

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

الجمهورية الجزائرية الديمقراطية الشعبية

MINISTRY OF HIGHER EDUCATION  
AND SCIENTIFIC RESEARCH

HIGHER SCHOOL IN APPLIED SCIENCES  
--T L E M C E N--



المدرسة العليا في العلوم التطبيقية  
École Supérieure en  
Sciences Appliquées

وزارة التعليم العالي والبحث العلمي

المدرسة العليا في العلوم التطبيقية  
-تمسان-

Mémoire de fin d'étude

Pour l'obtention du diplôme de Master

Filière : Automatique  
Spécialité : Automatique

Présenté par : HADJIAT Abderrahim  
BEMMERZOUK Lynda

Thème

**Optimisation du transfert d'énergie d'un  
panneau solaire à l'aide d'outils de  
l'intelligence artificielle**

Soutenu publiquement, le 02/07/2024 , devant le jury composé de :

Mme A.Ghouali	MCA	ESSA. Tlemcen	Président
M A.Dali	Docteur	CDER. ALGER	Directeur de mémoire
M B.Charki	Professeur	ESSA. Tlemcen	Co- Directeur de mémoire
M SM.Abdi	MCB	ESSA. Tlemcen	Examinateur 1
M F.boukli-hacène	MAB	ESSA. Tlemcen	Examinateur 2

Année universitaire : 2023 / 2024

# DÉDICACE

Je prends la liberté de vous adresser ces quelques lignes pour partager mon ressenti en cette fin de parcours académique. Ces années ont été sans conteste les plus enrichissantes de ma vie, et je suis particulièrement fier de cette dernière année et de ce projet de fin d'études que je dédie aux personnes les plus importantes de mon existence.

Je remercie tout d'abord Dieu, le Tout-Puissant et Miséricordieux, de nous avoir accordé la santé, la force et le courage nécessaires pour mener à bien ce projet de fin d'études.

Je voudrais ensuite exprimer ma profonde gratitude envers mes parents. Leur soutien, leurs encouragements constants et leur amour ont été les moteurs de ma réussite. Leur présence à mes côtés, dans les moments de doute comme dans les instants de joie, a été une source inestimable de motivation et de réconfort.

Je tiens également à remercier ma petite sœur et mon petit frère. Leur complicité, leur joie de vivre me rappellent l'importance de la famille et m'ont aidé à garder le cap dans les moments difficiles. Je leur souhaite un avenir radieux dans leurs études et qu'ils puissent accomplir tous leurs rêves et ambitions.

Je voudrais aussi exprimer ma sincère gratitude à mes grands-parents. Leur sagesse, leurs conseils avisés et leur amour inébranlable ont été une source d'inspiration constante tout au long de mon parcours. Leur présence chaleureuse et leur fierté ont illuminé mon chemin, et je suis profondément reconnaissant pour tout ce qu'ils ont fait pour moi.

Je voudrais également adresser un merci tout particulier à mes amis proches qui se reconnaîtront. Votre amitié et vos encouragements ont été des piliers importants tout au long de ce voyage académique. Vous avez partagé avec moi les hauts et les bas de cette aventure, et je suis profondément reconnaissant pour chaque moment passé ensemble.

Je n'oublie pas non plus de remercier mes collègues de l'ESSAT. Votre collaboration, vos conseils et votre camaraderie ont enrichi mon parcours et ont rendu cette période encore plus significative. J'ai beaucoup appris en travaillant à vos côtés et je suis heureux d'avoir pu partager ces années avec vous.

En toute fin, je remercie mon binôme, **Lynda BEMMERZOUK**, qui m'a fait confiance pour ce projet. Je voudrais te remercier pour ta gentillesse, ton sérieux et ta persévérance tout au long de ce projet.

---

Avant tout, je remercie Dieu le tout puissant, le Miséricordieux, de nous avoir donné la santé, la force et le courage de terminer ce projet de fin d'études.

Nous voilà parvenus à la fin de cinq longues et riches années qui ont sans aucun doute laissé une empreinte indélébile sur ma vie, une période académique marquante, pleine de défis relevés, de succès célébrés et de leçons apprises. C'est avec un cœur rempli de satisfaction et de nostalgie que je tiens à exprimer ma plus profonde gratitude envers les personnes qui ont été mes piliers, mes guides et mes inspirations tout au long de ce parcours.

Je dédie ce travail à mes parents pour leurs amour et leurs soutien incommensurables. Merci petite maman chérie pour tout les sacrifices que tu as fait pour moi, pour ton encouragement continue. Tes paroles réconfortantes ont toujours su apaiser mon coeur.

À mes très chers grands-parents, qui m'ont donné la meilleure éducation possible, qui m'ont toujours épaulé et soutenu dans mes décisions. Merci, Mima et Abba, de m'avoir accompagné depuis mon jeune âge jusqu'à aujourd'hui. Je vous dois beaucoup, car c'est en grande partie grâce à vous que j'ai pu réaliser mon projet de fin d'études et enfin devenir ingénieur.

À ma très chère tante, qui a été une deuxième maman pour moi, qui m'a soutenu tout au long de ma vie et veillé à ce que je ne manque de rien.

À mes chers oncles Chafik et Nadir, pour tous les sacrifices que vous avez faits pour moi, pour tous les conseils que vous m'avez transmis. Sans vous, je ne serais sans doute pas arrivé là où je suis aujourd'hui.

À ma petite soeur Sirine et mon petit frère Fares adorés, vous avez illuminé ma vie par votre amour, je vous souhaite un avenir tout aussi resplendissant que le mien.

À ma cousine, ma soeur, ma jumelle Lamia et à mon ingénieux cousin Rafik dont le soutien indéfectible et la présence réconfortante m'ont été d'une grande aide.

À mes petits cousins Manel , Ali, Wisssem, Djalil et enfin mon petit boutchou Arselane qui apportent énergie et joie de vivre à ma vie et qui attendent avec impatience la fin de mon travail.

À Maïssa, ma meilleure amie et confidente, qui a toujours été là pour m'écouter lorsque ça n'allait pas bien, prête à me soutenir et à me remonter le moral.

À Azedine ,une personne qui a toujours cru en moi et m'a poussé à dépassé mes limites même si parfois tes mots étaient rudes mais cela a porté ses fruits et je t'en suis reconnaissante.

À mes amis (Khaima club) Mohieddine, Nadir, Wadie, Nassim, Rym et Yasmine , avec qui j'ai vécu des moments de complicité, de bonheur et de rires mémorables.

À mes amis Manel, Nihel, Asmaa, Mehdi, Rifel, Wassen, Bouchraa et Meriem dont la présence , l'amitié et le soutien restent indéfectibles

À tous mes camarades d'automatique et collègues de Fablab ,ensemble, nous avons surmonté les défis et célébré nos réussites, créant des souvenirs qui resteront gravés dans ma mémoire. Merci pour votre camaraderie et votre esprit d'équipe qui ont rendu cette aventure académique enrichissante et inoubliable.

À tous les membres de l'association des petits anges aux quel je fait partie et principalement mon enseignante Naima qui m'a appris à me donner au fond de moi même.

À mon binôme **Abderrahim HADJIAT** avec qui j'ai partagé cette aventure remplie de surmenage, de stress et de réussite. Je voudrais te remercier pour ton travail, ton soutien et ta bonne humeur.

# REMERCIEMENTS

*Nous souhaitons tout d'abord exprimer notre profonde reconnaissance envers notre encadrant, **M. Ali DALI**, pour avoir accepté de superviser notre projet de recherche. Sa disponibilité, son expertise et sa confiance en notre travail ont été des éléments essentiels au cours de notre projet de fin d'étude.*

*Nous remercions également notre co-encadrant **M. CHERKI Brahim** pour toutes les orientations et les conseils qu'il nous a prodigué tout au long de ce travail. Sa direction éclairée nous a permis d'aborder notre recherche avec assurance et détermination, et nous lui en sommes sincèrement reconnaissants.*

*À l'issue de ce projet de fin d'études, nous remercions **Mme. GUERRI Ouahiba**, chef de division éolienne au sein du Centre de Recherche des Énergies Renouvelables (CDER Ben Aknoun), pour nous avoir ouvert les portes du centre, nous permettant ainsi de réaliser notre stage de fin d'études.*

*Nous aimerions adresser nos sincères remerciements aux chercheurs du CDER pour leur chaleureux accueil et leur bienveillance. Un remerciement spécial à **M. BOU-DIA Sidi Mohamed**, pour sa bonne humeur et sa joie de vivre tout au long des stages. Nous remercions aussi **M. Kherbachi Abdelhamid**, **M. Lakhdari Halim** et **M. Meziane Fares** pour leur soutien et leurs précieux conseils durant cette période.*

*Nous remercions **M. ADJIM Ramz-Eddine Abderrezak** responsable du fablab pour ses conseils et son aide.*

*Nous tenons à exprimer notre profonde gratitude envers **Mme GHOUALI Amel** pour avoir accepté de présider l'honorable jury de notre soutenance. De même, nous souhaitons adresser nos remerciements les plus sincères à **M. ABDI Sidi-Mohammed** et à **M. BOUKLI HACENE Fazil Lotfi** pour avoir accepté d'évaluer notre travail en tant qu'examineurs.*

*Nous tenons enfin à rendre hommage à **M. ROUISSAT Boucherit**, directeur de l'ESSAT, à **M.MEGNAFI Hichem**, chef de département du second cycle, à **M. ARICHI Fayssal** chef de la filière automatique ainsi qu'à **M. KHEFIF Sidi-Mohammed** pour nous avoir accordé l'accès au FabLab.*

# TABLE DES MATIÈRES

<b>Abréviations</b>	<b>xi</b>
<b>Nomenclatures</b>	<b>xi</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Système photovoltaïque</b>	<b>3</b>
Introduction . . . . .	3
1.1 L'énergie et le rayonnement solaire . . . . .	4
1.2 Cellules photovoltaïques . . . . .	4
1.3 Principe de conversion . . . . .	5
1.4 Les différents types de cellules . . . . .	5
1.5 Les caractéristiques d'une cellule PV . . . . .	6
1.5.1 La tension à vide $V_{oc}$ . . . . .	6
1.5.2 Le courant de court-circuit $I_{cc}$ . . . . .	6
1.5.3 Le point de puissance maximal MPP . . . . .	7
1.5.4 Le Facteur de forme FF . . . . .	7
1.5.5 Le rendement de conversion . . . . .	7
1.6 Modélisation de la cellule PV : . . . . .	8
1.6.1 Modèle à 4 paramètres . . . . .	8
1.6.2 Modèle simplifié . . . . .	9
1.7 Association des cellules PV . . . . .	10
1.7.1 Association en série . . . . .	10
1.7.2 Association en parralèle . . . . .	11
1.8 Le générateur photovoltaïque . . . . .	12
1.9 Effet de l'irradiation solaire . . . . .	13
1.10 Effet de la température . . . . .	13
1.11 Convertisseur DC/DC . . . . .	14
1.11.1 Convertisseur buck . . . . .	14
1.12 Modélisation du Convertisseur Statique dévolteur (convertisseur buck)	15
1.12.1 Linéarisation du système autour d'un point de fonctionnement	17
1.12.2 Représentation d'état du convertisseur . . . . .	17
Conclusion . . . . .	19

---

<b>2</b>	<b>Généralités sur les réseaux neurones</b>	<b>20</b>
	Introduction . . . . .	20
	2.1 Neurone biologique . . . . .	21
	2.2 Un neurone artificiel . . . . .	21
	2.3 Liaison entre les neurones biologiques et les neurones artificiels . . . . .	22
	2.4 Architecture d'un réseau neurone . . . . .	22
	2.5 Fonction d'activation . . . . .	23
	2.6 Types de réseaux neurones . . . . .	24
	2.6.1 Perceptron . . . . .	24
	2.6.2 Perceptron multicouche . . . . .	24
	2.6.3 Réseaux non bouclés (non récurrents) . . . . .	25
	2.6.4 Les réseaux bouclés (récurrents) . . . . .	25
	2.7 Apprentissage des réseaux de neurones . . . . .	26
	2.7.1 Apprentissage supervisé . . . . .	26
	2.7.2 Apprentissage non supervisé . . . . .	27
	2.7.3 Apprentissage renforcé . . . . .	27
	2.8 Algorithme d'apprentissage des réseaux de neurones multicouches . . . . .	27
	2.9 Algorithme de Levenberg-Marquardt . . . . .	27
	2.10 Avantages et inconvénients des réseaux neurones . . . . .	29
	Conclusion . . . . .	30
<b>3</b>	<b>Synthèse de lois de commande MPPT</b>	<b>31</b>
	Introduction . . . . .	31
	3.1 Commande optimale . . . . .	32
	3.2 Commande MPPT à base de réseaux neurones . . . . .	33
	3.2.1 Objectifs . . . . .	33
	3.2.2 Procédure de construction d'un réseau de neurones . . . . .	33
	3.2.3 Collecte d'une base de données . . . . .	33
	3.2.4 Construction du premier réseau de neurones . . . . .	34
	3.2.5 Construction du deuxième réseau de neurones . . . . .	34
	3.2.6 Entraînement des réseaux neurones . . . . .	35
	3.3 Simulation des commandes MPPT . . . . .	39
	3.3.1 Simulation de la commande LQR . . . . .	41
	3.3.2 Simulation de la commande par réseau neurone . . . . .	44
	3.4 Comparaison entre les deux commandes . . . . .	46
	3.4.1 L'erreur quadratique moyenne . . . . .	47
	3.4.2 Interprétation des résultats . . . . .	47
	Conclusion . . . . .	47
<b>4</b>	<b>Implémentation des commandes MPPT</b>	<b>48</b>
	Introduction . . . . .	48
	4.1 Méthodologie . . . . .	49
	4.1.1 Unité de commande . . . . .	49
	4.1.2 Unité de mesure . . . . .	50

---

---

4.2	Convertisseur buck . . . . .	52
4.3	Implémentation des commandes . . . . .	53
4.3.1	Application avec une alimentation . . . . .	54
4.3.2	Application avec le panneau photovoltaïque . . . . .	58
	Conclusion . . . . .	62
	<b>Conclusion générale</b>	<b>63</b>
	<b>A Programme MATLAB</b>	<b>64</b>

# TABLE DES FIGURES

1.1	Schéma explicatif de la norme Air Mass (AM). . . . .	4
1.2	Cellule photovoltaïque . . . . .	4
1.3	Schéma explicatif du fonctionnement d'une cellule solaire . . . . .	5
1.4	Caractéristiques I-V et P-V . . . . .	7
1.5	Le circuit équivalent du modèle à une diode d'une cellule PV. . . . .	8
1.6	Le circuit simplifié du modèle à une diode d'une cellule PV. . . . .	9
1.7	Groupement en série de cellules PV . . . . .	10
1.8	Caractéristique I-V d'un groupement en série . . . . .	11
1.9	Groupement en parallèle de cellules PV . . . . .	11
1.10	Caractéristique I-V d'un groupement en parallèle . . . . .	12
1.11	Cellule, module, panneau ,système photovoltaïque . . . . .	12
1.12	Caractéristique I-V pour différents niveaux de rayonnement . . . . .	13
1.13	Caractéristique I-V pour différentes valeurs de températures . . . . .	13
1.14	Schéma du principe du convertisseur MPPT . . . . .	14
1.15	Schéma électrique du convertisseur buck . . . . .	14
1.16	Schéma d'un signal PWM . . . . .	15
1.17	Schéma équivalent dans le mode de fonctionnement (0-DT). . . . .	15
1.18	Schéma équivalent dans le mode de fonctionnement (DT-T) . . . . .	16
2.1	Représentation schématique d'un neurone biologique . . . . .	21
2.2	Représentation d'un neurone artificiel. . . . .	22
2.3	Perceptron multicouche. . . . .	24
2.4	Perceptron multicouche. . . . .	25
2.5	Réseau non bouclé . . . . .	25
2.6	réseau bouclé. . . . .	26
2.7	Schéma bloc de l'apprentissage supervisé. . . . .	26
2.8	Algorithme de Levenberg-Marquardt . . . . .	28
3.1	Schema explicatif pour le choix du gain de commande. . . . .	32
3.2	Réseau neurone pour estimer $V_{mpp}$ et $I_{mpp}$ . . . . .	34
3.3	Réseau neurone de la commande . . . . .	35
3.4	Entraînement du réseau neurone de $V_{mpp}$ et $I_{mpp}$ . . . . .	35
3.5	Performances du réseau neurone de $V_{mpp}$ et $I_{mpp}$ . . . . .	36
3.6	Régression du réseau neurone de $V_{mpp}$ et $I_{mpp}$ . . . . .	36



---

3.7	Entrainement du réseau neurone de la commande . . . . .	37
3.8	Performances du réseau neurone de la commande . . . . .	37
3.9	Régression du réseau neurone de la commande . . . . .	38
3.10	Circuit simulink de l'hacheur buck . . . . .	39
3.11	Schema bloc général de la commande MPPT d'un PV . . . . .	40
3.12	Scénario de la température . . . . .	40
3.13	Scénario de l'irradiation . . . . .	41
3.14	Schéma de la commande par réseau neurone. . . . .	41
3.15	Représentation de la tension du PV par rapport au temps . . . . .	42
3.16	Représentation du courant du PV par rapport au temps . . . . .	42
3.17	Représentation du rapport cyclique par rapport au temps . . . . .	43
3.18	Représentation de la commutation par rapport au temps . . . . .	43
3.19	Schéma de la commande par réseau neurone. . . . .	44
3.20	Représentation de la tension d'entrée par rapport au temps . . . . .	44
3.21	Représentation du courant du PV par rapport au temps . . . . .	45
3.22	Représentation du rapport cyclique par rapport au temps . . . . .	45
3.23	Représentation de la tension du PV par rapport au temps . . . . .	46
3.24	Zoom sur la représentation de la tension d'entrée par rapport au temps . . . . .	46
4.1	Schéma bloc de la méthodologie de la commande . . . . .	49
4.2	Carte STM32 . . . . .	50
4.3	Carte cjmcu-232H . . . . .	50
4.4	Circuits des capteurs . . . . .	50
4.5	Capteur LV 25-P . . . . .	51
4.6	Capteur LTS 55-P . . . . .	51
4.7	Thermocouple 80BK-A . . . . .	51
4.8	Prototype final de l'hacheur buck . . . . .	52
4.9	Schéma Simulink de la commande . . . . .	53
4.10	Schéma Simulink pour l'acquisition des données . . . . .	53
4.11	Illustration de la manipulation . . . . .	54
4.12	Représentation de la température par rapport au temps . . . . .	54
4.13	Représentation de l'irradiation par rapport au temps . . . . .	55
4.14	Représentation de la tension d'entrée par rapport au temps . . . . .	55
4.15	Représentation du rapport cyclique en fonction du temps . . . . .	56
4.16	Représentation de la température par rapport au temps . . . . .	56
4.17	Représentation de l'irradiation par rapport au temps . . . . .	57
4.18	Représentation de la tension d'entrée par rapport au temps . . . . .	57
4.19	Représentation du rapport cyclique en fonction du temps . . . . .	58
4.20	Illustration de la manipulation . . . . .	58
4.21	Datasheet du PV . . . . .	59
4.22	Représentation de la tension d'entrée par rapport au temps . . . . .	60
4.23	Représentation du rapport cyclique en fonction du temps . . . . .	60
4.24	Représentation de la tension d'entrée par rapport au temps . . . . .	61
4.25	Représentation du rapport cyclique en fonction du temps . . . . .	61

# LISTE DES TABLEAUX

1.1	Comparaison entre les cellules PV . . . . .	6
2.1	Relation entre les neurones biologiques et artificiels . . . . .	22
2.2	Fonctions d'activation usuelles . . . . .	23
3.1	Paramètres en STC du PV . . . . .	39
4.1	Paramètres en STC du PV . . . . .	59

# ABRÉVIATIONS

**AM** Air Mass.

**ANN** Artificial Neural Network.

**CAO** Conception assistée par ordinateur.

**DC** Continue/Continue.

**GPV** Générateur photovoltaïque.

**LMI** Inégalités Matricielles Linéaires.

**LQR** Régulateur Linéaire Quadratique.

**MOSFET** Metal-Oxide-Semiconductor Field-Effect Transistor.

**MPPT** Maximum Power Point Tracking.

**MPP** Maximum Power Point.

**NOCT** Nominal Operating Cell Temperature.

**PCB** Printed Circuit Board.

**PF** Point de fonctionnement.

**PI** Proportionnel Intégral.

**PMC** Perceptron Multicouche.

**PV** Panneau photovoltaïque.

**PWM** Pulse Width Modulation (Modulation à Largeur d'Impulsion).

**RNN** Recurrent Neural Network.

**STC** Conditions de test standard.

# NOMENCLATURES

$\alpha_{cc}$	Coefficient de température du courant de court-circuit
$\eta$	Rendement de conversion
$D$	Rapport cyclique
$e_m$	Erreur quadratique moyenne
$f_s$	Fréquence de commutation
$FF$	Facteur de forme
$G$	Irradiation
$G_{STC}$	Irradiation STC
$H$	Hessien
$I_{cc}$	Courant de court-circuit
$I_{cell}$	Courant délivré par la cellule
$I_D$	Courant à travers la diode
$I_L$	Courant de l'inductance
$I_{mpp}$	Courant au point de puissance maximale
$I_{ph}$	Photo-courant
$I_{PV}$	Courant du panneau photovoltaïque
$I_s$	Courant de saturation
$J$	Jacobien
$k$	Constante de Boltzmann
$k_T$	Coefficient de la température du courant de court circuit
$L$	Inductance
$n$	Facteur d'idéalité de la jonction

$P_{in}$	Puissance d'entrée
$P_{max}$	Puissance maximale
$P_{mpp}$	Puissance au point de puissance maximale
$q$	Charge électrique élémentaire
$R$	Résistance
$R_p$	Résistance parallèle
$R_s$	Résistance série
$R_L$	Résistance de l'inductance
$T$	Température
$T_e$	Temps d'échantillonnages
$T_m$	Température de fonctionnement de la cellule
$T_s$	Période de commutation
$T_{cell}$	Température de la cellule
$T_{NOCT}$	Température de fonctionnement nominale
$T_{off}$	Temps à l'état bloqué
$T_{on}$	Temps à l'état passant
$T_{STC}$	Température STC
$U$	Erreur de la commande
$u$	Commande
$V_g$	Energie du band gap
$V_{cell}$	Tension aux bornes de la cellule
$V_{mpp}$	Tension au point de puissance maximale
$V_{oc}$	Tension en circuit ouvert
$V_{out}$	Tension de sortie
$V_{PV}$	Tension du panneau photovoltaïque
$V_{th}$	Tension thermique
$w$	Poids synaptique

# INTRODUCTION GÉNÉRALE

L'énergie solaire, en tant que source d'énergie renouvelable inépuisable, joue un rôle crucial dans la transition vers un avenir énergétique durable. Les systèmes photovoltaïques, qui convertissent la lumière du soleil en électricité, sont au cœur de cette révolution énergétique. Cependant, pour maximiser l'efficacité et l'exploitation de l'énergie solaire, il est essentiel d'intégrer un convertisseur DC-DC qui permettra à l'aide d'un algorithme (MPPT) le suivi avec précision du point de puissance maximale (MPP).

Dans ce contexte, l'intelligence artificielle, et plus particulièrement les réseaux de neurones, offrent des opportunités prometteuses pour améliorer la gestion et l'efficacité des systèmes photovoltaïques. En exploitant les principes inspirés du fonctionnement du cerveau humain, les réseaux de neurones artificiels permettent de développer des stratégies de contrôle avancées pour les systèmes photovoltaïques, notamment en ce qui concerne le suivi du point de puissance maximale.

Ce travail vise à démontrer comment l'utilisation des réseaux de neurones peut conduire à des solutions plus faciles et performantes dans l'optimisation de l'énergie photovoltaïque. Ce manuscrit est constitué de trois chapitres suivis d'une conclusion générale.

Le premier chapitre se concentrera sur les fondamentaux des systèmes photovoltaïques, en abordant les principes de l'énergie solaire, la conception et le fonctionnement des cellules photovoltaïques, ainsi que l'impact des conditions environnementales sur leurs performances. De plus, la modélisation des cellules photovoltaïques et le fonctionnement des convertisseurs DC-DC seront également discutés.

Le deuxième chapitre présentera les fondamentaux des réseaux de neurones artificiels, en débutant par les neurones biologiques qui les inspirent. Il détaillera l'architecture des réseaux de neurones, les différents types de réseaux (perceptrons simples, multicouches, récurrents et non récurrents) ainsi que les méthodes d'apprentissage qui leur sont associées.

---

Le troisième chapitre traite de l'optimisation de l'énergie photovoltaïque grâce à l'utilisation d'algorithmes d'intelligence artificielle. Il commence par un rappel de l'approche optimale, qui utilise les inégalités matricielles linéaires (LMI) pour le suivi du point de puissance maximale (MPPT). Ensuite, cette méthode de commande est transformée en une commande par réseau de neurones. Ces concepts seront appliqués au MPPT d'un générateur photovoltaïque.

Enfin, le quatrième chapitre traitera de l'implémentation des commandes MPPT. Il couvrira les aspects pratiques de la mise en œuvre, incluant les unités de commande et de mesure, l'utilisation de convertisseurs buck, ainsi que les applications pratiques avec des alimentations et des panneaux photovoltaïques. Les résultats expérimentaux seront discutés pour évaluer la performance des commandes implémentées.

La conclusion générale de ce manuscrit mettra en lumière les objectifs atteints et les perspectives futures dans le domaine de l'optimisation des systèmes photovoltaïques grâce à l'intelligence artificielle.

# CHAPITRE

## 1

# SYSTÈME PHOTOVOLTAÏQUE

## Introduction

Les systèmes photovoltaïques représentent une solution prometteuse et durable pour répondre aux besoins énergétiques mondiaux croissants. En tirant parti de l'énergie solaire, une source abondante et renouvelable, les systèmes photovoltaïques convertissent directement la lumière du soleil en électricité, contribuant ainsi à la réduction de la dépendance aux combustibles fossiles et à la diminution des émissions de gaz à effet de serre.

Ce chapitre explore en profondeur les différents aspects des systèmes photovoltaïques, en commençant par les principes fondamentaux de l'énergie solaire et du rayonnement, en passant par la conception et le fonctionnement des cellules photovoltaïques, jusqu'aux caractéristiques des différents types de cellules disponibles.

Nous aborderons également la modélisation des cellules photovoltaïques et leurs différentes méthodes d'association ainsi que l'impact des conditions environnementales telles que l'irradiation solaire et la température sur les performances de ces dernières.

Enfin, nous nous intéresserons à la modélisation et au fonctionnement du convertisseur DC-DC, élément essentiel dans l'optimisation de l'énergie fournie par le générateur photovoltaïque.



## 1.1 L'énergie et le rayonnement solaire

L'énergie solaire est une source d'énergie abondante et renouvelable qui provient du rayonnement du soleil. Ce rayonnement solaire est constitué de photons, des particules élémentaires transportant de l'énergie, qui voyagent à travers l'espace et atteignent la surface de la Terre. Une fois sur Terre, ce rayonnement solaire peut être capturé et utilisé pour produire de l'électricité à l'aide de panneaux solaires photovoltaïques.

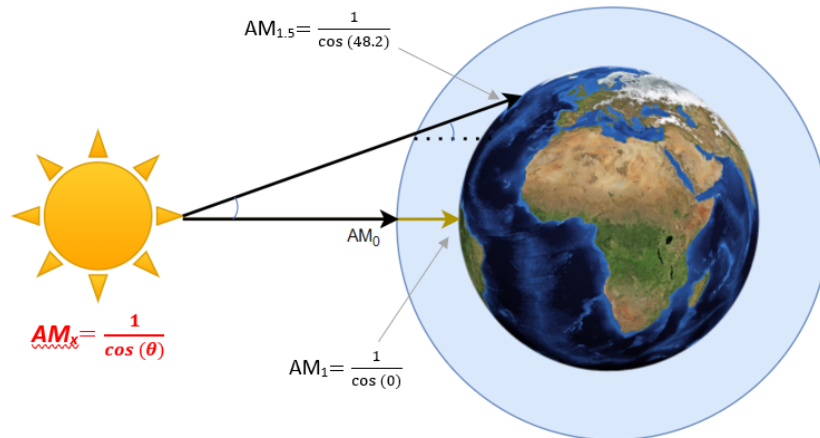


FIGURE 1.1 – Schéma explicatif de la norme Air Mass (AM).

L'indice Air Mass (AM) est une mesure clé pour évaluer le spectre solaire et l'énergie émise par le soleil. Il est défini comme le rapport entre la distance parcourue par la lumière solaire à travers l'atmosphère et l'épaisseur de celle-ci. L'indice Air Mass 1.5 (**AM1.5**) caractérise le spectre de la lumière solaire dans des conditions standardisées lorsque le soleil est à un angle de 48.2° par rapport au zénith (figure 1.1) [11][18].

## 1.2 Cellules photovoltaïques

Une cellule photovoltaïque montrée sur la figure 1.2 (photon : grain de lumière, volt : unité de tension) est un composant optoélectronique à base de matériaux semi-conducteurs tels que le silicium. Elle transforme directement la lumière solaire en électricité par un processus appelé " effet photovoltaïque ". [5][15]



FIGURE 1.2 – Cellule photovoltaïque

### 1.3 Principe de conversion

L'effet photovoltaïque utilisé dans les cellules solaires permet de convertir directement l'énergie lumineuse des rayons solaires en électricité par le biais de la production et du transport dans un matériau semi-conducteur comportant deux couches, l'une présentant un excès d'électrons (dopée de type N) et l'autre un déficit en électrons (dopée de type P) [5] [10].




FIGURE 1.3 – Schéma explicatif du fonctionnement d'une cellule solaire

On peut résumer le processus de fonctionnement en trois principales étapes (figure 1.3)[4] [10] :

- Absorption des photons (dont l'énergie est supérieure au gap) par le matériau constituant le dispositif
- Conversion de l'énergie du photon en énergie électrique, ce qui correspond à la création de paires électron/trou dans le matériau semi-conducteur.
- Collecte des particules générées dans le dispositif.

### 1.4 Les différents types de cellules

Il existe plusieurs types de cellules solaires dont chaque type de cellules possède un rendement et un coût qui lui est propre. Cependant, quelque soit leur type, leur rendement reste assez faible, variant de 8% à 23% de l'énergie qu'elles reçoivent. En effet, il existe trois principaux types de cellules à l'heure actuelle.

Ci-dessous un tableau comparatif des différentes cellules solaires [5] :


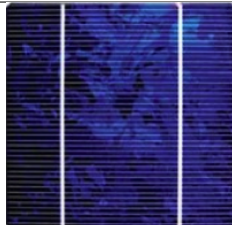

Type de cellules	Silicium monocristallin	Silicium polycristallin	Amorphe
Photo des cellules			
Processus de fabrication	Complexe	Moin complexe	Simple
Rendement	Élevé(13%-17%)	Moyen( 11%-15% )	Faible (6%-10% )
Coût	Élevé	Moyen	Faible à moyen
Structure	Cristal unique de silicium	Multiples cristaux de silicium	Silicium non cristallin
Applications	<ul style="list-style-type: none"> <li>— Grands projets solaires</li> <li>— Toits résidentiels et commerciaux</li> <li>— Aérospatiales</li> </ul>	<ul style="list-style-type: none"> <li>— Projets solaires à grande échelle</li> <li>— éclairage public</li> <li>— Systèmes de pompage solaire</li> </ul>	<ul style="list-style-type: none"> <li>— Appareils électroniques</li> <li>— Montre</li> <li>— Calculatrice</li> </ul>

TABLEAU 1.1 – Comparaison entre les cellules PV

## 1.5 Les caractéristiques d'une cellule PV

Pour un éclairement et une température données, la cellule ou le générateur photovoltaïque se distingue par deux courbe (figure 1.4) : courant-tension (I-V) et puissance-tension (P-V). Ces courbe mettent en évidence plusieurs grandeurs physiques :

### 1.5.1 La tension à vide $V_{oc}$

La tension en circuit ouvert ( $V_{oc}$ ) est la tension aux bornes du générateur PV lorsque les bornes du générateur sont non connectées à un circuit externe. Cette tension représente la capacité maximale de tension du générateur dans des conditions spécifiques d'éclairement et de température.

### 1.5.2 Le courant de court-circuit $I_{cc}$

Le courant de court-circuit ( $I_{cc}$ ) est le courant électrique maximal qui peut circuler à travers le générateur photovoltaïque lorsque les bornes du circuit sont court circuitées ( $R_{charge} = 0$ ).

### 1.5.3 Le point de puissance maximal MPP

Le point de puissance maximale (MPP) est le point de fonctionnement optimal pour lequel le panneau opère à sa puissance maximale ( $P_{mpp}$ ). Ce point est caractérisé par un courant et une tension au point de puissance maximale ( $I_{mpp}, V_{mpp}$ ) comme montré ci-dessous.

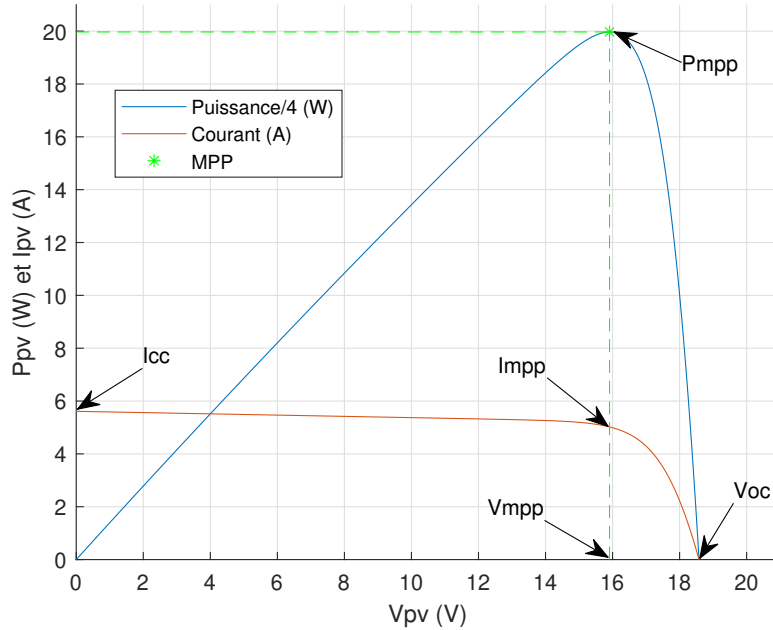


FIGURE 1.4 – Caractéristiques I-V et P-V

### 1.5.4 Le Facteur de forme FF

Un paramètre important est souvent utilisé à partir de la caractéristique I(V) pour qualifier la qualité d'une cellule ou d'un générateur PV : c'est le facteur de forme (fill factor). Ce coefficient représente le rapport entre la puissance maximale que peut délivrer la cellule notée  $P_{mpp}$  et la puissance formée par le rectangle  $I_{cc} * V_{oc}$ . Plus sa valeur est élevée, plus la puissance exploitable est grande.[10]

$$FF = \frac{P_{mpp}}{I_{cc} * V_{oc}} \quad \text{avec } 0 < FF < 1 \quad (1.1)$$

### 1.5.5 Le rendement de conversion

Il exprime la capacité de la cellule à convertir efficacement les photons de la lumière incidente en courant électrique. Il est calculé par le rapport entre la puissance maximale fournie par le panneau  $P_{mpp}$  et la puissance d'entrée de la cellule  $P_{in}$  (puissance d'éclairement solaire incident).[10]

$$\eta = \frac{P_{mpp}}{P_{in}} = \frac{I_{cc} * V_{oc} * FF}{P_{in}} \quad (1.2)$$

## 1.6 Modélisation de la cellule PV :

Les modèles électriques équivalents, tels que les circuits à une ou deux diodes, sont couramment utilisés pour caractériser le comportement des cellules photovoltaïques en raison de leur forte non-linéarité, principalement attribuée aux jonctions semi-conductrices. Ces modèles, décrits dans la littérature, varient selon le nombre de paramètres nécessaires pour décrire avec précision la relation entre la tension et le courant de sortie d'une cellule photovoltaïque.[7]

### 1.6.1 Modèle à 4 paramètres

Une cellule PV peut être représentée par le circuit électrique équivalent illustré sur la figure 1.5. Ce circuit est constitué d'un générateur de courant continu  $I_{ph}$  qui modélise la conversion du flux lumineux en énergie électrique, d'une diode qui représente la jonction P-N de la cellule, et de deux résistances  $R_p$  et  $R_s$  caractérisant respectivement les courants de fuite de la jonction et les diverses résistances des contacts de connexion [5] [24].

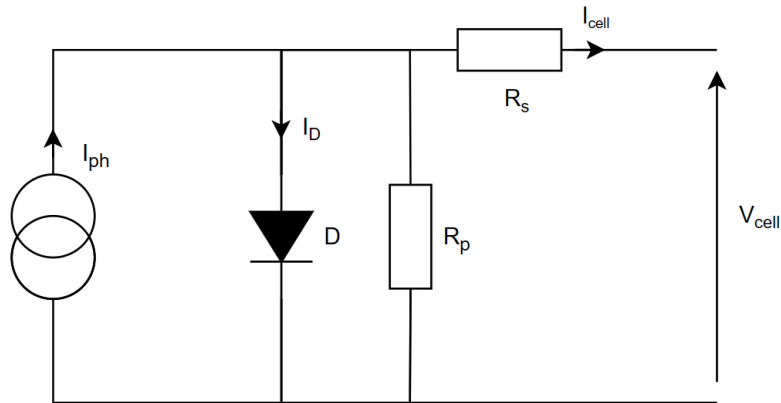


FIGURE 1.5 – Le circuit équivalent du modèle à une diode d'une cellule PV.

avec :

- $R_s$  : Résistance série
- $R_p$  : Résistance parallèle
- $I_{ph}$  : Photo-courant
- $I_D$  : Courant à travers la diode
- $I_{cell}$  : Courant délivré par la cellule
- $V_{cell}$  : Tension aux bornes de la cellule
- $n$  : Facteur d'idéalité de la jonction
- $k$  : Constante de Boltzmann
- $T$  : Température de la cellule
- $q$  : Charge électrique élémentaire

On peut écrire :

$$I_{cell} = I_{ph} - I_D - \frac{V_D}{R_p} \quad (1.3)$$

$$I_D = I_s(e^{\frac{V_D}{V_{th}}} - 1) \quad (1.4)$$

$$V_D = V_{cell} + R_s I_{cell} \quad (1.5)$$

d'où

$$I_{cell} = I_{ph} - I_s(e^{\frac{V_{cell} + R_s I_{cell}}{V_{th}}} - 1) - \frac{V_{cell} + R_s I_{cell}}{R_p} \quad (1.6)$$

$V_{th} = \frac{nkT}{q}$  est appelée tension thermique.

### 1.6.2 Modèle simplifié

Généralement, l'effet de la résistance parallèle est négligé en raison de sa grande valeur ce qui en découle un circuit électrique équivalent simplifié comme le montre la figure 1.6 ci-dessous.[7] [19]




FIGURE 1.6 – Le circuit simplifié du modèle à une diode d'une cellule PV.

Le courant délivré par la cellule est alors donné par l'expression :

$$I_{cell} = I_{ph} - I_s(e^{\frac{V_{cell} + R_s I_{cell}}{V_{th}}} - 1) \quad (1.7)$$

La tension aux bornes de la cellule est donnée par :

$$V_{cell} = -R_s I_{cell} + V_{th} \ln \left( \frac{I_{ph} - I_{cell} + I_s}{I_s} \right) \quad (1.8)$$

le photocourant généré pour n'importe quel valeur d'irradiation  $G$  et de température  $T$  est donné par :

$$I_{ph} = I_{ccSTC} \frac{G}{G_{STC}} (1 + \alpha_{cc}(T - T_{STC})) \quad (1.9)$$

Le coefficient de température du courant de court-circuit  $\alpha_{sc}$  est généralement donné par le fabricant sur le datasheet en pourcentage de changement par degré Celsius et peut être calculé de la manière suivante :

$$\alpha_{cc} = \frac{I_{ccT_2} - I_{ccSTC}}{T_2 - T_{STC}} \quad (1.10)$$

Le courant de saturation  $I_s$  de la diode pour la température  $T_{STC}$ , est donné par :

$$I_{sSTC} = \frac{I_{ccSTC}}{e^{\frac{V_{ocSTC}}{V_{thSTC}}} - 1} \quad (1.11)$$

Le courant de saturation pour une température donnée est calculée par l'équation suivante :

$$I_s = I_{sSTC} \left( \frac{T}{T_{STC}} \right)^{\frac{3}{n}} e^{\frac{-qV_g}{nk} \left( \frac{1}{T} - \frac{1}{T_{STC}} \right)} \quad (1.12)$$

avec

$V_g$  est appelée énergie du band gap, sa valeur dépend du matériau constituant la cellule (1.2 ev pour le silicium) [9].

## 1.7 Association des cellules PV

Les cellules photovoltaïques individuelles produisent généralement une puissance électrique insuffisante pour la plupart des applications domestiques ou industrielles. Pour pallier cette limitation, des générateurs photovoltaïques sont construits par association, en série et/ou en parallèle, d'un grand nombre de cellules élémentaires.

### 1.7.1 Association en série

Une association de  $N_s$  cellules en série comme montré sur la figure 1.7 permet d'augmenter la tension du système photovoltaïque. Les cellules sont alors traversées par le même courant et la caractéristique résultant du groupement série est obtenue par addition des tensions élémentaires de chaque cellule ( $V_{pv} = N_s V_{cell}$ ) [10].

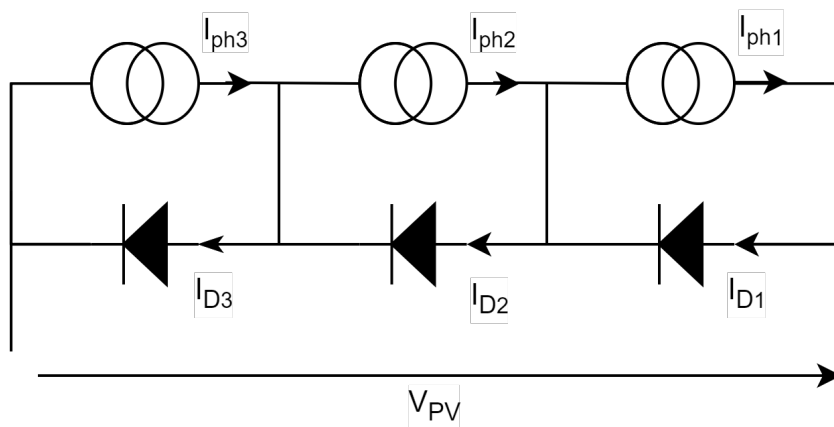


FIGURE 1.7 – Groupement en série de cellules PV




FIGURE 1.8 – Caractéristique I-V d'un groupement en série

### 1.7.2 Association en parallèle

Une association de  $N_p$  cellules en parallèle comme montré sur la figure 1.9 permet d'augmenter le courant de sortie du système photovoltaïque. Les cellules sont alors soumises à la même tension et la caractéristique résultant du groupement parallèle est obtenue par addition des courants élémentaires de chaque cellule ( $I_{pv} = N_p I_{cell}$ ) [10].




FIGURE 1.9 – Groupement en parallèle de cellules PV






FIGURE 1.10 – Caractéristique I-V d'un groupement en parallèle

## 1.8 Le générateur photovoltaïque

Un générateur photovoltaïque est constitué d'un ensemble de cellules qui convertissent la lumière solaire en électricité. Toutefois, Ces cellules sont regroupées en série et/ou en parallèle pour former un module photovoltaïque. Ensuite, ces modules sont connectés entre eux pour constituer un panneau photovoltaïque. Enfin, plusieurs de ces panneaux sont reliés ensemble pour former un champ ou un système photovoltaïque capable de produire de l'électricité à grande échelle [5] (figure 1.11).

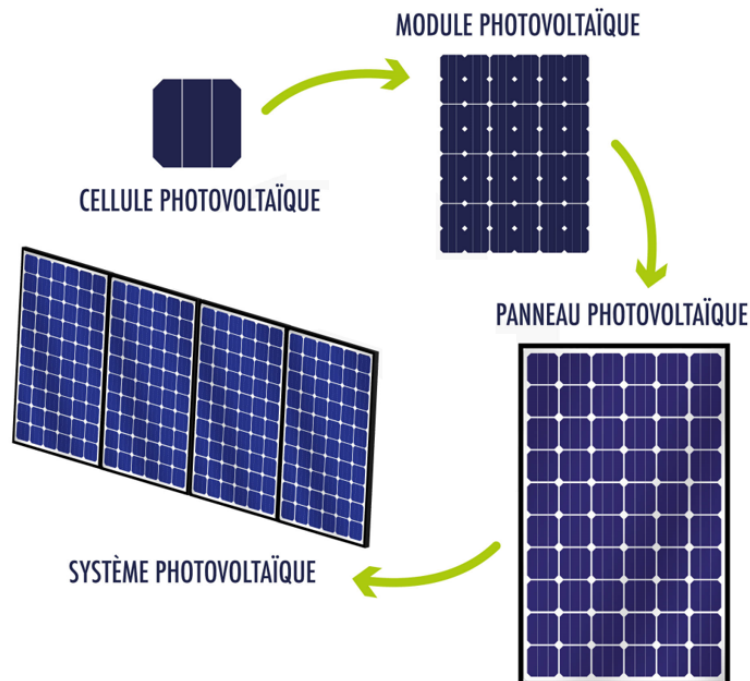


FIGURE 1.11 – Cellule, module, panneau ,système photovoltaïque

## 1.9 Effet de l'irradiation solaire

La variation du courant en fonction de la tension pour différents niveaux d'éclairements à température maintenue constante ( $30^{\circ}\text{C}^{\circ}$ ) (figure 1.12) montre clairement que le courant du court-circuit  $I_{cc}$  varie proportionnellement par rapport à la variation de l'irradiation tandis que la tension de circuit ouvert  $V_{oc}$  varie très peu [10][25].

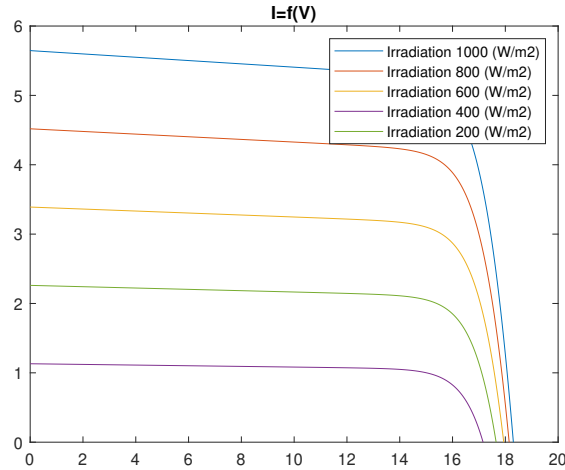


FIGURE 1.12 – Caractéristique I-V pour différents niveaux de rayonnement

## 1.10 Effet de la température

La température a également une influence sur la caractéristique I-V de la cellule photovoltaïque. La figure 1.13 présente la variation du courant en fonction de la tension pour différentes valeurs de températures à un éclairement fixé ( $800\text{W}\cdot\text{m}^{-2}$ ). L'évolution de cette caractéristique en fonction de la température est complexe : alors que la température augmente, la tension de circuit ouvert diminue tandis que le courant de court-circuit connaît une légère augmentation [10][25].

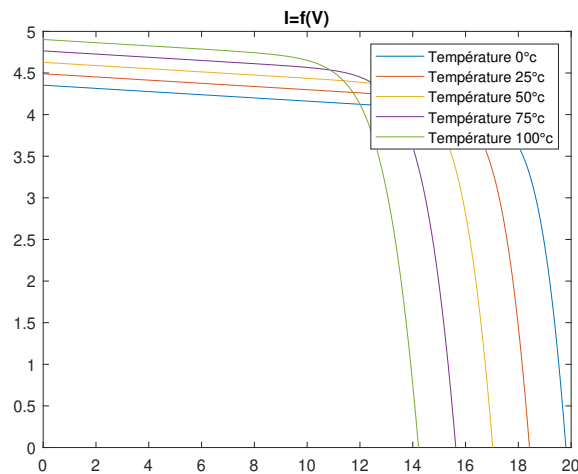


FIGURE 1.13 – Caractéristique I-V pour différentes valeurs de températures

## 1.11 Convertisseur DC/DC

Dans le cadre des systèmes photovoltaïques, le convertisseur DC/DC joue un rôle essentiel en assurant l'adaptation entre la source (GPV) et la charge (batterie) afin de maximiser le transfert de puissance (voir 1.14). Le convertisseur DC/DC est muni d'un algorithme de poursuite du point de puissance maximum (MPPT). Cet algorithme ajuste dynamiquement le rapport cyclique du convertisseur suivant les changements climatiques (température, irradiation) pour maintenir le fonctionnement du GPV à son point de puissance maximale (voir figure 1.4). [8]

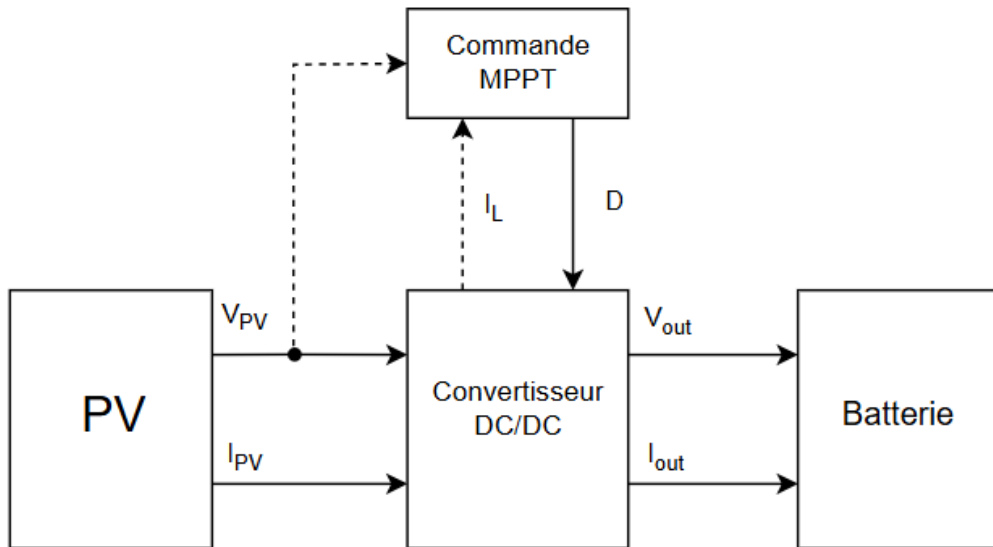


FIGURE 1.14 – Schéma du principe du convertisseur MPPT

### 1.11.1 Convertisseur buck

L'hacheur Buck, également connu sous le nom de convertisseur abaisseur, est un type de convertisseur de puissance à découpage utilisé pour abaisser la tension d'une source d'alimentation continue (DC) (figure 4.8).




FIGURE 1.15 – Schéma électrique du convertisseur buck

Le commutateur  $S_1$  est activé et désactivé avec une fréquence de commutation  $f = \frac{1}{T}$  avec  $T$  période de commutation et  $T = T_{on} + T_{off}$ .

La relation entre la tension d'entrée et la tension de sortie est donnée par

$$V_{out} = DV_{PV}$$

avec  $D = \frac{T_{on}}{T}$  qui est le rapport cyclique ( $0 < D < 1$ ).

## 1.12 Modélisation du Convertisseur Statique dévolteur (convertisseur buck)

Le convertisseur abaisseur utilise un interrupteur  $S_1$  (commutateur) contrôlé à travers un signal PWM (figure 1.16) pour réguler la tension d'entrée suivant deux modes de conductions continus.

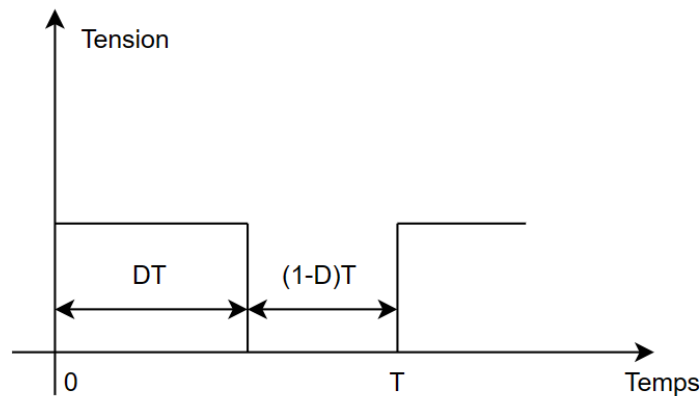


FIGURE 1.16 – Schéma d'un signal PWM

### Mode de fonctionnement continu (0 à DT)

Lorsque le commutateur  $S_1$  est ouvert, la charge est isolée de son alimentation mais le courant persiste grâce à l'énergie stockée dans l'inductance  $L$  et passe à travers la diode de roue libre  $D$ .




FIGURE 1.17 – Schéma équivalent dans le mode de fonctionnement (0-DT).

En appliquant les lois des nœuds et des mailles nous obtenons :

$$\begin{cases} L \frac{dI_L}{dt} + R_L I_L = V_{PV} - V_{out} \\ C_1 \frac{dV_{PV}}{dt} = I_{PV} - I_L \end{cases} \quad \text{De } 0 \text{ à } DT \quad (1.13)$$

### Mode de fonctionnement continu (DT à T)

Lorsque le commutateur  $S_1$  est ouvert, la charge est isolée de son alimentation mais le courant persiste grâce à l'énergie stockée dans l'inductance  $L$  et passe à travers la diode de roue libre  $D$ .




FIGURE 1.18 – Schéma équivalent dans le mode de fonctionnement (DT-T)

En appliquant les lois des nœuds et des mailles nous obtenons :

$$\begin{cases} L \frac{dI_L}{dt} + R_L I_L = -V_{out} \\ C_1 \frac{dV_{PV}}{dt} = I_{PV} \end{cases} \quad \text{De } DT \text{ à } T \quad (1.14)$$

Dans le cas général :

$$\begin{cases} L \frac{dI_L}{dt} + R_L I_L = DV_{PV} - V_{out} \\ C_1 \frac{dV_{PV}}{dt} = I_{PV} - DI_L \end{cases} \quad \text{De } 0 \text{ à } T \text{ avec } D \in [0, 1] \quad (1.15)$$

$$\begin{cases} \frac{dV_{PV}}{dt} = \frac{I_{PV} - DI_L}{C_1} \\ \frac{dI_L}{dt} = \frac{DV_{PV} - V_{out} - R_L I_L}{L} \end{cases} \quad (1.16)$$

Nous avons un système non linéaire sous la forme :

$$\dot{x} = f(x, u)$$

Avec  $I_L$  et  $V_{PV}$  sont les états du système et  $D$  est la commande.

$$f(x, u) = \begin{bmatrix} \frac{I_{PV} - DI_L}{C_1} \\ \frac{DV_{PV} - V_{out} - R_L I_L}{L} \end{bmatrix} \quad (1.17)$$

### 1.12.1 Linéarisation du système autour d'un point de fonctionnement

#### 1.12.1.1 Calcul des points de fonctionnements

Les points de fonctionnement optimaux (pour lesquels le PV délivre un maximum de puissance) peuvent être calculés en résolvant les équations suivantes :

$$f(x_0, u_0) = \begin{bmatrix} \frac{I_{PV_0} - DI_{L_0}}{C_1} \\ \frac{DV_{PV_0} - V_{out} - R_L I_{L_0}}{L} \end{bmatrix} = 0 \quad (1.18)$$

On trouve :

$$\begin{cases} I_{L_0} = \frac{I_{PV_0}}{D_0} \\ D_0 = \frac{V_{out} + \sqrt{V_{out}^2 + 4R_L I_{PV_0} V_{PV_0}}}{2V_{PV_0}} \end{cases} \quad (1.19)$$

#### 1.12.2 Représentation d'état du convertisseur

En appliquant le Jacobian on détermine la matrice d'état  $A$  et la matrice de commande  $B$  :

$$A = \left. \frac{\partial f}{\partial x} \right|_{x=x_0, u=u_0} = \begin{bmatrix} 0 & -\frac{D_0}{C_1} \\ \frac{D_0}{L} & -\frac{R_L}{L} \end{bmatrix} \quad (1.20)$$

$$B = \left. \frac{\partial f}{\partial u} \right|_{x=x_0, u=u_0} = \begin{bmatrix} -\frac{I_{L_0}}{C_1} \\ \frac{V_{PV_0}}{L} \end{bmatrix} \quad (1.21)$$

où  $V_{PV_0} = V_{mpp}$  et  $I_{PV_0} = I_{mpp}$  sont exactement la tension et le courant maximales que peut fournir le PV

Notre système peut s'écrire sous la représentation d'état suivante :

$$\begin{aligned} \begin{bmatrix} \dot{V}_{PV} \\ \dot{I}_L \end{bmatrix} &= \begin{bmatrix} 0 & \frac{-D_o}{C_1} \\ \frac{D_o}{L} & \frac{-R_L}{L} \end{bmatrix} \begin{bmatrix} V_{PV} - V_{mpp} \\ I_L - I_{L_0} \end{bmatrix} + \begin{bmatrix} \frac{-I_{L_0}}{C_1} \\ \frac{V_{mpp}}{L} \end{bmatrix} [D - D_0] \\ y &= \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} V_{PV} - V_{mpp} \\ I_L - I_{L_0} \end{bmatrix} \end{aligned} \quad (1.22)$$

Notre système peut s'écrire sous la représentation d'état suivante :

$$\begin{aligned} \begin{bmatrix} \dot{V}_{PV} \\ \dot{I}_L \end{bmatrix} &= \begin{bmatrix} 0 & \frac{-D_o}{C_1} \\ \frac{D_o}{L} & \frac{-R_L}{L} \end{bmatrix} \begin{bmatrix} V_{PV} - V_{mpp} \\ I_L - I_{L_0} \end{bmatrix} + \begin{bmatrix} \frac{-I_{L_0}}{C_1} \\ \frac{V_{mpp}}{L} \end{bmatrix} [D - D_0] \\ y &= \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} V_{PV} - V_{mpp} \\ I_L - I_{L_0} \end{bmatrix} \end{aligned} \quad (1.23)$$

On pose le changement de variable :

$$\begin{aligned} U &= D - D_0 \\ e_1 &= V_{PV} - V_{mpp} \\ e_2 &= I_L - I_{L_0} \end{aligned}$$

L'ajout d'un troisième état qui est l'intégrale de l'erreur  $e_0 = \int e_1 dt$  va jouer le rôle d'un intégrateur (erreur de position null).

Et donc le système devient :

$$\begin{aligned} \begin{bmatrix} \dot{e}_0 \\ \dot{e}_1 \\ \dot{e}_2 \end{bmatrix} &= \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & \frac{-D_o}{C_1} \\ 0 & \frac{D_o}{L} & \frac{-R_L}{L} \end{bmatrix} \begin{bmatrix} e_0 \\ e_1 \\ e_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{-I_{L_0}}{C_1} \\ \frac{V_{mpp}}{L} \end{bmatrix} U \\ y &= \begin{bmatrix} 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} e_0 \\ e_1 \\ e_2 \end{bmatrix} \end{aligned} \quad (1.24)$$

Linéariser un modèle non linéaire autour de points de fonctionnement spécifiques est une technique courante en contrôle et en analyse de systèmes dynamiques.

Nous avons choisis neuf points de fonctionnement basés sur des combinaisons de température (23, 25, 27) et d'irradiation (600, 800, 1000). Ces dernières sont représentatifs des conditions réelles auxquelles un panneau photovoltaïque est souvent soumis.

## Conclusion

En conclusion, les systèmes photovoltaïques constituent une technologie clé pour une transition énergétique vers des sources renouvelables et durables.

Ce chapitre a mis en lumière les principes de base du fonctionnement des cellules photovoltaïques, les différents types de cellules ,leur modélisation ainsi que les effets de l'irradiation et de la température sur leurs performances.L'utilisation et la modélisation du convertisseur Buck ont également été abordées.

En synthèse, les systèmes photovoltaïques ne sont pas seulement une réponse aux défis énergétiques contemporains, mais également une voie vers un avenir énergétique durable.



## CHAPITRE

### 2

# GÉNÉRALITÉS SUR LES RÉSEAUX NEURONES

## Introduction

Dans le cadre des avancées fulgurantes de la science et de la technologie, les réseaux de neurones artificiels se sont imposés comme un outil essentiel en intelligence artificielle, inspirés par le fonctionnement complexe des neurones biologiques. Ce chapitre explore en profondeur la structure et les mécanismes des neurones biologiques ainsi que leur correspondance avec les neurones artificiels, éléments de base de tout réseau de neurones.

Nous examinerons l'architecture des réseaux de neurones artificiels, en mettant en lumière l'organisation en couches des neurones qui permet au réseau d'apprendre et de résoudre des problèmes complexes grâce à l'ajustement des poids synaptiques pendant l'entraînement.

Nous discuterons des différents types de réseaux de neurones, y compris les perceptrons simples et multicouches, ainsi que les réseaux récurrents et non récurrents, chacun ayant des architectures distinctes. L'apprentissage des réseaux de neurones est également un point central de ce chapitre. Nous présenterons les méthodes d'apprentissage supervisé, non supervisé et par renforcement, expliquant comment chaque approche permet au réseau de s'adapter et d'optimiser ses performances sur des tâches spécifiques.

## 2.1 Neurone biologique

Le neurone est une cellule hautement spécialisée du système nerveux, essentielle pour la transmission des informations à travers le corps. Il se compose de quatre parties principales :

- Corps cellulaire (Le soma) est le centre métabolique du neurone. Il intègre les signaux électriques reçus des dendrites et contient le noyau ainsi que la majorité des organites cellulaires.
- Dendrites sont des extensions ramifiées qui reçoivent les signaux électriques d'autres neurones et les transmettent au corps cellulaire.
- Axone est le prolongement unique qui transmet les signaux électriques du corps cellulaire vers d'autres neurones, muscles ou glandes.
- Synapse est la jonction entre deux neurones qui permet la transmission des signaux via des neurotransmetteurs.




FIGURE 2.1 – Représentation schématique d'un neurone biologique

## 2.2 Un neurone artificiel

Un neurone artificiel est une unité de traitement dotée de  $n$  entrées  $x_1, x_2, \dots, x_n$  et d'une seule sortie. Son rôle est de produire une sortie  $y$  en appliquant une fonction de seuillage, également appelée fonction d'activation (figure 2.2)[3].

La sortie du neurone peut être exprimée sous la forme :

$$y(x) = f\left(w_0 + \sum_{i=1}^M (w_i x_i)\right) \quad (2.1)$$

Avec

$f$  est la fonction d'activation.

$x = \{x_1, x_2, \dots, x_M\}$  est le vecteur des entrées.

$w = \{w_1, w_2, \dots, w_M\}$  est le vecteur des poids correspondants à chaque entrée.

$w_0$  est le biais (généralement  $w_0 = 1$ ).

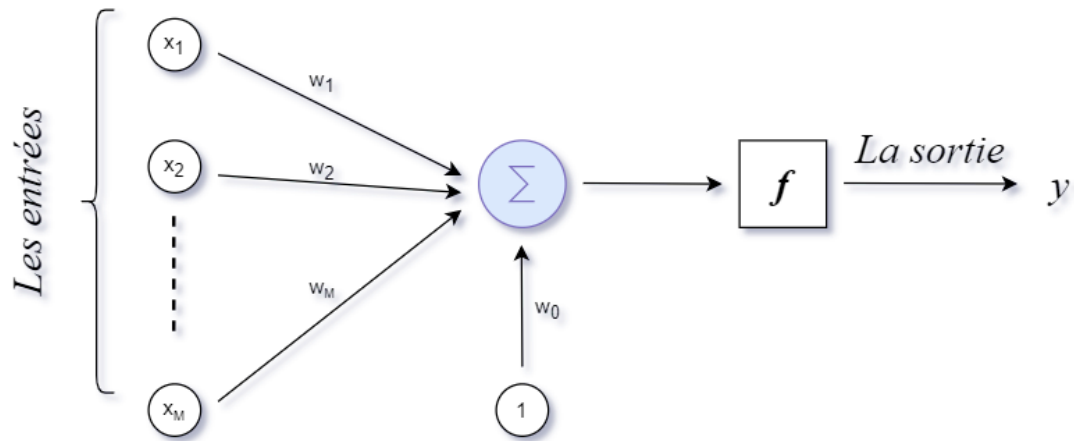


FIGURE 2.2 – Représentation d'un neurone artificiel.

## 2.3 Liaison entre les neurones biologiques et les neurones artificiels

Neurone biologique	Neurone artificiel
Corps cellulaire	Somme pondérée
Noyau	Fonction d'activation
Dendrites	Entrées
Axone	Sortie
Synapse	Poids synaptiques

TABEAU 2.1 – Relation entre les neurones biologiques et artificiels

## 2.4 Architecture d'un réseau neurone

Un réseau de neurones artificiels est un ensemble de neurones associés en couches et fonctionnant en parallèle. Il se compose de trois couches interconnectées :

- La couche d'entrée.
- Les couches cachées.
- La couche de sortie.

Ces couches sont reliées par des connexions pondérées qui transmettent l'information entre les neurones. Grâce à cette architecture, le réseau peut apprendre et résoudre des problèmes complexes en ajustant les poids des connexions lors de l'entraînement, sans nécessiter de programmation explicite pour chaque tâche.[2]

## 2.5 Fonction d'activation

La fonction d'activation dans un réseau de neurones détermine comment une somme pondérée des entrées est transformée en une sortie du neurone. Elle introduit une non-linéarité essentielle permettant au réseau de modéliser des relations complexes. Le tableau 2.2 présente les fonctions d'activations les plus utilisées :

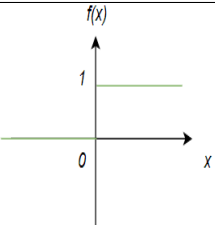
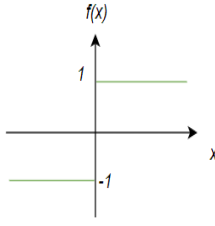
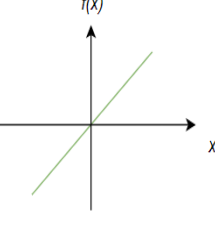
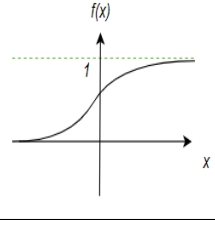
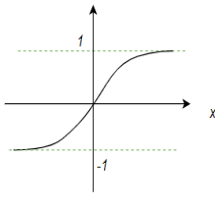
Nom de la fonction	Relation entrée/sortie	Allure
Seuil	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{sinon} \end{cases}$	
Seuil symétrique	$f(x) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{sinon} \end{cases}$	
Linéaire	$f(x) = x$	
Sigmoïde	$f(x) = \frac{1}{1+e^{-x}}$	
Tangente hyperbolique	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

TABLEAU 2.2 – Fonctions d'activation usuelles

## 2.6 Types de réseaux neurones

Il existe plusieurs types de réseaux de neurones, chacun conçu pour des applications spécifiques et possédant des architectures distinctes [12]. On peut les classer selon les critères suivants :

- La nature du traitement de l'information effectué au niveau des nœuds individuels.
  - Single layer network (perceptron).
  - Multi-layer network.
- Les géométries de connexion.
  - Les réseaux de neurones non bouclés (Feed-forward).
  - Les réseaux de neurones bouclés ou dits récurrents (Feed-back).

### 2.6.1 Perceptron

Le perceptron est un réseau de type feedforward, il est composé d'une seule couche de neurones avec des connexions directes entre les neurones d'entrée et un neurone de sortie. Il utilise des poids ajustables et une fonction d'activation à seuil pour produire une sortie binaire. Il est généralement utilisé pour résoudre des opérations logiques simples(et/ou).[2]




FIGURE 2.3 – Perceptron multicouche.

### 2.6.2 Perceptron multicouche

Un perceptron multicouche (PMC) (figure 2.4) est composé de plusieurs couches de neurones : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie, chaque couche cachée contenant plusieurs neurones. Les PMC utilisent des fonctions d'activation non linéaires dans les couches cachées pour modéliser des relations complexes et non linéaires, ce qui les rend capables de résoudre des problèmes que les perceptrons simples ne peuvent pas [2].




FIGURE 2.4 – Perceptron multicouche.

### 2.6.3 Réseaux non bouclés (non récurrents)

Ce sont des réseaux unidirectionnels (figure 2.5) sans retour arrière (feedforward). Le signal de sortie est directement obtenu après application du signal d'entrée. Cette absence de rétroaction élimine les problèmes de dépendance temporelle et de convergence, rendant les FNN efficaces pour des tâches de prédiction.[1]




FIGURE 2.5 – Réseau non bouclé

### 2.6.4 Les réseaux bouclés (récurrents)

Les réseaux récurrents (figure 2.6) possèdent des connexions récurrentes qui renvoient l'information en arrière par rapport au sens de propagation. Ainsi la sortie peut être en fonction d'elle-même ce qui n'est possible que si l'on tient compte de la notion temps.[13]




FIGURE 2.6 – réseau bouclé.

## 2.7 Apprentissage des réseaux de neurones

L'apprentissage constitue une phase cruciale dans le développement d'un réseau de neurones. Il s'agit du processus par lequel un réseau ajuste ses poids synaptiques pour optimiser ses performances sur une tâche spécifique. On peut distinguer trois types d'apprentissage :

- Apprentissage supervisé.
- Apprentissage non supervisé.
- Apprentissage par renforcement.

### 2.7.1 Apprentissage supervisé

L'apprentissage dit supervisé représenté dans la figure 3.3 est caractérisé par la présence d'un "professeur" qui possède une connaissance approfondie de l'environnement dans lequel évolue le réseau de neurones. Dans cette méthode, le modèle est entraîné sur des données étiquetées, où chaque entrée est associée à une sortie correcte. Le réseau de neurones ajuste ses poids afin de minimiser l'écart entre ses prédictions et les sorties réelles [20][17].




FIGURE 2.7 – Schéma bloc de l'apprentissage supervisé.

### 2.7.2 Apprentissage non supervisé

Contrairement à l'apprentissage supervisé, l'apprentissage non supervisé est caractérisé par l'absence complète de "professeur" et donc ne nécessite pas de données étiquetées pour entraîner les modèles. Dans cette approche, on introduit au réseau des entrées et on le laisse évoluer de manière autonome. Le réseau s'auto-organise de façon à optimiser une certaine fonction de coût pour enfin déterminer les poids synaptiques du réseau [20][17].

### 2.7.3 Apprentissage renforcé

L'apprentissage par renforcement s'inspire des mécanismes d'apprentissage animal, où il n'existe pas de superviseur fournissant les réponses correctes. Le système apprend à partir des effets de ses actions : si une action améliore les performances, elle est renforcée. Les composants responsables de cette action sont soit récompensés, soit punis, selon leur contribution à l'amélioration ou à la dégradation des performances du système [17].

## 2.8 Algorithme d'apprentissage des réseaux de neurones multicouches

Les réseaux de neurones multicouches utilisent généralement, dans leur apprentissage, un algorithme de rétropropagation du gradient. Dans celui-ci, les poids et les biais du réseau sont ajustés de manière itérative afin de minimiser une fonction de coût prédéfinie, en utilisant seulement les données d'entrée/sortie. Cette technique consiste à calculer les gradients de la fonction de coût par rapport à chaque poids du réseau. Ces gradients indiquent la direction dans laquelle les poids doivent être ajustés pour réduire l'erreur de prédiction du réseau. En rétropropageant ces gradients à travers le réseau, de la sortie vers l'entrée, les poids sont mis à jour de manière à améliorer progressivement les performances.[14]

## 2.9 Algorithme de Levenberg-Marquardt

Egalement connu sous le nom de méthode des moindres carrés pondérés, il combine les aspects des méthodes de descente de gradient et de Gauss-Newton pour atteindre une convergence rapide et une robustesse dans la résolution des problèmes. Cet algorithme utilise l'idée de rétropropagation dans le calcul du Jacobien afin d'ajuster les poids synaptique du réseau neurone.[21]

Considérant la fonction d'erreurs  $E$  à minimiser :

$$E = \frac{1}{2} \sum_{i=0}^N e_i^2 = \frac{1}{2} \sum_{i=0}^N (y_i - f(x_i, w))^2 \quad (2.2)$$

Où :

$x_i$  et  $y_i$  sont les données d'entrée et de sortie respectivement  
 $f(x_i, w)$  est le modèle non linéaire paramétré par le vecteur de poids  $w$ .



Par suite on définit le Jacobien de cette fonction sous la forme :

$$J_{i,j} = \frac{\partial e_i}{\partial w_j} \quad (2.3)$$

De plus le Hessien de la fonction d'erreur peut être approximé par l'expression suivante :

$$H = J^T J + \mu I \quad (2.4)$$

Où :

$\mu > 0$  est appelé coefficient de combinaison qui assure la inversibilité du Hessien.

$I$  est la matrice identité

Les poids du réseau neurone peuvent s'exprimer de la manière suivante

$$w^{(k+1)} = w^{(k)} - H^{-1}(J^{(k)}e^{(k)}) \quad (2.5)$$

$$w^{(k+1)} = w^{(k)} - (J^T J + \mu I)^{-1}(J^{(k)}e^{(k)}) \quad (2.6)$$

Ci-dessous le diagramme explicatif de l'algorithme Levenberg-Marquardt

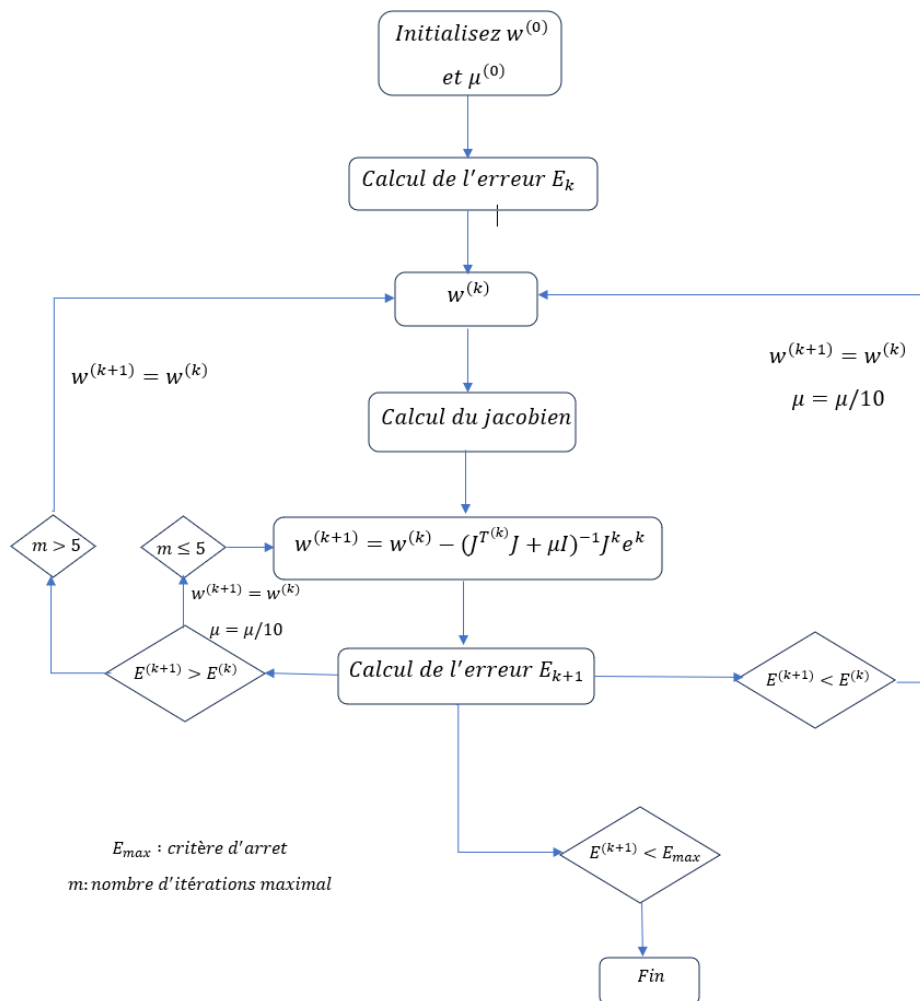


FIGURE 2.8 – Algorithme de Levenberg-Marquardt

## 2.10 Avantages et inconvénients des réseaux neurones

Les réseaux de neurones artificiels présentent des avantages considérables

- **Capacité d'apprentissage complexe** : Ils peuvent modéliser des relations non linéaires complexes.
- **Adaptabilité** : Ils peuvent être adaptés pour une variété de tâches, y compris la classification, la régression, la reconnaissance d'images, et plus encore.
- **Robustesse et tolérance aux erreurs** : Ils sont souvent robustes aux bruits et aux données manquantes, permettant de maintenir des performances acceptables dans des environnements variés.
- **Généralisation** : Lorsqu'ils sont correctement entraînés, ils peuvent bien généraliser sur des données non vues, offrant des prédictions précises sur de nouveaux ensembles de données.
- **Capacité à traiter des données multimodales** : Ils peuvent intégrer et traiter différentes formes de données simultanément, ce qui les rend très polyvalents pour des tâches multimodales.

Cependant, les réseaux de neurones présentent aussi plusieurs inconvénients qu'il est important de considérer.

- **Besoins en grandes quantités de données** : Pour atteindre de bonnes performances, ils nécessitent généralement de vastes ensembles de données, ce qui peut être difficile à obtenir.
- **Temps de calcul élevé** : L'entraînement des réseaux de neurones, en particulier des modèles profonds, peut être très exigeant en termes de calcul et nécessiter des ressources matérielles puissantes.
- **Risque de surapprentissage (overfitting)** : Si un réseau est trop complexe ou mal régularisé, il peut mémoriser les données d'entraînement plutôt que d'apprendre les patterns, ce qui conduit à une mauvaise performance sur de nouvelles données.
- **Difficulté d'optimisation** : Le processus d'optimisation des hyperparamètres peut être complexe et nécessiter des essais et des erreurs approfondis.
- **Sensibilité aux paramètres d'initialisation** : La performance peut être très sensible aux conditions initiales, et un mauvais choix d'initialisation des paramètres peut affecter la convergence et les performances finales.

## Conclusion

En conclusion, ce chapitre a offert une analyse approfondie des neurones biologiques et artificiels, en mettant en lumière leurs similitudes structurelles et fonctionnelles. Nous avons examiné les diverses architectures de réseaux de neurones artificiels, telles que les perceptrons multicouches et les réseaux récurrents, qui démontrent la complexité et l'adaptabilité de ces systèmes. Les différentes méthodes d'apprentissage, qu'elles soient supervisées, non supervisées ou par renforcement, ont été présentées comme des éléments cruciaux pour l'amélioration des performances des réseaux de neurones. En comprenant ces concepts, nous sommes mieux préparés à développer des systèmes intelligents capables d'apprentissage et d'adaptation, ouvrant ainsi la voie à des applications innovantes dans divers domaines.

## CHAPITRE

### 3

# SYNTHÈSE DE LOIS DE COMMANDE MPPT

## Introduction

Ce chapitre explore l'application des techniques d'intelligence artificielle, notamment des réseaux de neurones, pour la commande MPPT (Maximum Power Point Tracking) d'un générateur photovoltaïque. Notre objectif est de remplacer la commande optimale, qui utilise des inégalités matricielles linéaires (LMI), par une méthode de commande basée sur des réseaux de neurones. Cette approche promet de simplifier la mise en œuvre de la commande tout en maintenant, voire améliorant, la robustesse et les performances dynamiques du système.

Dans les sections suivantes, nous examinerons les concepts théoriques et les techniques pratiques permettant d'optimiser la puissance extraite des panneaux solaires. Nous détaillerons la procédure de construction des réseaux de neurones, leur entraînement, ainsi que les simulations et comparaisons de performance avec les méthodes traditionnelles. L'objectif final est de démontrer comment l'intelligence artificielle peut être efficacement intégrée dans les systèmes de génération d'énergie renouvelable pour maximiser l'efficacité énergétique.

### 3.1 Commande optimale

Dans notre mémoire d'ingénieur, nous nous sommes intéressés à la commande optimale du convertisseur DC/DC . Nous avons vu précédemment (voir le chapitre 1) que notre système est un système à neuf commutations qui varie en fonction de la température et de l'irradiation. Il peut s'écrire sous la forme :

$$\dot{x} = A_i x + B_i u \quad , i \in [1, 2..9] \quad (3.1)$$

avec :

$$x = \begin{bmatrix} e_0 \\ e_1 \\ e_2 \end{bmatrix} \text{ et } u = D - D_0 \quad (3.2)$$

$e_0 = \int e_1 dt$  : est l'intégrale de l'erreur de le tension fournie par le PV.

$e_1 = V_{PV} - V_{PV_0}$  : est l'erreur de le tension fournie par le PV.

$e_2 = I_L - I_{L_0}$  : est l'erreur du courant de l'inductance.

$u$  : est l'erreur du rapport cyclique

Afin de garantir le suivi du MPP ainsi que la stabilité globale du système lors de la commutation ,nous avons opté pour la théorie des LMI qu'on utilisera afin de résoudre un LQR et enfin calculé les neuf gains de commande ( $u = K_i x$ ) correspondant aux neuf sous-systèmes.

Dans cette approche, le processus de sélection du gain de commande est conditionné par la valeur de la tension maximale que peut délivrer le PV ( $V_{mpp}$ ), cette valeur sera approximée à l'aide d'une équation et comparée aux tensions de références préalablement calculés pour les neuf sous-systèmes .

La tension de référence peut s'écrire sous la forme :  $V_{ref_\sigma} = \frac{V_{mpp_\sigma} + V_{mpp_{\sigma+1}}}{2}$




FIGURE 3.1 – Schema explicatif pour le choix du gain de commande.

## 3.2 Commande MPPT à base de réseaux neurones

Notre commande MPPT intelligente sera composée de deux réseaux de neurones en série. Le premier réseau de neurones (ANN) aura pour rôle d'estimer en temps réel les valeurs de  $V_{mpp}$  et  $I_{mpp}$  pour lesquelles le panneau solaire devra se positionner afin de délivrer une puissance maximale. Quant au deuxième réseau de neurones, il remplacera la commande MPPT classique et aura comme sortie un rapport cyclique qui commandera le convertisseur.

### 3.2.1 Objectifs

- Éliminer les erreurs d'approximation de  $V_{mpp}$  et  $I_{mpp}$  (erreur de 5%)
- Simplifier la mise en œuvre de la commande, tout en maintenant la robustesse et les performances du système dynamique.

### 3.2.2 Procédure de construction d'un réseau de neurones

La procédure de conception d'un réseau de neurone peut être résumée en cinq étapes

- Collecter une base de données pertinente.
- Diviser la base de données en trois sous ensembles (base d'apprentissage, base de validation et base de test).
- Déterminer le type de réseau neuronal (PMC, RNN,.. etc.) et définir sa structure (nombre de couches, nombre de neurones par couche et les fonctions d'activation appropriées pour chaque couche).
- Choisir l'algorithme d'apprentissage.
- Entraîner le réseau de neurones sur les bases d'apprentissage et de validation.
- Mesurer les performances du réseau de neurone sur la base de test.

### 3.2.3 Collecte d'une base de données

L'objectif de cette étape est de rassembler un nombre de données suffisant qui servira à la fois à l'apprentissage, au test et à l'évaluation du réseau neuronal, elle sera divisée en trois sous ensembles (70% Apprentissage, 15% Test et 15 %Validation).

Dans notre cas on a construit notre base de données à partir des résultats de simulations 130 données pour chaque variable sur le 1er réseau (température (T), irradiation (G),  $V_{mpp}$  et  $I_{mpp}$ ) et 1000052 données pour chaque variable sur le 2ème réseau ( $e_0$ ,  $e_1$ ,  $e_2$  et  $u$ ). Ensuite, ces données ont été normalisées de sorte qu'elles soient toutes sur la meme échelle [0,1] facilitant ainsi le processus d'apprentissage.

### 3.2.4 Construction du premier réseau de neurones

La figure 3.2 montre bien que notre réseau est un perceptron multicouche (feedforward) constitué de :

- Une couche d'entrée composée de deux neurones ce qui correspond aux variables "Température" et "Irradiation".
- Deux couches cachées dotées de cinq neurones chacune avec des fonctions d'activations de type sigmoïde tangentielle.
- Une couche de sortie avec deux neurones représentant  $V_{mpp}$  et  $I_{mpp}$  dont la fonction d'activation employée est de type linéaire.

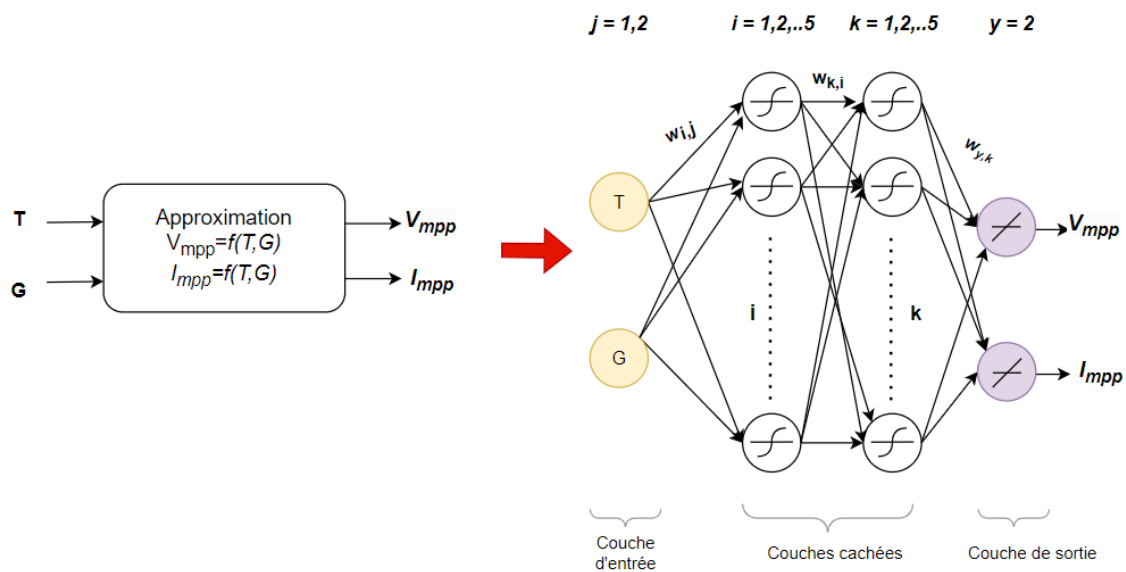


FIGURE 3.2 – Réseau neurone pour estimer  $V_{mpp}$  et  $I_{mpp}$  .

### 3.2.5 Construction du deuxième réseau de neurones

Egalement pour ce réseau ,on considerera un perceptron multicouche composé de deux couches cachées, avec 7 neurones chacune. Les entrées seront les mêmes que ceux vu dans la commande classique ( $e_0, e_1, e_2$  : les composants du vecteur d'état  $x$ ), afin d'obtenir la commande  $u$  qui controlera l'entrée du convertisseur.




FIGURE 3.3 – Réseau neurone de la commande

### 3.2.6 Entraînement des réseaux neurones

L'entraînement des deux réseaux neurones (figure 3.4 et 3.7) a été effectué avec l'algorithme Levenberg-Marquart en utilisant la fonction 'trainlm' (voir Programme A.1, Programme A.2).

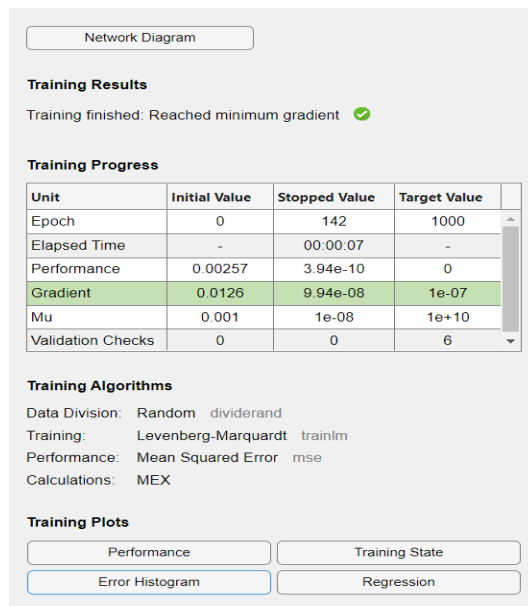


FIGURE 3.4 – Entraînement du réseau neurone de  $V_{mpp}$  et  $I_{mpp}$






FIGURE 3.5 – Performances du réseau neurone de  $V_{mpp}$  et  $I_{mpp}$




FIGURE 3.6 – Régression du réseau neurone de  $V_{mpp}$  et  $I_{mpp}$

La figure 3.5 illustre la performance du réseau de neurones entraîné sur les ensembles d'entraînement, de validation et de test. On observe que l'erreur quadratique moyenne diminue grandement au fil des itérations jusqu'à ce que le critère d'arrêt du gradient soit atteint. Cela montre que l'algorithme de Levenberg-Marquardt est efficace pour optimiser les poids du réseau qui va estimer  $V_{mpp}$  et  $I_{mpp}$ .

La figure de régression 3.6 montre une très bonne régression grâce aux points alignés près de la ligne idéale, suggérant que le réseau peut estimer avec précision les valeurs de  $V_{mpp}$  et  $I_{mpp}$ .

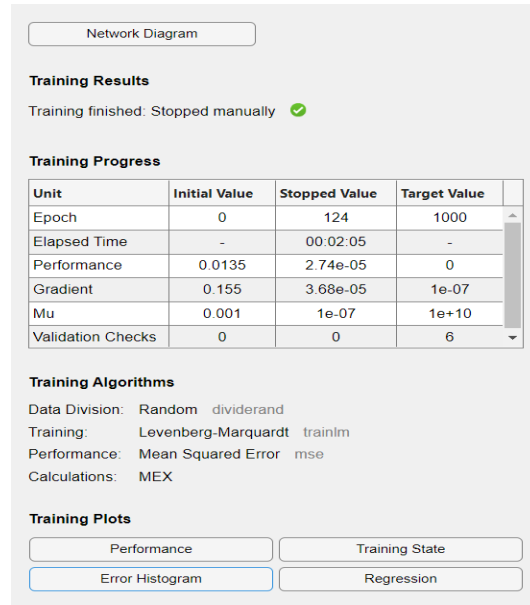


FIGURE 3.7 – Entrainement du réseau neurone de la commande




FIGURE 3.8 – Performances du réseau neurone de la commande




FIGURE 3.9 – Régression du réseau neurone de la commande

La figure 3.8 illustre les performances des réseaux de neurones entraînés sur les ensembles d'entraînement, de validation, et de test. On observe que l'erreur quadratique moyenne diminue progressivement au fil des itérations. Ces résultats démontrent l'efficacité de l'algorithme de Levenberg-Marquardt pour optimiser les poids du réseau.

Les figures de régression 3.9 montrent la précision des prédictions des réseaux par rapport aux valeurs réelles. Une bonne régression est illustrée par les points alignés, cela montre que le réseau de neurones pourra calculer la commande  $u$  nécessaire à la régulation de la tension du PV.

### 3.3 Simulation des commandes MPPT

Pour simuler un générateur photovoltaïque, nous allons utiliser Matlab et son environnement Simulink, qui offrent les outils nécessaires pour une modélisation complète. Simulink inclut le bloc "PV Array" pour modéliser les panneaux solaires selon un modèle à quatre paramètres d'une cellule photovoltaïque. Il contient également le bloc "Neural Network" pour représenter un réseau neuronal, essentiel pour les algorithmes d'apprentissage et de prédiction. En outre, Simulink propose des composants électroniques indispensables pour la modélisation d'un hacheur, tels que les Mosfets, les diodes, les inductances et les condensateurs, permettant de simuler efficacement un convertisseur DC-DC.

Les données à saisir sur le bloc de paramètres du PV sont ceux donnés sur le datasheet du panneau en STC (conditions de test standard AM1.5,  $T = 25^{\circ}\text{C}$ ,  $G = 1000\text{W}/\text{m}^2$ ).

Paramètres(STC)	Valeurs
Puissance maximale ( $P_{max}$ )	80 W
Tension au point de puissance maximale ( $V_{mpp}$ )	15.90 V
Courant au point de puissance maximale ( $I_{mpp}$ )	5.03 A
Tension du circuit ouvert ( $V_{oc}$ )	18.58 V
Courant de court-circuit ( $I_{cc}$ )	5.59 A
Température de fonctionnement nominale	$47 \pm 2^{\circ}\text{C}$

TABLEAU 3.1 – Paramètres en STC du PV

La figure 3.10 représente le modèle simulink d'un hacheur buck qui jouera le rôle d'un étage d'adaptation d'impédance entre le PV et une batterie de 12V.

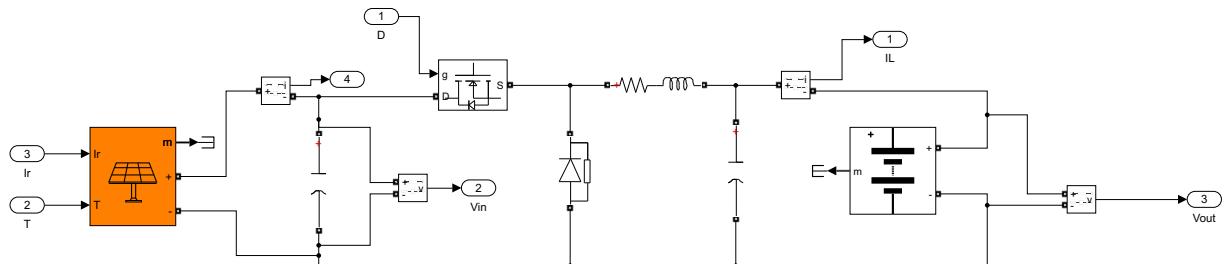


FIGURE 3.10 – Circuit simulink de l'hacheur buck

Le dimensionnement des composants du convertisseur est le suivant :

Capacité d'entrée  $C_1 = 2200 \mu\text{F}$

Capacité de filtrage  $C_2 = 22 \mu\text{F}$

Inductance  $L = 2.4 \text{mH}$

Résistance de l'inductance  $R_L = 0.4 \Omega$

Temps d'échantillonnage  $T_e = 10^{-6} \text{s}$

Tension de sortie  $V_{out} = 12\text{V}$

La figure 3.11 représente le schéma globale du système avec sa commande

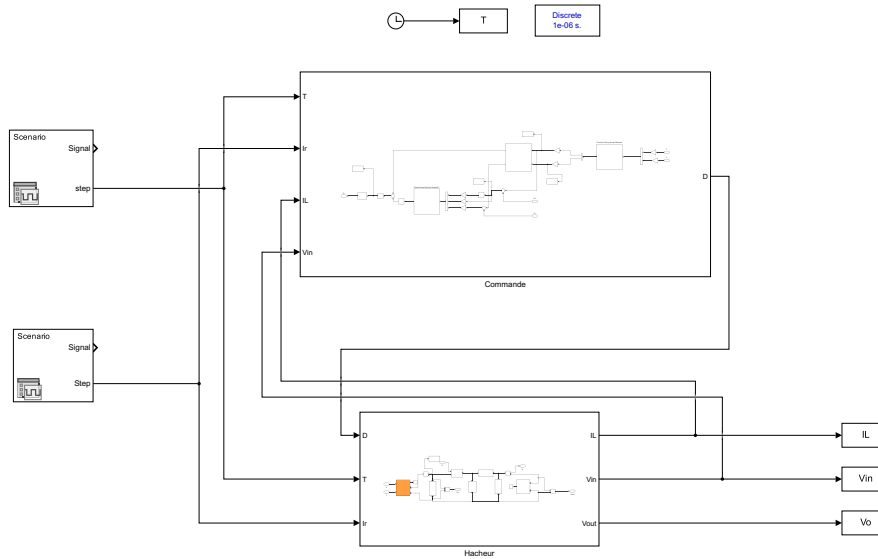


FIGURE 3.11 – Schema bloc général de la commande MPPT d'un PV

Dans le but de visualiser le suivi du MPP représenté par  $(V_{mpp}, I_{mpp})$  en utilisant la commande par réseaux de neurones artificiels, une simulation est effectuée pour des scénarios de température et d'irradiation (3.12 et 3.13) :




FIGURE 3.12 – Scénario de la température




FIGURE 3.13 – Scénario de l'irradiation

### 3.3.1 Simulation de la commande LQR

La figure 3.14 illustre la commande LQR qui est composé d'un premier réseau neurone ayant pour entrées la température et l'irradiation et comme sorties les valeurs de  $(V_{mpp}, I_{mpp})$  pour lesquels le panneau sera à son maximum de puissance. Ces valeurs seront utilisés pour calculer les points de fonctionnement  $(D_0, I_{L_0})$  (voir chapitre 1).

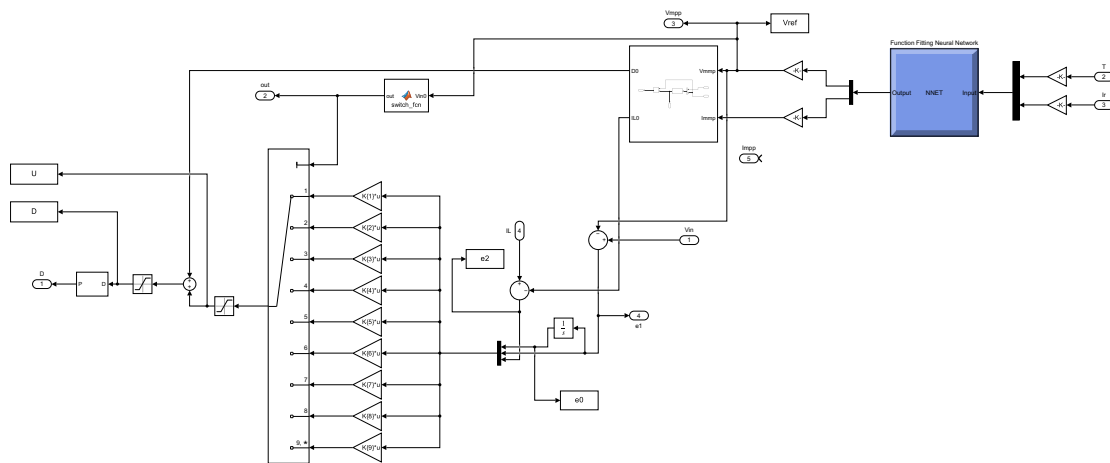


FIGURE 3.14 – Schéma de la commande par réseau neurone.

### 3.3.1.1 Résultats de la commande optimale

Les figures 3.15 et 3.16 représentent les résultats de la tension et du courant du PV suite à une régulation par la commande classique et l'estimation de  $V_{mpp}$  et  $I_{mpp}$  par réseau de neurone.




FIGURE 3.15 – Représentation de la tension du PV par rapport au temps




FIGURE 3.16 – Représentation du courant du PV par rapport au temps

La figure 3.17 représente la valeur du rapport cyclique résultant de la commande optimale.




FIGURE 3.17 – Représentation du rapport cyclique par rapport au temps

La figure 3.18 représente les décisions choisies par la fonction de commutation.




FIGURE 3.18 – Représentation de la commutation par rapport au temps



### 3.3.2 Simulation de la commande par réseau neurone

La figure 3.19 illustre le remplacement de la commande optimale classique par un deuxième réseau de neurones.

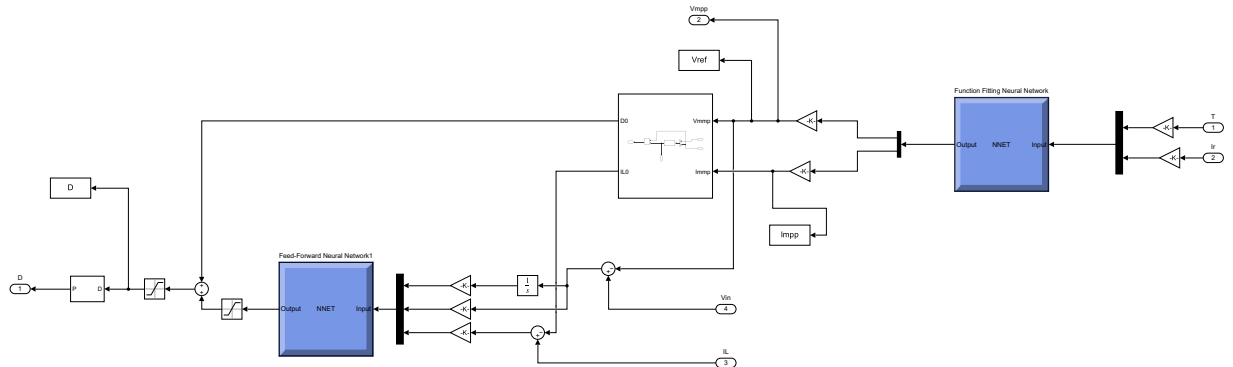


FIGURE 3.19 – Schéma de la commande par réseau neurone.

#### 3.3.2.1 Résultats de la commande par réseau de neurone

Les figures (3.20 et 3.21) représentent les résultats de la tension et le courant du PV suite à une régulation avec une commande par réseau neurone.




FIGURE 3.20 – Représentation de la tension d'entrée par rapport au temps




FIGURE 3.21 – Représentation du courant du PV par rapport au temps

La figure 3.22 représente la valeur du rapport cyclique qui a été calculé par la commande par réseau neurone.




FIGURE 3.22 – Représentation du rapport cyclique par rapport au temps

### 3.4 Comparaison entre les deux commandes

La figure 3.23 représente les résultats de simulation des deux commande MPPT pour un générateur photovoltaïque (commade optimale et commande par réseau neurone)




FIGURE 3.23 – Représentation de la tension du PV par rapport au temps

La figure 3.24 représente les résultats de la tension de sortie du PV qui est commandé par les deux commandes.




FIGURE 3.24 – Zoom sur la représentation de la tension d'entrée par rapport au temps

### 3.4.1 L'erreur quadratique moyenne

$$e_{puissance} = \frac{\sum_{i=0}^N (P_{fournie,i} - P_{mpp,i})^2}{N} \quad (3.3)$$

$N$  : Le nombre de points

On trouve pour chaque commande

$$e_{LQR} = 18.5414 \quad (3.4) \quad e_{ANN} = 17.2574 \quad (3.5)$$

### 3.4.2 Interprétation des résultats

Les graphiques montrent que la tension et le courant délivrés par le panneau photovoltaïque suivent la tension et le courant de référence ( $V_{mpp}, I_{mpp}$ ).

On remarque que le système réagit rapidement aux différents changements climatiques tout en restant stable.

Le rapport cyclique reflète la modulation de largeur d'impulsion (PWM) utilisée pour contrôler le Mosfet. Les variations du rapport cyclique montrent comment le système adapte sa sortie pour suivre le MPP en temps réel.

On remarque aussi que la commande ANN semble revenir vers la consigne plus rapidement par rapport à la commande classique.

D'après les erreurs quadratiques moyennes, on peut dire qu'avec une commande à base de neurone artificiel, on diminuera la perte d'énergie par rapport à la commande par LMI.

La commande optimale avec réseau de neurones nous permet de rendre le système de contrôle moins lourd par rapport à la commande optimale classique, en supprimant la fonction de commutation qui choisit le gain approprié.

## Conclusion

Nous concluons que ce chapitre nous a permis d'explorer l'application de la commande MPPT (Maximum Power Point Tracking) basée sur les réseaux de neurones pour un générateur photovoltaïque afin de maximiser la puissance extraite des panneaux solaires. Cette approche a simplifié la mise en œuvre de la commande classique, traditionnellement complexe. Notre étude confirme ainsi le potentiel des techniques d'intelligence artificielle, et en particulier des réseaux de neurones, pour améliorer les performances des systèmes de génération d'énergie renouvelable.

## CHAPITRE

### 4

# IMPLÉMENTATION DES COMMANDES MPPT

## Introduction

Dans ce chapitre, nous plongeons au cœur de l'expérimentation et de la validation des concepts théoriques et des simulations vus dans le chapitre précédent. Pour cela, nous présenterons le matériel requis pour la mise en œuvre de la commande MPPT (Maximum Power Point Tracking) pour un générateur photovoltaïque.

L'introduction des réseaux de neurones dans la commande MPPT sera également abordée, dans le but d'améliorer la précision et la performance de cette commande.

Pour évaluer la robustesse et la performance des commandes MPPT, nous réaliserons deux expériences distinctes. La première expérience sera conduite avec une simple alimentation électrique, permettant de simuler les conditions d'un panneau photovoltaïque dans un environnement contrôlé. Quant à la deuxième expérience, elle sera effectuée avec un véritable panneau photovoltaïque, exposé à des conditions environnementales telles que l'ensoleillement et la température. Cette deuxième expérimentation reflète fidèlement les conditions d'utilisation réelles des panneaux photovoltaïques.

En optimisant la commande MPPT de manière innovante et prometteuse, nous ouvrons la voie à une gestion plus efficace de l'énergie solaire.

## 4.1 Méthodologie

La figure 4.1 illustre le schéma bloc de la commande MPPT d'un générateur photovoltaïque, incluant les différentes unités de commande et de mesure.

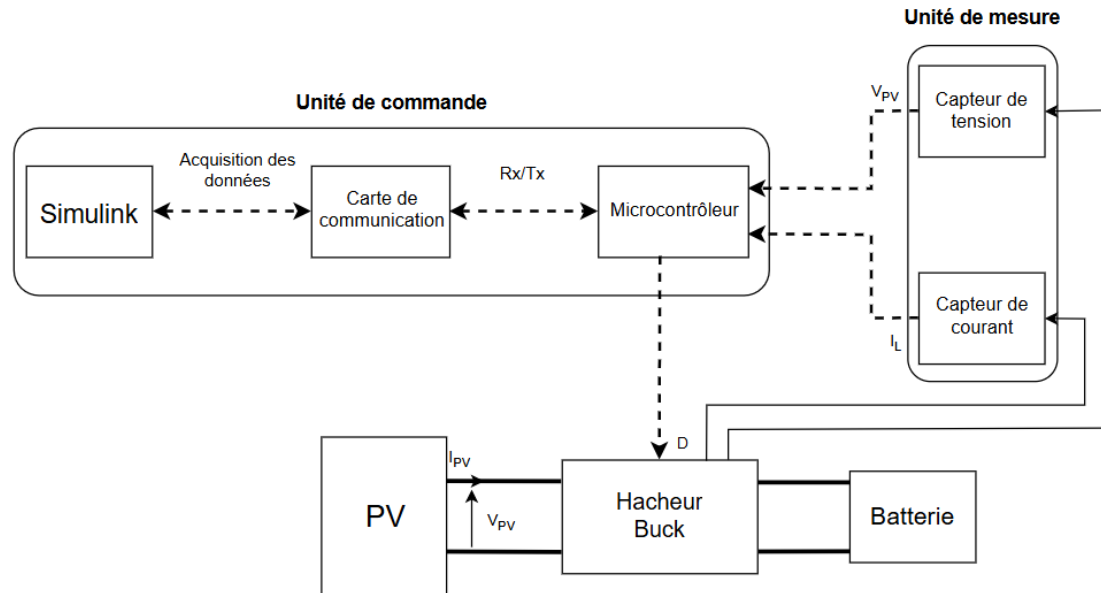


FIGURE 4.1 – Schéma bloc de la méthodologie de la commande

La commande est implémentée sur un microcontrôleur grâce à la bibliothèque Waijung, qui permet de convertir les fichiers Simulink en langage C. Une carte de communication est utilisée pour permettre la communication en temps réel avec le microcontrôleur et l'acquisition des données. Des capteurs mesurent la tension du panneau et le courant de l'inductance, valeurs utilisées pour calculer le rapport cyclique.

### 4.1.1 Unité de commande

#### 4.1.1.1 Microcontrôleur

Les microcontrôleurs, des circuits intégrés contenant les composants essentiels d'un ordinateur (processeur, mémoire, interfaces d'entrée/sortie) sur une seule puce, sont utilisés pour contrôler divers dispositifs et systèmes. Le microcontrôleur STM32 a été choisi pour sa compatibilité avec Simulink et sa capacité de communication en temps réel.[16]




FIGURE 4.2 – Carte STM32

#### 4.1.1.2 Carte de communication

Une carte de communication permet à l'ordinateur d'interagir avec des périphériques externes via des protocoles de communication série tels que UART, SPI ou I2C. La carte cjmcu-232H a été choisie pour l'échange de données et de signaux entre Simulink et le microcontrôleur.[6]



FIGURE 4.3 – Carte cjmcu-232H

### 4.1.2 Unité de mesure

La commande MPPT nécessite une mesure précise de la tension de sortie du panneau solaire (PV) ainsi que du courant de l'inductance.(figure 4.4).



FIGURE 4.4 – Circuits des capteurs

#### 4.1.2.1 Capteur de tension

Le capteur de tension LEM LV 25-P, basé sur l'effet Hall, est utilisé pour assurer des mesures fiables.[23]



FIGURE 4.5 – Capteur LV 25-P

#### 4.1.2.2 Capteur de courant

Le microcontrôleur ne pouvant pas mesurer le courant, le LTS 55-P de LEM, un transducteur de courant utilisant la technologie à effet Hall, est utilisé pour sa sortie instantanée, son excellente précision et sa très bonne linéarité.[22]




FIGURE 4.6 – Capteur LTS 55-P

#### 4.1.2.3 Thermocouple

Un thermocouple est un capteur de température qui fonctionne grâce à l'effet Seebeck, générant une tension électrique proportionnelle à la différence de température entre deux jonctions métalliques distinctes. Le thermocouple 80BK-A de Fluke, de type K, est conçu pour mesurer des températures allant de  $-40\text{ }^{\circ}\text{C}$  à  $260\text{ }^{\circ}\text{C}$  et se connecte facilement aux multimètres numériques.



FIGURE 4.7 – Thermocouple 80BK-A



## 4.2 Convertisseur buck

La figure 4.8 illustre le prototype du convertisseur buck que nous utiliserons pour réaliser l'adaptation d'impédance entre le PV et la batterie. Il est constitué de :

- Un Mosfet IRF4905 de type P.
- Une inductance de  $2.4\text{ mH}$
- Une capacité d'entrée  $C_1 = 2200\ \mu\text{F}$ . pour filter la tension de sortie du PV.
- Une capacité de sortie  $C_2 = 22\ \mu\text{F}$  pour filter le courant de sortie du convertisseur.
- Un driver HCPL 31-20 (optocoupleur) qui permet l'isolation galvanique entre la partie commande et puissance
- Un circuit Snubber pour protéger les composants tels que les transistors, les diodes, et autres éléments de commutation contre les surtensions, les pics de courant.




FIGURE 4.8 – Prototype final de l'hacheur buck

## 4.3 Implémentation des commandes

Nous reprenons nos fichier simulink (figure 4.9 et 4.10) qui nous permet d'implémenter sur la carte STM32 et l'acquisition des données.

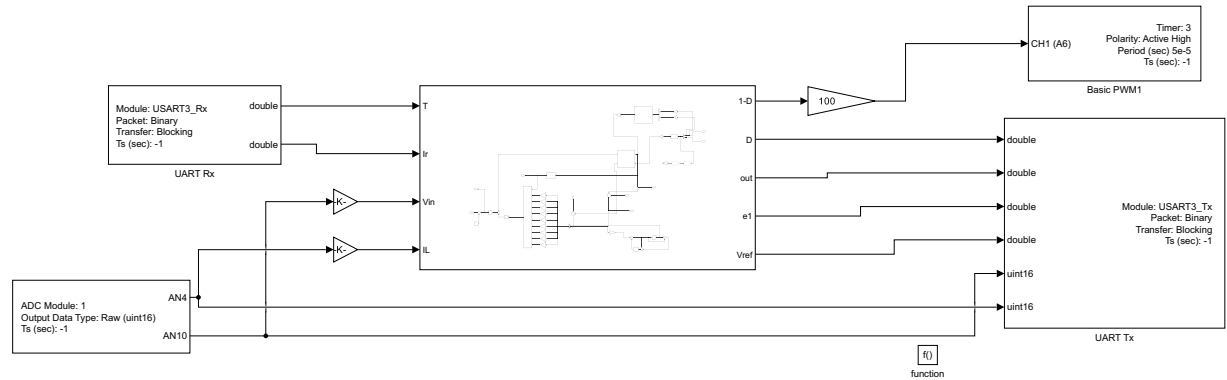


FIGURE 4.9 – Schéma Simulink de la commande

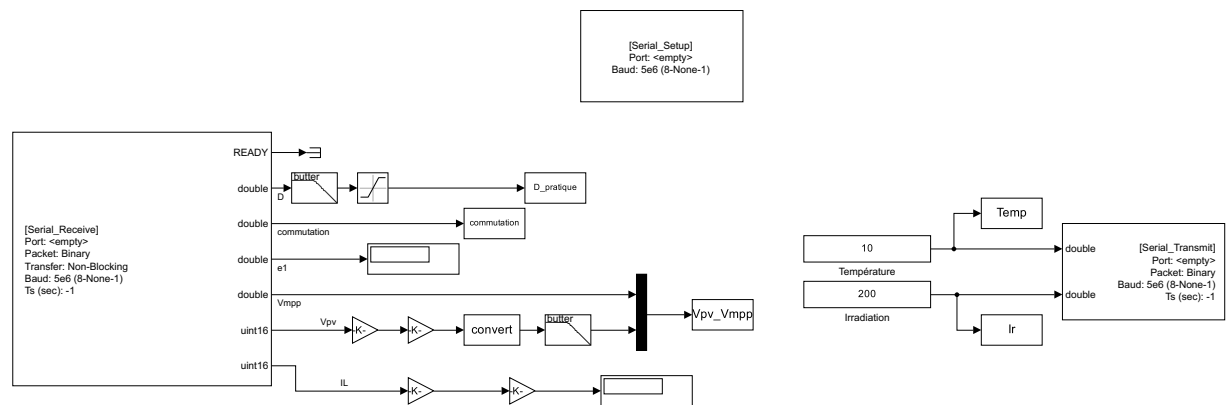


FIGURE 4.10 – Schéma Simulink pour l'acquisition des données

Nous avons rajouté un filtre numérique pour pouvoir bien visualiser les données sur les courbes.

### 4.3.1 Application avec une alimentation

La figure 4.11 illustre l'essai expérimental de la commande MPPT implémentée sur la carte STM32 afin de commander l'entrée de l'hacheur et charger une batterie de 12 V. Une alimentation réglée en source de courant est utilisée pour simuler un panneau photovoltaïque.




FIGURE 4.11 – Illustration de la manipulation

#### 4.3.1.1 Résultat de la commande optimale

Les figures (4.12 et 4.13) représentent respectivement les scénarios de températures et d'irradiations en temps réel.

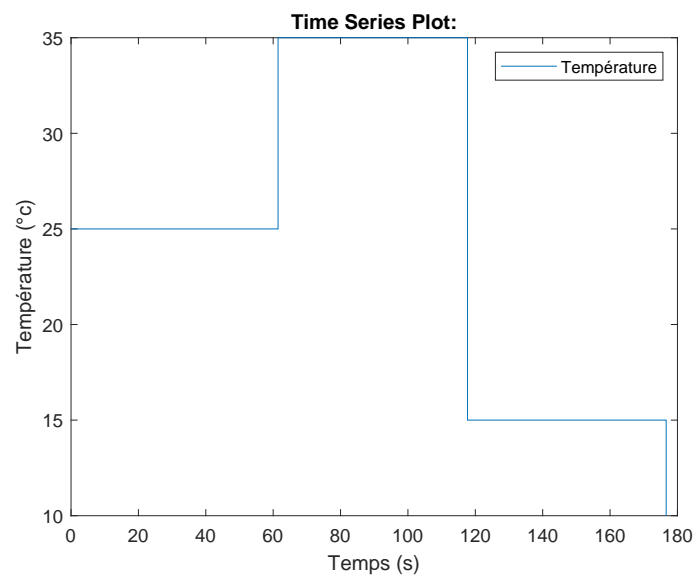


FIGURE 4.12 – Représentation de la température par rapport au temps




FIGURE 4.13 – Représentation de l'irradiation par rapport au temps

Les figures (4.14 et 4.15) représentent respectivement la tension fournie par l'alimentation et la variation du rapport cyclique suite à une régulation par la commande MPPT classique (l'estimation des valeurs de  $V_{mpp}$  et  $I_{mpp}$  est faites grace au réseau neurone).




FIGURE 4.14 – Représentation de la tension d'entrée par rapport au temps




FIGURE 4.15 – Représentation du rapport cyclique en fonction du temps

### Remarque

On constate que la tension de référence ( $V_{mpp}$ ) et la tension du panneau ( $V_p v$ ) sont bien alignées et que les bruits sont atténués par rapport aux résultats du mémoire d'ingénieur grâce à une meilleure estimation de  $V_{mpp}$  et  $I_{mpp}$  par le réseau de neurone.

#### 4.3.1.2 Résultat de la commande par réseau de neurone

Après avoir introduit le premier réseau de neurone pour l'estimation  $V_{mpp}$  et  $I_{mpp}$ , on introduira un nouveau réseau neurone qui remplacera la commande MPPT classique. Les figures (4.16 et 4.17) représentent respectivement les scénarios de températures et d'irradiations en temps réel.

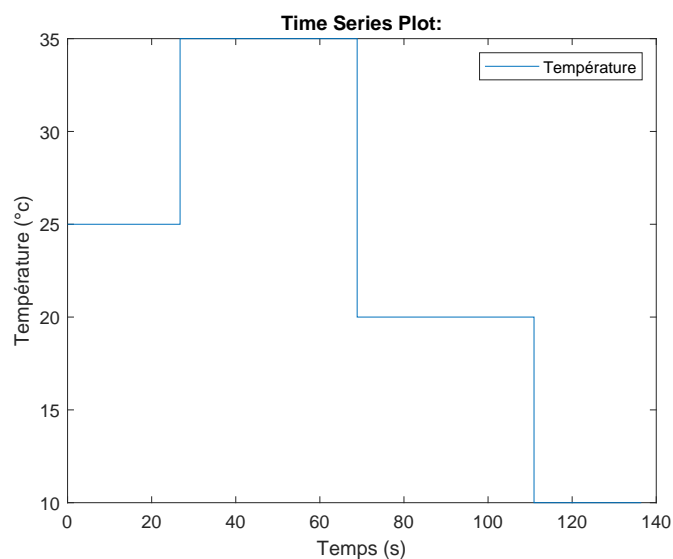


FIGURE 4.16 – Représentation de la température par rapport au temps




FIGURE 4.17 – Représentation de l'irradiation par rapport au temps

Les figures (4.18 et 4.19) représentent respectivement les valeurs de la tension fournie par l'alimentation et la variation du rapport cyclique.




FIGURE 4.18 – Représentation de la tension d'entrée par rapport au temps




FIGURE 4.19 – Représentation du rapport cyclique en fonction du temps

### Remarque

On remarque une excellente stabilité et réactivité. La tension suit de près la référence avec peu de fluctuations, même en présence de variations de la température et d'irradiation.

#### 4.3.1.3 Interprétation des résultats

Les deux commandes présentent une stabilité remarquable.

On observe clairement que la commande optimale génère moins de bruit que celle basée sur un réseau de neurones.

### 4.3.2 Application avec le panneau photovoltaïque

Nous appliquerons les deux commandes vues précédemment en vue d'optimiser l'énergie d'un panneau photovoltaïque de 80W type *VS80M – 32* (figure 4.20) dont le data-sheet est donné dans la figure 4.21.



FIGURE 4.20 – Illustration de la manipulation

Modol : VS80M-32	
Rated Maximum Power (Pmax)	80W
Tolerance (Tol)	0~+3%
Voltage at Pmax (Vmp)	15.90V
Current at Pmax (Imp)	5.03A
Open-Circuit Voltage (Voc)	18.58V
Short-Circuit Current (Isc)	5.59A
Nominal Operating Cell Temperature (NOCT)	⚠ 47±2°C
Maximum System Voltage	1000VDC
Maximum Series Fuse Rating	10A
Operating Temperature	-40°C to 85°C
Protection Class	Class A
Cell Technology	Mono-Si
Weight (Kg)	8.00
Dimensions (mm)	1068×554×35
Technical performance data recorded at Standard Test Conditions (STC) Am=1.5 E=1000 W/m² TC=25°C	
Autovia del Salar Nº 12, Torre IV, 1ª Piso 46013 Valencia – SPAIN Tel: +34 963 344 366 // fax: +34 963 354 076 Mail: info@viselpiaces.com // Web: www.viselpiaces.com	

FIGURE 4.21 – Datasheet du PV

Nous avons utilisé :

- Un thermocouple pour mesurer la température ambiante.
- Un ampèremètre pour mesurer le courant du court-circuit  $I_{cc}$  du panneau afin de tirer la valeur de l'irradiation  $G$  selon les équations suivantes.

$$I_{cc} = I_{ccSTC} \frac{G}{G_{STC}} (1 + k_T(T - T_{STC})) \quad (4.1)$$

D'où

$$G = \frac{I_{cc} G_{STC}}{I_{ccSTC} (1 + k_T(T - T_{STC}))} \quad (4.2)$$

Avec :

Paramètres	Valeurs
Température dans les conditions STC ( $T_{STC}$ )	25°C
Irradiation dans les conditions STC ( $G_{STC}$ )	1000 W/m <sup>2</sup>
Courant du court circuit dans les conditions STC ( $I_{ccSTC}$ )	5.59 A
Courant de court-circuit mesuré ( $I_{cc}$ )	4.18 A
Température ambiante	28 °c
Coefficient de la température du courant de court circuit ( $k_T$ )	0.00123 1/°c

TABLEAU 4.1 – Paramètres en STC du PV

L'expérience a été faite dans les conditions météorologique (28°C, 745 W/m<sup>2</sup>)



#### 4.3.2.1 Résultat de la commande optimale

Les figures (4.22 et 4.23) représentent respectivement la tension du PV et le rapport cyclique suite à une régulation par la commande MPPT classique.




FIGURE 4.22 – Représentation de la tension d'entrée par rapport au temps




FIGURE 4.23 – Représentation du rapport cyclique en fonction du temps

### 4.3.2.2 Résultat de la commande par réseau de neurone

Les figures (4.24 et 4.25) représentent respectivement la tension du PV et le rapport cyclique suite à une régulation par la commande MPPT par réseau de neurone.

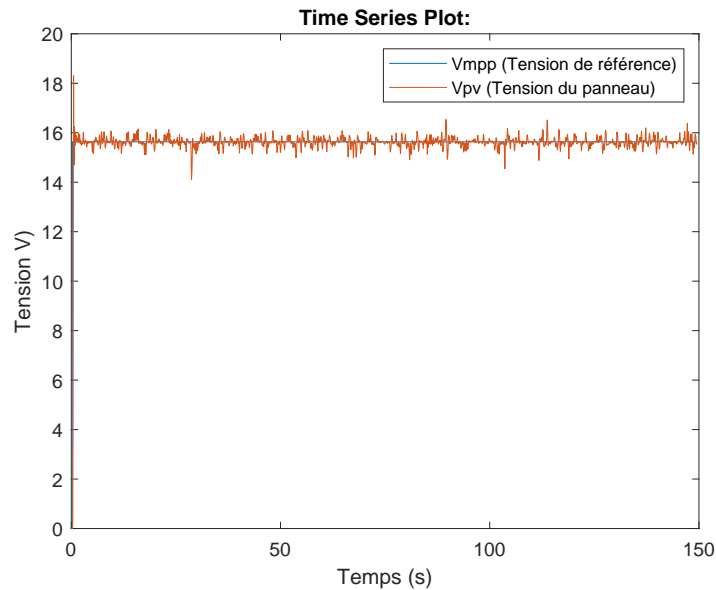


FIGURE 4.24 – Représentation de la tension d'entrée par rapport au temps




FIGURE 4.25 – Représentation du rapport cyclique en fonction du temps

### 4.3.2.3 Interprétation des résultats

Les résultats obtenus en utilisant le PV sont moins bruités que ceux avec l'alimentation, cela est dû au fait que le courant maximal que peut fournir l'alimentation est de 3 A cependant les points de fonctionnements exigent des courants plus élevés (jusqu'à 6 A) ce qui est une source de bruit.

## Conclusion

En conclusion, ce chapitre offre un aperçu approfondi de la mise en œuvre des commandes pour maximiser l'énergie d'un panneau photovoltaïque. Grâce à l'utilisation de technologies avancées telles que les microcontrôleurs STM32, les réseaux de neurones et les capteurs de mesure précis, il est possible d'optimiser efficacement la production d'énergie solaire. Cette approche méthodologique rigoureuse ouvre la voie à des applications plus efficaces et durables dans le domaine de l'énergie renouvelable, contribuant ainsi à un avenir plus propre et plus éco-responsable.

# CONCLUSION GÉNÉRALE

Dans ce mémoire, nous avons exploré l'utilisation des réseaux de neurones pour améliorer les systèmes de commande des panneaux photovoltaïques, en particulier pour le suivi du point de puissance maximale (MPPT). En comparant la commande optimale qui utilise les LMI avec une commande basée sur des réseaux de neurones, nous avons démontré plusieurs avantages significatifs.

Les résultats de nos simulations montrent que la commande par réseaux de neurones offre une meilleure performance en termes de rapidité de réponse et de précision dans le suivi du MPP, réduisant ainsi les pertes d'énergie. Cette approche permet également de simplifier la structure de la commande en supprimant la nécessité de fonctions de commutation complexes pour sélectionner le gain approprié.

L'implémentation pratique des commandes MPPT, en utilisant des microcontrôleurs STM32 et des capteurs de mesure précis, a confirmé l'efficacité de notre approche. Les réseaux de neurones se sont révélés être une solution prometteuse pour l'optimisation de l'énergie photovoltaïque, contribuant à un système plus efficace et plus fiable. Cette étude ouvre la voie à de nouvelles recherches et améliorations dans le domaine des systèmes photovoltaïques intelligents.

L'utilisation des réseaux de neurones pour le suivi du point de puissance maximale (MPPT) dans les systèmes photovoltaïques offre plusieurs perspectives prometteuses. L'amélioration des algorithmes, notamment avec des architectures avancées comme les réseaux neuronaux convolutifs (CNN) et récurrents (RNN), pourrait améliorer la robustesse et la performance face aux variations environnementales. L'intégration de techniques d'intelligence artificielle, comme l'apprentissage par renforcement, permettrait une adaptation dynamique et une optimisation continue de la production d'énergie.

## ANNEXE

### A

# PROGRAMME MATLAB

Programme A.1 – Programme entraînement réseau neurone pour l'estimation

```
1 x = Data_input';
2 t = Data_output';
3 trainFcn = 'trainlm'; % Levenberg-Marquardt
   backpropagation.
4
5 % Create a Fitting Network
6 hiddenLayerSize = [5,5];
7 net = fitnet(hiddenLayerSize,trainFcn);
8
9 % Setup Division of Data for Training, Validation,
   Testing
10 net.divideParam.trainRatio = 70/100;
11 net.divideParam.valRatio = 15/100;
12 net.divideParam.testRatio = 15/100;
13
14 % Train the Network
15 [net,tr] = train(net,x,t);
16
17 % Test the Network
18 y = net(x);
19 e = gsubtract(t,y);
20 performance = perform(net,t,y)
21
22 % View the Network
23 view(net)
24 gensim(net)
```

---

Programme A.2 – Programme entraînement réseau neurone pour la commande

```
1 close all
2 clear
3 clc
4
5 % Load data
6 load the_data4.mat
7 load data_time4.mat
8 e1 = TheData(:,1)/max(TheData(:,1));
9 e2 = TheData(:,2)/max(TheData(:,2));
10 e0= TheData(:,6)/max(TheData(:,6));
11 D = TheData(:,7);
12
13 % Combine features
14 features = [e0,e1,e2];
15
16 % Split data into training, validation, and testing sets
    (adjust ratios as needed)
17 [trainIdx, valIdx, testIdx] = dividerand(size(features,1)
    , 0.7, 0.15, 0.15);
18 trainFeatures = features(trainIdx,:);
19 trainCycle = D(trainIdx);
20 valFeatures = features(valIdx,:);
21 valCycle = D(valIdx);
22 testFeatures = features(testIdx,:);
23 testCycle = D(testIdx);
24
25 % Define the ANN architecture (replace with your desired
    number of neurons)
26 hiddenLayerSize = [7,7]; % Number of neurons in the
    hidden layer
27 numInputs = size(features,2);
28 numOutputs = 1;
29
30 % Create the ANN using feedforward network
31 net = feedforwardnet(hiddenLayerSize);
32
33 net = trainlm(net,trainFeatures', trainCycle');
34
35 % Evaluate on validation set (optional, but recommended)
36 predictedCycleVal = net(valFeatures');
37 validationMSE = mean((predictedCycleVal' - valCycle).^2);
38 disp(['Validation MSE: ', num2str(validationMSE)]);
39
40 % Predict power consumption for testing set
41 predictedCycleTest = net(testFeatures');
42
43 % Evaluate on testing set
44 testMSE = mean((predictedCycleTest' - testCycle).^2);
```

---

```
45 disp(['Testing MSE: ', num2str(testMSE)]);
46
47 % You can plot the actual vs predicted power for further
   analysis
48 plot(Time(testIdx),testCycle', Time(testIdx),
   predictedCycleTest);
49 %plot(Time,D, Time ,net(features'));
50
51 xlabel('Actual Power Consumption');
52 ylabel('Predicted Power Consumption');
53 title('Load Curve Forecast (ANN)');
54 gensim(net)
```

# BIBLIOGRAPHIE

- [1] LOUKRIZ Abdelouadoud. optimisation de la modélisation et de la commande d'un système photovoltaïque par les techniques d'intelligence artificielle. *mémoire Magister, Université de M'sila*, 2014.
- [2] Bilel Ben Nasser. Étude et modélisation de la commande mppt avec matlab. 2021.
- [3] B Bendib, F Krim, H Belmili, and Med F Almi. Modélisation et commande mppt d'un système photovoltaïque autonome en utilisant les réseaux de neurones artificiels.
- [4] E Benkhelil and A Gherbi. Modélisation et simulation d'un générateur photovoltaïque avec un étage d'adaptation dc/dc. *Revue des Energies Renouvelables ICESD'11 Adrar*, pages 159–170, 2011.
- [5] Omar Boukli-Hacene. Conception et réalisation d'un générateur photovoltaïque muni d'un convertisseur mppt pour une meilleure gestion énergétique. 2011.
- [6] FTDI Chip. Cjmcu-232h. *Internet* : [https://ftdichip.com/wp-content/uploads/2020/07/DS\\_UM232H.pdf](https://ftdichip.com/wp-content/uploads/2020/07/DS_UM232H.pdf).
- [7] Ali Dali. Synthèse de commande et observateur pour une classe de systèmes dynamiques hybrides : théorie et applications. 2021.
- [8] Maria Carmela Di Piazza and Gianpaolo Vitale. *Photovoltaic sources : modeling and emulation*. Springer, 2013.
- [9] digischool. les semi-conducteurs et le silicium. *Internet* : <https://www.digischool.fr/cours/les-semi-conducteurs-et-le-silicium>.
- [10] Mr. OUARI Mondher et Mr. ZINE Yakoub. Étude des commandes mppt d'un système photovoltaïque. 2020.
- [11] G2V. Qu'est-ce que la masse d'air a à voir avec la lumière du soleil? *Internet* : <https://g2voptics.com/air-mass-solar-intensity/>.



- 
- [12] Crina Grosan and Ajith Abraham. *Intelligent systems*, volume 17. Springer, 2011.
- [13] Amine HARENDI and Ali ARBAOUI. *Calcul de l'MPPT par réseaux de neurone pour un système photovoltaïque*. PhD thesis.
- [14] Nsenge Mpia Héritier and Inipaivudu Baelani Nephtali. L'algorithme de rétro-propagation de gradient dans le perceptron multicouche : Bases et étude de cas. *International Journal of Innovation and Applied Studies*, 32(2) :271–290, 2021.
- [15] Antonio Luque and Steven Hegedus. *Handbook of photovoltaic science and engineering*. John Wiley & Sons, 2011.
- [16] Mbed. Stm32f446re. *Internet* : <https://os.mbed.com/platforms/ST-Nucleo-F446RE/>.
- [17] Lakhdar Melakhessou. *Contrôle et identification des systèmes non linéaires par les techniques neuronales*. PhD thesis, Université de Batna 2, 2011.
- [18] MEZIANI Zahra Mémoire de Magister. Modélisation de modules photovoltaïques. 2012.
- [19] Akihiro Oi. *Design and simulation of photovoltaic water pumping system*. California Polytechnic State University, 2005.
- [20] Marc Parizeau. *Réseaux de neurones, Université Laval*, volume 124. 2004.
- [21] S Sapna, A Tamilarasi, M Pravin Kumar, et al. Backpropagation learning algorithm based on levenberg marquardt algorithm. *Comp Sci Inform Technol (CS and IT)*, 2 :393–398, 2012.
- [22] LEM Sensor. La 55-p. *Internet* : [https://www.lem.com/sites/default/files/products\\_datasheets/la\\_55-p\\_e.pdf](https://www.lem.com/sites/default/files/products_datasheets/la_55-p_e.pdf).
- [23] LEM Sensor. lv-25p. *Internet* : <https://www.lem.com/en/product-list/lv-25p>.
- [24] Hongmei Tian, Fernando Mancilla-David, Kevin Ellis, Eduard Muljadi, and Peter Jenkins. A cell-to-module-to-array detailed model for photovoltaic panels. *Solar energy*, 86(9) :2695–2706, 2012.
- [25] Weidong Xiao. *A modified adaptive hill climbing maximum power point tracking (MPPT) control method for photovoltaic power systems*. PhD thesis, University of British Columbia, 2003.

## Résumé

Dans ce mémoire, nous explorons comment améliorer la commande développée dans notre mémoire d'ingénieur pour un système photovoltaïque. Nous remplaçons la commande optimale LQR utilisant des inégalités matricielles linéaires (LMI) par une commande basée sur des réseaux de neurones, afin d'optimiser le suivi du point de puissance maximal (MPPT) et de simplifier le système de commande.

**Mots clés :** Commande optimale, inégalités matricielles linéaires LMI, réseau de neurones, point de puissance maximal MPPT, système photovoltaïque, optimisation, simplification.

## Abstract

In this thesis, we explore how to improve the control system developed in our engineering thesis for a photovoltaic system. We replace the optimal control using linear matrix inequalities (LMI) with a neural network-based control to optimize the maximum power point tracking (MPPT) and simplify the control system.

**Keywords:** Optimal control, linear matrix inequalities LMI, neural network, maximum power point tracking MPPT, photovoltaic system, optimization, simplification.

## ملخص

في هذا البحث، نستكشف كيفية تحسين التحكم المُطور في بحثنا الهندسي لنظام الطاقة الشمسية الكهروضوئية. نقوم باستبدال التحكم الأمثل باستخدام عدم المساواة الخطية للمصفوفات LMI بنظام تحكم قائم على شبكات عصبية اصطناعية، وذلك لتحسين تتبع نقطة القوة القصوى (MPPT) وتبسيط نظام التحكم.

**الكلمات المفتاحية:** التحكم الأمثل، عدم المساواة الخطية للمصفوفات LMI، تتبع نقطة القوة القصوى MPPT، النظام الكهروضوئي، التحسين، التبسيط.