modèle expérimental de la cellule et le modèle standard, durant l'étape de validation.

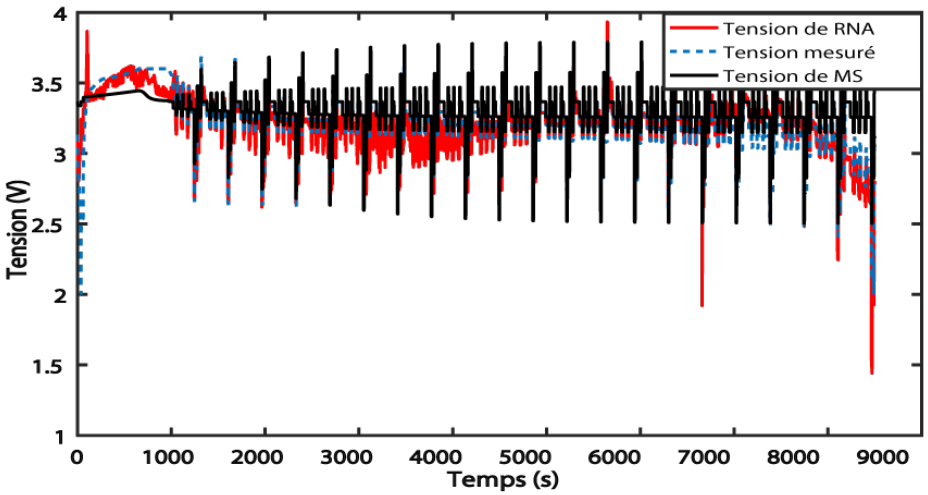


FIGURE 2.26 – Comparaison entre la réponse de tension des données expérimentales, le modèle standard et le modèle RNA

La Figure 2.27 montre un zoom de la Figure 2.26, pendant un intervalle de temps [5700s,6200s], pour mieux illustrer la comparaison des résultats des trois modèles.

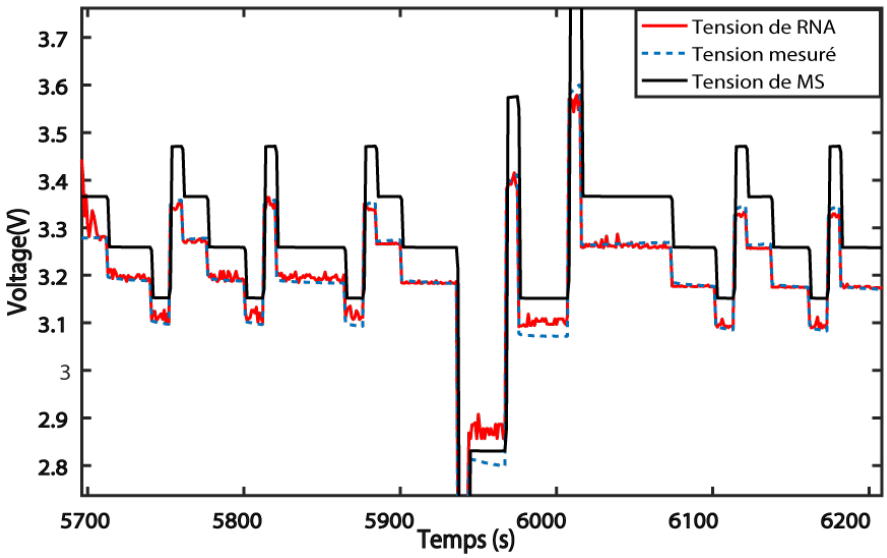


FIGURE 2.27 – Comparaison entre la réponse de tension des données expérimentales, le modèle standard et le modèle RNA, pour des données de validation.

D'après Ce zoom, on constate que la tension du modèle proposé est plus proche de la tension du modèle expérimental qu'au la tension du modèle standard de la batterie. Ce qui montre la haute performance du modèle proposé.

La Figure 2.28 présente l'erreur relative entre la tension du modèle proposé et standard et la tension mesurée de la cellule.

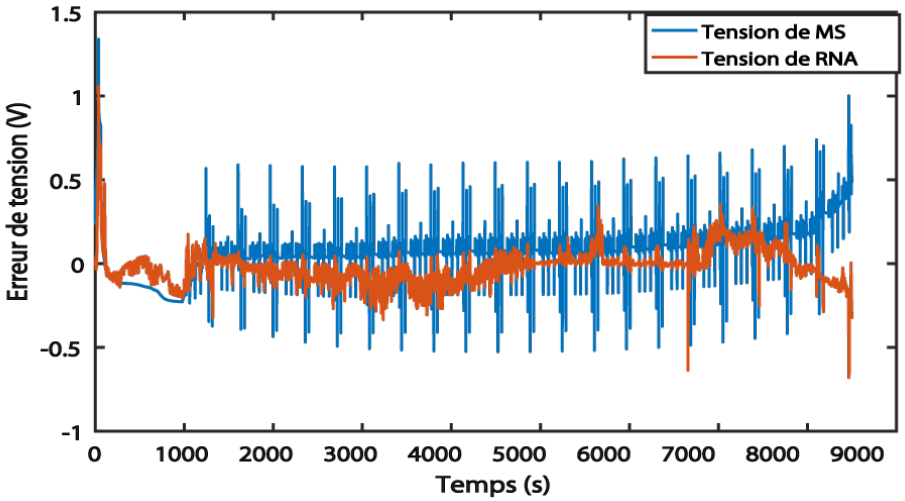


FIGURE 2.28 – Comparaison de l'erreur de tension entre le MS et RNA avec la tension mesurée

L'erreur maximale du modèle proposé est de 10%, ce qui comprend a une erreur de 0.1V en tension. Nous pouvons voir aussi quelque pic d'erreur dans notre modèle en raison du degré élevé de décharge de la batterie(Figure 2.28), mais la courbe du modèle proposé converge rapidement vers la courbe du modèle expérimental, ce qui montre la robustesse du modèle proposé.

2.3 Estimation de l'état de charge (SOC) de la batterie

Le chalenge fondamental du Battery Management Système (BMS) est la connaissance du SOC, qui représente la capacité restante dans la cellule de la batterie en pourcentage de la capacité maximale. Cet état n'est pas directement mesurable. Pour cette raison, de nombreux chercheurs ont proposé différentes méthodes d'estimation du SOC.

2.3.1 La méthode d'intégration de courant

La technique la plus commune pour le calcul de l'état de charge de la batterie (SOC) est la méthode de comptage de Coulomb, également connu sous le nom intégration de courant[66, 67]. Cette méthode basée sur l'intégration de courant de la batterie, est donné par l'équation 2.7 .

$$SOC = SOC(t=0) + \frac{\int i(t)dt)}{Q_m} \tag{2.7}$$

Avec $SOC(t=0)$ représente l'état de charge initial, i(t) le courant de charge/décharge de la batterie, Q_m représente la capacité nominale de la batterie.

L'état de charge initial représente le problème principal de cette méthode, en effet à cause du phénomène de vieillissement durant l'état de repos de la batterie, l'état de charge initial devient inconnu. Par conséquent, cette méthode est efficace si l'état de charge initial est connu.

2.3.2 La méthode de tension en circuit ouvert

La mesure de tension en circuit ouvert, Open Circuit Voltage (OCV) est la méthode la plus basique pour déterminer le SOC. Elle consiste en une mesure de tension OCV lorsque les cellules sont en repos et stabilisées. L'état de charge de la batterie est déterminée via la relation entre l'OCV et le SOC [68, 69].

L'avantage de cette méthode est que la quantité mesurée est relativement simple et la précision obtenue est plus élevée [70]. L'inconvénient majeur de cette méthode est que la détermination d'état de charge en ligne n'est pas possible lors des phases d'utilisation, car la mesure d'OCV nécessite une certain temps, après le repos, pour que les cellules deviennent stables.

L'utilisation d'un modèle simple de la batterie peut résoudre ce problème de mesure d'OCV durant le fonctionnement. Ce modèle est spécialement utilisée pour des batteries de simple non-linéarité entre la tension en circuit ouvert et l'état de charge. Pour la tech-

nologie Li-ion, la forte non-linéarité rend la détermination de SOC à partir de OCV très difficile[70, 71].

2.3.3 Les méthodes basées sur des modèles circuit équivalent

Ces méthodes sont globalement basées sur un modèle électrique des cellules de la batterie pour estimer l'état de charge SOC de cette dernière. Les paramètres de ce modèle sont adaptés selon les mesures effectuées durant l'utilisation de la batterie comme le montre la Figure 2.29.

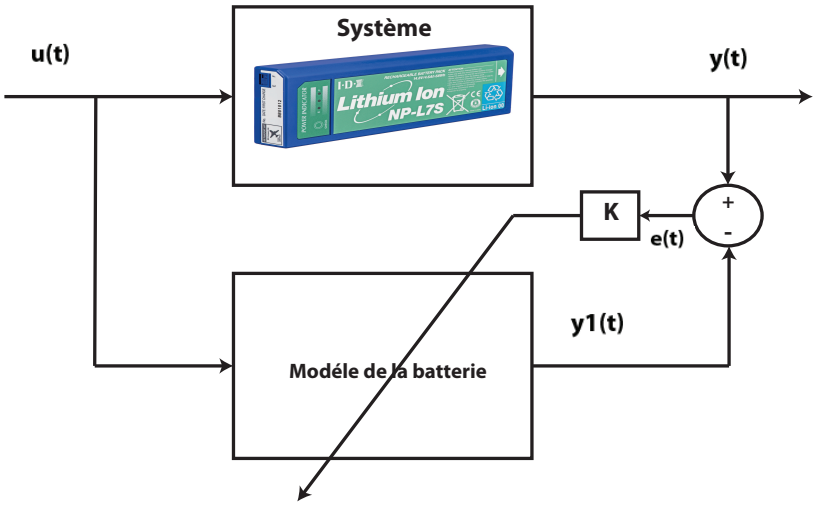


FIGURE 2.29 – Principe d'un estimateur d'état pour la batterie

Parmi les methodes couramment utilisés, on peut citer les observateurs à mode glissant[72, 73] et les filtres de Kalman [74, 75].

2.3.3.1 L'observateur mode glissant

Un observateur est un algorithme permettant d'estimer des états inaccessibles à la mesure, à partir des mesures disponibles et d'un modèle mathématique des dynamiques mises en jeu.

L'observateur mode glissant Sliding Mode Observer (SMO) est une extension du contrôleur mode glissant Sliding Mode Controller (SMC) . L'estimation d'état de charge SOC par SMO a été utilisée pour la première fois par Kim [72]. L'approche de conception de SMO a été combinée avec les équations d'état de modèle électrique de la batterie, la convergence de SMO a été prouvée par les fonctions de Lyapunov[72]. Cependant puisque l'erreur de modélisation existe, les termes d'incertitude sont ajoutés à l'équation d'état de la batterie pour compenser cette erreur comme illustré sur les équations 2.8, 2.9.

$$\dot{x}(t) = Ax(t) + Bu(t) + Tf(t) \tag{2.8}$$

$$y(t) = Cx(t) \tag{2.9}$$

Avec : A : matrice d'état

B : matrice d'entrée

C : matrice de sortie

x(t) : vecteur d'état

$\dot{x}(t)$: dérivée premier ordre de vecteur d'état

u(t) : entrée de système,

y(t) : la sortie de système

Tf(t) : l'erreur de modélisation.

2.3.3.2 Filtre de Kalman

Le filtre de Kalman est un observateur optimal inventé la première fois en 1960 par Rudolf Kalman. Ce filtre représente une nouvelle approche pour le filtrage linéaire des données discrètes et le problème de prédiction. il consiste en une estimation linéaire et récursive basée sur l'évolution de l'état en utilisant la théorie de probabilité, plus précisément, les propriétés de variables conditionnelles aléatoires de type gaussien, mini-

misant la variance de l'erreur. Ce travail a été l'origine du fameux estimateur de Kalman, appelé Filtre de Kalman (KF) [51].

Le filtre de Kalman est un observateur optimal dont le principe consiste à minimiser en temps réel les erreurs entre les sorties estimées et mesurées à l'aide d'une chaîne de retour qui ajuste les paramètres incertaines du modèle utilisé. La correction est pondérée par un vecteur gain K qui permet de fixer la dynamique et les performances du filtre. Ce gain est calculé à chaque itération, à partir des prédictions d'erreur, et des incertitudes (bruits) sur les états et les mesures. Le réglage de la dynamique du filtre repose sur l'initialisation des matrices de bruits d'état Q et de mesure R ainsi qu'au travers de l'initialisation de la matrice de covariance d'erreur supposée P [76]. Les filtres de Kalman sont une catégorie très utilisé pour l'estimation d'état de charge de la batterie [75, 77, 78, 79, 80] en raison de sa capacité de fonctionnement avec les modèles non linéaires.

Dans[77], l'auteur utilise le filtre de Kalman pour estimer l'état de charge de la batterie au plomb utilisant le modèle linéaire. Cependant, KF a tendance à diverger dans les systèmes non linéaires. Différentes extensions de filtre de Kalman, telles que Extended Kalman Filtre (EKF), Uncented Kalman Filtre (UKF) ont été proposées pour résoudre ce problème et ont été largement utilisés pour estimer le SOC des batteries avec des caractéristiques non linéaires. Le Filtre EKF a été élaboré la première fois par Plett [75]. C'est un Filtre de Kalman plus développé utilisé pour les systèmes non linéaires, il a été appliqué pour une cellule lithium ion polymère. Une autre recherche en [81] utilise EKF pour l'estimation de l'état de charge par l'utilisation de la relation entre la tension en circuit ouvert OCV et l'état de charge. Cependant, EKF utilise une linéarisation analytique pour linéariser le modèle de la batterie, ce qui provoque des problèmes numériques dans le calcul jacobin du modèle[78]. Le problème de calcul jacobin est résolu par le Filtre de Kalman Uncented (UKF), car le jacobin dans UKF est calculé à l'aide d'une linéarisation statique. Dans la référence [79], un UKF est utilisé pour estimer le SOC d'une batterie au lithium-ion sur la base d'un modèle de batterie électrochimique non linéaire. Autre

UKF a été développé pour l'évaluation en ligne SoC d'une batterie au lithium-ion[80]. L'inconvénient majeur de cette approche d'estimation est que les filtres de Kalman ont besoin d'un modèle adapté pour la batterie, cependant, l'utilisation des rétroactions dans ce modèle nécessitera un bon état d'initialisation pour la convergence du modèle.

Une autre méthode est discutée dans[82, 83] basée sur le calcul des paramètres de la batterie via des impédances de spectroscopies électrochimiques. Une fois que les paramètres du modèle sont connus, le SOC peut être estimé. Néanmoins, ces méthodes ne conviennent pas aux applications en ligne.

2.3.4 Les méthodes d'intelligence artificielle

Les méthodes d'intelligence artificielle sont des méthodes basées sur des algorithmes d'apprentissage en raison de leurs capacités d'apprendre et d'approcher la relation entre l'entrée et la sortie du système sans aucune connaissance physique. Ces méthodes ont été largement appliquées aux systèmes de batteries pour l'estimation de charge SOC, car ils fournissent les meilleures estimations de SOC. Parmi ces méthodes, on trouve Support Victor Machine(SVM) [84, 85, 86], logique floue (FL)[87, 88], et les réseaux de neurones[89, 90, 91, 92, 93, 94].

2.3.4.1 Estimation de l'état de charge par SVM

Le SVM est un ensemble de techniques d'apprentissage supervisé, et destinés à résoudre des problèmes non linéaires en raison de sa capacité importante à la linéarisation [95, 96]. La référence [84] présente une application de SVM pour l'estimation de l'état de charge. L'estimateur SOC proposé extrait les paramètres du modèle des cycles d'essai de charge / décharge de la batterie, en utilisant les données de tension, de courant et de température comme variables indépendantes. Les tests sont effectués sur une cellule lithium-ion de 60 Ah avec le cycle DST pour la conception du modèle SVM.

une autre application de SVM pour l'estimation de SOC des véhicules électriques dans

des conditions de conduite diversifiées a été proposée dans la référence [85]. La même technique a été utilisée dans la référence [86] pour l'estimation de SOC d'une batterie lithium-ion polymère à grande échelle. Cette solution donne des estimations précises de SOC, en utilisant la norme industrielle US06 [86].

2.3.4.2 Estimation de l'état de charge par Logique de Flou (FL)

La logique floue (Fuzzy Logic) est une logique polyvalente où les valeurs de vérité des variables sont des réels entre 0 et 1 au lieu d'être vrai ou faux. Elle était appliquée pour l'estimation d'état de charge de la batterie. La référence [87] présente une implémentation dans le microcontrôleur Motorola MC 68HC12 d'un modèle de logique floue pour l'estimation de SOC. Dans la référence [88], le modèle de logique floue a été appliqée pour sur des données collectées par impédance spectroscopie, pour la modélisation mathématique de la batterie et l'estimation d'état de charge.

2.3.4.3 Estimation de l'état de charge par les réseaux de neurones artificials (RNA)

Dans la référence[90], un RNA récurrent a été utilisé pour l'estimation de SOC à l'aide de mesures de la température, du courant et des valeurs de SOC précédentes à partir d'un polymère au lithium de 4,2 V, 100 Ah cellule. Cette méthode a été vérifiée à l'aide de données des courants, des tensions et d'état de charge d'un test de conduite urbain européen. Dans la référence [91], l'auteur propose une stratégie basée sur plusieurs RNA pour un estimateur d'état de charge de batterie au lithium-ion pour téléphones portables.

La référence[93] illustre une autre méthode d'estimation d'état de charge par la fusion de deux réseaux de neurones. Le premier RNA est un réseau de neurones linéaire utilisé pour modéliser la batterie et qui peut être utilisé pour identifier les paramètres du modèle électrochimique de premier ordre ou du modèle électrochimique de second ordre pour la batterie, le deuxième RNA est de type BP (Back-Propagation) utilisé pour la capture de la relation entre OCV et SOC.

La référence [94] montre une estimation de l'état de charge avec sur un réseau de neurones de type Wavelet Neural Network (WNN). Les résultats de simulation et d'expérimental montrent que l'algorithme proposé est efficace et réalisable pour estimer le SOC de la batterie au lithium avec une vitesse de convergence rapide et de plus grande précision. Les méthodes d'estimation à base de RNA peuvent être plus pratiques que les méthodes basées sur des modèles physiques. Néanmoins, les méthodes RNA présentent également des inconvénients : la qualité d'estimation et la précision de modèle dépendent de la quantité des données d'entraînement.

Récemment, d'autres types de méthodes hybrides ont été développés pour améliorer la précision de l'estimation :

Dans la référence [97], une méthode hybride a été proposée pour l'estimation de SOC basée sur un réseau de neurones et d'un Filtre de Kalman. Le RNA est développé pour estimer SOC, à partir des données mesurées de tension et courant et l'UKF est utilisé pour réduire les erreurs dans l'estimation de SOC. La méthode est validée à l'aide des données de batterie LiFePO4 collectées à partir du Fédérale Driving Schedule [97].

La référence[98] illustre une autre méthode hybride qui utilise un RNA et EKF pour l'estimation de SOC. Ce modèle hybride offre la meilleure performance d'estimation de la précision avec une erreur inférieure à 1%. Mais l'inconvénient majeur d'EKF c'est dans le calcul de jacobine, ce qui limite l'utilisation de filtre de kalman dans les applications non lineair

Dans la [99] nous avons développé un modèle hybride constitué par deux réseaux de neurones de types différents Nonlinear Autoregressive EXogenous (NARX) et Feed Forward Neural Network (FFNN). Le premier réseau NARX modélise la batterie comme une boîte noire avec le courant, la température actuelle, et l'état de charge comme des entrées. Le deuxième réseau de neurones FFNN est utilisé pour estimer le SOC. La méthode est validée à l'aide des données de batterie LiFePO4 collectées de NASA AMES Pronostics Data Repository [57].

2.3.5 Modélisation de la batterie et estimation de l'état de charge

Dans le travail référé dans l'article [35], nous avons développé un modèle hybride pour la batterie Li-Ion. Ce modèle constitué par deux réseaux de neurones du type Nonlinear Autoregressive EXogenous (NARX) et Feed Forward Neural Network (FFNN).

Le premier réseau modélise la batterie comme une boîte noire. C'est le modèle que nous avons déjà signalé dans la section 2.2.4. Le deuxième réseau de neurones du type FFNN) pour l'estimation de SOC.

Le modèle a été conçu et validé à l'aide des données de batterie collectées de NASA AMES Pronostics Data Repository [57].

2.3.5.1 La description du modèle proposé

Le modèle proposé [35] est composé par deux RNA : Le premier RNA est le modèle proposé dans notre précèdent travail [59] mentionnée dans la section 2.2.4. Le deuxième RNA est un estimateur d'état de charge de type boite noire, les entrées de ce réseau sont : le courant, la température et la tension de la batterie (sortie de premier RNA) et la sortie c'est l'état de charge SOC. Nous avons utilisé des retards Z^{-1} pour utilisées les données précédents de tension et de l'état de charge de la batterie comme illustré dans la Figure 2.30.

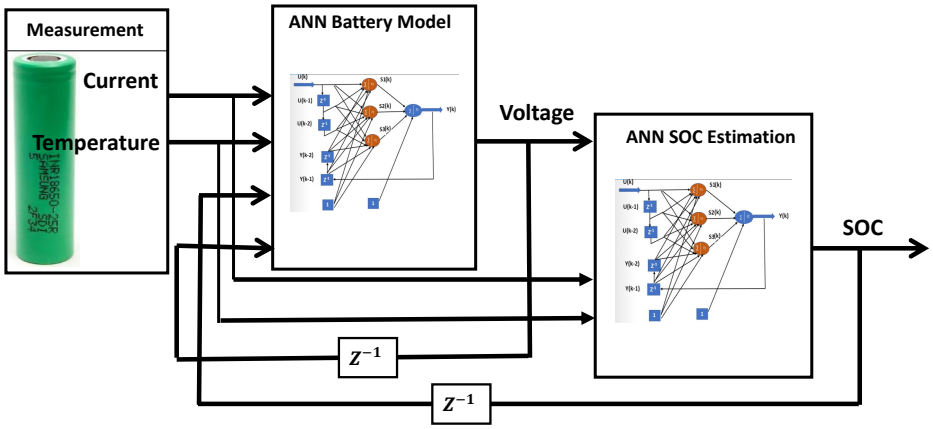


FIGURE 2.30 – Modèle proposé de la batterie Li-ion

Le modèle ayant la forme d'une boîte noire a besoin de mesures directes de courant et de température pour modéliser la batterie et estimer son état de charge SOC. Donc, c'est un modèle qui prend en considération l'effet de température et de l'état de charge de la batterie.

2.3.6 Simulation et discussion des résultats

Les résultats de simulation suivants montrent la comparaison entre le modèle proposé et le modèle expérimental, durant l'étape de validation.

La Figure 2.31 illustre la comparaison entre l'état de charge expérimental et l'état de charge estimé par le modèle proposé.

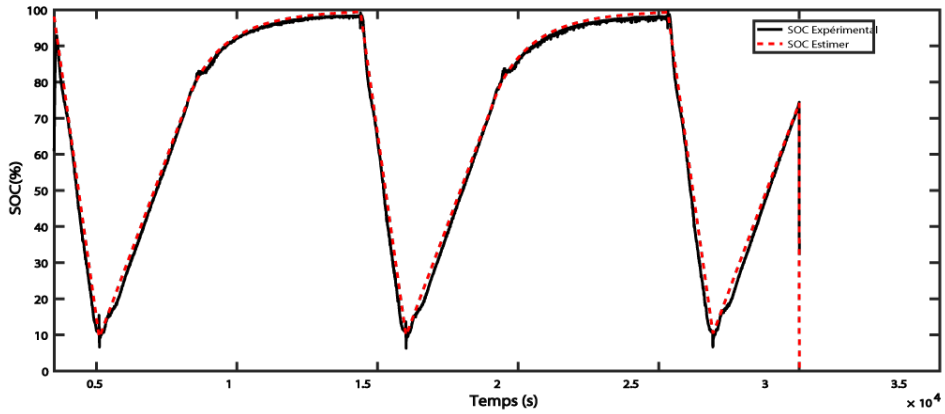


FIGURE 2.31 – Comparaison entre le SOC expérimental et le SOC estimé

On peut constater sur la figure précédente, une grande similitude, entre l'état de charge estimé par le modèle proposé et l'état de charge du modèle expérimental. La Figure 2.32 illustre la comparaison entre la tension expérimentale mesurée et la tension du modèle proposé.

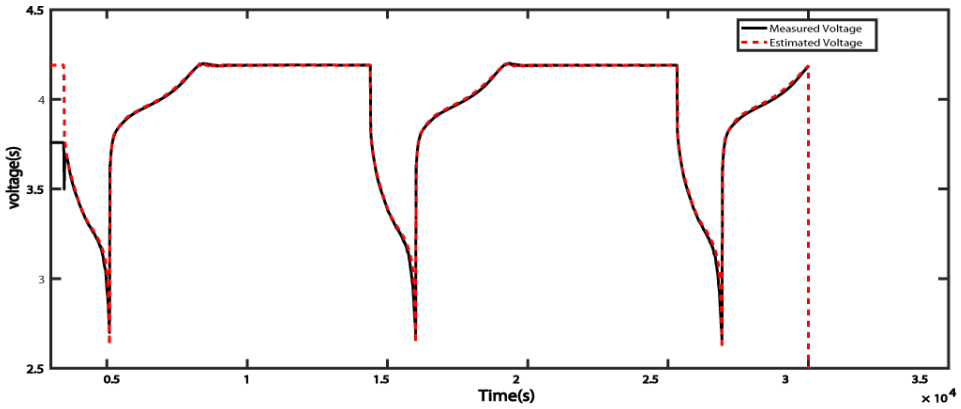


FIGURE 2.32 – Comparaison entre la tension expérimentale et la tension estimée

La même interprétation pour la figure 2.32, une grande similitude, entre la tension du modèle proposé et la tension du modèle expérimental. les résultats de simulation montrent une similitude importante entre les courbes des grandeurs estimées et les grandeurs du modèle expérimental. Mais, nous pouvons voir quelque pic d'erreur en raison du degré

élevé de décharge de la batterie. Ces pics montrent la robustesse de notre modèle, car la convergence vers la courbe expérimentale est rapide. Pour le deuxième RNA qui estime l'état de charge, l'erreur maximale est de 10%, en raison de la propagation des erreurs dans les deux réseaux de neurones.

2.4 Conclusion

Les travaux décrits dans ce chapitre portent sur la modélisation et l'estimation de l'état de charge de la batterie. L'objectif principal de ce chapitre était de développer un nouveau modèle pour la batterie Li-ion prenant en compte l'effet de l'état de charge et de la température dans son comportement, afin de l'utiliser pour la gestion d'énergie au sein de microgrid. D'après nos contributions, nous avons montré que les réseaux de neurones artificiels sont une très bonne technique pour modéliser et estimer l'état de charge de la batterie,

Dans la première contribution, nous avons développé le modèle générique de la batterie, par intégration de l'effet de température dans ces paramètres internes à l'aide des Réseaux de Neurones Artificial (RNA). Les résultats de simulation montrent que l'intégrat ion de température dans les paramètres interne de ce modèle, augmente la similarité entre la réponse du modèle générique développé et le modèle expérimental [56].

Dans la deuxième contribution, nous avons proposé un nouveau modèle de la batterie, c'est un modèle de type boîte noire, qui a été conçu à l'aide d'un réseau de neurones du type NARX. La comparaison des résultats de ce modèle, avec le modèle générique de la batterie et le modèle expérimental montre que la réponse de notre modèle est plus proche du modèle expérimental [35].

Dans la troisième contribution, nous avons développé un modèle hybride de la batterie Li-ion, ce modèle est composé d'une combinaison de deux réseaux de neurones de type différent NARX et FFNN. Le premier réseau pour la modélisation de la batterie, et le

deuxième pour l'estimation d'état de charge (SOC). Les résultats de simulation montrent que l'intégration de l'effet de la température et d'état de charge dans la modélisation de la batterie est très importante, car nous avons trouvé une grande similitude entre le modèle proposé et le modèle expérimental [59].

CHAPITRE 3

CONTRÔLE INTELLIGENT DE CONVERTISSEUR DC/DC BIDIRECTIONNEL

3.1 Introduction

Les systèmes de stockage d'énergie sont importants pour la stabilité et la disponibilité de l'énergie dans les microgrids. Les batteries Li-ion sont les systèmes de stockage les plus utilisés dans les microgrids, en raison de leurs avantages par rapport aux autres types de batteries, mais l'utilisation de ces batteries nécessite une attention particulière, car elles sont très sensibles. Par conséquent, un système de protection est nécessaire pour maintenir un fonctionnement sécurisé des MG. La batterie est connectée au microgrid à travers, un convertisseur bidirectionnel DC/DC. Ce dernier a pour rôle de protéger la batterie et assurer l'équilibre au bus de microgrid.

Nous allons consacré ce chapitre à un ensemble de travaux portant sur le contrôle du convertisseur bidirectionnel DC/DC pour les deux types de microgrid (isolé et connecté). Nous allons introduire différentes méthodes de contrôle pour ce convertisseur, ensuite la modélisation de chaque composant de microgrid, et finalement nous allons présenter le contrôleur Artificial Neural Network Contrôler (ANNC) proposé pour le contrôle de ce convertisseur.

3.2 Contrôle de convertisseur bidirectionnel

Un microgrid est un réseau de distribution d'énergie qui s'appuie sur des moyens locaux de production d'électricité. Il est conçu pour fonctionner indépendamment ou en synchronisation avec le réseau électrique, dans une zone définie (isolée ou éloignée). C'est aussi l'occasion de profiter d'une énergie propre distribuée et renouvelable. Les sources d'énergies renouvelables représentent les principales sources d'énergie pour les micro-grids [31]. Ces sources renouvelables comprenant, les micro-turbines, les éoliennes, les panneaux photovoltaïques etc, sont peu polluantes, peu coûteuses et très fiables [100]. Par contre le plus grand défi de ces sources d'énergie est la dépendance de conditions

météorologiques, ce qui rend le microgrid instable [101]. Pour cette raison, le stockage d'énergie joue un rôle important dans l'équilibre entre l'énergie disponible et l'énergie demandée de microgrid. Les batteries Li-ion sont les meilleurs types de batteries électrochim iques. Cependant, ce type de batteries oblige à utiliser un système de gestion de batterie pour les protéger contre l'explosion [35].

Les systèmes de gestion de la batterie protègent la batterie et assurent la stabilité et la gestion d'énergie du microgrid. L'élément principal dans les systèmes de gestion de la batterie est le convertisseur DC / DC bidirectionnel, car il connecte la batterie avec le bus de microgrid [102].

Le convertisseur DC/DC bidirectionnel gère la charge et la décharge de la batterie afin d'équilibrer l'énergie au DC Bus [103]. Ce convertisseur est contrôlé, afin de réguler la tension de Bus dans des limites de sécurité et imposer simultanément un flux d'énergie donné entre la batterie et le microgrid.

De nombreux articles sont concentrés sur la régulation de la tension DCBus par le contrôle du convertisseur bidirectionnel [104, 105, 106]. Les méthodes de contrôles conventionnel de ce convertisseur, tels que les contrôleurs Proportionnel Intégral Dérivé (PID), sont largement utilisées dans la littérature [107].

Les auteurs dans [104] proposent un contrôleur PI utilisé dans les véhicules hybrides pour récupérer l'énergie de freinage pour charger la batterie et pour maintenir la tension du bus du véhicule électrique constante.

De même, le travail rapporté dans [106] présente une comparaison de contrôle par PI et PID pour un convertisseur DC/DC bidirectionnel.

Une autre solution également basée sur le contrôleur PI appliqué dans les véhicules électriques à base de surface de glissement formée par l'erreur de courant d'inducteur a été rapportée dans [105]. Cette solution conduit à de très bonnes performances de régulation, mais, l'optimisation PID dépend de la référence utilisée. De même, cette stratégie de contrôle n'est pas performante que pour les systèmes linéaires.

D'un autre côté, les méthodes non linéaires comme le contrôleur mode glissant [108, 109] sont plus performantes que les méthodes linéaires [110].

Néanmoins, ces types de méthodes nécessitent une modélisation mathématique précise et une connaissance détaillée du système contrôlé. Cependant, l'intermittence des ressources d'énergie renouvelable et la grande dépendance de conditions météorologiques, la demande variable des charges électriques, et la présence de défauts de réseau peuvent compliquer la modélisation du système et conduire à des performances de contrôle insatisfaisantes [111].

Ces limitations ont motivé les chercheurs à utiliser des stratégies de contrôle plus évoluées et adaptatives afin de contrôler les systèmes hautement non linéaires [112]. Le principal avantage des techniques de contrôle intelligentes pour un microgrid est l'augmentation de la robustesse contre les interruptions qui se traduisent par une alimentation efficace pour les charges électriques.

Le contrôleur de réseau de neurone Artificial Neural Network Controller (ANNC) est parmi les contrôleurs intelligents les plus puissants pour les systèmes non linéaires. L'ANNC a une grande capacité de résoudre les problèmes non linéaires et peut fournir un mappage non linéaire entre les entrées et les sorties d'un système, sans la connaissance d'un modèle prédéterminé. De plus, il permet de résoudre le problème principal des contrôleurs PID, qui est sa dépendance des références utilisées. Par contre, l'ANNC en raison de ses capacités de généralisation, ne dépend que du signal utilisé pour l'apprentissage. Par conséquent, ANNC est un bon choix pour le contrôle de convertisseur bidirectionnel.

Récemment, divers modèles artificiels ont été utilisées pour le contrôle des convertisseurs. Un des premiers exemples d'utilisation de l'approche ANN pour le contrôle a été présentée dans [113], cette approche basée sur un réseau de neurones du type Feed Forward Neural Network (FFNN) pour surmonter d'une part, les problèmes de partage de puissance et d'autre part, réguler la tension d'un microgrid isolé [114].

Autre solution récente [115] propose une nouvelle approche de contrôle basée sur l'utilisation d'un système de contrôle hybride(ANN et logique floue). Cette combinaison présente une bonne méthode de contrôle, mais sans implémentation sur des systèmes non linéaires, nous ne pouvons pas valider cette méthode.

Les contrôleurs de réseaux de neurones artificiels sont une autre approche du développement d'ANN. Récemment, plusieurs auteurs [116, 117, 118] ont utilisé ces contrôle- urs pour plusieurs applications. Les auteurs de la référence [116] utilisent ANNC pour remplacer le contrôleur PID dans le contrôle d'un moteur à courant continu pour entraîner un bras de robot. Ceux de [117], pour le développement et l'analyse des performances du contrôleur adaptatif de référence de modèle pour les entraînements à moteur CC sans balais. Le contrôleur ANNC est utilisé également pour le contrôle des générateurs synchrones [118].

Après cette étude bibliographique sur les contrôleurs, nous avons opté d'appliquer le contrôleur ANNC pour le contrôle du convertisseur bidirectionnel DC-DC afin de couvrir toute la puissance de charge nécessaire et de stabiliser la valeur de tension DCBus.

3.3 Modélisation des composants du microgrid

Dans notre thèse, le microgrid à étudier est composé d'un système PhotoVoltaïque (PV), une turbine éolienne, un système de stockage d'énergie par batterie, des convertisseurs de puissance et des charges électriques. Cette section présentera la modélisation de chaque composants de microgrid ètudié.

3.3.1 Le système photovoltaïques PV

Le système photovoltaïque se compose d'un panneau photovoltaïque, d'un convertisseur de puissance et d'un contrôleur Maximum Power Point Tracking (MPPT) comme illustré sur la Figure 3.1.

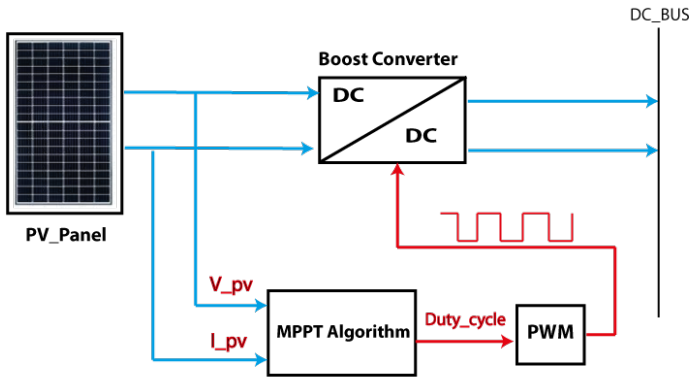


FIGURE 3.1 – Système photovoltaïque

3.3.1.1 Cellule photovoltaïques

Une cellule photovoltaïque est un composant électronique qui permet de produire de l'électricité grâce à son exposition au soleil. La cellule peut être utilisée seule ou assemblée à d'autres cellules solaires pour former un panneau photovoltaïque. Plusieurs modèles de cellules PV existent et varient en complexité et en précision. Celui qui sera retenu dans ces travaux concerne le modèle à une diode(modèle implémenté sur Matlab/Simulink) comme l'illustre la Figure 3.2 [119].

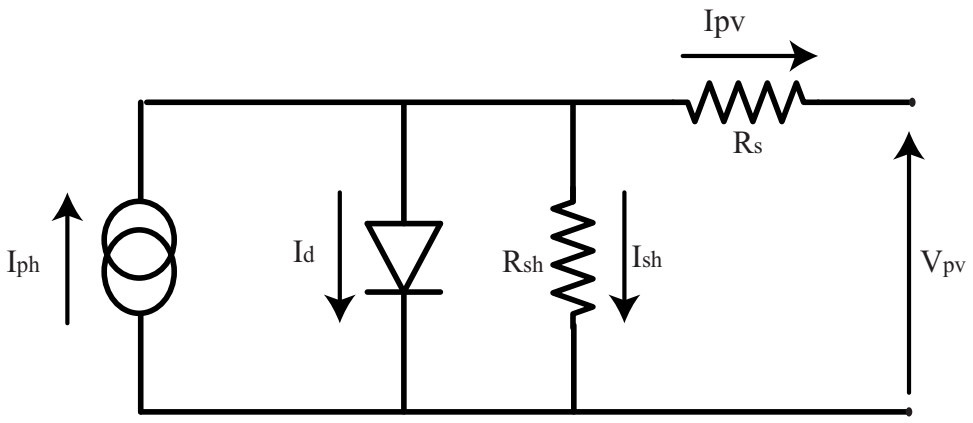


FIGURE 3.2 – Schéma électrique équivalent d'une cellule photovoltaïque

Ce modèle (Figure 3.2) appelé également modèle à cinq paramètres [120].

Le shéma du circuit électrique équivalent de cellule photovoltaïque se compose d'une source du courant I_{ph} modélisant le flux lumineux, les pertes sont modélisées par une résistance shuntR_{sh}, et une résistance série R_s. Le courant produit par la cellule photovoltaïque I_{pv} est déduit en appliquant la loi de Kirchhoff comme le montre l'équation 3.1.

$$I_{pv} = I_{ph} - I_d - I_{sh} \tag{3.1}$$

Avec :

$$I_d = I0 \times [exp\frac{q \times V_d}{K_b \times T_c} - 1] \tag{3.2}$$

Le courant électrique produit par la cellule est alors donné par l'expression de l'equation 3.3 :

$$I_{pv} = I_{ph} - I_0 \times [exp\frac{q \times V_d}{K_b \times T_c} - 1] - \frac{V_d}{R_{sh}} \tag{3.3}$$

Avec I_0 est le courant de saturation(A), T_c :Température effective de la cellule (K), V_d : Tension de la diode(V), K_b : la constante de Boltzman = $1,38.10^{-23}$ J/K, q : Charge de l'électron = $1,602.10^{-19}$ Coulomb

3.3.1.2 Convertiseur DC/DC de type boost

Le convertisseur DC/DC de type boost est le principal dispositif pour la mise en œuvre de la stratégie MPPT. Il est utilisé pour assurer le transfert de la puissance maximale du panneau solaire vers la charge électrique. Le convertisseur boost est utilisé pour faire varier la tension de sortie en ajustant le rapport cyclique comme montre l'équation3.4

$$\frac{V_{out}}{V_{in}} = \frac{D}{1-D} \tag{3.4}$$

Avec D est le rapport cyclique, Vin, Vout, sont la tension d'entrée, et de sortie. La valeur du rapport cyclique (D) doit être modifiée par un contrôleur MPPT pour s'assurer que le générateur PV fonctionne toujours à son point maximal quelles que soit les conditions de fonctionnement d'irradiation et de température.

La Figure 3.3 montre la configuration du convertisseur DC-DC boost connecté au panneau PV. Lorsqu'on a des changements en irradiation ou bien de la température, l'algorithme du contrôleur change et ajuste la valeur du rapport cyclique (D). En utilisant la valeur de ce dernier, le bloc Pulse Width Modulation (PWM) génère un signal de commande pour le dispositif de commutation du convertisseur boost, afin de contrôler la tension des panneaux PV.

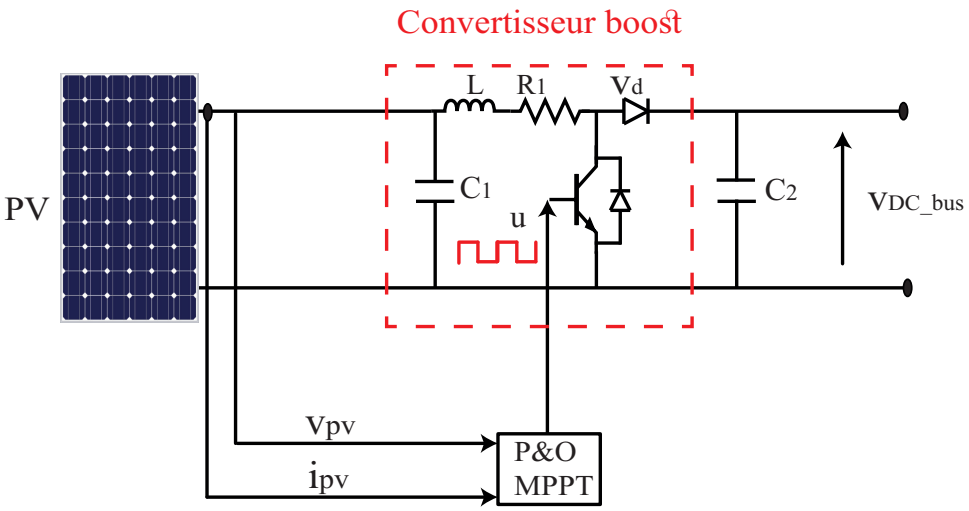


FIGURE 3.3 – Convertisseur boost

Le contrôleur MPPT peut être réalisé à l'aide de différentes méthodes et algorithmes. Perturbe et Observe (P and O) est l'algorithme le plus utilisé appartenant à la classe des techniques MPPT directes.

3.3.1.3 La commande MPPT

La commande MPPT permet de faire fonctionner un panneau PV de façon à produire en permanence le maximum de sa puissance quelles que soient les conditions météorologiques. A l'aide des mesures directes et instantanées de tension et de courant du panneau photovoltaïque, le contrôleur MPPT trouve le rapport cyclique qui sera transféré au bloc PWM pour la génération de signal de contrôle du convertisseur [121].

De nombreuses techniques MPPT ont été proposées dans la littérature :

— Méthode Perturb and Observe (P and O) [122, 123]

— Méthode Incremental Conductance(IC) [124],

— Méthode Artificial Neural Network (ANN) [125],

— Méthode Fuzzy Logic (FL) [126],

Ces techniques varient entre elles sur plusieurs aspects, notamment la simplicité, la vitesse de convergence, la mise en œuvre matérielle, les capteurs requis, le coût, la plage d'efficacité. L'algorithme (P and O) est généralement le plus utilisé dans la pratique en raison de sa simplicité de mise en œuvre.

A partir de la caractéristique du panneau photovoltaïque, on considère que le panneau photovoltaïque fonctionne à un point qui n'est pas nécessairement le Point de Puissance Maximal (MPP) comme le montre la Figure 3.4.

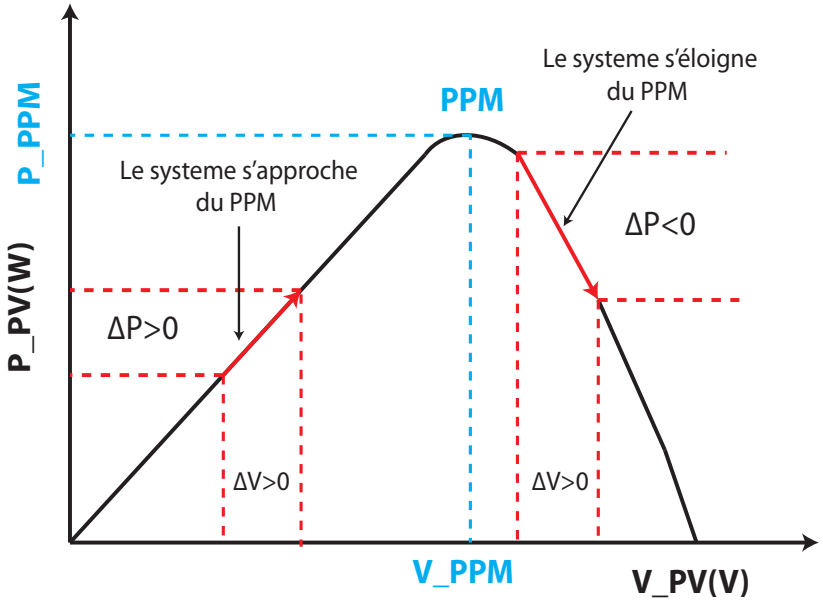


FIGURE 3.4 – Caractéristiques de fonctionnement de la méthode P and O

Ensuite, on perturbe la tension de fonctionnement avec (ΔV) et on observe la variation (ΔP) de la puissance électrique du panneau. Si (ΔP) est positif, alors la perturbation de la tension déplace le point de fonctionnement vers un point plus proche de la MPP. Si (ΔP) est négatif, le point de fonctionnement s'éloigne de la MPP, donc la perturbation de tension (ΔV) doit donc être inversée pour ramener le point de fonctionnement vers la MPP.

La Figure 3.5 présente le process d'algorithme P and O depuis la mesure de tension courant jusqu'à la détermination du rapport cyclique.

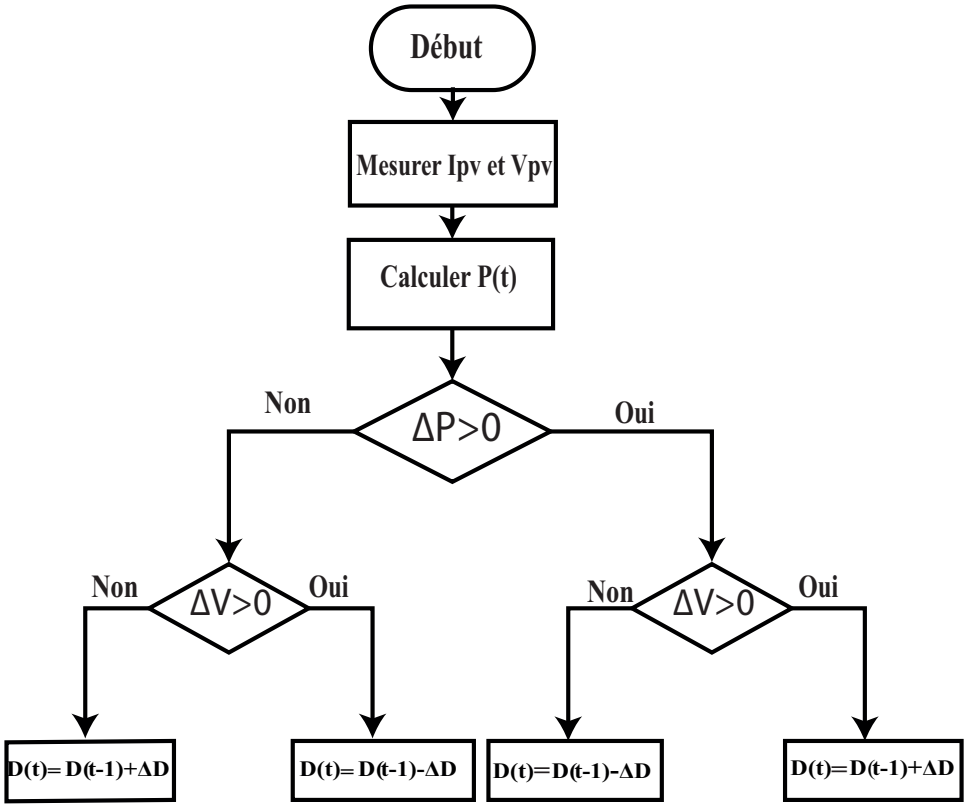


FIGURE 3.5 – Organigramme de l'algorithme P and O

3.3.2 Le générateur éolienne

Le générateur éolienne utilisé est composé d'une turbine éolienne, d'une génératrice synchrone à aimant permanent, et des convertisseurs de puissance contrôlés par une commande MPPT (Figure 3.6).

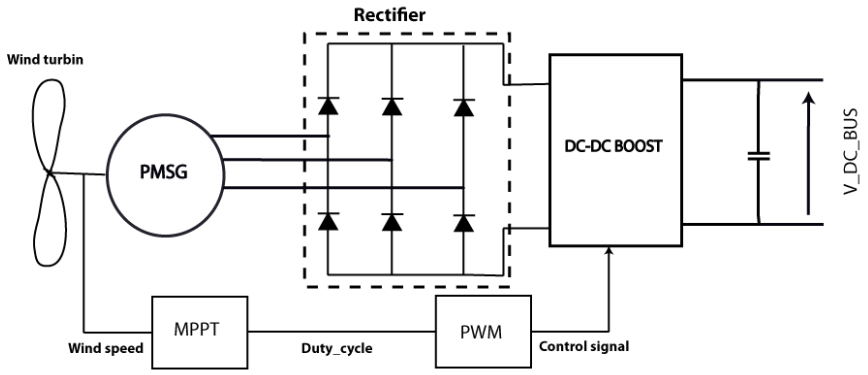


FIGURE 3.6 – Système de conversion éolienne

La commande MPPT pour le système éolienne est basée sur le même principe et même algorithme est utilisé pour le panneau photovoltaïque.

3.3.2.1 Turbine éolienne

Une turbine éolienne est un dispositif qui transforme l'énergie cinétique du vent en énergie mécanique, dite énergie éolienne. La puissance mécanique générée par une turbine éolienne peut être représentée par l'équation 3.5 [127, 128, 129] :

$$P_m = \frac{1}{2} \times C_p(\lambda, \beta) \times A\rho v^2 \tag{3.5}$$

Avec : P_m : est la puissance aérodynamique du rotor,

C_p : est le coefficient de puissance de la turbine,

A : est la zone balayée par les pales du rotor,

v : est la vitesse du vent,

ρ : est la densité de l'air,

λ : est le rapport vitesse de pointe,

β : est l'angle d'inclinaison de la lame (en degrés).

Afin de maximiser la puissance de sortie d'une éolienne, nous devons optimiser la valeur de C_p. Le coefficient de performance est une fonction non linéaire du λ, qui dépend des facteurs tels que le nombre de pales, le pas et la forme des pales. La valeur maximale que Cp peut atteindre en théorie est d'environ 59% [127].

Le rapport de vitesse de pointe λ est défini par l'equation 3.6 :

$$\lambda = \frac{\Omega \times R}{v} \tag{3.6}$$

Avec : R : est le rayon de la lame,

v : est la vitesse du vent,

Ω : est la vitesse angulaire de la turbine.

Le couple de sortie de la turbine T_m est calculé par l'equation 3.7 :

$$T_m = \frac{P_m}{\Omega} \tag{3.7}$$

Si le rapport de vitesse λ est maintenu à sa valeur optimale λ_{opt}, le coefficient de puissance est à sa valeur maximale $C_{pm} = C_p(\lambda_{opt})$, la puissance maximale de l'éolienne sera :

$$P_m^{opt} = \frac{1}{2} \times C_{pm}(\lambda, \beta) \times A\rho v^2 \tag{3.8}$$

Lorsque le rapport de vitesse supposé être maintenu à la valeur optimale, on obtient la vitesse angulaire optimale de la turbine par l'equation 3.9 :

$$\lambda_{opt} = \frac{\Omega_{opt} \times R}{v} \Rightarrow \Omega_{opt} = \frac{\lambda_{opt} \times R}{v} \tag{3.9}$$

Ainsi, pour chaque vitesse du vent, il y a une vitesse maximale du rotor Ω_{opt} qui fait une puissance maximale récupérée de l'éolienne comme le montre la Figure 3.7

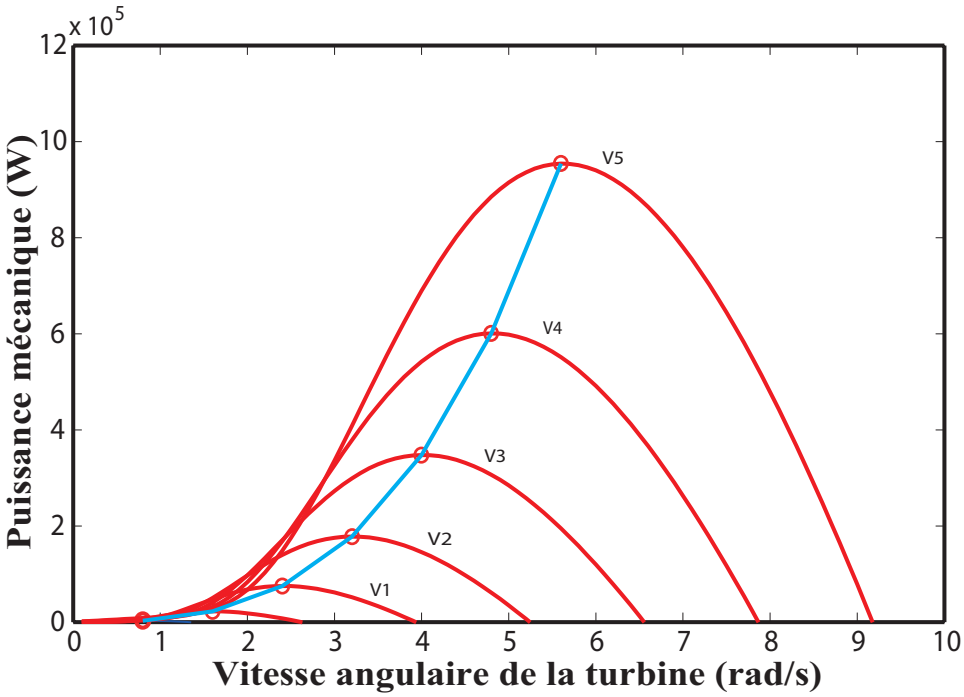


FIGURE 3.7 – Système de conversion éolienne

On peut voir sur la Figure 3.7 que pour chaque vitesse de vent, il n'y a qu'une seule vitesse de rotation pour laquelle l'éolienne produit une puissance maximale.

3.3.2.2 Génératrice synchrone à aimant permanent (PMSG)

La génératrice est l'élément d'une éolienne qui transforme l'énergie mécanique en énergie électrique. La topologie utilisée jusqu'à présent pour les systèmes éoliens à vitesse variables est celle basée sur des génératrices à induction. Cependant, la topologie basée sur les générateurs à aimants permanents a également une part de marché importante et croissante ces dernières années. Par rapport à la machine à induction, la machine à aimants permanents est plus efficace, moins gênante et surtout plus facile à contrôler. L'expression générale qui représente la dynamique de la génératrice synchrone à aimant permanent est

donnée par l'équation 3.10

$$T_t = T_e + f\omega_m + T_d + J\frac{d\omega_m}{dt}. \tag{3.10}$$

Avec : T_e : est le couple électromagentique.

T_t : le couple de la turbine.

f : le coefficient de frottement visqueux.

T_d : le couple de frottement sec.

J : le moment d'inertie.

ω_m : la vitesse angulaire mécanique.

3.3.3 Le système de stockage d'energie

Le système de stockage de batterie est constitué d'une batterie Li-ion, d'un convertisseur DC-DC bidirectionnel, et d'un système de contrôle pour la charge et la décharge de la batterie.

3.3.3.1 Batterie Li-ion

Dans le cadre de cette thèse, la technologie choisie pour la batterie est le lithium fer phosphate (LiFePO4). Les batteries lithium-ion sont la source d'alimentation préférée pour de nombreuses applications de système de stockage en raison de ses avantages par rapport aux autres types de batteries. La batterie Li-ion est un système compliqué pour la modélisation en raison de la non-linéarité de la réponse en tension. Dans notre micro-grid, nous avons utilisé le modèle dynamique de la batterie de la bibliothèque SimPower-Systèmes de Simulink[130, 131].

Le circuit équivalent de la batterie est composé d'une résistance connectée en série avec un source de tension V_{oc}.

En mode décharge, la tension $V_{oc} = V_{Dish}$ est donnée par l'équation 3.11.

$$V_{Dish} = E_0 - \frac{KQ}{Q-q}i - \frac{KQ}{Q-q}q + Aexp(-Bq) \tag{3.11}$$

Avec :

V_{oc} = tension en circuit ouvert (V), E_0 : est la tension constante de la batterie (V), K : est la constante de polarisation $(V/(Ah))$ ou résistance de polarisation (Ω), Q : est la capacité de la batterie (Ah), $q = it$: est la charge réelle de la batterie (Ah), A : est l'amplitude de zone exponentielle (V), B : est une constante de temps de zone exponentielle inverse (Ah), R : est la résistance interne (Ω),

En mode charge, la tension $V_{oc} = V_{Ch}$ est donnée par l'équation 3.12 :

$$V_{Ch} = E_0 - \frac{KQ}{0.1Q-q}i - \frac{KQ}{Q-q}q + Aexp(-Bq) \tag{3.12}$$

3.3.3.2 Convertisseur DC/DC Bidirectionnel

La batterie Li-ion est connectée au microgrid DC à l'aide d'un convertisseur DC-DC bidirectionnel (Buck-boost convertisseur) comme illustré sur la Figure 3.8 [132].

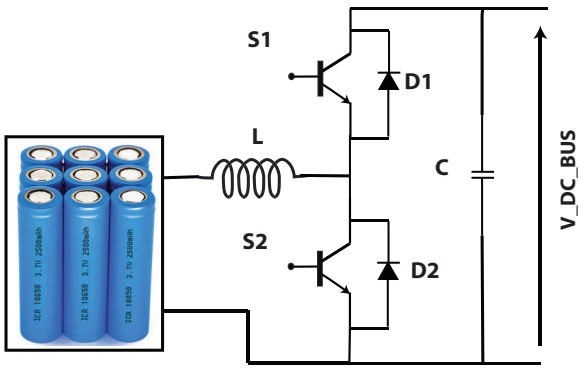


FIGURE 3.8 – Schéma du convertisseur DC-DC bidirectionnel

Le convertisseur utilisé pour notre microgrid est un convertisseur de topologie Insulated Gate Bipolar Transistor (IGBT) en demi-point, fonctionnant en Mode de Conduction Continue (CCM).

Le convertisseur fonctionne en deux modes :

Mode boost : pour décharger la batterie, et permettra à cette dernière de fournir de l'énergie au microgrid.

Mode Buck : pour charger la batterie, et stocker le surplus d'énergie au microgrid.

— **Mode charge de la batterie** :

En mode charge, le convertisseur bidirectionnel fonctionne en mode Buck. Ainsi, la direction du flux de puissance est du microgrid vers la batterie pour charger la batterie.

Ce mode de fonctionnement est divisé en deux étapes et décrit comme suit :

Étape 1.a : $S1$ **allumé et** $S2$ **éteint**

Dans l'état 1.a, le transistor $S1$ est allumé, $S2$ est éteint et les diodes $D1$ et $D2$ sont polarisées en inverse (bloquées)(Figure 3.9). Donc la tension V_L charge l'inductance L linéairement comme décrit dans l'équation 3.13 :

$$V_L = V_{Bus} – V_{batt} \tag{3.13}$$

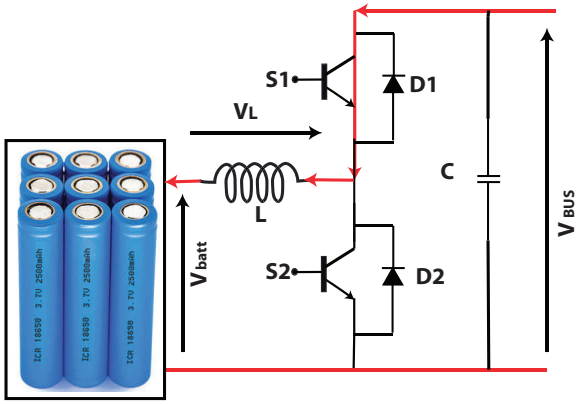


FIGURE 3.9 – Convertisseur en mode de charge Step1.a

Étape 1.b : $S1$ **éteint et** $S2$ **éteint**

Dans l'état 1 b, les transistors $S1$ et $S2$ sont éteints, la diode $D1$ est bloquée et la diode $D2$ polarisée en direct (passante) (Figure 3.10). Donc, la tension aux bornes de l'inductance L égale :

$$V_L = -V_{batt} \tag{3.14}$$

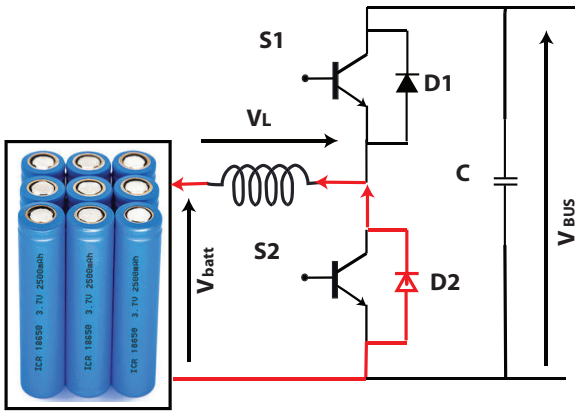


FIGURE 3.10 – Convertisseur en mode de charge Step1.b

— **Mode décharge de la batterie**

Dans ce mode, le convertisseur bidirectionnel fonctionne en mode Boost. Alors, la direction du flux de puissance est de la batterie vers le microgrid pour décharger la batterie.

Ce mode de fonctionnement est divisé en deux étapes est décrit comme suit :

Étape 2.a : $S1$ **éteint et** $S2$ **allumé**

Dans l'état 2.a, le transistor $S1$ est éteint, $S2$ est allumé et les diodes $D1$ et $D2$ sont polarisées en inverse (bloquées)(Figure 3.11). Donc, la tension de l'inductance est d'environ (voire l'équation 3.15) :

$$V_L = -V_{batt} \tag{3.15}$$

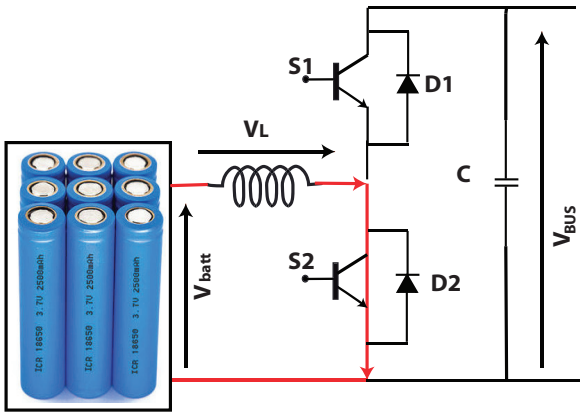


FIGURE 3.11 – Convertisseur en mode de décharge Step2.a

Étape 2.b : $S1$ éteint et $S2$ éteint

Dans l'état 2.b, les transistors $S1$ et $S2$ sont éteints, la diode $D2$ est bloquée et la diode $D1$ polarisée en direct (passante) (Figure 3.12). Donc, la tension aux bornes de l'inductance de filtrage L est décrite par l'équation 3.16 :

$$V_L = V_{Bus} - V_{batt} \tag{3.16}$$

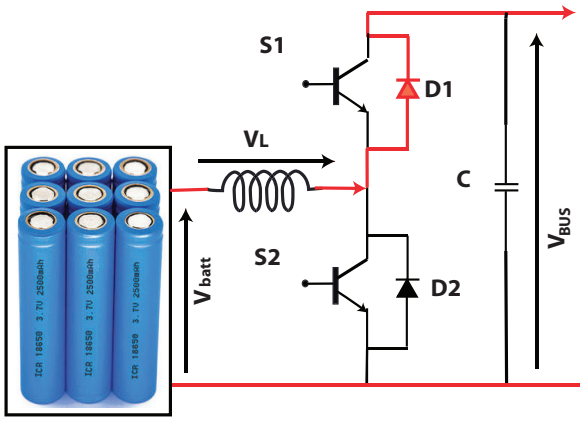


FIGURE 3.12 – Convertisseur en mode de décharge Step2.b

3.4 Contrôle de convertisseur bidirectionnel pour un microgrid autonome

Dans cette contribution [132], nous avons travaillé sur un microgrid autonome, qui est un système électrique utilisé pour l'électrification des emplacements qui ne sont pas équipés par le réseau électrique. L'objectif principal de cette contribution est le contrôle du convertisseur bidirectionnel DC/DC, qui connecte la batterie Li-ion avec le microgrid par l'utilisation de Contrôleur de Réseau de Neurone Artificial ANNC. Ce contrôleur est très efficace pour les systèmes non linéaires.

La technique de contrôle proposée ne nécessite pas de modèle prédéfini de convertisseur bidirectionnel, elle dépend uniquement des données mesurées dans le microgrid. Nous avons utilisé Matlab/Simulink pour la simulation de microgrid et pour la conception du contrôleur. La comparaison avec le contrôleur Proportional, Integral, Derivative (PID) du résultat obtenu, démontre la robustesse et les performances satisfaisantes de la stratégie de contrôle proposée.

3.4.1 Contrôleur de Réseau de Neurone Artificial ANNC

Les contrôleurs ANNC ont été appliqués avec succès au contrôle des applications d'ingénierie et surtout pour le contrôle des systèmes non linéaires[116].

Le contrôleur ANNC appelé également NARMA-L2 est une architecture de contrôleur à base de réseau neurone disponible dans MATLAB Neural Network Toolbox [133]. La mise en place du contrôleur NARMA-L2 qui comporte deux étapes : l'étape d'identification du système et l'étape de conception du contrôleur.

L'étape d'identification du système : permet de développer un modèle du réseau de neurone de système à contrôler comme le montre l'équation 3.22.

L'étape de conception du contrôleur : est utilisée pour former le contrôleur à l'aide

du modèle conçu durant l'étape d'identification comme l'illustre l'équation 3.23.

$$Y(k+d) = G[Y(k), Y(k-1), ..., Y(k-n+1), U(k), U(k-1), ..., U(k-n+1)] \quad (3.17)$$

Avec $U(k)$ est l'entrée système, $Y(k)$ est la sortie système.

Pour la phase d'identification, un réseau de neurone entraîné hors ligne par la base de données générée par le système de référence pour trouver la fonction non linéaire G. Nous voulons que la réponse du système suive la trajectoire de référence comme illustré par l'équation 3.18.

$$Y(k+d) = Y_r(k+d) \quad (3.18)$$

Par conséquent, le contrôleur non linéaire sera sur le formulaire suivant (équation 3.19) :

$$U(k) = G[Y(k), Y(k-1), ..., Y(k-n+1), Yr(k+d), U(k-1), ..., U(k-m+1)] \quad (3.19)$$

Le problème majeur de ce contrôleur est l'estimation de la fonction G. Un réseau de neurones avec rétropropagation du gradient dynamique peut estimer cette fonction, mais cela pourra être assez lent.

Une autre solution plus efficace proposée par Narendra et Mukhopadhyay [134, 135] basée sur l'utilisation de modèle approximatif pour décrire le système. La forme du modèle approximatif NARMA-L2 est représentée par l'équation 3.20 :

$$\begin{aligned} \hat{Y}(k+d) = {} & f[Y(k), Y(k-1), ..., Y(k-n+1), U(k-1), ..., U(k-m+1)] \\ & + g[Y(k), Y(k-1), ..., Y(k-n+1), U(k-1), ..., U(k-m+1)]U(k) \end{aligned} \quad (3.20)$$

Le principal avantage de cette forme est que la prochaine entrée de contrôleur $U(k)$ n'est pas contenue dans la non-linéarité du système. Par conséquent, le contrôleur résultant sera sous la forme :

$$\begin{aligned} U(k) = Yr(k+d) - f[Y(k), Y(k-1), ..., Y(k-n+1), U(k-1), ..., \\ U(k-n+1)]g[Y(k), Y(k-1), ..., Y(k-n+1), U(k-1), ..., U(k-n+1)] \end{aligned} \tag{3.21}$$

L'utilisation directe de cette équation peut poser des problèmes de réalisation, car nous devons déterminer l'entrée de commande $U(k)$ en fonction de la sortie $Y(k)$ en même temps. Donc, l'équation mathématique qui modélisera notre contrôleur, est :

$$\begin{aligned} y(k+d) = f[y(k), y(k-1), ..., y(k-n+1), u(k), u(k-1), ..., u(k-n+1)] \\ +g[y(k), ..., y(k-n+1), u(k), ..., u(k-n+1)]u(k+1) \end{aligned} \tag{3.22}$$

Avec $d \geq 2$.

La représentation schématique du contrôleur ANNC est présentée par la Figure 3.13

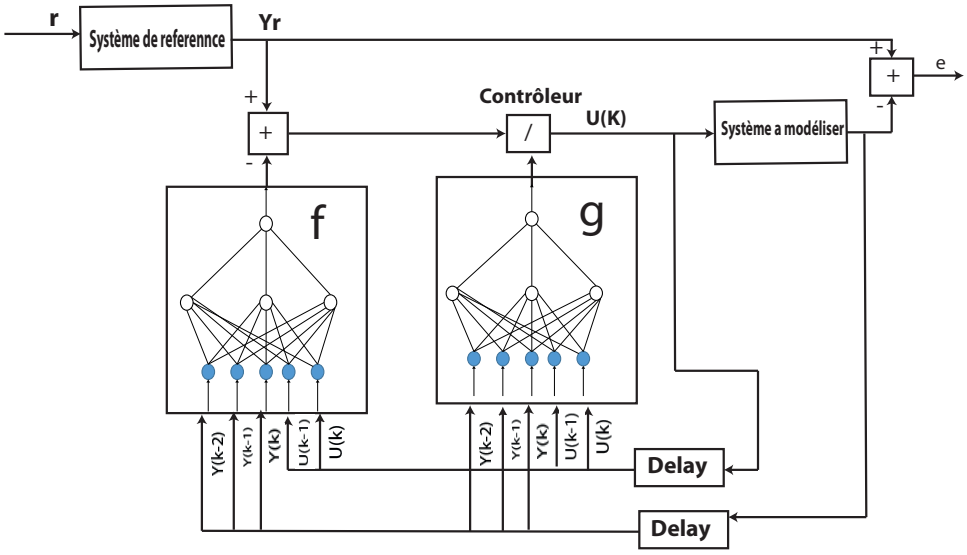


FIGURE 3.13 – Représentation schématique du contrôleur ANNC

Par conséquent, en utilisant le modèle NARMA-L2, nous pouvons obtenir le signal de contrôle suivant :

$$U(k+1) = \frac{(Y(k+d) - f[y(k),...,y(k-n+1),u(k),...,u(k-n+1)])}{g[y(k),...y(k-n+1),u(k),...u(k-n+1)]} \tag{3.23}$$

Dans notre contribution, l'ANNC permettera de contrôler le convertisseur DC-DC bidirectionnel par génération du rapport cyclique pour le PWM block afin de maintenir la tension du DCBus stable sur la valeur de la tension de référence. Par conséquent, les entrées de contrôleur sont : la tension de référence, la tension mesurée au DCBus du microgrid, et la sortie est la valeur de rapport cyclique. Pour construire ANNC, de nombreux tests ont été effectués afin de préparer une base de données.

3.4.2 Simulation et discussions des résultats

Le microgrid que nous avons utilisé dans cette contribution est constitué d'un panneau photovoltaïque, d'une batterie connectée avec le microgrid à l'aide d'un convertisseur

bidirectionnel DC-DC et d'une charge électrique comme montre la Figure 3.14.

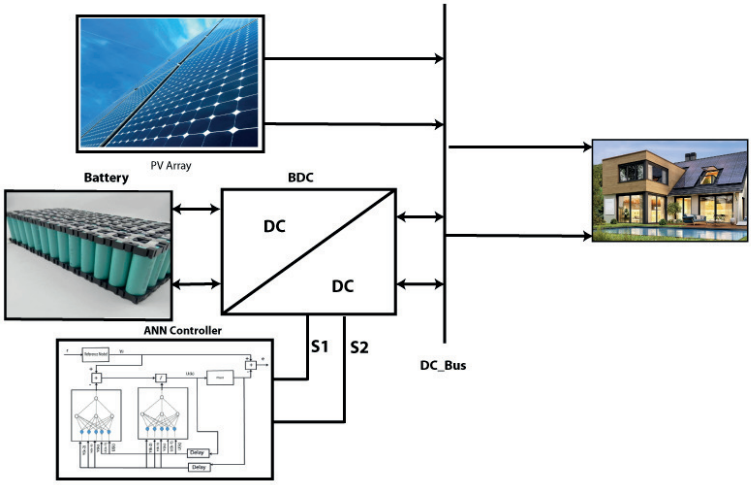


FIGURE 3.14 – Microgrid proposé

Le convertisseur DC-DC bidirectionnel, utilisé entre la batterie et le bus de micro-grid a pour but de contrôler la charge et la décharge de la batterie afin d'avoir une tension stable au microgrid. La batterie est un élément essentiel pour le microgrid isolé. Par conséquent, le contrôle de ce convertisseur est un facteur important de la gestion des échanges d'énergie entre le Bus DC, la charge et la batterie.

La stratégie de gestion de l'énergie appliquée dans cette contribution, est basée, comme le montre la Figure 3.15, sur la régulation de la tension du microgrid à 200V et le maintien de l'équilibre de puissance entre les sources et la charge.

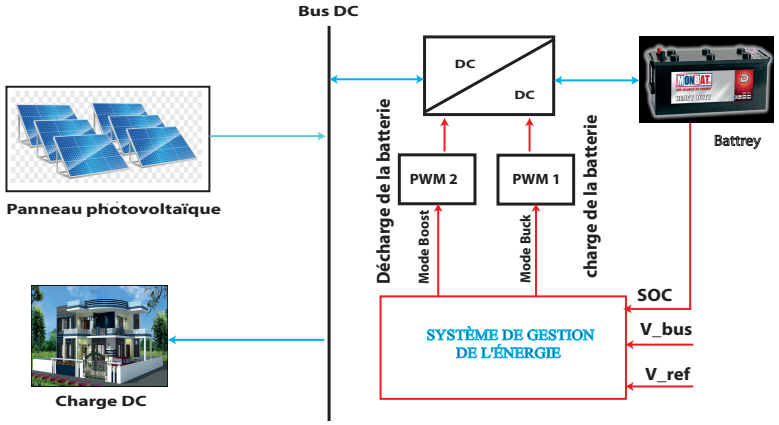


FIGURE 3.15 – Système de gestion de l'énergie appliqué au microgrid

La stratégie de gestion de l'énergie est appliquée entre panneaux, batteries, charges et réseau. Plusieurs configurations du fonctionnement possibles pour le système proposé qui sont définies en fonction des irradiations solaires, de l'état de charge SOC et de la puissance demandée par la charge DC. L'algorithme de la Figure 3.16 détaille le fonctionnement de tous les cas possibles envisagés du système de gestion d'énergie.

Lorsqu'une charge est connectée et qu'elle demande une puissance, le système de gestion Energy Management System (EMS) teste :

— Si le SOC dans l'état optimal de fonction, c'est à dire $(20\% < SOC < 80\%)$ le système de gestion compare la tension au BUS avec celle de référence :

  * Si $V_{Bus} > 200V$, EMS force le chargement de la batterie afin de décroître la tension au bus vers $200V$;
  * Si $V_{Bus} < 200V$,EMS force la décharge de la batterie afin d'augmenter la tension jusqu'à $200V$;

— Si la batterie est déchargée, c'est-à-dire $(SOC < 20\%)$, le système de gestion compare la tension au BUS avec celle de référence :

  * Si $V_{Bus} > 200V$, EMS force le chargement de la batterie afin de décroître la tension au bus vers $200V$.
  * Si $V_{Bus} < 200V$, EMS déconnecte la batterie, et ajoute un source de secours

pour couvrir le besoin de la charge.

— Si la batterie est chargée, c'est-à-dire $(SOC > 80\%)$, le système de gestion compare la tension au BUS avec celle de référence :

  * Si $V_{Bus} > 200V$, EMS système de gestion déconnecte la batterie et ajoute une charge de secours afin de décroître la tension au bus vers $200V$;
  * Si $V_{Bus} < 200V$, EMS force le décharge de la batterie afin d'augmenter la tension jusqu'à $200V$;

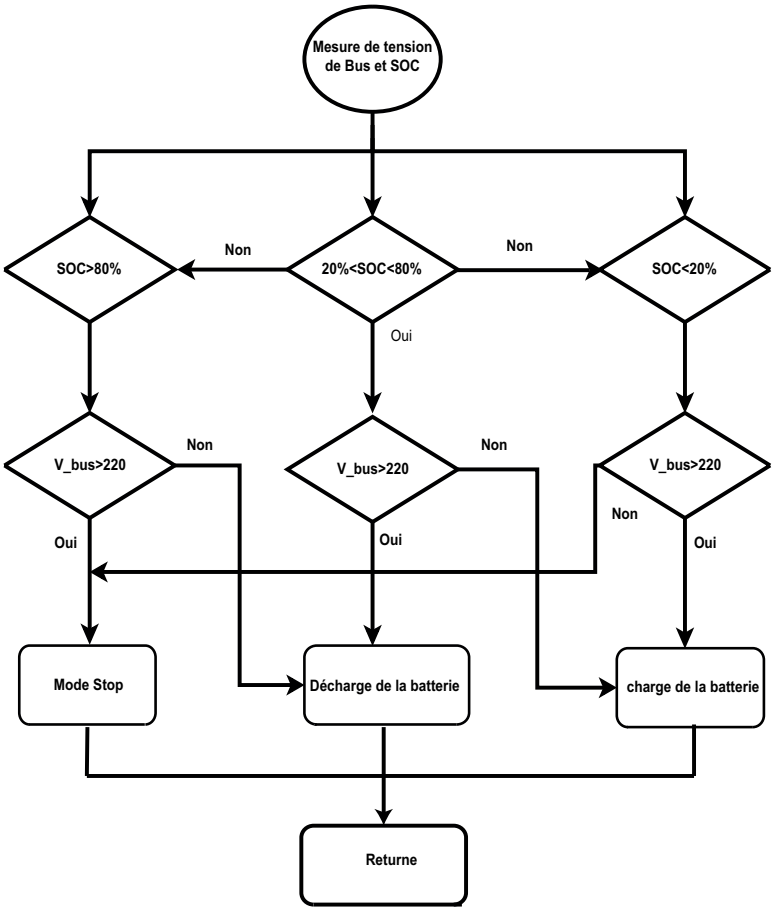


FIGURE 3.16 – L'organigramme de stratégie de gestion d'énergie

La simulation a été exécutée pendant une seconde avec un temps d'échantillonnage $1e^{-5}$. L'énergie produite par le panneau photovoltaïque n'est pas stable et dépend à chaque

instant des conditions météorologiques. L'objectif principal de cette simulation est de tester la performance du contrôleur sous la variation d'énergie photovoltaïque. Par conséquent, afin de tester la réponse du système de microgrid sous un changement brutal d'irradiation, nous avons choisi un scénario qui contient plusieurs changements d'irradiation comme le montre la Figure 3.17.

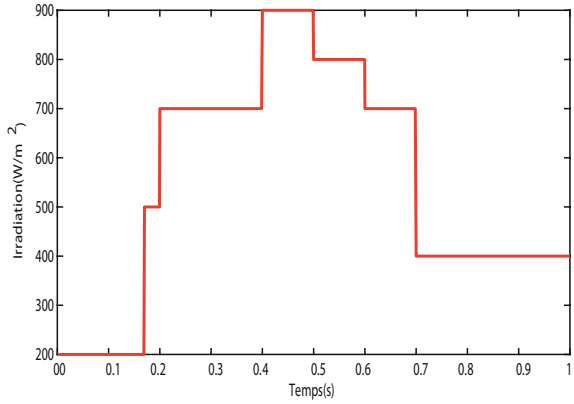


FIGURE 3.17 – Scénario d'irradiation

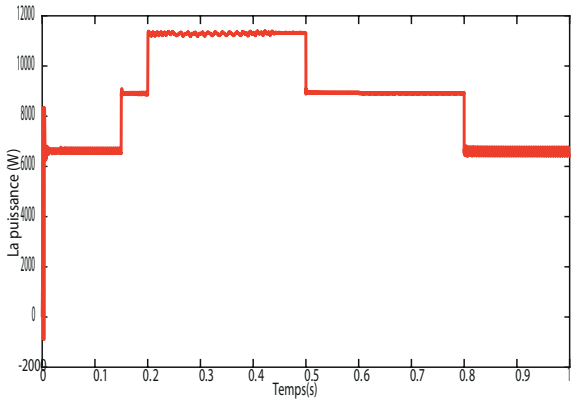


FIGURE 3.18 – Puissance du panneau PV

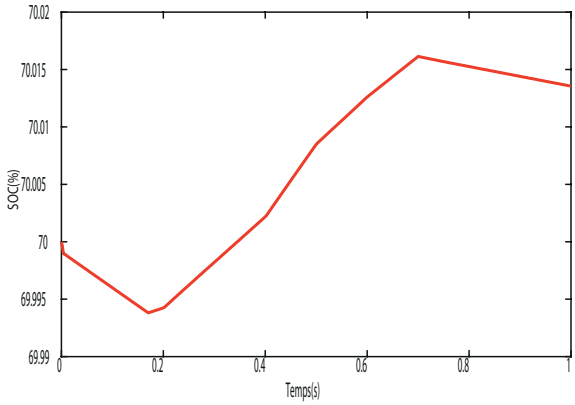


FIGURE 3.19 – SOC de la batterie

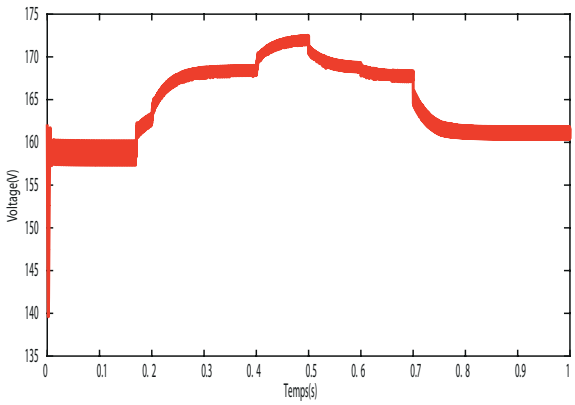


FIGURE 3.20 – Tension de la batterie

Au début de la simulation, on constate que la puissance produite par le panneau PV est inférieure à $10KW$ (Figure 3.18) car l'irradiation n'est pas suffisante $(200W/m^2)$ (Figure 3.17). Cela signifie qu'une autre source d'alimentation est nécessaire pour équilibrer le système. Comme nous l'avons décrit précédemment, la batterie sera utilisée en cas de

déséquilibre d'énergie entre la charge et les sources. Par conséquent, comme nous pouvons voir sur la Figure 3.19, la courbe d'état de charge de la batterie diminue à ce moment, ce qui signifie que la batterie fournit l'énergie au système pour maintenir l'équilibre de puissance entre la production et la charge demandée.

Lorsque la puissance produite par le panneau PV est supérieure à la puissance de charge demandée comme le montre la Figure 3.18.

Entre $0,18s$ et $0,7s$, le surplus d'énergie est stocké dans la batterie. Ce qui explique l'augmentation de l'état de charge de la batterie à ce moment. La Figure 3.20 illustre la variation de tension de la batterie, qui reste presque constante à 160 V pendant le mode de fonctionnement de décharge, et monte jusqu'à $174V$ pendant le mode de charge.

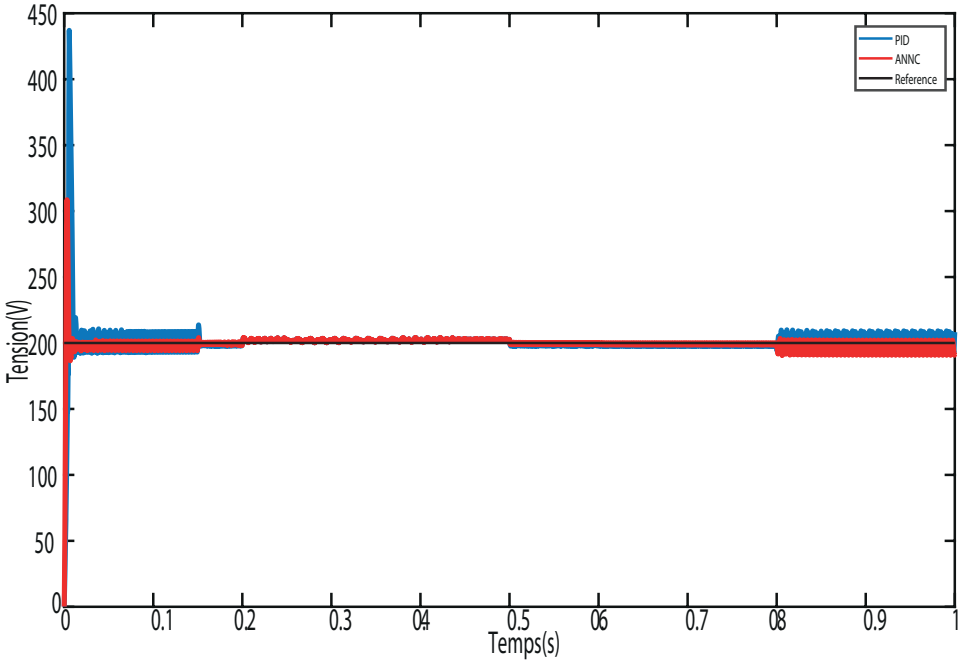


FIGURE 3.21 – Comparaison entre la tension de DC bus et de référence

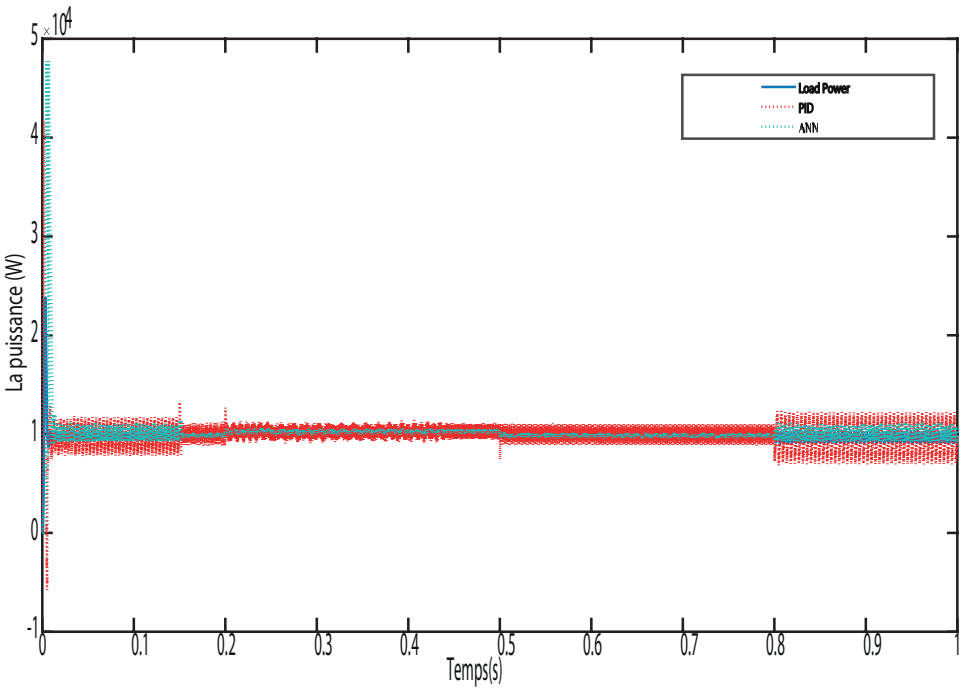


FIGURE 3.22 – Comparaison entre la puissance demandée et la puissance produite

La Figure 3.21 montre la comparaison entre la variation de tension de DCBus et la tension de référence, à la fois durant le contrôle avec PID et ANNC. Nous pouvons le voir d'après le résultat de la simulation, l'efficacité des deux méthodes avec un petit avantage de l'ANNC dans la stabilisation de la tension de Bus, ce qui se traduit par une stabilisation plus importante à la courbe de la puissance de Bus (Figure 3.22).

Afin de valider le contrôleur de réseau de neurones artificiels, nous avons besoin des données inconnues aux données d'apprentissage. Nous avons augmenté la puissance demandée de $10kw$ à $1Mw$ et nous avons fixé la référence de tension sur $2KV$, ce qui changera toutes les données du système. Le principal problème avec la stratégie PID est durant le changement des caractéristiques du système, il est nécessaire de trouver les paramètres optimaux à chaque changement. Au contraire, l'ANNC dépend uniquement de la base de données utilisée dans l'étape d'apprentissage.

la simulation est effectuée sans aucun changement dans l'ANNC et avec d'autres pa-

ramètres optimaux du contrôleur PID, les Figures3.23 et 3.24 présentent la comparaison de la tension et de la puissance au Bus à l'étape de validation. Pour les deux stratégies de contrôle, nous pouvons constater que le contrôleur proposé (ANNC), est robuste contre les changements du système.

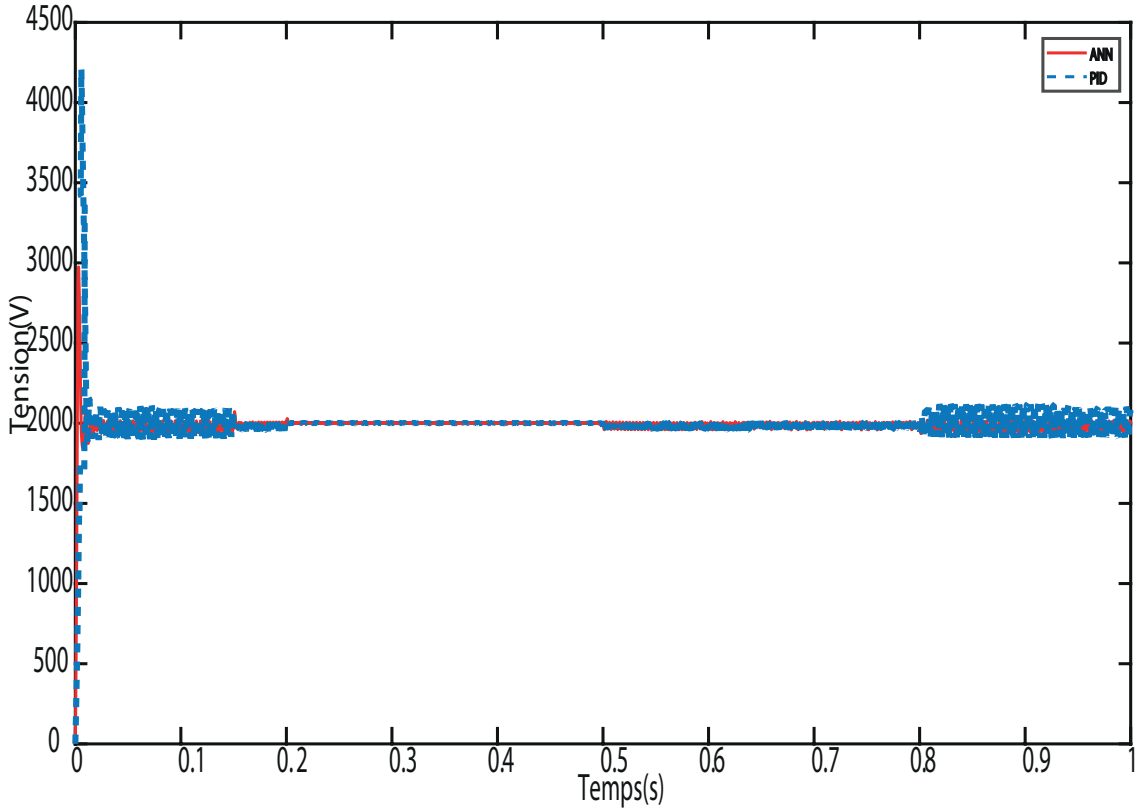


FIGURE 3.23 – Comparaison entre la tension de DC bus et de référence

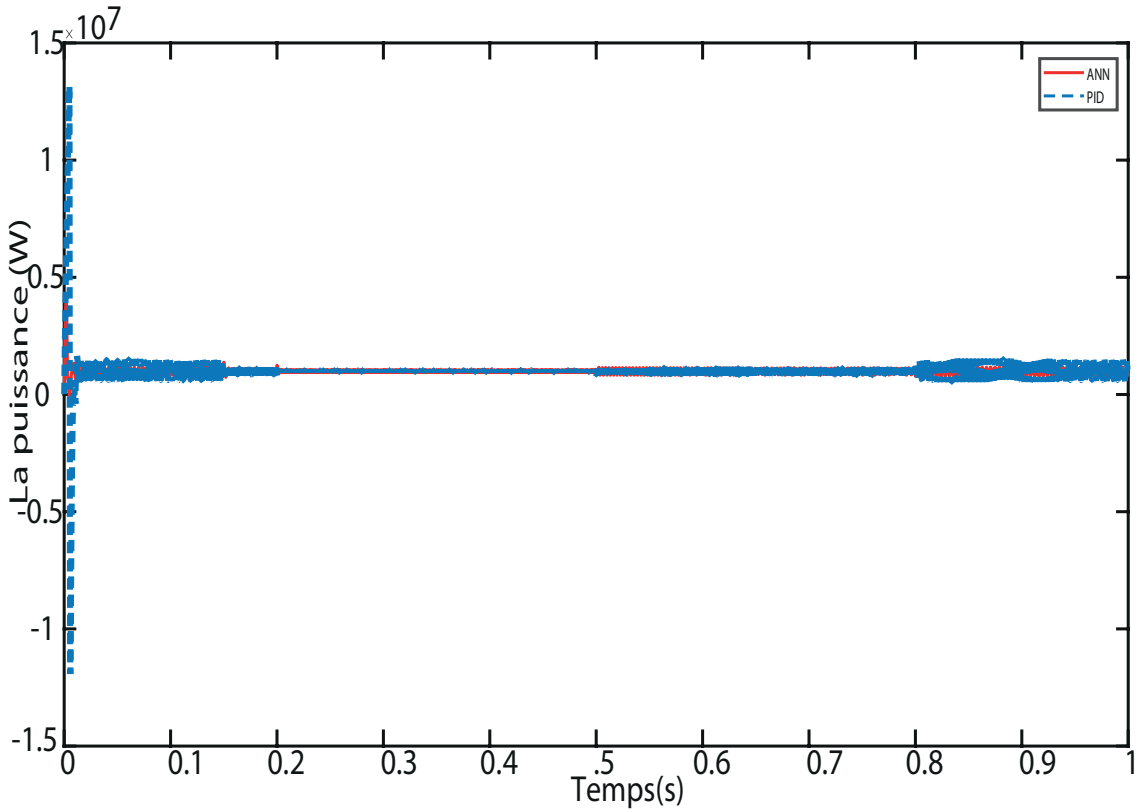


FIGURE 3.24 – Comparaison entre la puissance demandée et la puissance produite

Les résultats de simulation montrent l'efficacité du contrôleur proposé, mais la stratégie de gestion d'énergie reste incomplète car on a des cas où il est obligé de déconnecter la batterie, ou bien d'ajouter une charge électrique pour équilibrer le système, ce qui engendre des pertes d'énergie. Par conséquent, dans la contribution suivante, nous avons appliqué le même contrôleur avec une autre stratégie de gestion d'énergie afin de résoudre ce problème de perte d'énergie.

3.5 Contrôle de convertisseur bidirectionnel pour un microgrid connecté au réseau électrique

Dans la contribution précédente, nous avons contrôlé le convertisseur pour un microgrid isolé. Dans la contribution [136], nous proposons la même stratégie de contrôle, mais pour un microgrid plus compliqué. Le système est composé d'un panneau photovoltaïque, d'une batterie Li-ion et des charges électriques(AC et DC) comme le montre la Figure 3.25.

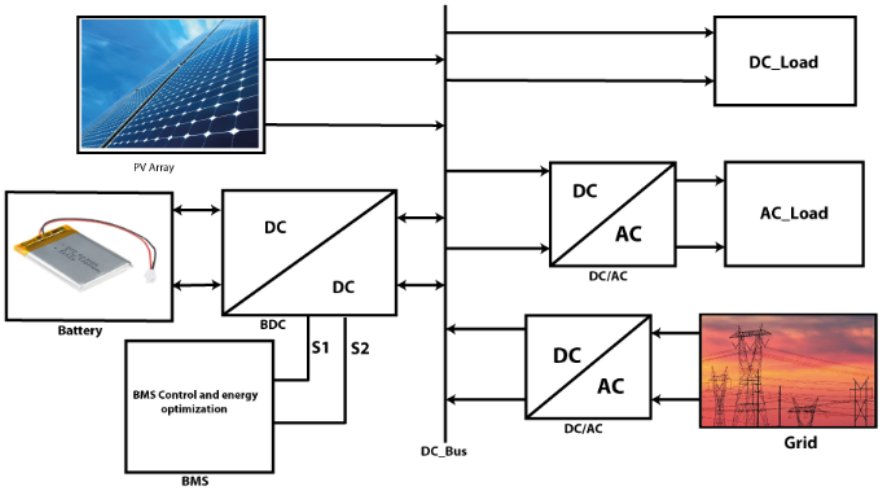


FIGURE 3.25 – Le microgrid proposé

Toutes les sources d'énergie sont dimensionnées afin que chaque source couvre les besoins en énergie des charges du système. La somme des charges AC et DC est égale à $15KW$. Par conséquent, nous allons dimensionner chaque source pour couvrir $15KW$.

Les caractéristiques de la batterie Li-ion utilisées dans ce système sont : une tension nominal de $48V$ et une capacité de $315Ah$, ensuite pour le système photovoltaïque : une cellule solaire American Solar (ASW-280M) avec une puissance maximale de 280W et une tension maximale de 37V qu'on peut trouver sur le toolbox power système de Matlab/Simulink. Six cellules sont connectées en série pour augmenter la tension à 220 V,

et neuf connectées en parallèle pour avoir une puissance de 16KW. Le réseau électrique (Grid) est connecté à l'aide d'un convertisseur AC/DC.

La gestion de l'énergie de la batterie représente l'objectif principal de cette contribution, par contrôle d'interface de connexion entre la batterie et le microgrid, et l'estimation de son état de charge. Les principales nouveautés de cette solution sont l'intégration du ANN pour l'estimation de l'état de charge de la batterie (SOC) et le Artificial Neural Network Controller (ANNC) pour le contrôle du convertisseur bidirectionnel.

3.5.1 Simulation et discussion des résultats

Dans cette partie, nous représentons les résultats de simulation concernant le fonctionnement de la stratégie de gestion d'énergie avec la possibilité d'utiliser le réseau électrique en cas de besoin ou bien en cas de surplus d'énergie. Les tests sont réalisés avec une irradiation variable et une température de 25°C.

L'algorithme de la Figure 3.26 détaille le fonctionnement de tous les cas possibles envisagés du système de gestion d'énergie.

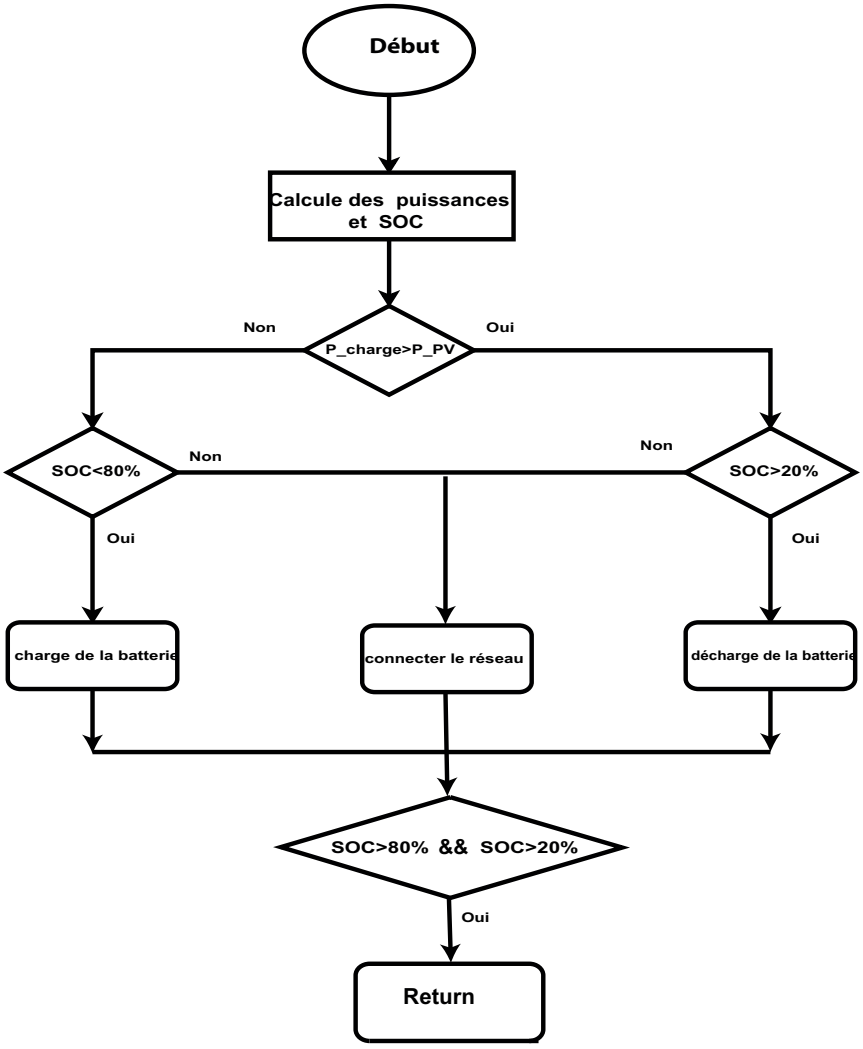


FIGURE 3.26 – La stratégie de gestion d'énergie

Lorsqu'une charge est connectée et qu'elle demande une puissance, le Energy Management Système (EMS), compare la puissance demandée avec la puissance produite par le panneau photovoltaïque :

— Si $(P_{charge} > P_{PV})$ le système de gestion teste l'état de charge SOC :

  * Si $SOC > 20\%$, EMS force la décharge de la batterie afin de couvrir le besoin d'énergie.
  * Si $SOC < 20\%$, EMS connecte le réseau électrique, pour couvrir le besoin

d'énergie, et chargé la batterie.

— Si $(P_{charge} < P_{PV})$ le système de gestion test l'etat de charge SOC :

  * Si $SOC < 80\%$, EMS force le chargement de la batterie afin de stocker le surplus d'énergie.
  * Si $SOC > 80\%$, EMS connecte le réseau électrique, pour injecter le surplus d'énergie.

Afin d'avoir tous les modes de fonctionnements de microgrid, un profil variable d'irradiation solaire a été proposé (Figure 3.27). Ceux qui nous donnent une puissance photovoltaïque variable comme le montre la Figure 3.28,

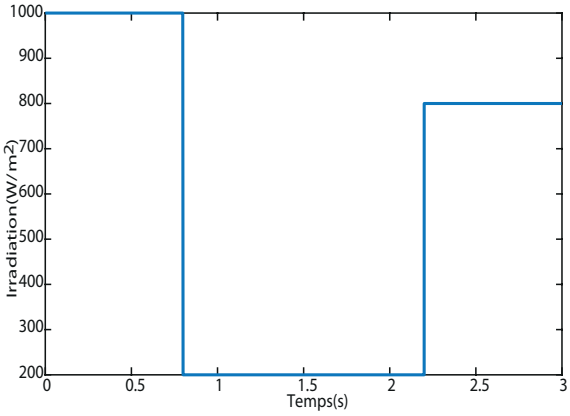


FIGURE 3.27 – Scénario d'irradiation

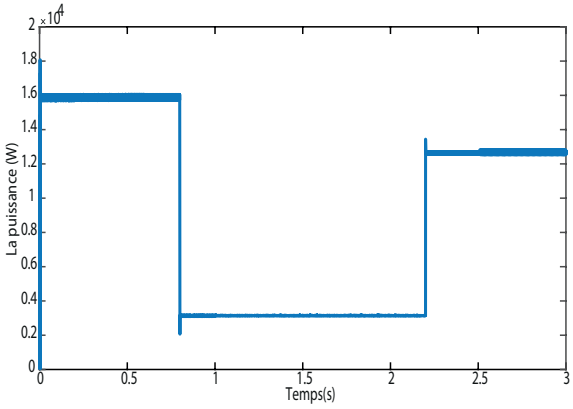


FIGURE 3.28 – Puissance du panneau PV

Au début de la simulation(0 à 0.8s), la puissance produite par le panneau photovoltaïque est supérieure à $(15KW)$ (Figure 3.28. Cela signifie qu'on a un surplus d'énergie dans le bus DC de microgrid. La Figure 3.29 montre une augmentation dans la courbe d'état de charge, c'est-à-dire, ce surplus a été stocké dans la batterie.

A (t=0.8s) la puissance produite par le panneau photovoltaïque décroît vers $(300W)$, Cela signifiait qu'on aura besoin d'énergie dans le bus DC de microgrid. Ce besoin a été couvert par la batterie,

A (t=1 s) l'état de charge de la batterie arrive à son SOC minimal. Donc, la batterie sera déconnectée. Dans ce cas, le besoin en énergie dans le bus DC et le chargement de la

batterie a été couvert par le réseau électrique comme le montre la Figure 3.30.

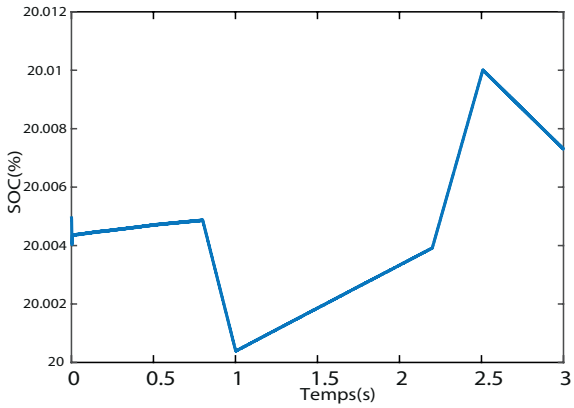


FIGURE 3.29 – Etat de charge

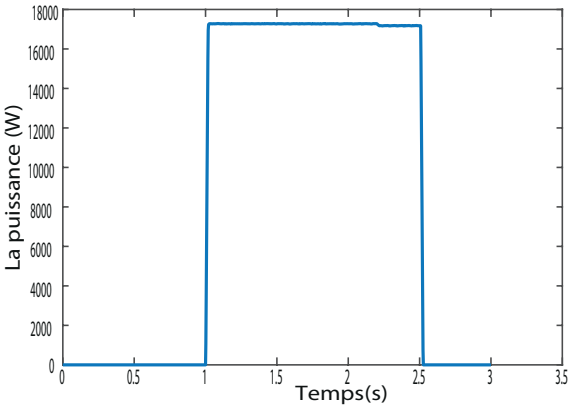


FIGURE 3.30 – Puissance du réseau

A(t=2.2s) la puissance produite par le panneau photoltaique augment autre fois à $(12KW)$, et la batterie dépasse son état de charge minimal. Donc, le réseau électrique se déconnecte car le besoin en énergie sera couvert par le panneau solaire et la batterie.

La Figure 3.31 montre une similitude importante entre la courbe de tension de Bus DC et la tension de référence.

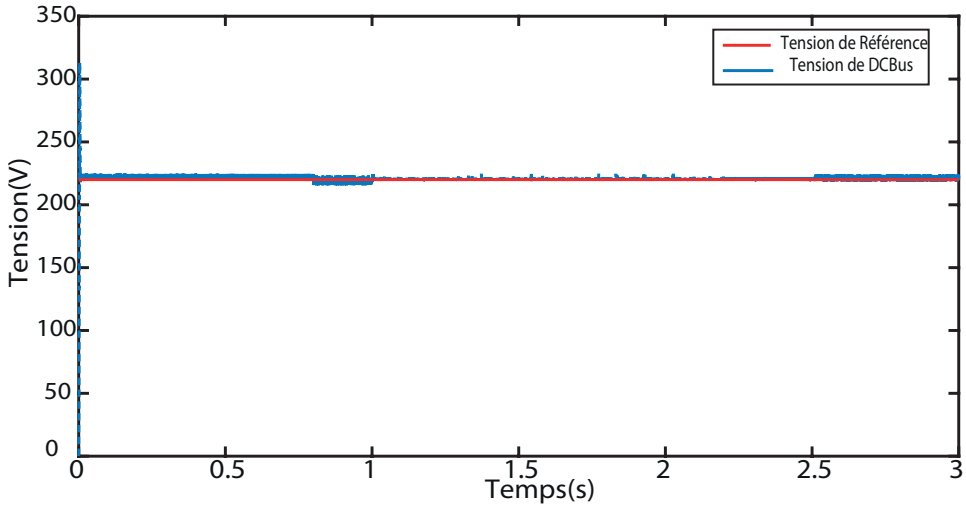


FIGURE 3.31 – Comparaison entre la tension de référence et la tension mesurée au DC bus

D'après les résultats de simulation, on constate que la stratégie de gestion d'énergie utilisée, est très efficace en matière de protection de la batterie, stabilisation de bus de microgrid, et sa robustesse contre les brutales variations des conditions météorologiques.

3.6 Conclusion

Dans ce chapitre, nous avons proposé des structures et développé des algorithmes de la gestion d'énergie et de protection de la batterie dans les microgrid autonome et connecté au réseau électrique.

Nous avons montré que le système de stockage d'énergie est un élement essentiel pour les microgrids, mais son utilisation sans un système de gestion d'énergie peut générer plusieurs accidents. Pour faire face à ce problème, nous avons proposé un contrôleur de réseau de neurones artificial ANNC, avec une stratégie de gestion d'énergie pour les systèmes autonomes et les systèmes connectés au réseau électrique [132] [136]. Les résultats de simulation obtenus ont montré l'utilité de ce système, dans la gestion et la supervision de la batterie lors de son utilisation dans les microgrids sous plusieurs conditions météorologiques. Nous avons proposé en premier lieu un contrôleur ANNC [132], pour contrôler le convertisseur bidirectionnel, afin de superviser la batterie, avec un EMS pour assurer l'équible de puissance dans le Bus du microgrid autonome, durant toute la phase de fonctionnement. Mais, nous avons remarqué qu'on a des pertes au niveau de ce système. Ensuite nous avons développé l'algorithme de gestion d'énergie et le système électrique par la connexion de ce microgrid avec le réseau électrique, afin de minimiser les pertes et maximiser l'utilisation d'énergie solaire [136].

Pour conclure, nous avons pu, dans ce chapitre, faire la conception et la simulation d'un microgrid sous la supervision d'un système de gestion d'énergie. Mais ce système de gestion d'énergie peut être moins efficace en cas de plusieurs sources d'énergie renouvelable, en raison du degré de non-linéarité élevé des sources d'énergie renouvelable.

Dans le chapitre qui suit, nous verrons, en détail, l'implémentation d'une approche de gestion d'énergie décentralisée par les systèmes multiagents, pour un microgrid composé par plusieurs sources d'énergie renouvelable

CHAPITRE 4

LA GESTION D'ÉNERGIE DANS UN MICROGRID

4.1 Introduction

Les systèmes d'énergie renouvelable hybrides ou les systèmes à ressources énergétiques multiples, appelés aussi microgrids : sont des systèmes d'alimentation électriques fournissant une électricité équilibrée et propre. Le photovoltaïques (PV) et l'éolienne sont les sources d'énergies renouvelables les plus utilisées dans la plupart des régions du monde et l'une des formes les plus propres de conversion d'énergie disponible [137]. L'hybridation de différentes sources d'énergie vise, d'une part, à fournir une électricité durable et équilibrée dans les zones isolées et d'autre part à assurer une capacité de production électrique maximale avec le coût le plus bas pour les zones connectées au réseau électrique [138]. Cependant, la nature intermittente des sources d'énergies renouvelables et leur dépendance aux conditions météorologiques peuvent poser certains problèmes notamment en matière de stockage. Par conséquent, un système de gestion de l'énergie ou Energy Management System (EMS) est nécessaire pour contrôler le flux d'énergie.

Dans ce chapitre, nous présentons une stratégie intelligente pour la gestion d'énergie d'un microgrid constitué par plusieurs sources d'énergie. Cette stratégie est basée sur l'utilisation de concept intelligent de multi agents système et les réseaux de neurones. L'approche des systèmes multi agents est proposée pour gérer le microgrid par la prise de décision des agents développés sous le framework JADE. En premier, nous présentons l'approche centralisée et décentralisée pour la gestion d'énergie, puis nous exposerons la stratégie de gestion proposée.

4.2 La gesion d'energie au sein du microgrid

La gestion de l'énergie dans un microgrid est une stratégie économique de répartition des sources d'énergie et de gestion des charges. La gestion de l'énergie minimise, non seulement le coût de fonctionnement, mais répond également à la demande de charge

dans les contraintes opérationnelles du microgrid. Le système de gestion d'énergie EMS, défini par la Commission électrotechnique internationale par la norme IEC 61970, est un système informatique comprenant une plate-forme logicielle fournissant des services de support de base et un ensemble d'applications fournissant les fonctionnalités nécessaires au fonctionnement efficace des installations de production et de transmission d'électricité, de manière à garantir une sécurité adéquate de l'approvisionnement énergétique au coût le plus bas[139].

Dans notre thèse, la stratégie de gestion d'énergie est basée sur les axes suivants : le contrôle de convertisseur bidirectionnel, afin de protéger la batterie et de garder l'équilibre d'énergie dans le bus de microgrid. Maximisation de la production des sources renouvelables par l'utilisation de stratégie MPPT.

4.2.1 Système de gestion d'énergie centralisé

Le système EMS centralisé comprend un contrôleur d'alimentation central configuré pour contrôler la distribution d'énergie électrique à un microgrid. Le principal avantage de la stratégie centralisée EMS est la minimisation des conflits et la facilité d'application des algorithmes d'optimisation pendant l'opération en raison de la décision de plus haut niveau, car toutes les informations des sources d'énergie distribuées et de la demande des charges finissent jusqu'au contrôleur central[140]. Néanmoins, le système EMS central présente également certains inconvénients. Lorsque le microgrid devient plus gros et plus complexe, l'existence d'un serveur puissant capable de gérer la grande quantité de données devient obligatoire, afin de mettre en œuvre la gestion du système en temps réel. Cela augmente le coût du système et le rend moins flexible, de plus la stratégie de contrôle doit être mise à jour avec tous les simples changements dans le système. On notera également que s'il a un problème dans le serveur principal, tout le système tombe en panne[141].

4.2.2 Système de gestion d'énergie décentralisé

La stratégie EMS décentralisée vise à atteindre le fonctionnement optimal d'un microgrid, en offrant la plus grande autonomie possible aux différentes sources en connectant chaque source d'énergie à son propre contrôleur, afin d'optimiser la production d'énergie indépendamment pour toutes les sources[142]. Ces dernières années, des approches décen tralisées de gestion d'énergie ont été mises en œuvre avec succès dans les microgrids[143, 144]. L'avantage principal de cette architecture est que la gestion partielle de microgrids rend le système plus sécurisé en cas de dysfonctionnement d'une partie du microgrid. De plus, en raison du développement récent des microcontrôleurs et de la diminution importante de leur coût.

L'architecture décentralisée EMS peut réduire le coût d'investissement par rapport à une approche centralisée. Les approches décentralisées ont été principalement abordées dans la littérature technique en utilisant le cadre des Systèmes Multi Agents (MAS), qui sont des systèmes intelligents de gestion d'énergie pour les microgrids[145]. Cette stratégie maintient l'équilibre de puissance entre les charges et les sources par l'utilisation des données de production et de demandes des charges électriques.

Récemment, plusieurs auteurs ont appliqué l'approche de MAS pour la gestion d'energie. Dans la référence [146] Boudoudouh et Maâroufi ont proposé un MAS pour la gestion d'énergie au sein de microgrid. Les simulations ont été exécutées à l'aide du logiciel Matlab-Simulink et java pour les développeurs d'agents (JADE). La fiabilité de ce modèle a été validée en remplissant des exigences telles que son autonomie et sa flexibilité, de manière à ce que les modifications apportées ne puissent perturber l'ensemble du système de stratégie de contrôle. Une autre approche de MAS proposée dans[147] pour un microgrid afin d'obtenir une utilisation optimale des sources distribuées avec un niveau de production maximal utilisant des sources renouvelables et une consommation de diesel optimale. Dans la référence [148], l'approche MAS a été appliquée pour un micro-

grid pour la planification de la production et la gestion de la demande. Ces publications montrent l'efficacité du MAS dans la gestion d'energie pour les microgrids. Dans ce chapitre, un système de gestion de l'énergie pour un microgrid a été implémenté, basé sur la maximisation de production des sources renouvelables par l'approche MAS, et le contrôle du convertisseur DC / DC bidirectionnel en utilisant ANNC.

4.3 Gestion de l'énergie en temps réel pour DC Microgrid en utilisant les multi agents.

Le microgrid utilisé est constitué de deux sources d'énergie renouvelable (système solaire photovoltaïque et éolienne) et connecté au Bus du microgrid à travers des convertisseurs DC/DC pour implémenter les MPPT de chaque source. Un système de secours composé d'une batterie Li-ion et d'un réseau électrique, avec un système de management d'énergie comme le montre la Figure 4.1.

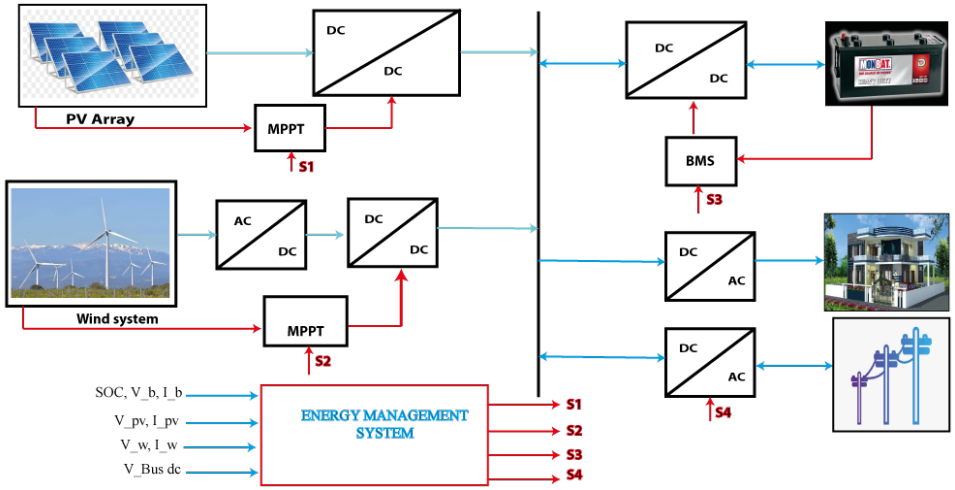


FIGURE 4.1 – Système de gestion de l'énergie proposé

Le système de gestion d'énergie proposé dans cette contribution est basé sur l'extraction maximale d'énergie des sources renouvelables, en les faisant fonctionner en mode

Maximum Power Point Tracking (MPPT), ces deux algorithmes MPPT sont implémentés avec Multi-Agent Système. De plus, la gestion de l'énergie stockée dans la batterie se fait par le contrôle optimal de la charge et de la décharge de la batterie à l'aide de Contrôleurs de Réseau de Neurones Artificiels (ANNC). L'objectif principal de ce système est de maintenir l'équilibre de puissance dans le microgrid et de fournir un contrôle configurable et flexible pour les différents scénarios de toutes sortes de variations. Tous les composants du système sont modélisés en Matlab / Simulink. Le système MAS a été développé en utilisant JADE et MACSIMJX a été utilisé pour assurer la communication entre Simulink et JADE.

4.3.1 Système de stockage de batterie

Le système de stockage de batterie se compose d'une batterie Li-ion et d'un convertisseur DC-DC bidirectionnel. Ce convertisseur est responsable de la stabilisation de la tension DC Bus via un contrôleur ANNC comme indiqué sur la Figure 4.2.

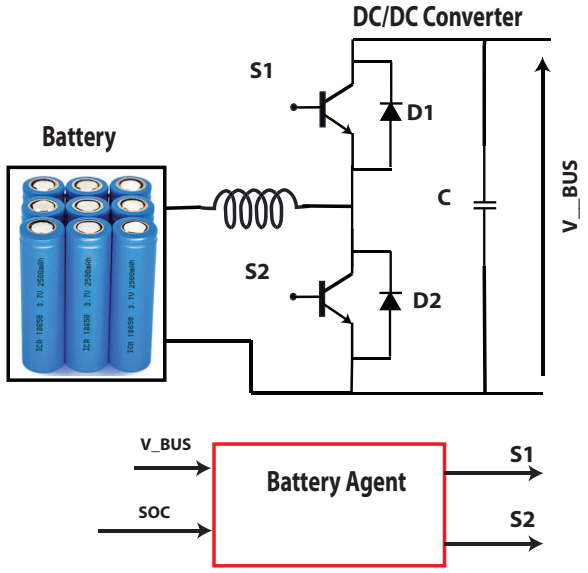


FIGURE 4.2 – Système de stockage d'énergie par batterie pour microgrid

Comme nous l'avons vu précédemment, les batteries lithium-ion sont les sources

d'alimentation préférées pour de nombreuses applications en raison de leurs avantages par rapport aux autres types de batteries. Malgré tous les avantages des batteries Li-ion, elles nécessitent un soin particulier contrairement aux autres types. La surcharge/décharge est la principale raison derrière la plupart des accidents d'explosion des batteries Li-ion. Par conséquent, un système de gestion de batterie est important pour un fonctionnement sécurisé du microgrid. La fonctionnalité principale du système de stockage d'énergie par batterie dans ce microgrid est de stabiliser la tension au Bus DC. L'organigramme suivant montre la stratégie de contrôle du système de stockage d'énergie.

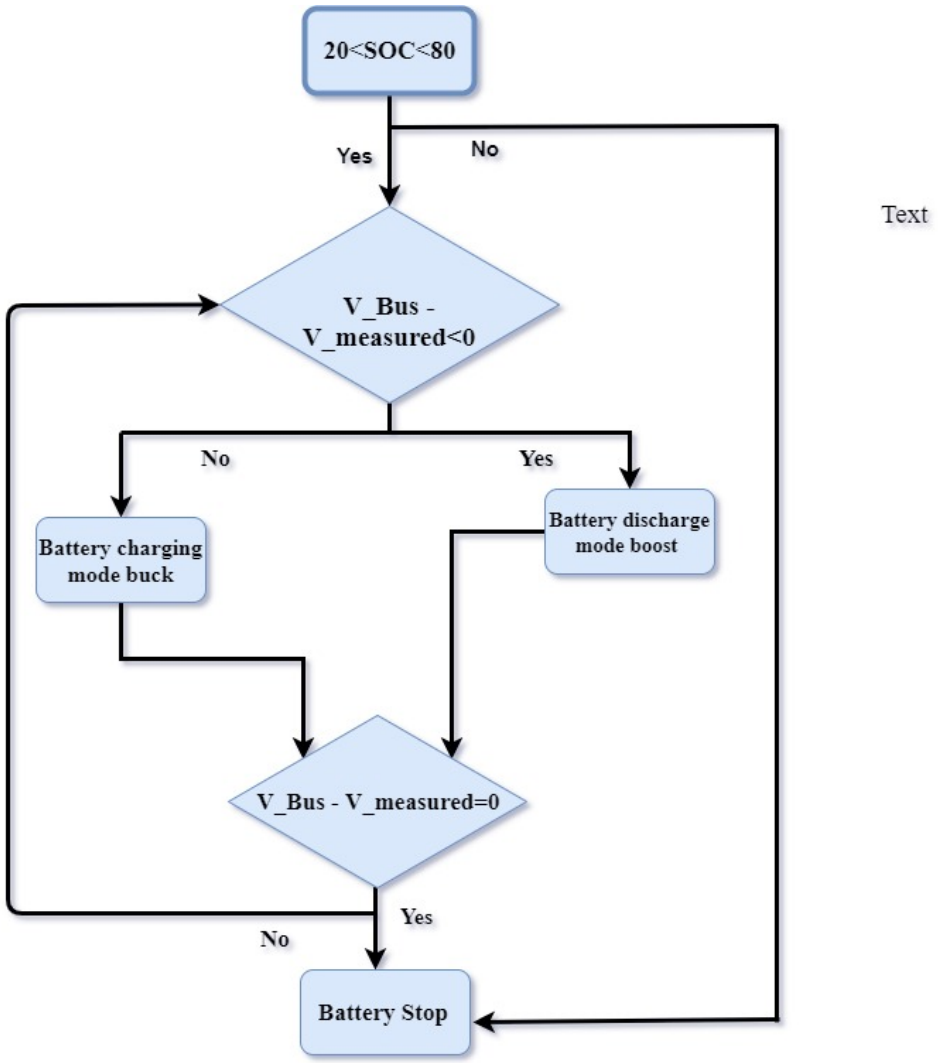


FIGURE 4.3 – Stratégie de contrôle du système d'énergie de batterie

4.3.2 Multi-Agent Système MAS

Les systèmes multi-agents MAS sont un type spécifique de systèmes intelligents distribués, composés d'un ensemble d'agents, situés dans un certain environnement et interagissant selon certaines relations. Un agent est une entité caractérisée par le fait qu'elle est, au moins partiellement, autonome[149]. Le parallélisme dans l'interaction des agents est le principal avantage de la SMA. Il permet de résoudre le problème du parallélisme

de la modélisation de la S-fonction de Matlab Simulink. Nous avons utilisé le logiciel JADE pour le développement et la simulation de stratégie de contrôle et la plate-forme MacsimJX pour la communication entre Matlab/simulink et JADE comme illustré sur la Figure 4.4.

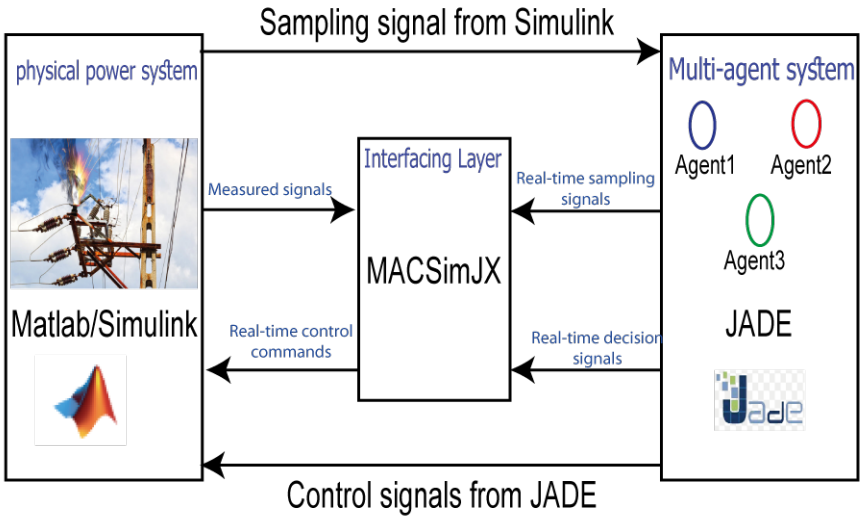


FIGURE 4.4 – L'interface MacsimJX de co-simulation

L'objet principal de ce travail est le contrôle de tous les convertisseurs du système par l'approche de multiagents système. Cinq agents sont utilisés : agent PV MPPT, agent Wind MPPT, agent de charge, agent de batterie et agent de réseau électrique. La description de la tâche de chaque agent est présentée dans le tableau 4.1.

4.3.3 Simulation et discussion des résultats

Le tableau 4.2 présente la description du microgrid étudié. L'électricité produite par les sources renouvelables n'est pas stable dans le temps en raison de l'intermittence de ces dernières. Par conséquent, deux modes de traitement différents apparaissent : le surplus et le manque d'énergie au niveau du DCBus.

TABLEAU 4.1 – Description des tâches de chaque agent du microgrid

Agents	La description des tâches
MPPT agent de panneau photovoltaïque	Calcul de puissance produite par le panneau.
	Application de l'algorithme P and O.
	Envoi des valeurs de rapport cyclique au bloc PWM pour la génération du contrôle du signal.
	Communication avec les autres agents.
MPPT agent de turbine éolienne	Calcul de puissance produite par la turbine éolienne.
	Application de l'algorithme P and O.
	Envoi des valeurs de rapport cyclique au bloc PWM pour la génération du contrôle du signal.
	Communication avec les autres agents.
Les agents de la batterie	Recevoir la valeur de l'état de charge SOC et la valeur de tension au BUS DC.
	Calcul de la puissance de produite par la batterie.
	Comparaison de la valeur de tension de référence et de tension au DC BUS pour la génération du signal de rapport cyclique pour le convertisseur DC-DC bidirectionnel.
	Communication avec les autres agents
Agent de réseau électrique	Recevoir la valeur de puissance produite par le microgrid et la valeur d'état de charge.
	Envoi du signal de commande pour connecter le microgrid au réseau pour les deux utilisations : recevoir le surplus ou donner de l'énergie au DC BUS.

TABLEAU 4.2 – Description du microgrid

SYMBOL	Specification
DC_BUS	V=220v ; P=15KW
Battery	V=48V ; Q_batt= 320
PV PANEL	P_pv=14kW, V_pv=40V
Wind turbin	P_W= 14KW,
Load	P_Ldc +P_LAC =15KW
Electrical GRID	P_grid=15KW

La simulation se déroule pendant 7 secondes avec un temps d'échantillonnage de $(1e-5s)$. Afin de tester l'EMS pour différentes valeurs d'irradiation solaire et de vitesse du vent comme le montre la Figure 4.5 et Figure 4.6.

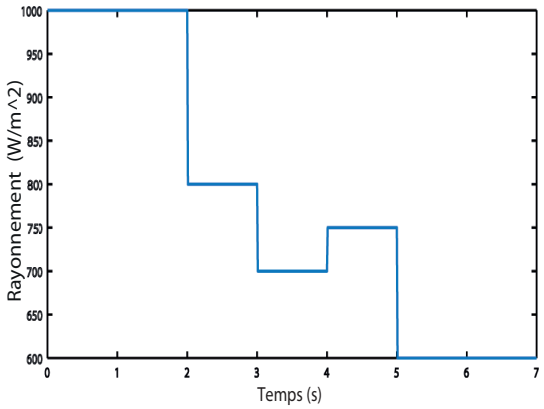


FIGURE 4.5 – Scénario d'irradiation

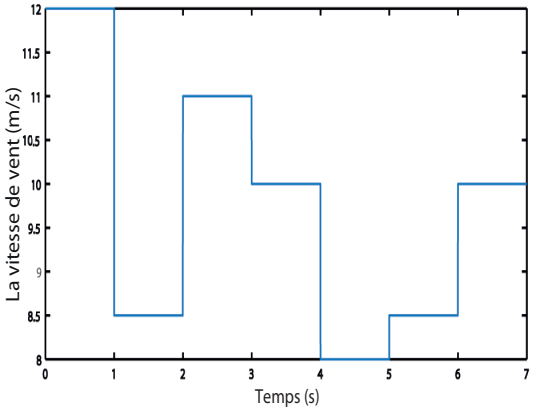


FIGURE 4.6 – Scénario de vitesse de vent

Au début de la simulation(1 à 2s), la puissance produite par le panneau photovoltaïque est $(14KW)$ (Figure 4.7), et par la turbine éolienne est $(6KW)$(Figure 4.8). En effet, la puissance nécessaire dans le microgrid est $(15kw)$, cela signifie qu'on a un surplus de $(5KW)$ dans le bus du microgrid.

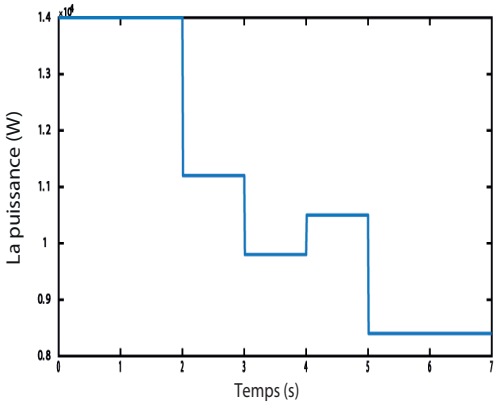


FIGURE 4.7 – La puissance de PV

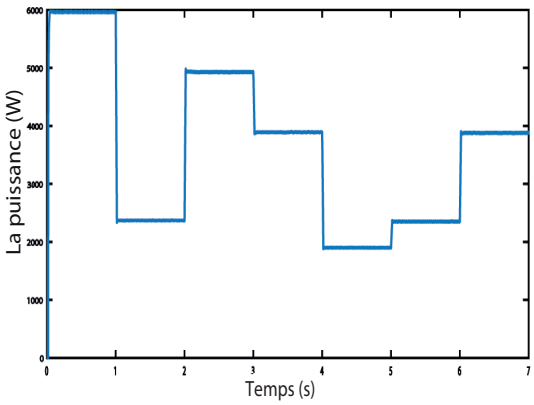


FIGURE 4.8 – La puissance d'éolienne

La batterie est dans la zone de sécurité, car son SOC est d'environ 70% . Donc, le surplus d'énergie sera stocké dans la batterie, qui se traduit par une croissance de la courbe d'état de charge (Figure 4.9).

La Figure 4.10 illustre que la puissance de la batterie est $(-5KW)$, cela signifie que la batterie reçoit une quantité d'énergie d'environ $(5KW)$.

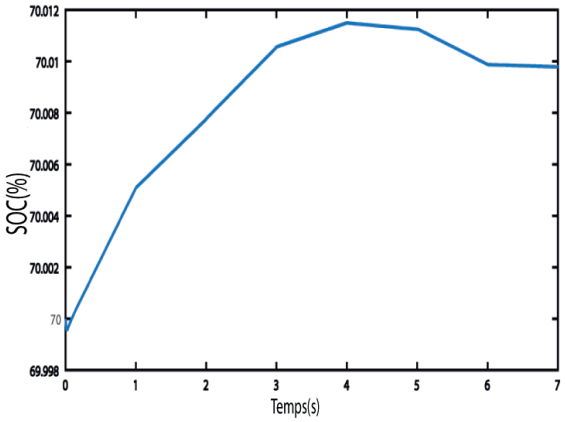


FIGURE 4.9 – Etat de charge de la batterie

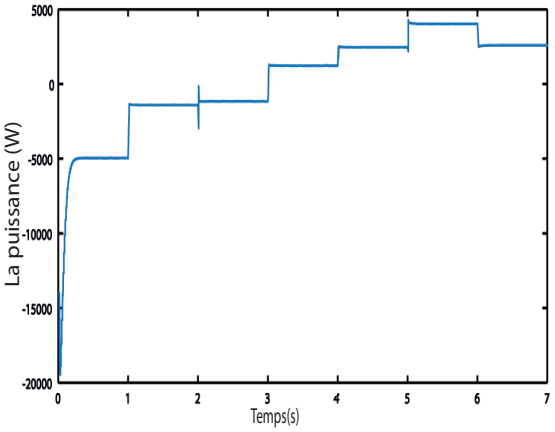


FIGURE 4.10 – La puissance de la batterie

De (1 à 4 s), on remarque que la puissance produite par les sources renouvelables décroît, ce qui résulte moins de surplus dans le bus du microgrid, cela traduit par un chargement de la batterie avec une pente moin faible que celle du début de la simulation.

A(t=4 s) la puissance produite par les sources renouvelables décroît vers $(12KW)$, cela signifie qu'on a un besoin d'énergie dans le bus du microgrid. Ce besoin a été couvert par la batterie comme illustré sur la Figure 4.9.

Malgré le degré élevé de non linéarité du système en raison de l'utilisation de plusieurs sources d'énergies renouvelables et les changements brutaux dans les scénarios proposés des conditions météorologiques, on constate que la tension du bus est stable dans la tension de référence comme le montre la Figure 4.11.

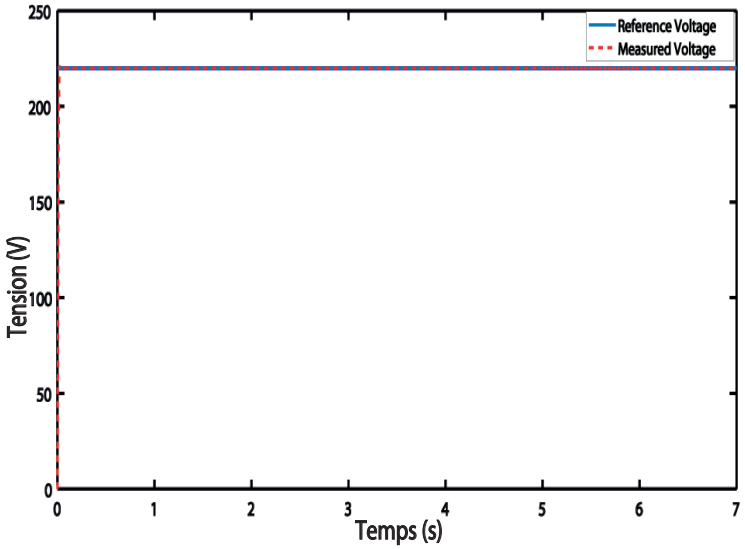


FIGURE 4.11 – Comparaison entre la tension mesurée et la tension de référence

La Figure 4.12 montre la comparaison entre la puissance produite par le microgrid, et la puissance demandée par les charges électriques.

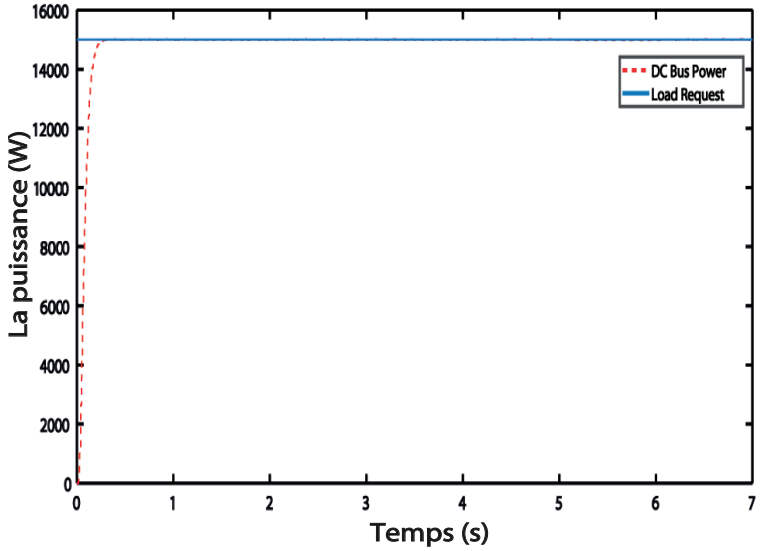


FIGURE 4.12 – Comparaison entre la puissance demandée et la puissance du système produite

On constate que malgré les surplus et les besoins d'énergie dans le bus DC de micro-grid, la puissance est toujours stable sur $(15KW)$.

Les résultats obtenus montrent l'efficacité et la robustesse de notre système de gestion d'énergie face à tous les changements brutaux des conditions météorologiques.

4.4 Conclusion

Nous avons consacré ce chapitre pour la gestion d'énergie au sein du microgrid. Dans cette contribution, nous avons implémenté une stratégie intelligente pour la gestion d'énergie d'un microgrid constitué par plusieurs sources d'énergie. La stratégie de gestion intelligente basée sur l'utilisation de concepts intelligents de multi-agents système et les réseaux de neurone. L'objectif principal de cette contribution était toujours de garantir une utilisation optimale pour la batterie, en plus de maximiser la production d'énergie de chaque source.

CONCLUSION GÉNÉRALE

Les travaux réalisés dans cette thèse consistent à développer des solutions permettant d'améliorer l'implémentation de systèmes de stockage d'énergie par batterie au lithium pour les microgrids DC. Afin d'atteindre cet objectif, nous avons présenté une étude bibliographique qui présente le contexte général de thèse. D'après cette étude bibliographique, nous avons trouvé plusieurs limitations liées à la sécurité de la batterie. Dans cette thèse, nous avons proposé plusieurs solutions pour surmonter ces limitations et assurer la sécurité de la batterie durant son implémentation aux microgrids.

Dans un premier temps, nous avons proposé plusieurs solutions, parmi eux on cite les contributions suivantes :

— Dans la première contribution, nous avons développé le modèle générique de la batterie, par intégration de l'effet de température dans les paramètres internes de ce modèle à l'aide des Réseaux de Neurones Artificial (RNA). Les résultats de simulation montrent que l'intégration de température dans les paramètres interne de ce modèle, augmente la similarité entre la réponse du modèle générique développé et le modèle expérimental [56].

— Dans la deuxième contribution, nous avons proposé un nouveau modèle de la batterie, le modèle proposé est de type boîte noire, il a été conçu à l'aide d'un réseau de neurones du type NARX. D'après la comparaison des résultats de ce modèle avec le modèle générique de la batterie et le modèle expérimental, nous avons trouvé que la réponse de notre modèle est plus proche du modèle expérimental

[59].

— Dans la troisième contribution, nous avons développé un modèle hybride de la batterie Li-ion, ce modèle est composé d'une combinaison de deux réseaux de neurones de types différents NARX et FFNN. Le premier réseau pour la modélisation de la batterie, et le deuxième pour l'estimation d'état de charge SOC. Les résultats de simulation montrent que l'intégration de l'effet de la température et d'état de charge SOC dans la modélisation de la batterie est très importante, car nous avons trouvé une grande similitude entre le modèle proposé et le modèle expérimental [35].

.

En outre, nous avons proposé des structures et développé des algorithmes de gestion d'énergie et de protection de la batterie dans les microgrids. Les solutions proposées sont résumées dans les contributions suivantes :

— Dans la première contribution, nous avons proposé un contrôleur ANNC, pour contrôler le convertisseur bidirectionnel, afin de superviser la batterie, avec un EMS pour assurer l'équilibre de puissance dans le Bus du microgrid autonome, durant toute la phase de fonctionnement, mais nous avons remarqué des pertes au niveau de ce système[132].

— Dans la deuxième contribution, nous avons développé l'algorithme de gestion d'énergie et le système électrique par la connexion de ce microgrid avec le réseau électrique, afin de minimiser les pertes et maximiser l'utilisation d'énergie solaire. Les résultats de simulation obtenus ont montré l'utilité de ce système, dans la gestion et la supervision de la batterie lors de son utilisation dans les microgrids sous plusieurs conditions météorologiques [136].

— Dans la troisième contribution, nous avons implémenté une stratégie intelligente pour la gestion d'énergie d'un microgrid constitué par plusieurs sources d'énergie. La stratégie de gestion que nous avons utilisé est basée sur l'utilisation de concepts

intelligents de multi-agents système et les réseaux de neurone. Afin de garantir une utilisation optimale pour la batterie, en plus de maximiser la production d'énergie de chaque sources.

Les résultats des travaux de cette thèse peuvent être améliorés en envisageant les perspectives suivantes :

- La validation expérimentale des modèles proposés pour la batterie, et l'application de ces modèles dans un microgrid pour tester l'efficacité de ce modèle avec des conditions réelles ;
- La détermination de la température interne de la batterie et l'intégration de son effet aux modèles de la batterie ;
- La validation expérimentale du contrôleur ANNC, et le test de son efficacité avec systèmes non linéaires plus compliqués ;
- L'utilisation d'autres logiciels pour le développement des systèmes multiagents, afin de résoudre le problème de l'incompatibilité des nouvelles versions de Matlab/Simulink avec le logiciel JADE ;

Bibliographie

[1] John Frederic Daniell. X. on voltaic combinations. in a letter addressed to michael faraday, dcl, frs, fullerian prof. chem. royal institution, corr. memb. royal & imp. acadd. of science, paris, petersburgh, &c. by j. frederic daniell, frs, prof. chem. in king's college, london. *Philosophical Transactions of the Royal Society of London*, (126) :107–124, 1836.

[2] Ahmed F Zobaa. *Energy Storage : Technologies and Applications*. BoD–Books on Demand, 2013.

[3] Hussein Ibrahim and Adrian Ilinca. Techno-economic analysis of different energy storage technologies. In *Energy Storage-Technologies and Applications*. IntechOpen, 2013.

[4] Steven C Smith, PK Sen, and Benjamin Kroposki. Advancement of energy storage devices and applications in electrical power system. In *2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century*, pages 1–8. IEEE, 2008.

[5] Alessandro %J Philosophical transactions of the Royal Society of London Volta. Xvii. on the electricity excited by the mere contact of conducting substances of different kinds. in a letter from mr. alexander volta, frs professor of natural philosophy in the university of pavia, to the rt. hon. sir joseph banks, bart. kbpr s. (90) :403–431, 1800.

[6] Gaston Planté. *Recherches sur l'électricité de 1859 à 1879*. Gauthier-Villars, 1883.

[7] Ernst Waldemar Jungner. Reversible galvanic battery., September 1 1903. US Patent 738,110.

[8] Howard E Rhodes. Alkaline primary cell, May 30 1950. US Patent 2,509,249.

[9] Lewis F Urry, William L Kennedy, and Howard M Brown. Leak-resistant dry cell, April 26 1955. US Patent 2,707,200.

[10] Neil Gregor. *Daimler-Benz in the Third Reich*. Yale University Press, 1998.

[11] AG Volkswagen. *Unregulated motor vehicle exhaust gas components*. na, 1989.

[12] Tsuyoshi Nakajima and Rachid Yazami. Lithium cell, May 21 1991. US Patent 5,017,444.

[13] Akira Yoshino, Kenichi Sanechika, and Takayuki Nakajima. Secondary battery, May 26 1987. US Patent 4,668,595.

[14] John B Goodenough and Koichi Mizuchima. Electrochemical cell with new fast ion conductors, November 24 1981. US Patent 4,302,518.

[15] J Robert and J %J D Alzieu. Accumulateurs-considérations théoriques, techniques de l'ingénieur, vol. 2004.

[16] Dinh Vinh Do. *Diagnostic de batteries Lithium ion dans les applications embarquées*. Thesis, 2010.

[17] Rongrong Miao, Jun Yang, Xuejiao Feng, Hao Jia, Jiulin Wang, and Yanna %J Journal of Power Sources Nuli. Novel dual-salts electrolyte solution for dendrite-free lithium-metal based rechargeable batteries with high cycle reversibility. 271 :291–297, 2014.

[18] Aurélien Lièvre. *Développement d'un système de gestion de batterie lithium-ion à destination de véhicules" mild hybrid" : détermination des indicateurs d'état (SoC, SoH et SoF)*. Thesis, 2015.

[19] Nicolas Gauthier. *Caractérisation physico-chimique des interfaces électrode/électrolyte dans les accumulateurs lithium-ion constitués d'une anode Li4Ti5O12, de leurs vieillissements et de leurs interactions : Analyse complémentaire par XPS, ToF-SIMS et AES*. Thesis, 2019.

[20] Selvaraj Mohana Roopan and Rajesh %J Electrochemical Sompalle. Review on outlook of coating materials for li-ion battery. 8 :12–28, 2016.

[21] Pier Paolo Prosini, Daniela Zane, and Mauro %J Electrochimica acta Pasquali. Improved electrochemical performance of a lifepo4-based composite cathode. 46(23) :3517–3523, 2001.

[22] Aïssa BOUTTE. *Identification des paramètres internes d'une batterie Pour des applications photovoltaïques*. PhD thesis, University of sciences and technology in Oran, 2015.

[23]

[24] Mohammad A Hannan, MS Hossain Lipu, Aini Hussain, and Azah Mohamed. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications : Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 78 :834–854, 2017.

[25] Feng Leng, Cher Ming Tan, and Michael Pecht. Effect of temperature on the aging rate of li ion battery operating above room temperature. *Scientific reports*, 5(1) :1–12, 2015.

[26] Jurgen Garche and Andreas Jossen. Battery management systems (bms) for increasing battery life time. In *TELESCON 2000. Third International Telecommunications Energy Special Conference (IEEE Cat. No. 00EX424)*, pages 81–88. IEEE.

[27] Quanyuan Jiang, Meidong Xue, and Guangchao %J IEEE transactions on power systems Geng. Energy management of microgrid in grid-connected and stand-alone modes. 28(3) :3380–3389, 2013.

[28] Ngoc An Luu. *Control and management strategies for a microgrid*. Thesis, 2014.

[29] Estefanía Planas, Jon Andreu, José Ignacio Gárate, Iñigo Martínez De Alegría, Edorta %J Renewable Ibarra, and Sustainable Energy Reviews. Ac and dc technology in microgrids : A review. 43 :726–749, 2015.

[30] Laurent Bridier. *Modélisation et optimisation d'un système de stockage couplé à une production électrique renouvelable intermittente*. Thesis, 2016.

[31] Yimy E García Vera, Rodolfo Dufo-López, and José L Bernal-Agustín. Energy management in microgrids with renewable energy sources : A literature review. *Applied Sciences*, 9(18) :3854, 2019.

[32] Wencong Su and Jianhui Wang. Energy management systems in microgrid operations. *The Electricity Journal*, 25(8) :45–60, 2012.

[33] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4) :115–133, 1943.

[34] saurbah mhatre. *What Is The Relation Between Artificial And Biological Neuron*, 2021 (accessed january 2, 2021).

[35] Younes Boujoudar, Hassan Elmoussaoui, and Tijani Lamhamdi. Lithium-ion batteries modeling and state of charge estimation using artificial neural network. *International Journal of Electrical & Computer Engineering (2088-8708)*, 9, 2019.

[36] Youcef DJERIRI et al. *Commande directe du couple et des puissances d'une MADA associée à un système éolien par les techniques de l'intelligence artificielle*. PhD thesis, 2015.

[37] Erik M Johansson, Farid U Dowla, and Dennis M Goodman. Backpropagation learning for multilayer feed-forward neural networks using the conjugate gradient method. *International Journal of Neural Systems*, 2(04) :291–301, 1991.

[38] Horace B Barlow. Unsupervised learning. *Neural computation*, 1(3) :295–311, 1989.

[39] Mohamed Yessin Ammar. *Mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition batch/continu*. PhD thesis, 2007.

[40] Sheng Shui A review on the separators of liquid electrolyte li-ion batteries. 164(1) :351–364, 2007.

[41] Christopher Marc Doyle. Design and simulation of lithium rechargeable batteries. 1995.

[42] Marc Doyle, John Newman, Antoni S Gozdz, Caroline N Schmutz, and Jean-Marie %J Journal of the Electrochemical Society Tarascon. Comparison of modeling predictions with experimental data from plastic lithium ion cells. 143(6) :1890, 1996.

[43] Matthieu Urbain. *Modélisation électrique et énergétique des accumulateurs Li-Ion. Estimation en ligne de la SOC et de la SOH*. Thesis, 2009.

[44] VH %J Journal of power sources Johnson. Battery performance models in advisor. 110(2) :321–329, 2002.

[45] Ronan German, N Solis, L Reyes, L Silva, F-A LeBel, João P Trovão, and A Bouscayrol. Coupled electric and thermal batteries models using energetic macroscopic representation (emr) for range estimation in electric vehicles. In *2017 19th European Conference on Power Electronics and Applications (EPE'17 ECCE Europe)*, pages P. 1–P. 8. IEEE.

[46] Matthias Dürr, Andrew Cruden, Sinclair Gair, and JR %J Journal of power Sources McDonald. Dynamic model of a lead acid battery for use in a domestic fuel cell system. 161(2) :1400–1411, 2006.

[47] HL Chan. A new battery model for use with battery energy storage systems and electric vehicles power systems. In *2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No. 00CH37077)*, volume 1, pages 470–475. IEEE.

[48] Shuo Pang, Jay Farrell, Jie Du, and Matthew Barth. Battery state-of-charge estimation. In *Proceedings of the 2001 American control conference.(Cat. No. 01CH37148)*, volume 2, pages 1644–1649. IEEE.

[49] Hongwen He, Rui Xiong, and Jinxin %J energies Fan. Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach. 4(4) :582–598, 2011.

[50] Ziyad M Salameh, Margaret A Casacca, and William A %J IEEE Transactions on Energy Conversion Lynch. A mathematical model for lead-acid batteries. 7(1) :93–98, 1992.

[51] Aïssa BOUTTE. *Identification des paramètres internes d'une batterie Pour des applications photovoltaïques*. Thesis, 2015.

[52] Min Chen and Gabriel A %J IEEE transactions on energy conversion Rincon-Mora. Accurate electrical battery model capable of predicting runtime and iv performance. 21(2) :504–511, 2006.

[53] Clarence M %J Journal of the Electrochemical Society Shepherd. Design of primary and secondary cells : Ii. an equation describing battery discharge. 112(7) :657, 1965.

[54] Olivier Tremblay, Louis-A Dessaint, and Abdel-Illah Dekkiche. A generic battery model for the dynamic simulation of hybrid electric vehicles. In *2007 IEEE Vehicle Power and Propulsion Conference*, pages 284–289. Ieee.

[55] Olivier Tremblay and Louis-A %J World electric vehicle journal Dessaint. Experimental validation of a battery dynamic model for ev applications. 3(2) :289–298, 2009.

[56] Youness Boujoudar, Hanane Hemi, Hassan El Moussaoui, Hassane El Markhi, and Tijani Lamhamdi. Li-ion battery parameters estimation using neural networks. In *2017 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS)*, pages 1–4. IEEE, 2017.

[57] B. Saha and K. Goebel. *Battery Data Set*, 2021 (accessed january 3, 2021).

[58] Srikar Geethaprabhu Beechu. Development of lithium ion battery dynamic model. 2016.

[59] Younes Boujoudar, Hassan Elmoussaoui, and Tijani Lamhamdi. Lithium-ion batteries modeling using narx nonlinear model. In *2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS)*, pages 1–6. IEEE, 2019.

[60] Gary Hunt et al. Usabc electric vehicle battery test procedures manual. *Washington, DC, USA : United States Department of Energy*, 1996.

[61] Yinjiao Xing, Wei He, Michael Pecht, and Kwok Leung Tsui. State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. *Applied Energy*, 113 :106–115, 2014.

[62] Wei He, Nicholas Williard, Chaochao Chen, and Michael 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*, 62 :783–791, 2014.

[63] Anthony TC Goh. Back-propagation neural networks for modeling complex systems. *Artificial intelligence in engineering*, 9(3) :143–151, 1995.

[64] Martin T Hagan and Mohammad B Menhaj. Training feedforward networks with the marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6) :989–993, 1994.

[65] Kong Soon Ng, Chin-Sien Moo, Yi-Ping Chen, and Yao-Ching Hsieh. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied energy*, 86(9) :1506–1511, 2009.

[66] Kong Soon Ng, Chin-Sien Moo, Yi-Ping Chen, and Yao-Ching %J Applied energy Hsieh. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. 86(9) :1506–1511, 2009.

[67] Seonwoo Jeon, Jae Jung Yun, Sungwoo %J Indian Journal of Science Bae, and Technology. Comparative study on the battery state-of-charge estimation method. 8(26) :IPL0524, 2015.

[68] Yinjiao Xing, Wei He, Michael Pecht, and Kwok Leung %J Applied Energy Tsui. State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. 113 :106–115, 2014.

[69] Kong-Soon Ng, Chin-Sien Moo, Yi-Ping Chen, and Yao-Ching Hsieh. State-of-charge estimation for lead-acid batteries based on dynamic open-circuit voltage. In *2008 IEEE 2nd International Power and Energy Conference*, pages 972–976. IEEE.

[70] Lei Pei, Rengui Lu, and Chunbo %J IET Electrical Systems in Transportation Zhu. Relaxation model of the open-circuit voltage for state-of-charge estimation in lithium-ion batteries. 3(4) :112–117, 2013.

[71] Mingyue Zhang and Xiaobin %J World Electric Vehicle Journal Fan. Review on the state of charge estimation methods for electric vehicle battery. 11(1) :23, 2020.

[72] Il-Song %J Journal of Power Sources Kim. The novel state of charge estimation method for lithium battery using sliding mode observer. 163(1) :584–590, 2006.

[73] Fei Zhang, Guangjun Liu, and Lijin Fang. A battery state of charge estimation method using sliding mode observer. In *2008 7th world congress on intelligent control and automation*, pages 989–994. IEEE.

[74] Gregory L %J Journal of power sources Plett. Extended kalman filtering for battery management systems of lipb-based hev battery packs : Part 2. modeling and identification. 134(2) :262–276, 2004.

[75] Gregory L %J Journal of Power sources Plett. Extended kalman filtering for battery management systems of lipb-based hev battery packs : Part 3. state and parameter estimation. 134(2) :277–292, 2004.

[76] Dinh Vinh Do, Christophe Forgez, KEK Benkara, and Guy Friedrich. Surveillance temps reel de batterie li ion. In *Conference EF ; UTC, Compiegne*.

[77] Bikramjit S Bhangu, Paul Bentley, David A Stone, and Christopher M %J IEEE transactions on vehicular technology Bingham. Nonlinear observers for predicting state-of-charge and state-of-health of lead-acid batteries for hybrid-electric vehicles. 54(3) :783–794, 2005.

[78] Achille Murangira. *Nouvelles approches en filtrage particulaire. Application au recalage de la navigation inertielle*. Thesis, 2014.

[79] Shriram Santhanagopalan and Ralph E %J International Journal of Energy Research White. State of charge estimation using an unscented filter for high power lithium ion cells. 34(2) :152–163, 2010.

[80] Fengchun Sun, Xiaosong Hu, Yuan Zou, and Siguang %J Energy Li. Adaptive unscented kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles. 36(5) :3531–3540, 2011.

[81] Seongjun Lee, Jonghoon Kim, Jaemoon Lee, and Bo H %J Journal of power sources Cho. State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge. 185(2) :1367–1373, 2008.

[82] Arijit Guha and Amit %J IEEE Transactions on Transportation Electrification Patra. State of health estimation of lithium-ion batteries using capacity fade and internal resistance growth models. 4(1) :135–146, 2017.

[83] Juan Pablo Rivera-Barrera, Nicolás Muñoz-Galeano, and Henry Omar %J Electronics Sarmiento-Maldonado. Soc estimation for lithium-ion batteries : Review and future challenges. 6(4) :102, 2017.

[84] Juan Carlos Alvarez Anton, Paulino Jose Garcia Nieto, Cecilio Blanco Viejo, and José Antonio Vilán %J IEEE Transactions on power electronics Vilán. Support vector machines used to estimate the battery state of charge. 28(12) :5919–5926, 2013.

[85] JN Hu, JJ Hu, HB Lin, XP Li, CL Jiang, XH Qiu, and WS %J Journal of Power Sources Li. State-of-charge estimation for battery management system using optimized support vector machine for regression. 269 :682–693, 2014.

[86] Terry Hansen and Chia-Jiu %J Journal of Power Sources Wang. Support vector based battery state of charge estimator. 141(2) :351–358, 2005.

[87] Pritpal Singh, Ramana Vinjamuri, Xiquan Wang, and David %J Journal of power sources Reisner. Design and implementation of a fuzzy logic-based state-of-charge meter for li-ion batteries used in portable defibrillators. 162(2) :829–836, 2006.

[88] Alvin J Salkind, Craig Fennie, Pritpal Singh, Terrill Atwater, and David E %J Journal of Power sources Reisner. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. 80(1-2) :293–300, 1999.

[89] Jean-Noel Patillon and Olivier Gerard. System for monitoring charging/discharging cycles of a rechargeable battery, and host device including a smart battery, October 20 1998. US Patent 5,825,156.

[90] Akram Eddahech, Olivier Briat, and Jean-Michel Vinassa. Adaptive voltage estimation for ev li-ion cell based on artificial neural networks state-of-charge meter. In *2012 IEEE International Symposium on Industrial Electronics*, pages 1318–1324. IEEE.

[91] S Grewal and DA Grant. A novel technique for modelling the state of charge of lithium ion batteries using artificial neural networks. 2001.

[92] Cheng Bo, Bai Zhifeng, Cao %J Energy conversion Binggang, and management. State of charge estimation based on evolutionary neural network. 49(10) :2788–2794, 2008.

[93] Xuanju Dang, Li Yan, Kai Xu, Xiru Wu, Hui Jiang, and Hanxu %J Electrochimica Acta Sun. Open-circuit voltage-based state of charge estimation of lithium-ion battery using dual neural network fusion battery model. 188 :356–366, 2016.

[94] Fengwu Zhou, Lujun Wang, Huiping Lin, and Zhengyu Lv. High accuracy state-of-charge online estimation of ev/hev lithium batteries based on adaptive wavelet neural network. In *2013 IEEE ECCE Asia Downunder*, pages 513–517. IEEE.

[95] Mohammad A Hannan, MS Hossain Lipu, Aini Hussain, Azah %J Renewable Mohamed, and Sustainable Energy Reviews. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications : Challenges and recommendations. 78 :834–854, 2017.

[96] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20(3) :273–297, 1995.

[97] Wei He, Nicholas Williard, Chaochao Chen, Michael %J International Journal of Electrical Power Pecht, and Energy Systems. State of charge estimation for li-ion batteries using neural network modeling and unscented kalman filter-based error cancellation. 62 :783–791, 2014.

[98] Mohammad Charkhgard and Mohammad %J IEEE transactions on industrial electronics Farrokhi. State-of-charge estimation for lithium-ion batteries using neural networks and ekf. 57(12) :4178–4187, 2010.

[99] Younes Boujoudar, Hassan Elmoussaoui, Tijani %J International Journal of Electrical Lamhamdi, and Computer Engineering. Lithium-ion batteries modeling and state of charge estimation using artificial neural network. 9, 2019.

[100] Mohamed Azeroual, Aboubakr El Makrini, Hassan El Moussaoui, and Hassane EL MARKHI. Renewable energy potential and available capacity for wind and solar power in morocco towards 2030. *Journal of Engineering Science & Technology Review*, 11(1), 2018.

[101] Agustín Agüera-Pérez, José Carlos Palomares-Salas, Juan José González de la Rosa, and Olivia Florencias-Oliveros. Weather forecasts for microgrid energy management : Review, discussion and recommendations. *Applied Energy*, 228 :265–278, 2018.

[102] Biao Zhao, Qingguang Yu, and Weixin Sun. Extended-phase-shift control of isolated bidirectional dc–dc converter for power distribution in microgrid. *IEEE Transactions on power electronics*, 27(11) :4667–4680, 2011.

[103] Yuan-Chih Chang, Hao-Chin Chang, and Chien-Yu Huang. Design and implementation of the battery energy storage system in dc micro-grid systems. *Energies*, 11(6) :1566, 2018.

[104] Fatma Keskin Arabul, Ibrahim Senol, Ahmet Yigit Arabul, and Ali Rifat Boynuegri. Providing energy management of a fuel cell-battery hybrid electric vehicle. *World Academy of Science, Engineering and Technology, International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, 9(8) :920–924, 2015.

[105] Woonki Na, Basheer Quattum, Andy Publes, and Vamsipriya Maddipatla. A sliding mode control based multi-functional power converter for electric vehicles and energy applications. In *2013 International Electric Machines & Drives Conference*, pages 742–746. IEEE, 2013.

[106] KC Ramya and V Jegathesan. Comparison of pi and pid controlled bidirectional dc-dc converter systems. *International Journal of Power Electronics and Drive Systems*, 7(1) :56, 2016.

[107] Wang Zhifu, Wang Yupu, and Rong Yinan. Design of closed-loop control system for a bidirectional full bridge dc/dc converter. *Applied Energy*, 194 :617–625, 2017.

[108] H El Fadil and F Giri. Sliding mode control of fuel cell and supercapacitor hybrid energy storage system. *IFAC Proceedings Volumes*, 45(21) :669–674, 2012.

[109] Mustafa Ergin Şahın, Halil İbrahim Okumuş, and Hakan Kahvecı. Sliding mode control of pv powered dc/dc buck-boost converter with digital signal processor. In *2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe)*, pages 1–8. IEEE, 2015.

[110] Aitor Etxeberria, Ionel Vechiu, Haritza Camblong, and J-M Vinassa. Comparison of sliding mode and pi control of a hybrid energy storage system in a microgrid application. *Energy Procedia*, 12 :966–974, 2011.

[111] Teresa Orłowska-Kowalska, Frede Blaabjerg, and José Rodríguez. *Advanced and intelligent control in power electronics and drives*, volume 531. Springer, 2014.

[112] N Chettibi and A Mellit. Intelligent control strategy for a grid connected pv/sofc/bess energy generation system. *Energy*, 147 :239–262, 2018.

[113] T Vigneysh and Narayanan Kumarappan. Artificial neural network based droop-control technique for accurate power sharing in an islanded microgrid. *International Journal of Computational Intelligence Systems*, 9(5) :827–838, 2016.

[114] Weizhen Dong, Shuhui Li, and Xingang Fu. Artificial neural network control of a standalone dc microgrid. In *2018 Clemson University Power Systems Conference (PSC)*, pages 1–5. IEEE, 2018.

[115] Ipsita Das and Moumi Pandit. A comparative analysis of determination of design parameters of boost and buck–boost converters using artificial intelligence. In *Advances in Systems, Control and Automation*, pages 117–125. Springer, 2018.

[116] N Leena and R Shanmugasundaram. Artificial neural network controller for improved performance of brushless dc motor. In *2014 International Conference on Power Signals Control and Computations (EPSCICON)*, pages 1–6. IEEE, 2014.

[117] N Leena and R Shanmugasundaram. Adaptive controller for improved performance of brushless dc motor. In *2012 International Conference on Data Science & Engineering (ICDSE)*, pages 117–122. IEEE, 2012.

[118] Abdulrahim Thiab Humod and Abdullah Sahib Abdulsada. Neural network-based robust automatic voltage regulator (avr) of synchronous generator. *Engineering and Technology Journal*, 29(7), 2011.

[119] Samer Said, Ahmed Massoud, Mohieddine Benammar, and Shehab Ahmed. A matlab/simulink-based photovoltaic array model employing simpowersystems toolbox. *Journal of Energy and Power Engineering*, 6(12) :1965, 2012.

[120] Kamelia Helali. *Modelisation d'une cellule photovoltaique : etude comparative*. PhD thesis, Université Mouloud Mammeri, 2012.

[121] Roberto Faranda and Sonia Leva. Energy comparison of mppt techniques for pv systems. *WSEAS transactions on power systems*, 3(6) :446–455, 2008.

[122] N Femia, D Granozio, G Petrone, G Spagnuolo, and Massimo Vitelli. Optimized one-cycle control in photovoltaic grid connected applications. *IEEE Transactions on Aerospace and Electronic Systems*, 42(3) :954–972, 2006.

[123] Nicola Femia, Giovanni Petrone, Giovanni Spagnuolo, and Massimo Vitelli. A technique for improving p&o mppt performances of double-stage grid-connected photovoltaic systems. *IEEE transactions on industrial electronics*, 56(11) :4473–4482, 2009.

[124] KH Hussein, I Muta, T Hoshino, and Ml Osakada. Maximum photovoltaic power tracking : an algorithm for rapidly changing atmospheric conditions. *IEE Proceedings-Generation, Transmission and Distribution*, 142(1) :59–64, 1995.

[125] Hong Hee Lee, Phan Quoc Dzung, Nguyen Truong Dan Vu, et al. The new maximum power point tracking algorithm using ann-based solar pv systems. In *TENCON 2010-2010 IEEE Region 10 Conference*, pages 2179–2184. IEEE, 2010.

[126] B Bendib, F Krim, H Belmili, MF Almi, and S Boulouma. Advanced fuzzy mppt controller for a stand-alone pv system. *Energy Procedia*, 50(2014) :383–392, 2014.

[127] Cuong Hung Tran, Frédéric Nollet, Najib Essounbouli, and Abdelaziz Hamzaoui. Maximum power point tracking techniques for wind energy systems using three levels boost converter. In *IOP Conf Ser Earth Environ Sci*, volume 154, pages 1–9, 2018.

[128] Jogendra Singh Thongam and Mohand Ouhrouche. Mppt control methods in wind energy conversion systems. *Fundamental and advanced topics in wind power*, (1) :339–360, 2011.

[129] Ibrahem E Atawi, Ahmed M Kassem, and Sherif A Zaid. Modeling, management, and control of an autonomous wind/fuel cell micro-grid system. *Processes*, 7(2) :85, 2019.

[130] Olivier Tremblay, Louis-A Dessaint, and Abdel-Illah Dekkiche. A generic battery model for the dynamic simulation of hybrid electric vehicles. In *2007 IEEE Vehicle Power and Propulsion Conference*, pages 284–289. Ieee, 2007.

[131] Olivier Tremblay and Louis-A Dessaint. Experimental validation of a battery dynamic model for ev applications. *World electric vehicle journal*, 3(2) :289–298, 2009.

[132] Younes Boujoudar, Mohamed Azeroual, Hassan El Moussaoui, and Tijani Lamhamdi. Intelligent controller based energy management for stand-alone power system using artificial neural network. *International Transactions on Electrical Energy Systems*, 30(11) :e12579, 2020.

[133] Moleykutty George and K Prasad Basu. Narma-l2 controlled variable frequency three-phase induction motor drive. *Eur. J. Sci. Res*, 70(1) :98–111, 2012.

[134] Kumpati S Narendra and Snehasis Mukhopadhyay. Adaptive control using neural networks and approximate models. *IEEE Transactions on neural networks*, 8(3) :475–485, 1997.

[135] Shuhui Li, Michael Fairbank, Cameron Johnson, Donald C Wunsch, Eduardo Alonso, and Julio L Proao. Artificial neural networks for control of a grid-connected rectifier/inverter under disturbance, dynamic and power converter switching conditions. *IEEE transactions on neural networks and learning systems*, 25(4) :738–750, 2013.

[136] Younes Boujoudar, Mohamed Azeroual, Hassan Elmoussaoui, and Tijani Lamhamdi. Intelligent control of battery energy storage for microgrid energy management using ann. *International Journal of Electrical and Computer Engineering*, 11(4) :3415, 2021.

[137] Ann-Katrin Gerlach, Daniel Stetter, J Schmid, and Ch Breyer. Pv and wind power-complementary technologies. In *Proc. 26th European Photovoltaic Solar Energy Conference*, volume 2, 2011.

[138] Djamila Rekioua. *Hybrid Renewable Energy Systems : Optimization and Power Management Control*. Springer Nature, 2019.

[139] Bhim Singh, Rohini Sharma, and Seema Kewat. Robust control strategies for syrg-pv and wind-based islanded microgrid. *IEEE Transactions on Industrial Electronics*, 68(4) :3137–3147, 2020.

[140] Lexuan Meng, Eleonora Riva Sanseverino, Adriana Luna, Tomislav Dragicevic, Juan C Vasquez, Josep M %J Renewable Guerrero, and Sustainable Energy Reviews. Microgrid supervisory controllers and energy management systems : A literature review. 60 :1263–1273, 2016.

[141] Christos-Spyridon Karavas, George Kyriakarakos, Konstantinos G Arvanitis, George %J Energy Conversion Papadakis, and Management. A multi-agent decentralized energy management system based on distributed intelligence for the design and control of autonomous polygeneration microgrids. 103 :166–179, 2015.

[142] Rigoberto Jorge Rodriguez, Robert J Zeller, Richard Joseph Skertic, Michael P Dougherty, and Curtis Harvey Cline. Micro grid control system, January 7 2020. US Patent 10,530,163.

[143] Vijay K Sood, Mohammad Y Ali, and Faizan Khan. *Energy Management System of a Microgrid Using Particle Swarm Optimization (PSO) and Communication System*, pages 263–288. Springer, 2020.

[144] Hongjun Gao, Song Xu, Youbo Liu, Lingfeng Wang, Yingmeng Xiang, and Junyong %J Applied Energy Liu. Decentralized optimal operation model for cooperative microgrids considering renewable energy uncertainties. 262 :114579, 2020.

[145] T Bogaraj and J %J Sādhanā Kanakaraj. Intelligent energy management control for independent microgrid. 41(7) :755–769, 2016.

[146] Soukaina Boudoudouh and Mohamed Maâroufi. Multi agent system solution to microgrid implementation. *Sustainable cities and society*, 39 :252–261, 2018.

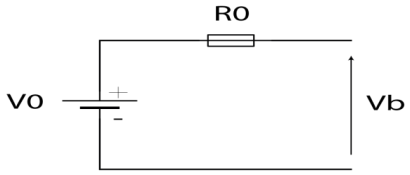
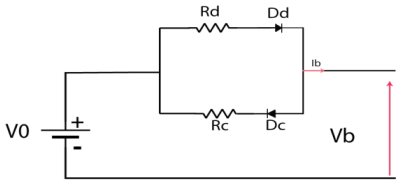
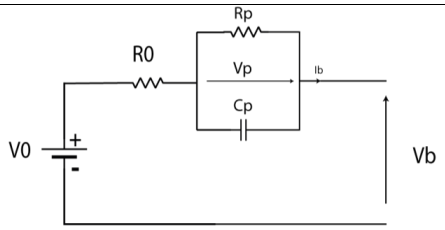
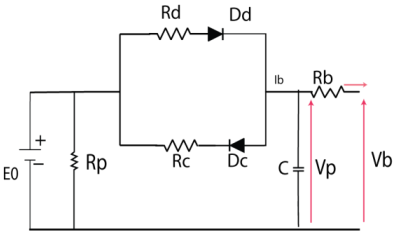
[147] H Nwe Aung, AM Khambadkone, Dipti Srinivasan, and T Logenthiran. Agent-based intelligent control for real-time operation of a microgrid. In *2010 Joint International Conference on Power Electronics, Drives and Energy Systems & 2010 Power India*, pages 1–6. IEEE, 2010.

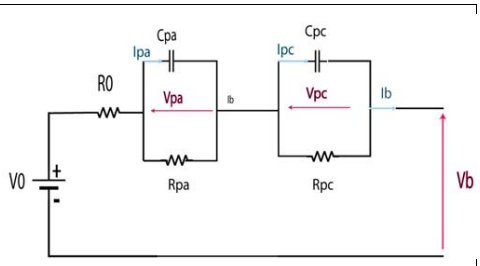
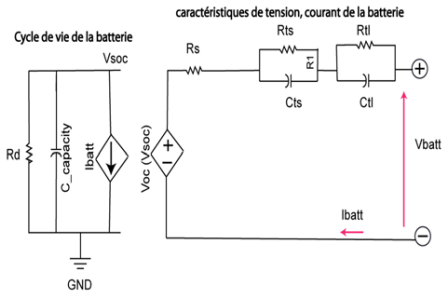
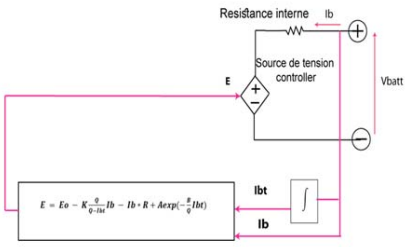
[148] Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M Khambadkone, and Htay Nwe Aung. Multiagent system for real-time operation of a microgrid in real-time digital simulator. *IEEE Transactions on smart grid*, 3(2) :925–933, 2012.

[149] Mihaela Oprea. Applications of multi-agent systems. In *Information technology*, pages 239–270. Springer, 2004.

[150] Chris M Bishop. Training with noise is equivalent to tikhonov regularization. *Neural computation*, 7(1) :108–116, 1995.

4.5 Annex 1

Non de modèle	**Advantage**		**Modèle**
Le modèle simple	Modèle très simple pour l'implémentation	Absence de comportement transitoire	 $Vb = V0 - RO * Ibatt$
Modèle résistif de Thevenin	très simple pour l'implémentation et plus efficace que le modèle simple	Absence de comportement transitoire	
Le modèle de Thevenin	Le comportement transitoire de la batterie a été étudié,	toutes les valeurs des paramètres sont supposées, constantes	
Modified Thevenin Model	. L'état de charge de la batterie peut être facilement calculé sous tension en circuit ouvert.	toutes les valeurs des paramètres sont supposées constantes	
Modèle de double polarisation	améliore les caractéristiques de polarisation ~~en simulant~~	toutes les valeurs des paramètres	

	séparément les effets de concentration et de polarisation électrochimique	sont supposées constantes	
Combined electrical circuit-based model	A battery model capable of predicting both run time and I-V performance and battery life	Très compliqué pour l'implémentation	
Generic based model	très simple pour l'implémentation et précis pour la modélisation de comportement	L'effet d'état de charge et de température n'est pas considéré	

4.6 Annex 2

Modélisation par les réseaux de neurones

La modélisation à l'aide des réseaux de neurones ou bien la modélisation boîte noire est une forme de modélisation réalisé uniquement à partir de données expérimentales ou d'observations pour modéliser des systèmes complexes du fait de leur aspect fortement multi variable et de leur forte non-linéarité[150]. La modélisation par les réseaux de neurones en général doit passer par l'enchaînement des étapes suivantes :

choix d'une base de données

L'apprentissage d'un réseau de neurones nécessite une base de données assez représentative sur l'espace de fonctionnement. Il faut donc déterminer les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser, c'est-à-dire détermination des entrées et sorties de réseau. Afin de développer une application à base de RNA, il est nécessaire d'avoir de deux bases de données, une pour effectuer l'apprentissage et l'autre pour la validation de réseau. Alors il faut séparer la base de données entre la base d'apprentissage, et base de validation. Généralement il n'y a pas une règle précise concernant cette séparation, néanmoins, d'une manière générale la base de validation représente entre 10% et 25% de la base de données.

élaboration d'architecture du réseau

L'architecture du réseau de neurones dépend fortement du type des données utilisé. Il faut d'abord choisir le type de réseau : un réseau de neurones direct, un réseau bouclé, un réseau de Kohonen, un réseau de Hopfield, etc. Il faut aussi les fonctions d'activation pour chaque couche comme nous avons déjà mentionné le choix de la fonction d'activation répondue au degré de complexité de fonction à modéliser. Par la suite il faudra déterminer nombre de neurones pour chaque couche. Dans le cas d'un réseau direct (perception multicouche), le nombre de neurones pour les couches d'entrées, sorties est déterminé par le nombre des entrées sorties du système à modéliser. Il reste juste à déterminer le nombre des couches cachées et le nombre des neurones pour chaque couche. Il n'existe pas, aucune méthode théorique ne permettant de prévoir le nombre nécessaire de couches cachées ou bien le nombre des neurones de chaque couche cachés pour obtenir une performance spécifique du modèle. Pour cette raison la phase d'optimisation est une

phase primordiale après l'étape d'apprentissage.

l'apprentissage de réseau

L'apprentissage est un problème numérique d'optimisation consiste à calculer les poids optimaux des différentes liaisons entre les neurones de réseau, par l'utilisation des échantillons depuis la base d'apprentissage. Après que les deux bases sont créées, et architecture fixée le réseau de neurones devient prêt pour l'apprentissage. L'algorithme de Rétropropagation dans sa forme de base utilise la technique de descente du gradient, celle-ci est parmi la plus simple, mais elle n'est pas très efficace dans le cas général, car elle utilise peu d'information sur la surface de l'erreur[36]. Dans la littérature, on trouve une grande quantité de techniques plus sophistiquées, dont on peut citer quelque une :

— Gradient descendant avec taux d'apprentissage variable.
— Rétropropagation résiliente ;
— L'algorithme du gradient conjugué ;
— L'algorithme de Fletcher Reeves ;
— Algorithme de Quasi-Newton ;
— Algorithme de Levenberg-Marquardt ;

Ce dernier algorithme sera utilisé dans notre travail pour sa rapidité de calcul par rapport à l'algorithme de Rétropropagation classique.

Optimisation et validation de réseau de neurones

La validation de réseau de neurones est évaluation de la capacité de réseau sur des données qui n'ont pas servi à l'apprentissage. Et après si les performances du réseau ne sont pas satisfaisantes, il faudra, soit modifier l'architecture du réseau, soit modifier la base d'apprentissage. La phase d'optimisation est une phase primordiale dans la conception des réseaux de neurones. Il s'agit de trouver le nombre optimal des couches cachées et le nombre de neurones par couches pour que le modèle RNA modélise correctement la fonction désirée. L'objectif principal de cette étape c'est d'éviter les phénomènes de sous apprentissage et le sur apprentissage qui sont les causes principales des mauvaises performances des RNA. Le sous-apprentissage est quand le RNA n'arrive pas encore à capturer les corrélations de l'ensemble d'apprentissage. Par conséquent l'erreur globale du réseau en phase d'apprentissage reste grande. La solution dans ce cas est de modifier l'archi-

tecture de réseau de neurones par ce que les RNA peuvent approximer n'importe qu'elle fonction à condition de mettre suffisamment de neurones dans les couches cachées[36]. Le sur apprentissage est désigné que le réseau de neurones contient plusieurs paramètres pour modélisé une simple fonction, dans ce cas l'erreur globale du système est diminuée toujours, mais durant utilisation des données de la base de validation l'erreur s'augmente. Alors pour éviter le sur apprentissage en peut continuer le changement d'architecture durant l'apprentissage tant que tant que l'erreur de validation diminue si non on n'arrête. La Figure **??** illustre la procédure à suivre durant l'optimisation de réseau pour éviter le sous apprentissage et le sur apprentissage et le

4.7 Annex 3

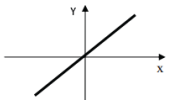
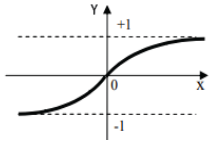
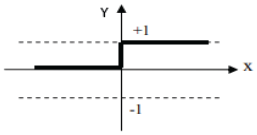
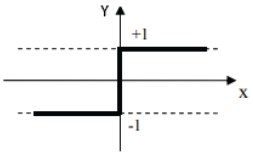
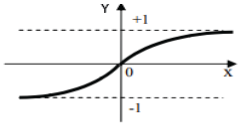
Nom de la fonction	Relation entrée(x) /sortie(y)	Représentation graphique
Linéaire	$Y = x$	
Sigmoïde	$y = \frac{1}{1+\exp -x}$	
Seuil	$y = 0 \quad si \quad x < 0$ $y = 1 \quad si \quad x \geq 0$	
Seuil symétrique	$y = -1 \quad si \quad x < 0$ $y = 1 \quad si \quad x \geq 0$	
Tangente hyperbolique	$y = \frac{\exp x - \exp -x}{\exp x + \exp -x}$	

FIGURE 4.13 – Les fonctions d'activation

4.8 Annex 4

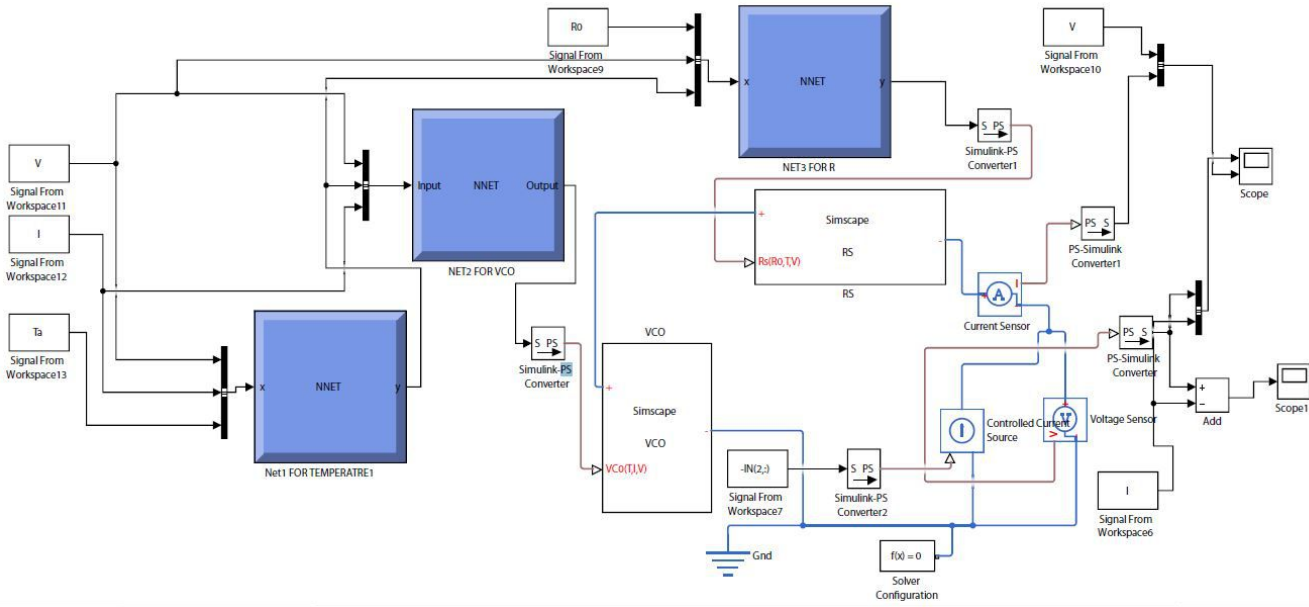


FIGURE 4.14 – Modèle proposé pour la batterie

4.9 Annex 5

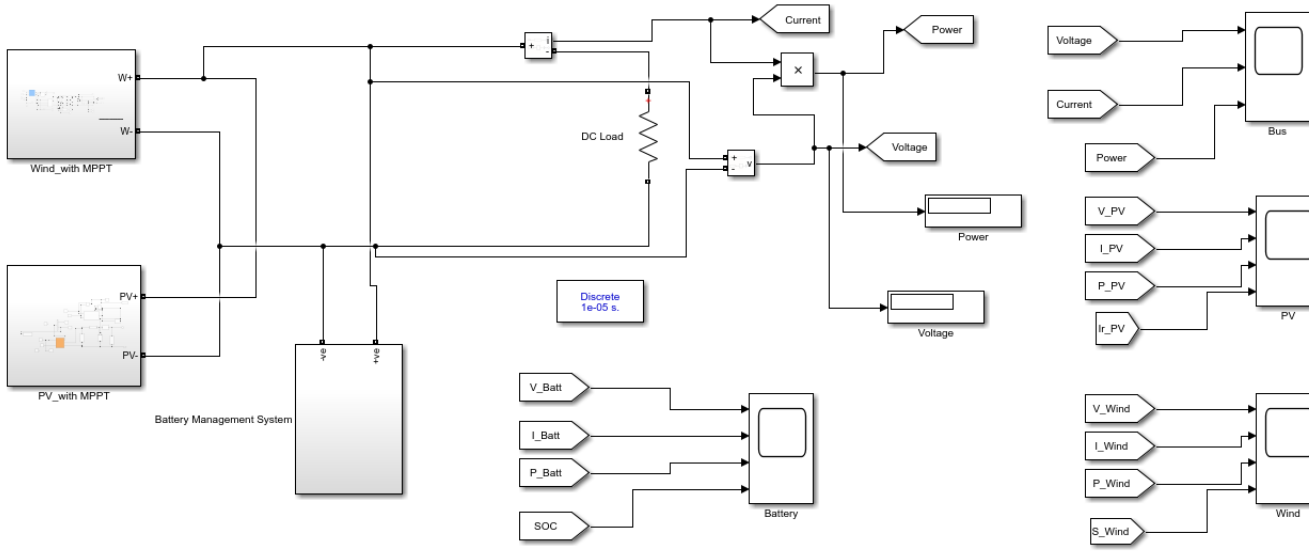


FIGURE 4.15 – Le schéma de microgrid autonome sous Simulink

4.10 Annex 6

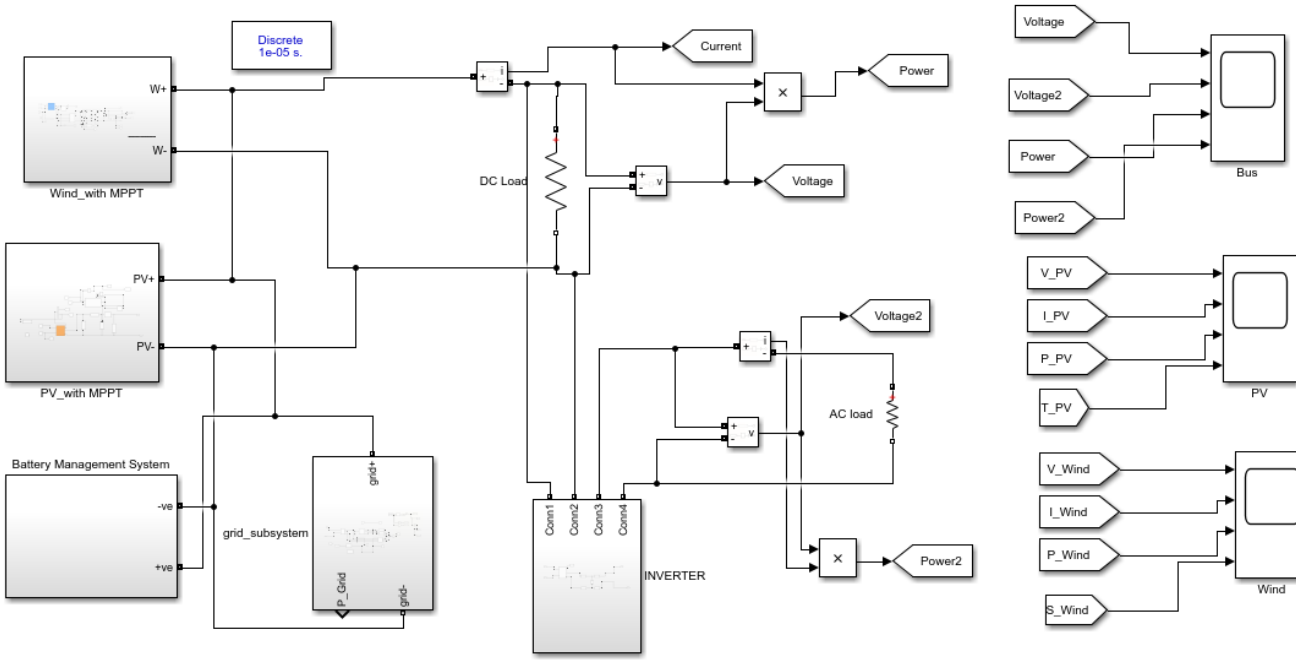


FIGURE 4.16 – Le schéma de microgrid connecté au réseau sous Simulink