



BIBLIOTHÈQUE

CÉGEP DE L'ABITIBI-TÉMISCAMINGUE
UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de l'auteur de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.

Université du Québec en Abitibi-Témiscamingue

UTILISATION DES RÉSEAUX DE NEURONES ARTIFICIELS POUR
L'OPTIMISATION DE LA COMMANDE MPPT ET LA DÉTECTION DES
DÉFAUTS DES PANNEAUX SOLAIRES

Mémoire
présenté
comme exigence partielle
de la maîtrise en ingénierie

Par
Oussema Aloulou

Octobre 2024

REMERCIEMENT

Je tiens à exprimer ma profonde gratitude à tous ceux qui ont contribué à la réalisation de ce projet de maîtrise. Un merci particulier à mon directeur de recherche, Professeur **Fouad Slaoui Hasnaoui** pour son soutien indéfectible, ses précieux conseils et sa patience tout au long de cette aventure académique. Je remercie aussi mon co-directeur de recherche, Professeur **Fouad Erchiqui** pour la supervision de mes travaux et les conseils. Je remercie également tous les membres du jury pour leurs retours constructifs et leur temps.

Un grand merci également à mes amis Ghada Chakroun et Bilel Bouaziz, pour leur soutien moral et leur camaraderie qui ont été d'une grande aide dans les moments les plus éprouvants de cette recherche. Mes remerciements vont aussi à mes collègues et amis de l'université pour leurs encouragements et les moments partagés pendant ces années d'étude.

Je suis particulièrement reconnaissant envers ma famille, pour leur amour inconditionnel, leur soutien sans faille et leur motivation constante. Vous avez été ma source d'inspiration et de force.

Enfin, je remercie toutes les personnes qui, de près ou de loin, ont contribué à la réussite de cette étude.

TABLES DE MATIÈRE

REMERCIEMENT	II
TABLES DE MATIÈRE	III
RÉSUMÉ	VIII
ABSTRACT	IX
LISTE DE FIGURES	X
LISTE DES TABLEAUX.....	XIII
LISTE DES ABRÉVIATIONS.....	XIV
CHAPITRE I: CADRE THÉORIQUE	1
1.1 INTRODUCTION.....	1
1.2 CONTEXTE GÉNÉRAL	1
1.3 PROBLÉMATIQUE.....	5
1.4 OBJECTIFS ET HYPOTHÈSES	6
1.4.1 Objectif général.....	6
1.4.2 Objectifs spécifiques	8
1.5 HYPOTHÈSES	8
1.6 MÉTHODOLOGIE DE RECHERCHE	9
1.6.1 L'APPROCHE SCIENTIFIQUE	9
1.6.2 La démarche suivie	10
1.7 CONCLUSION.....	12
CHAPITRE II: GÉNÉRALITÉ SUR LE SYSTÈME PHOTOVOLTAÏQUE	13
2.1 INTRODUCTION.....	13
2.2 HISTORIQUE PHOTOVOLTAÏQUE	13
2.3 SYSTÈME PHOTOVOLTAÏQUE.	14
2.3.1 Types de systèmes solaires photovoltaïques :.....	15

2.3.1.1	Systèmes sur réseau (grid-tied)	15
2.3.1.2	Systèmes hors réseau (off-grid)	16
2.3.1.3	Systèmes hybrides.....	17
2.4	MODULE PHOTOVOLTAÏQUE.....	17
2.4.1	La constitution d'un module photovoltaïque	18
2.4.2	Cellule photovoltaïque	19
2.4.2.1	L'effet photovoltaïque.....	19
2.4.2.2	Principe de fonctionnement.....	19
2.4.2.2	Technologies :	20
2.4.2.3	Caractérisation électrique d'une cellule photovoltaïque	21
2.4.2.4	Cellules mises en séries.....	23
2.4.2.5	Cellules mises en parallèle	24
2.4.2.6	Caractéristique courant-tension.....	24
2.4.2.7	Caractéristiques puissance-tension :	25
2.4.2.8	Influence de l'éclairement :.....	26
2.4.2.9	Influence de température.....	27
2.5	TYPES DE DÉFAUTS DES PANNEAUX SOLAIRES.....	28
2.6	CONVERTISSEUR CC-CC BOOST	29
2.6.1	Modélisation d'un convertisseur CC-CC Boost.....	30
2.6.2	Principe de fonctionnement d'un convertisseur Boost :	32
2.7	MÉTHODE D'EXTRACTION DU POINT DE PUISSANCE MAXIMUM (MPPT)	33
2.7.1	Principe de fonctionnement.....	33
2.7.2	Méthode de perturbation et observation (PO).....	33
2.8	CONCLUSION	35
CHAPITRE III : APPLICATIONS DES RNA DANS LES SYSTÈMES PV		36
3.1	INTRODUCTION.....	36
3.2	L'APPRENTISSAGE EN PROFONDEUR « DEEP LEARNING »	37
3.3	FONDEMENTS DE RÉSEAU DE NEURONES ARTIFICIELS	37

3.4	STRUCTURE D'INTERCONNEXION D'UN RÉSEAU DE NEURONES	39
3.4.1	Perceptron multicouche (PMC)	39
3.4.2	Les types de connexions d'un réseau de neurones	40
3.5	APPRENTISSAGE D'UN RÉSEAU DE NEURONES	42
3.5.1	Processus d'apprentissage d'un réseau de neurones	42
3.5.2	Types d'apprentissage	43
3.6	RÉSEAU DE NEURONES DE PROPAGATION AVANT (FEEDFORWARD)	44
3.7	ALGORITHME DE RÉTROPROPAGATION « ERROR BACK-PROPAGATION »	45
3.8	RÉSEAU DE NEURONES CONVOLUTIFS (CNN)	46
3.8.1	Architecture typique d'une CNN	47
3.8.2	Composants clés des CNNs	48
3.8.3	Exemples d'architectures de réseaux de neurones convolutifs (CNN) ...	49
3.9	L'ARCHITECTURE RESNET50	50
3.9.1	ResNet50 dans la détection des défauts des panneaux solaires :	52
3.9.2	Avantages et inconvénients de l'architecture ResNet50	52
3.10	FONCTION D'ACTIVATION	53
3.11	CONCLUSION	55
CHAPITRE IV : OPTIMISATION DE LA COMMANDE MPPT PAR RNA		56
4.1	INTRODUCTION	56
4.2	MODÉLISATION DU SYSTÈME PHOTOVOLTAÏQUE	56
4.2.1	Conception de la modélisation du système photovoltaïque	56
4.2.2	Caractéristique I-V et P-V pour le module Canadian Solar 295P	57
4.3	COMMANDE MPPT AVEC LA MÉTHODE PERTURBÉE ET OBSERVEZ (PO)	58
4.4	Commande MPPT avec un Réseau de Neurones Artificiels (RNA)	60
4.4.1	Acquisition et prétraitement des données	60
4.4.2	Architecture et configuration du réseau de neurones	61
4.4.3	Entraînement et validation du RNA	62
4.4.4	Modélisation et simulation dans MATLAB Simulink	64

4.4.4.1	Intégration du RNA dans le système de commande MPPT	66
4.4.4.2	Configuration du contrôleur PID pour la commande MPPT	68
4.4.5	Évaluation des performances du modèle RNA	70
4.4.5.1	Régression du modèle RNA.....	70
4.4.5.2	Évolution de l'Erreur Quadratique Moyenne (MSE) :	72
4.4.5.3	Évaluation de la précision des prédictions du réseau de neurones..	73
4.5	RÉSULTATS DES SIMULATIONS DU SYSTÈME PHOTOVOLTAÏQUE	75
4.5.1	Simulation avec la méthode perturbée et Observer (PO).....	75
4.5.2	Simulation avec la méthode Réseau de Neurones Artificiels (RNA)	78
4.5	COMPARAISON DES PERFORMANCES DES MÉTHODES RNA ET P&O.....	81
4.5.1	Comparaison de la précision des méthodes RNA et P&O.....	82
4.5.2	Comparaison de la rapidité des méthodes RNA et P&O	84
4.5.3	Comparaison de la stabilité des méthodes RNA et P&O.....	87
4.6	CONCLUSION.....	88
CHAPITRE V : DÉTECTION DES DÉFAUTS SUR LES PPV AVEC CNN.....		90
5.1	INTRODUCTION.....	90
5.2	OBJECTIFS DE LA DÉTECTION DE DÉFAUTS	90
5.3	FACTEURS IMPACTANT LA PERFORMANCE DES PANNEAUX SOLAIRES.....	91
5.4	IMPACT DES CONTAMINANTS ET DOMMAGES SUR LES PERFORMANCES DES PPV	92
5.5	INTÉGRATION DES CNN DANS LA MAINTENANCE PRÉVENTIVE	92
5.6	MÉTHODOLOGIE DE DÉTECTION DES DÉFAUTS	93
5.6.1	Choix des données	93
5.6.2	Préparation des données.....	95
5.6.3	Environnement de développement et ressources matérielles.....	95
5.6.4	Sélection de l'architecture du réseau ResNet50	96
5.7	ENTRAÎNEMENT ET VALIDATION DU MODÈLE	97
5.7.1	Adaptation de l'architecture ResNet-50	97

5.7.2	Définition des paramètres d'entraînement.....	98
5.7.3	Visualisation des résultats d'entraînement	100
5.8	ANALYSE DES RÉSULTATS D'ENTRAÎNEMENT ET DE VALIDATION	102
5.9	PRÉSENTATION DES RÉSULTATS DE TEST	103
5.9.1	Résultats quantitatifs de la classification	103
5.9.2	Évaluation de la matrice de confusion	109
5.9.3	Analyse des courbes ROC.....	110
5.10	DISCUSSION SUR LA QUALITÉ DE LA CLASSIFICATION	112
5.10.1	Interprétation visuelle des prédictions	112
5.10.2	Évaluation pratique	113
5.10.3	Comparaison avec les méthodes traditionnelles	114
5.11	QUELQUES STRATÉGIES DE MAINTENANCE PRÉVENTIVE	115
5.12	CONCLUSION.....	116
	CONCLUSION.....	118
	RÉFÉRENCES BIBLIOGRAPHIQUES.....	119
	ANNEXE I : FICHE TECHNIQUE DU PPV CS3K-295P	124

RÉSUMÉ

Ce projet vise à améliorer les performances et la fiabilité des systèmes photovoltaïques en intégrant les technologies avancées d'intelligence artificielle, spécifiquement à travers l'utilisation de réseaux de neurones artificiels (RNA) et de réseaux de neurones convolutifs (CNN). Nous avons appliqué les RNA pour optimiser la stratégie de commande du point de puissance maximale (MPPT) où ils ont été comparés à la méthode traditionnelle de Perturbation et Observation (P&O). Cette optimisation a été réalisée par la mise en œuvre de modèles de RNA qui ajustent dynamiquement la tension pour répondre aux fluctuations des conditions atmosphériques, modélisée et simulée à l'aide de MATLAB Simulink.

En parallèle, nous avons exploré l'application des CNN pour détecter et classifier les défauts des panneaux solaires, une étape essentielle pour la maintenance préventive et la gestion de l'efficacité des systèmes. Ces réseaux ont été entraînés et testés dans MATLAB Simulink, où ils ont démontré une capacité supérieure à identifier divers types de défauts photovoltaïques avec précision et rapidité.

Mots clés : Photovoltaïque, Convertisseur DC-DC Boost, MPPT, P&O, Intelligence artificielle, RNA, CNN, MATLAB Simulink.

ABSTRACT

This project aims to improve the performance and reliability of photovoltaic systems by integrating advanced artificial intelligence technologies, specifically using artificial neural networks (ANN) and convolutional neural networks (CNN). We applied ANNs to optimize the Maximum Power Point Tracking (MPPT) strategy, where they were compared with the traditional Perturb and Observe (P&O) method. This optimization was achieved by implementing ANN models that dynamically adjust the voltage to respond to fluctuations in atmospheric conditions, modeled and simulated using MATLAB Simulink.

In parallel, we explored the use of CNNs to detect and classify defects in solar panels, an essential step for preventive maintenance and system efficiency management. These networks were trained and tested in MATLAB Simulink, where they demonstrated superior ability to identify various types of photovoltaic defects with accuracy and speed.

Keywords : Photovoltaic, DC-DC Boost Converter, MPPT, P&O, Artificial Intelligence, ANN, CNN, MATLAB Simulink.

LISTE DE FIGURES

FIGURE 1.1: ÉVOLUTION DE LA PRODUCTION D'ÉNERGIE PAR SOURCE DE 2010 À 2027 ..	2
FIGURE 2.1: SCHÉMA FONCTIONNEL D'UN SYSTÈME PHOTOVOLTAÏQUE.....	14
FIGURE 2.2: SYSTÈME SOLAIRE CONNECTER AU RÉSEAU	15
FIGURE 2.3: SYSTÈME SOLAIRE AUTONOME (HORS RÉSEAU)	16
FIGURE 2.4: SYSTÈME SOLAIRE HYBRIDE	17
FIGURE 2.5: COMPOSITION D'UN MODULE SOLAIRE PHOTOVOLTAÏQUE	19
FIGURE 2.6: FONCTIONNEMENT D'UNE CELLULE PHOTOVOLTAÏQUE.....	20
FIGURE 2.7: LES DIFFERENTES TECHNOLOGIES DES CELLULES PV.	21
FIGURE 2.8: MODELE EQUIVALENT DE LA CELLULE PHOTOVOLTAÏQUE.....	23
FIGURE 2.9: CARACTERISTIQUES D'UN GROUPEMENT DES CELLULES EN SERIE.	23
FIGURE 2.10: CARACTERISTIQUES D'UN GROUPEMENT DES CELLULES EN PARALLELE.	24
FIGURE 2.11: COURBE COURANT / TENSION D'UNE CELLULE.....	25
FIGURE 2.12: CARACTÉRISTIQUES PUISSANCE / TENSION.	25
FIGURE 2.13: COURBE I(V) D'UNE CELLULE POUR DEUX VALEURS D'IRRADIANCES	26
FIGURE 2.14: COURBE P(V) D'UNE CELLULE POUR DEUX VALEURS D'IRRADIANCES. ..	27
FIGURE 2.15: LA VARIATION DE LA CARACTERISTIQUE I(V) ET P EN FONCTION DE T... ..	28

FIGURE 2.16: CIRCUIT ÉLECTRIQUE D'UN CONVERTISSEUR BOOST	30
FIGURE 2.17: LIAISON ENTRE LE PV ET LA CHARGE	33
FIGURE 2.18: ORGANIGRAMME DE L'ALGORITHME PO	34
FIGURE 3.1: STRUCTURE D'UN NEURONE ARTIFICIEL.	38
FIGURE 3.2: DÉFINITION DES COUCHES D'UN RÉSEAU MULTICOUCHE.	39
FIGURE 3.3: ORGANIGRAMME D'UNE SESSION.	43
FIGURE 3.4: SCHÉMA D'UN APPRENTISSAGE SUPERVISÉ.	44
FIGURE 3.5: ILLUSTRATION D'UN RÉSEAU DE NEURONES FEED-FORWARD.	45
FIGURE 3.6: ARCHITECTURE TYPIQUE D'UN CNN	47
FIGURE 3.7: ARCHITECTURE RESNET50	51
FIGURE 4.1: CARACTERISTIQUE I-V ET P-V POUR LE MODULE CS3K-295P.....	57
FIGURE 4.2: MODÉLISATION DE LA COMMANDE MPPT AVEC LA MÉTHODE PO.	59
FIGURE 4.3: SCHÉMA STRUCTURAL DE RÉSEAU.....	61
FIGURE 4.4: MODÉLISATION DE LA COMMANDE MPPT AVEC LA MÉTHODE RNA.....	65
FIGURE 4.5: SCHÉMA BLOC DE RNA	66
FIGURE 4.6: SCHÉMA BLOC DE RNA DE L'INTÉRIEUR.....	67
FIGURE 4.7: CONFIGURATION DU CONTRÔLEUR PID.....	68
FIGURE 4.8: PERFORMANCE DU MODÈLE RNA.....	70
FIGURE 4.9: COURBES D'ERREUR D'APPRENTISSAGE DU RNA	72
FIGURE 4.10: COMPARAISON DES PRÉDICTIONS RNA ET VALEURS RÉELLES DE VMP .	73
FIGURE 4.11: CORRÉLATION ENTRE LES VMP PRÉDITES ET LES VALEURS RÉELLES	74
FIGURE 4.12: PROFIL DE COURANT PO.....	75
FIGURE 4.13: PROFIL DE TENSION PO	76
FIGURE 4.14: PROFIL DE PUISSANCE PO.....	77
FIGURE 4.15: PROFIL DE DUTY CYCLE PO	77
FIGURE 4.16 : PROFIL DE COURANT RNA.....	78
FIGURE 4.17: PROFIL DE TENSION RNA	79
FIGURE 4.18: PROFIL PUISSANCE RNA	80
FIGURE 4.19: PROFIL DUTY CYCLE RNA.....	80

FIGURE 4.20: CAMPARAIISON DES PERFORMANCES MPPT (METHODES RNA ET PO) ...	82
FIGURE 4.21: L'EFFET DE L'IRRADIANCE SUR LA PUISSANCE PV (METHODE PO)	84
FIGURE 4.22: L'EFFET DE L'IRRADIANCE SUR LA PUISSANCE PV (MÉTHODE RNA)	84
FIGURE 5.1: ÉCHANTILLON DES CONDITIONS DES PANNEAUX SOLAIRES	93
FIGURE 5.2: EXTRAIT DE L'ARCHITECTURE RESNET50	96
FIGURE 5.3: COURBES DE L'ENTRAINEMENT DU RESEAU RESNET-50	100
FIGURE 5.4: COURBE DE PRECISION D'ENTRAINEMENT ET DE VALIDATION	101
FIGURE 5.5: COURBE DE PERTE D'ENTRAINEMENT ET DE VALIDATION	102
FIGURE 5.6: PERFORMANCES DE CLASSIFICATION SUR L'ENSEMBLE DE TESTS	103
FIGURE 5.7: MATRICE DE CONFUSION DES CLASSIFICATIONS DES PPV	108
FIGURE 5.8: COURBES ROC POUR LA CLASSIFICATION DES ETATS DES PANNEAUX	110
FIGURE 5.9: EXEMPLES DE CLASSIFICATION DES PPV PAR LE MODELE CNN	111
FIGURE 5.10: TESTS SUR DES PANNEAUX NON VUS PAR LE MODELE	112

LISTE DES TABLEAUX

<u>TABLE 3.1 : TYPES DE CONNEXIONS D'UN RÉSEAU DE NEURONES.....</u>	<u>41</u>
<u>TABLE 3.2 : AVANTAGES ET INCONVÉNIENTS DE L'ARCHITECTURE RESNET50.....</u>	<u>53</u>
<u>TABLE 3.3 : QUELQUES FONCTIONS D'ACTIVATION D'UN RÉSEAU DE NEURONES.....</u>	<u>54</u>
<u>TABLE 4.1 : GAINS DU CONTRÔLEUR PID.....</u>	<u>70</u>
<u>TABLE 4.2 : COMPARAISON DES ERREURS DE PRÉDICTION (MÉTHODES RNA ET PO)....</u>	<u>83</u>
<u>TABLE 4.3 : COMPARAISON DE LA RAPIDITÉ DES MÉTHODES RNA ET PO.....</u>	<u>86</u>
<u>TABLE 4.4 : COMPARAISON DE LA STABILITÉ DES MÉTHODES RNA ET PO.....</u>	<u>88</u>
<u>TABLE 5.1 : MÉTRIQUES DE PERFORMANCE PAR CLASSE.....</u>	<u>105</u>
<u>TABLE 5.2 : STATS MICRO ET MACRO</u>	<u>107</u>
<u>TABLE 5.3 : ÉTUDE COMPARATIVE AVEC TRAVAUX RELATIFS.....</u>	<u>115</u>

LISTE DES ABRÉVIATIONS

RNA	: Réseau de Neurones Artificiels
MPPT	: Maximum Power Point Tracking
PO	: Perturbation et Observation
CNN	: Réseaux de Neurones Convolutifs
PV	: Photovoltaïque
C-C	: Court-Circuit
DC	: Courant continu
AC	: Courant Alternatif
I _{cc}	: Courant à court-circuit
V _{co}	: Tension à court-circuit
ROC	: Receiver Operating Characteristic
AUC	: Area Under the Curve
FL	: Logique floue
IA	: Intelligence Artificielle
PMC	: Perceptron Multi Couche
RELU	: Rectified Linear Unit
RMS	: Root Mean Square
MSE	: Erreur Quadratique Moyenne
MAE	: Erreur Absolue Moyenne
PPV	: Panneaux Photovoltaïques

CHAPITRE I: CADRE THÉORIQUE

1.1 Introduction

Dans un monde de plus en plus conscient des impératifs environnementaux et confronté à l'urgence climatique, la recherche de solutions énergétiques durables est devenue une priorité absolue. L'énergie photovoltaïque émerge non seulement comme une réponse technologique viable, mais également comme une voie prometteuse pour assurer une production d'énergie respectueuse de l'environnement.

L'intérêt croissant pour les énergies renouvelables, en particulier l'énergie solaire, s'explique par le fait qu'elle est considérée comme une ressource verte et inépuisable. Abondamment disponible, elle nécessite très peu d'entretien, ce qui en fait une source d'énergie de plus en plus privilégiée. De surcroît, l'électricité solaire gagne du terrain avec l'accessibilité et l'amélioration des performances des modules photovoltaïques, qui affichent désormais un rendement acceptable.

1.2 Contexte général

Dans les dernières années, le réchauffement climatique et les politiques énergétiques sont devenus un sujet d'actualité sur le plan international. En effet, les raisons de la menace de l'épuisement des combustibles fossiles et de la nécessité de la réduction de l'émission de dioxyde constituent un stimulant à chercher des ressources d'énergie renouvelable.

Dans ce contexte, l'énergie photovoltaïque est l'une des importantes ressources disponibles qui présentent un dénouement à nos problèmes de production d'énergie. Cette révolution électrique est en train de s'imposer avec un rendement acceptable. L'année 2022 a enregistré la plus forte croissance de la capacité des énergies renouvelables jamais vue – le monde a ajouté près de 295 gigawatts (GW) de renouvelables, augmentant le stock d'énergie renouvelable de 9,6 % et contribuant à 83 % des ajouts de puissance globaux, en grande partie grâce à la croissance du

solaire et de l'éolien, ainsi qu'au déclassement continu des centrales électriques à combustibles fossiles dans plusieurs grandes économies. Le solaire à lui seul a représenté près des deux tiers des ajouts renouvelables avec un record de 192 GW [1]. La production solaire photovoltaïque a augmenté d'un niveau record de 270 TWh (en hausse de 26 %) en 2022, pour atteindre près de 1 300 TWh. Elle a démontré la plus forte croissance absolue de la production parmi toutes les technologies renouvelables en 2022, dépassant l'énergie éolienne pour la première fois de l'histoire [2].




Figure 1.1

Évolution de la production d'énergie par source de 2010 à 2027

Source : <https://www.iea.org/data-and-statistics/charts> consulté le 1er novembre 2022

La capacité électrique installée du solaire photovoltaïque est sur le point de dépasser celle du charbon d'ici 2027, devenant ainsi la plus grande au monde.

En outre, son principe qui se base sur la conversion du rayonnement solaire en électricité lui permet d'être une solution prometteuse en termes de sécurité d'approvisionnement et de préservation de l'environnement.

Au Québec, l'insolation journalière moyenne de la partie la plus habitée se situe entre 4,2 et 5 kWh/m². C'est une valeur supérieure à celle de l'Allemagne et similaire à celle du Japon. Néanmoins, ces deux pays sont actuellement parmi les chefs de file du marché mondial de l'énergie solaire photovoltaïque avec la Chine et les États-Unis. [3]

Cependant, la production d'énergie n'est pas linéaire et il n'y a qu'un seul point de fonctionnement où les panneaux solaires produisent la quantité optimale d'énergie. De plus, la position de ce point n'est pas fixe, mais se mobilise en fonction de l'ensoleillement et de la température. Cela demande un mécanisme qui permet le suivi du point de puissance maximale appelé "Maximum power point tracking" (MPPT) afin que la puissance maximale soit générée à tout instant. Par conséquent, de différents algorithmes pour la commande MPPT ont été développés et proposés dans la littérature. Les plus courantes sont : la méthode de perturbation et d'observation (P & O), la méthode de Hill Climbing, la méthode d'incrémental de la conductance, la méthode de la logique floue (FL), etc.

Dans le cadre de ce travail de recherche, nous allons plonger dans une méthode avancée d'optimisation de la production d'énergie photovoltaïque en utilisant des réseaux de neurones artificiels (RNA) pour le suivi du point de puissance maximale (MPPT). L'utilisation d'un RNA pour le MPPT est une approche contemporaine qui tire parti des capacités d'apprentissage adaptatif des réseaux de neurones pour gérer la variabilité des conditions atmosphériques affectant la production d'énergie solaire.

Les réseaux de neurones artificiels (RNA), une des branches de l'IA, sont particulièrement pertinents dans ce contexte. Ils sont capables de modéliser des relations complexes non linéaires entre les variables d'entrée et de sortie sans qu'une relation mathématique explicite ne soit établie. Cette propriété est cruciale lorsqu'il s'agit de traiter les signaux bruités et les données fluctuantes issues des installations photovoltaïques.

Les RNA simulent les processus cognitifs et sensoriels du cerveau humain, ce qui les rend particulièrement efficaces pour apprendre à partir de données historiques, identifier des modèles et faire des prédictions ou des ajustements en temps réel. Par exemple, ils peuvent être entraînés à reconnaître les modèles météorologiques et les variations de l'irradiance solaire pour prédire le point de puissance maximale sous

diverses conditions, permettant ainsi un ajustement dynamique des paramètres de l'installation photovoltaïque.

La production d'énergie par les panneaux solaires n'est pas constante, car il existe un seul point de fonctionnement, appelé le point de puissance maximale (MPPT), où les panneaux produisent l'énergie optimale. Ce point varie en fonction des conditions environnementales telles que l'ensoleillement et la température, nécessitant un système dynamique pour son suivi. Pour ce faire, plusieurs algorithmes de commande MPPT ont été développés, tels que la méthode de perturbation et d'observation (P&O), la méthode de Hill Climbing, et la méthode d'incrémental de la conductance, entre autres.

Dans le cadre de ce travail de recherche, nous explorons une approche avancée utilisant les réseaux de neurones artificiels (RNA) pour le suivi du MPPT. Les RNA offrent une capacité d'apprentissage adaptatif qui peut efficacement gérer la variabilité des conditions atmosphériques affectant la production d'énergie solaire. En particulier, cette étude met en œuvre des modèles de RNA qui ajustent dynamiquement la tension de référence du MPPT sous différentes conditions atmosphériques, en utilisant un contrôle précis sur un convertisseur élévateur DC-DC. Ce processus est modélisé et simulé dans MATLAB/Simulink, où l'efficacité de cette méthode est comparée à des techniques plus traditionnelles.

En parallèle, nous employons également des réseaux de neurones convolutifs (CNN) pour détecter et classifier les défauts des panneaux solaires, une fonction cruciale pour la maintenance préventive. Initialement développées pour la reconnaissance d'images, les CNN ont été adaptées pour apprendre et identifier les défauts à partir de caractéristiques extraites des images des panneaux solaires. [4]

L'utilisation des techniques d'IA pour le traitement des données photovoltaïques peut surmonter les obstacles des méthodes traditionnelles qui sont souvent limitées par les suppositions linéaires et les approximations. En traitant le bruit et les perturbations

comme des informations exploitables plutôt que des anomalies, l'IA renforce la fiabilité et l'efficacité des systèmes d'énergie renouvelable.

L'intégration de l'IA dans la gestion des systèmes photovoltaïques ouvre ainsi la voie à une automatisation plus intelligente, à une maintenance prédictive et à une maximisation de la production d'énergie, des aspects fondamentaux pour accélérer la transition vers une économie à faible émission de carbone

Ce projet illustre donc comment les technologies d'intelligence artificielle peuvent transcender les limitations des méthodes traditionnelles, offrant des solutions plus robustes et efficaces pour la gestion des systèmes photovoltaïques.

1.3 Problématique

Au cours de la dernière décennie, le rendement moyen des panneaux solaires composés de cellules à base de silicium cristallin a augmenté d'environ 12 % pour atteindre de 17 % à 20 %. En laboratoire, de tels panneaux peuvent atteindre jusqu'à 24,4 % d'efficacité. [3]

Récemment, les progrès technologiques ont permis de pousser encore plus loin ces limites. En 2023, des cellules solaires à base de silicium monocristallin ont démontré des efficacités de 19 % à 21 % dans des applications résidentielles, tandis que les technologies émergentes comme les cellules solaires en pérovskite ont atteint des efficacités de laboratoire d'environ 25 %, avec des perspectives de dépassement de 30 % en configuration tandem avec des cellules en silicium. [5]

Notre projet de recherche s'attaque aux défis majeurs de l'optimisation de l'efficacité des systèmes photovoltaïques dans un contexte marqué par des contraintes technologiques actuelles et des conditions environnementales variables. Bien que les technologies photovoltaïques aient évolué, plusieurs facteurs continuent de limiter le rendement des panneaux solaires :

(1) Exploitation Sous-Optimale : La gestion actuelle de l'énergie photovoltaïque n'exploite pas pleinement le potentiel des systèmes existants.

(2) Fluctuations environnementales : Les variations d'ensoleillement et de température impactent directement et inévitablement la performance énergétique des installations.

(3) Pertes énergétiques : Des pertes significatives se produisent durant la phase de production et la transmission de l'électricité, réduisant ainsi l'efficacité globale du système.

En réponse à ces enjeux, notre étude se concentre sur le développement d'une stratégie efficace pour le suivi en temps réel du point de puissance maximale (MPPT) pour maximiser le rendement des panneaux photovoltaïques. Par ailleurs, pour aborder la question cruciale de la maintenance et de la fiabilité des systèmes, notre projet explore également l'utilisation des réseaux de neurones convolutifs (CNN) pour la détection précise et la classification des défauts des panneaux solaires, y compris les défauts électriques, physiques, et ceux induits par des facteurs environnementaux comme la couverture de neige. Ces technologies d'intelligence artificielle, par leur capacité à modéliser des relations complexes et à traiter des données visuelles, offrent des solutions prometteuses pour surmonter les limitations des méthodes traditionnelles, améliorant ainsi l'efficacité et la durabilité des installations photovoltaïques.

1.4 Objectifs et hypothèses

1.4.1 Objectif général

L'objectif principal de cette recherche est de développer et d'évaluer des stratégies avancées pour améliorer l'efficacité des systèmes photovoltaïques en traitant deux aspects critiques : le suivi du point de puissance maximale (MPPT) et la gestion des défauts des panneaux solaires. Nous utilisons les réseaux de neurones artificiels

(RNA) pour optimiser le MPPT, visant à maximiser la capture de l'énergie solaire en ajustant dynamiquement les paramètres du système en fonction des conditions atmosphériques changeantes. Simultanément, les réseaux de neurones convolutifs (CNN) sont appliqués pour détecter et classifier de manière précise et efficace les défauts des panneaux solaires, tels que les défauts physiques et électriques, ainsi que les obstructions comme la couverture de neige. Ces deux approches technologiques sont évaluées pour leur capacité à augmenter la fiabilité et la performance globale des installations photovoltaïques, en contribuant à une maintenance préventive et à une exploitation optimale de l'énergie solaire.

Nous cherchons à comparer les RNA avec la méthode traditionnelle de Perturbation et Observation (P&O) en termes de précision, rapidité de réponse, et stabilité dans le suivi du MPP, en particulier sous des conditions météorologiques fluctuantes. En parallèle, nous évaluons comment l'intégration des CNN peut transformer la maintenance des panneaux solaires en identifiant efficacement divers types de défauts tels que les défauts électriques, physiques, ou ceux dus à la couverture de neige.

Nous anticipons que les RNA offriront une régulation plus efficace du rapport cyclique dans le convertisseur DC-DC, permettant une extraction optimale de la puissance. De même, nous prévoyons que l'utilisation des CNN renforcera la fiabilité du système photovoltaïque en améliorant significativement la capacité de diagnostic et de prévention des défaillances.

La réussite de cette recherche pourrait faciliter une transition vers une utilisation plus généralisée des technologies d'intelligence artificielle pour la gestion de l'énergie dans les systèmes PV, rendant ces systèmes plus efficaces et plus attractifs pour les consommateurs et les investisseurs.

1.4.2 Objectifs spécifiques

1. Présenter l'aspect théorique des générateurs photovoltaïques et des commandes MPPT.
2. Implémenter un modèle système photovoltaïque dans la plateforme Matlab/Simulink pour la simulation. Ce système PV est composé d'un module PV, d'un convertisseur élévateur DC-DC avec un contrôleur MPPT et une charge.
3. Appliquer les algorithmes de commandes MPPT, les méthodes PO et RNA sur notre système PV.
4. Comparer des résultats obtenus par les méthodes utilisées.
5. Utiliser le réseau de neurones à convolution CNN pour détecter et classifier les défauts de panneau solaire.

1.5 Hypothèses

La réalisation de cette étude repose sur plusieurs hypothèses fondamentales qui définissent les conditions opérationnelles et les attentes en matière de comportement des systèmes photovoltaïques. Ces hypothèses sont essentielles pour cadrer notre analyse et nos expérimentations. Elles sont énoncées comme suit :

- Uniformité de l'ensoleillement : Nous supposons que l'intensité de l'ensoleillement est constante et uniformément répartie sur la surface des panneaux solaires pendant les heures de fonctionnement. Cette hypothèse permet de simplifier les modèles de production d'énergie en excluant les variations dues à des facteurs externes fluctuants.
- Linéarité de la réponse photovoltaïque : La réponse du système photovoltaïque à l'ensoleillement est considérée comme linéaire, évitant ainsi les complications liées à la saturation ou aux effets de seuil qui pourraient autrement affecter l'analyse.

- Consommation constante de la charge : Il est présumé que la charge connectée au système photovoltaïque consomme de l'énergie de manière constante et prévisible, facilitant ainsi la modélisation des interactions entre la production d'énergie et la consommation d'énergie.
- Efficacité de la détection des défauts par CNN : Nous partons du principe que les réseaux de neurones convolutifs (CNN) sont capables de détecter et de classifier avec précision les défauts des panneaux solaires, même lorsqu'ils sont subtils ou masqués par des obstacles externes. Cette hypothèse est cruciale pour évaluer l'efficacité des CNN dans la maintenance préventive des installations photovoltaïques.

Ces hypothèses sont testées à travers des simulations et des analyses détaillées, utilisant des outils avancés comme MATLAB/Simulink pour les aspects liés au MPPT et des techniques de traitement d'images pour la partie détection des défauts. Les résultats obtenus permettront de valider ou de remettre en question ces hypothèses, contribuant ainsi à une compréhension approfondie des capacités et des limites des systèmes photovoltaïques modernes.

1.6 Méthodologie de recherche

1.6.1 L'approche scientifique

Ce projet cherche à contribuer à la recherche en proposant une stratégie optimale de gestion énergétique exploitant les énergies photovoltaïques. Notre but est de développer une méthodologie complète pour la gestion de l'énergie qui comprend :

- Modélisation, analyse et commande de système énergétique photovoltaïque : Amélioration de la gestion de la production d'électricité à travers des techniques avancées de modélisation et de contrôle.

- Optimisation, contrôle et régulation de la production d'énergie : Utilisation de méthodes optimisées pour réguler et contrôler la production énergétique, tant électrique que solaire, afin d'améliorer l'efficacité de la gestion de la production.
- Amélioration de la maîtrise des systèmes de production d'énergie et économie d'énergie : Renforcement des capacités de gestion des systèmes énergétiques pour maximiser les économies d'énergie.
- Détection et classification des défauts par CNN : Les CNN seront utilisées pour analyser les images des panneaux solaires afin de détecter et classifier efficacement les divers types de défauts, comme les fissures, la délamination, ou les obstructions dues à la neige. Cela permettra d'améliorer la maintenance préventive et d'augmenter la durabilité des installations.

Des simulations numériques seront réalisées dans MATLAB Simulink pour valider les performances des algorithmes de Perturbation et Observation (P&O) et des réseaux de neurones artificiels (ANN). Parallèlement, des données d'apprentissage pour les CNN seront générées et testées afin de confirmer leur capacité à reconnaître et réagir face aux défauts détectés, garantissant ainsi une meilleure fiabilité et efficacité du système photovoltaïque.

1.6.2 La démarche suivie

Étape 1 : Examen des Travaux antérieurs

Nous commencerons par une étude détaillée de la littérature scientifique et technique sur les algorithmes MPPT pour identifier les meilleures pratiques et les points d'amélioration possibles, établissant ainsi une base solide pour le développement ultérieur.

Étape 2 : Simulation du Système Photovoltaïque

La simulation du système photovoltaïque sera réalisée via Matlab/Simulink, en modélisant un module PV spécifique, un convertisseur DC-DC et un contrôleur

MPPT. Nous testerons initialement la méthode P&O pour établir une ligne de base pour les performances de suivi.

Étape 3 : Conception et Entraînement du Réseau de Neurones Artificiels

Cette étape sera consacrée à la création d'un RNA adapté aux spécificités de notre système :

(Acquisition de données, préparation des données, architecture du RNA, phase d'Entraînement et validation du modèle).

Étape 4 : Comparaison et Évaluation

Nous procéderons ensuite à une comparaison des performances entre la méthode de Perturbation et Observation (P&O) et l'approche utilisant les réseaux de neurones artificiels (RNA) pour la commande du MPPT. Cette analyse se fera à travers des simulations et des tests pratiques, incluant une évaluation des réactions du système aux variations climatiques et une analyse détaillée des performances générales. Les critères de comparaison incluront la précision, la rapidité de réponse et la stabilité des deux méthodes.

Étape 5 : Détection et Classification des Défauts avec CNN

Développement de modèles CNN pour identifier et classifier les défauts des panneaux solaires. Cette phase implique la préparation des données, l'élaboration de l'architecture de la CNN, et l'entraînement des modèles pour reconnaître divers défauts, tels que fissures et obstructions.

Étape 6 : Évaluation et Tests des CNN

Évaluation des CNN à travers des tests rigoureux pour mesurer leur précision et leur efficacité dans la détection des défauts sous diverses conditions environnementales. Les résultats seront comparés aux attentes et aux normes de l'industrie pour valider la fiabilité des modèles.

En appliquant cette méthodologie, notre recherche vise à développer un système de contrôle MPPT robuste et efficace en utilisant les technologies d'intelligence artificielle. Nous explorerons comment les réseaux de neurones artificiels (RNA) pour optimiser le MPPT et les réseaux de neurones convolutifs (CNN) pour détecter les défauts des panneaux solaires peuvent améliorer la gestion et la performance des systèmes photovoltaïques. Cette approche innovante aspire à renforcer la fiabilité et l'efficacité des installations photovoltaïques, contribuant ainsi à l'avancement des énergies renouvelables

1.7 Conclusion

Ce chapitre a introduit le sujet en détaillant la problématique, les objectifs fixés, et la méthodologie de recherche adoptée. Nous avons exploré les différentes approches pour optimiser le point de puissance maximale (PPM) des installations photovoltaïques, en utilisant notamment la méthode de Perturbation et Observation (P&O) et les réseaux de neurones artificiels (RNA). Ensuite, nous avons examiné l'utilisation des réseaux de neurones convolutifs (CNN) pour détecter et classifier les défauts des panneaux solaires, ce qui constitue une avancée significative dans la gestion et la maintenance des systèmes photovoltaïques. La suite de ce travail consistera à évaluer en profondeur ces méthodes pour confirmer leur efficacité et leur fiabilité dans des conditions opérationnelles variées, mettant en lumière leur potentiel pour révolutionner la gestion des énergies renouvelables.

CHAPITRE II: GÉNÉRALITÉ SUR LE SYSTÈME PHOTOVOLTAÏQUE

2.1 Introduction

L'énergie photovoltaïque est une forme d'énergie renouvelable qui est générée à partir de la lumière du soleil à l'aide de cellules photovoltaïques. L'effet photovoltaïque fait référence à la génération d'un courant électrique lorsque certains matériaux, comme le silicium, sont exposés à la lumière. Lorsque ces cellules sont disposées en réseau, elles forment des modules photovoltaïques, qui peuvent être utilisés pour produire de l'électricité. L'énergie photovoltaïque est propre, durable et largement disponible, ce qui en fait une alternative prometteuse aux combustibles fossiles.

2.2 Historique photovoltaïque

La photovoltaïque remonte à la découverte en 1839 de l'effet photovoltaïque par le physicien français Edmond Becquerel. Au milieu du XXe siècle, le développement des cellules solaires en silicium a marqué un jalon important dans la commercialisation du photovoltaïque.

La première cellule solaire fonctionnelle fut construite en 1883 par Charles Fritts. Mais le rendement de sa cellule, étant très faible, empêcha l'époque de son utilisation. [6]

Au fil des décennies, les avancées en matériaux et techniques de fabrication ont entraîné d'importants progrès en matière d'efficacité et de rentabilité des systèmes photovoltaïques. Aujourd'hui, le photovoltaïque joue un rôle important dans la transition mondiale vers les sources d'énergie renouvelable et est largement utilisé pour une gamme d'applications, allant de l'alimentation des foyers et des entreprises à celle des satellites et des systèmes de communication à distance.

2.3 Système photovoltaïque.

Un système solaire photovoltaïque convertit l'énergie du soleil en électricité. Les principaux éléments qui peuvent être inclus dans un système photovoltaïque et assurent son fonctionnement sont :

Capteurs solaires (panneaux photovoltaïques) : Ils capturent l'énergie solaire et la convertissent en courant électrique continu (DC).

Onduleur : Convertit le courant continu (DC) en courant alternatif (AC), utilisable par les appareils ménagers et pour l'injection sur le réseau électrique.

Stockage d'énergie (batteries) : Les batteries stockent l'électricité produite pour une utilisation ultérieure, surtout lorsque la production solaire est faible ou la demande est élevée.

Tableau électrique : Distribue l'électricité dans le bâtiment, il collabore avec l'onduleur pour gérer la production et la consommation.

Raccordement au réseau : Permet de vendre l'excédent de production à la compagnie d'électricité ou d'acheter de l'électricité lorsqu'il y a un manque de production. La figure 2.1 montre les étapes de fonctionnement d'un système solaire photovoltaïque.




Figure 2.1

Schéma fonctionnel d'un système photovoltaïque

Source : <https://www.effy.fr/> consulté le 1er novembre 2022

2.3.1 Types de systèmes solaires photovoltaïques :

2.3.1.1 Systèmes sur réseau (grid-tied)

Connectés au réseau électrique public, ils permettent de vendre l'excès d'énergie produite. Les principales caractéristiques d'un tel système sont les panneaux solaires, l'onduleur, un compteur mesure la quantité d'électricité qui est produite, Compteur bidirectionnel qui permet de mesurer l'électricité qui est injectée dans le réseau ou consommée depuis le réseau. L'électricité produite peut être utilisée directement par la maison ou entreprise, avec tout excédent envoyé au réseau électrique. La figure 2.2 montre un système solaire connecté au réseau.




Figure 2.2
Système solaire connecter au réseau

Source : www.solaire-offgride.com consulté le 1er novembre 2022

Ce type de système est le plus courant dans les zones urbaines où le réseau électrique est facilement accessible et fiable. La (figure 2.2) montre un système solaire connecter au réseau.

2.3.1.2 Systèmes hors réseau (off-grid)

Indépendants du réseau électrique, ils nécessitent souvent des batteries ou d'autres formes de stockage d'énergie. Voici les éléments qui composent généralement ce type de système :

Panneaux photovoltaïques, régulateur de charge qui protège les batteries contre la surcharge ou la décharge excessive en régulant le flux d'énergie, batteries pour stocker l'énergie solaire pour une utilisation quand il n'y a pas de soleil, comme la nuit ou lors de journées nuageuses. Onduleur (convertisseur) qui convertit le courant continu stocké dans les batteries en courant alternatif (AC) pour alimenter les appareils électriques et un système de gestion de l'énergie qui gère l'optimisation de la charge et de la décharge des batteries, la production d'énergie, et la consommation. La (figure 2.3) montre un système solaire autonome.

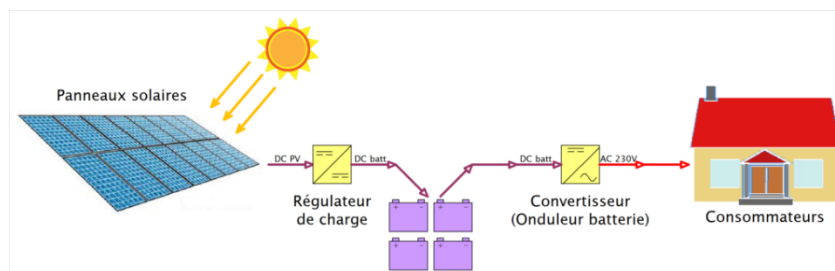


Figure 2.3
Système solaire autonome (hors réseau)

Source : www.solaire-offgride.com consulté le 1er novembre 2022

Les systèmes solaires autonomes hors réseau sont particulièrement adaptés pour les zones reculées, les cabanes, les bateaux ou les véhicules de loisirs, où l'accès au réseau électrique est inexistant ou peu pratique. La (figure 2.3) montre un système solaire photovoltaïque autonome.

2.3.1.3 Systèmes hybrides

Combinent les caractéristiques des systèmes sur réseau et hors réseau, souvent avec des batteries et la capacité de rester alimentés pendant une coupure de courant. Des systèmes hybrides peuvent intégrer d'autres formes d'énergie renouvelable comme l'éolien ou l'hydroélectricité, en plus des panneaux solaires. Certains systèmes hybrides intègrent un groupe électrogène comme source de secours pour assurer une alimentation continue en cas de longues périodes sans soleil ou en cas de problèmes avec le réseau comme la montre là (figure 2.4).

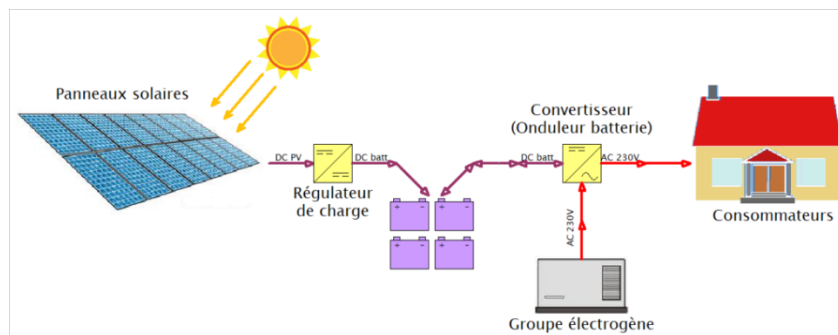


Figure 2.4
Système solaire hybride.

Source : www.solaire-offgride.com consulté le 1er novembre 2022

Chaque système a ses avantages et inconvénients, et le choix dépend de plusieurs facteurs tels que l'emplacement, les besoins en énergie, les incitations financières et les coûts.

2.4 Module photovoltaïque

Un module photovoltaïque est un ensemble de cellules photovoltaïques élémentaires disposées en série et/ou en parallèle afin d'obtenir les caractéristiques électriques souhaitées telles que : la puissance, le courant de court-circuit I_{cc} ou la tension en circuit ouvert V_{co} .

2.4.1 La constitution d'un module photovoltaïque

Un module solaire photovoltaïque est généralement composé de plusieurs strates ou couches permettant de protéger les cellules photovoltaïques des agressions extérieures :

Le cadre en aluminium (1) : il sert à maintenir le panneau en place, à le protéger contre les intempéries et à le soutenir.

Le substrat en verre (2) : C'est la couche supérieure du panneau solaire qui protège les cellules photovoltaïques contre les conditions météorologiques et les dommages mécaniques.

Le film d'encapsulation en EVA (Ethylene Vinyl Acetate) (3) : Il sert à protéger les cellules photovoltaïques contre les dommages causés par les intempéries, la poussière, la saleté et d'autres facteurs environnementaux

Les cellules photovoltaïques (4) : Elles sont les composants principaux du panneau solaire et convertissent l'énergie lumineuse en énergie électrique

La membrane en tedlar (5) : est utilisée pour protéger les cellules photovoltaïques contre les intempéries et les dommages mécaniques.

La boîte de jonction (6) : Elle se trouve à l'arrière du panneau et est utilisée pour relier les cellules photovoltaïques ensemble et les connecter à d'autres éléments du système photovoltaïque.




Figure 2.5
Composition d'un module solaire photovoltaïque
 Source : Eco sources panneau-solaire-photovoltaïque

Ces différentes strates travaillent ensemble pour convertir l'énergie lumineuse du soleil en énergie électrique utilisable pour alimenter les foyers et les entreprises.

2.4.2 Cellule photovoltaïque

2.4.2.1 L'effet photovoltaïque

L'effet photovoltaïque est un phénomène physique se produisant dans certains matériaux semi-conducteurs, qui permet de convertir l'énergie des photons en électricité. C'est sur cette base que fonctionnent les panneaux solaires photovoltaïques, utilisés pour produire de l'électricité à partir de l'énergie solaire.

2.4.2.2 Principe de fonctionnement

Les cellules photovoltaïques sont fabriquées à partir de matériaux semi-conducteurs tels que le silicium, qui ont la capacité de convertir l'énergie solaire en électricité lorsque les photons solaires sont absorbés par les atomes de silicium. Cette conversion se produit lorsque les photons solaires excitent les électrons des atomes de silicium, les libérant de leurs orbites et les faisant circuler dans un circuit électrique. Le courant électrique ainsi produit peut ensuite être utilisé pour alimenter des

appareils électroniques ou être stocké dans des batteries pour une utilisation ultérieure. [7]

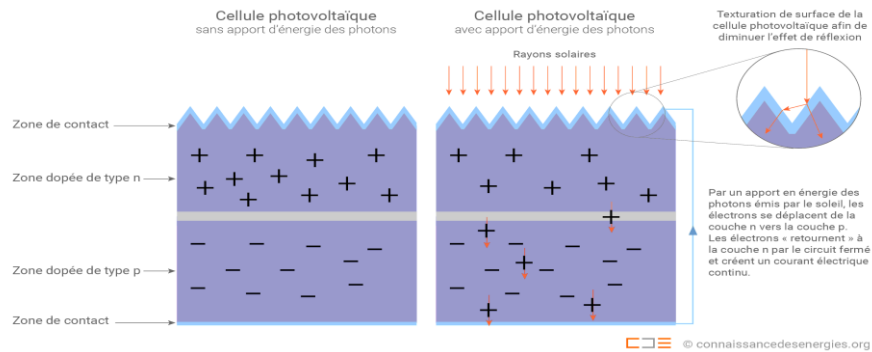


Figure 2.6
Fonctionnement d'une cellule photovoltaïque

Source : www.connaissancedesenergies.org

La (figure 2.6) présente la structure interne d'une cellule photovoltaïque et explique son fonctionnement avec et sans l'exposition à la lumière solaire.

2.4.2.2 Technologies :

Les plus part des cellules photovoltaïques sont fabriquées à partir de matériaux semi-conducteurs, tels que le silicium, le cadmium telluride (CdTe), le cuivre-indium-gallium-sélénium (CIGS), la pérovskite.

Les matériaux sont choisis en fonction de leur coût, de leur disponibilité, de leur performance et de leur durabilité.

Cellules en silicium cristallin : les plus couramment utilisées, ils sont fabriqués à partir de silicium pur et sont disponibles en différentes variantes telles que monocristallin et polycristallin de rendements environ 15 à 22%.

Cellules en film mince : fabriquées à partir de couches minces de matériaux tels que le cadmium telluride (CdTe) et le cuivre-indium-gallium-sélénium (CIGS), elles sont

plus économiques et écologiques que les cellules en silicium de rendement environ 10 à 13%.

Cellules DSC (dye-sensitized solar cell) : basées sur la photosensibilisation des organiques, elles ont une efficacité inférieure, mais sont souples et peu coûteuses de rendements environ 5 à 8%.

Cellules en pérovskite : basées sur des matériaux à base de pérovskite, elles ont connu une croissance rapide ces dernières années en raison de leur efficacité élevée et de leur coût relativement faible de rendements environ 15 à 22%.

Le rendement des cellules photovoltaïques dépend de plusieurs facteurs, notamment la technologie utilisée, la qualité de la production, les conditions environnementales.

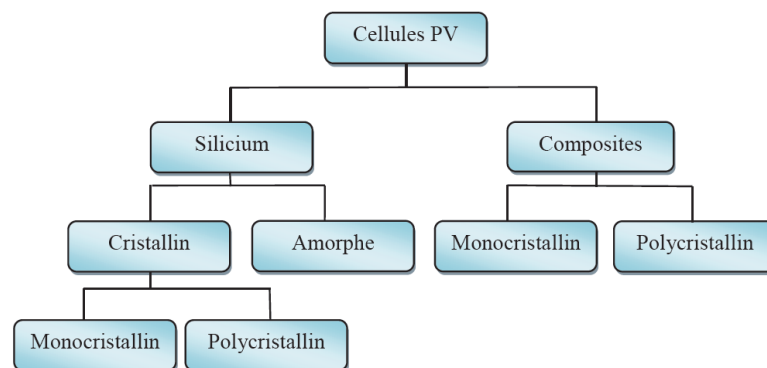


Figure 2.7
Les différentes technologies des cellules PV

2.4.2.3 Caractérisation électrique d'une cellule photovoltaïque

Lorsqu'une jonction NP est fabriquée à partir d'un matériau sensible à la lumière, elle a la spécificité de pouvoir servir de générateur d'énergie. Ce comportement en statique peut être décrit par les équations électriques définissant le fonctionnement d'une diode [8].

$$I_{sh} = \frac{V_{PV} \pm R_s I_{PV}}{R_{sh}} \quad (2.1)$$

$$I_{pv} = I_{cc} - I_d - I_{sh} \quad (2.2)$$

$$I_{pv} = I_{cc} - I_{sat} \left[\exp \frac{V_{PV} + R_s I_{PV}}{nV_T} - 1 \right] - \frac{V_{PV} \pm R_s I_{PV}}{R_{sh}} \quad (2.3)$$

$$I_{cc} = (I_{cc,n} + K_I \Delta T) \frac{E}{E_n} \quad (2.4)$$

Où le schéma équivalent est représenté par la (figure 2.8) et les termes constituant l'équation sont définis comme suit :

n : facteur de non-idéalité de la jonction.

I_{cc} : courant de court-circuit dépendant de l'éclairement et de la température.

I_{sat} : courant de saturation.

I_{PV} : courant fourni par la cellule.

V_{PV} : tension aux bornes de la cellule.

D : diode représentant la jonction PN.

R_{sh} : résistance shunt caractérisant les courants de fuite de la jonction.

R_s : résistance, série représentant les diverses résistances des contacts et des connexions.

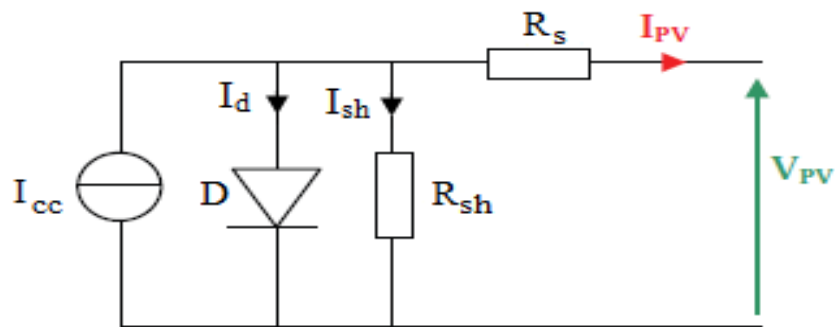


Figure 2.8
Modèle équivalent de la cellule photovoltaïque

2.4.2.4 Cellules mises en série

Les cellules photovoltaïques peuvent être connectées en série pour augmenter la tension totale produite. Cette configuration en série est courante dans les panneaux solaires photovoltaïques pour augmenter la tension à un niveau utilisable pour l'alimentation en électricité. Cependant, il est important de noter que si une seule cellule est endommagée ou défectueuse, cela peut affecter le fonctionnement de tout le système en série. La caractéristique résultant du groupement est obtenue par la figure suivante :




Figure 2.9
Caractéristiques d'un groupement des cellules en série. [9]

2.4.2.5 Cellules mises en parallèle

Les cellules photovoltaïques peuvent également être connectées en parallèle pour augmenter le courant total produit. Cette configuration en parallèle est courante dans les panneaux solaires photovoltaïques pour augmenter la puissance totale produite. Lorsqu'elles sont connectées en parallèle, les cellules travaillent ensemble pour produire plus de courant, ce qui peut être utilisé pour alimenter des appareils électriques plus gros. La caractéristique résultant du groupement est obtenue par la figure suivante :




Figure 2.10
Caractéristiques d'un groupement des cellules en parallèle. [9]

2.4.2.6 Caractéristique courant-tension

La caractéristique $I(v)$ du panneau solaire photovoltaïque est directement liée à celle de la cellule solaire de base. Elle présente la variation du courant qu'elle produit en fonction de la tension à ses bornes. Il existe deux cas extrêmes, un circuit ouvert ($V=U_V$, $I=0$) et un court-circuit ($V=0$, $I=I_{CC}$). Dans ces deux cas, aucune puissance n'est extraite du panneau photovoltaïque. Une meilleure combinaison permet d'obtenir le point de puissance maximale du panneau photovoltaïque. La tension et le

courant correspondant sont (U_{PM}) et (I_{PM}), la (figure 2.11) montre la courbe du courant-tension pour une irradiance de $G = 1000\text{W/m}^2$ et une température $\theta = 25^\circ\text{C}$.




Figure 2.11
Courbe courant-tension d'une cellule. [10]

2.4.2.7 Caractéristiques puissance-tension :

La puissance fournie par la cellule est exprimée par $P = U.I$. Pour chaque point de la courbe ci-dessus, nous pouvons déterminer la puissance P et tracer la courbe $P = f(U)$. Cette courbe se présente sur la (figure 2.12) :




Figure 2.12
Caractéristiques puissance / tension. [10]

Cette courbe présente un maximum de puissance (PM). Cette puissance correspond à une tension U_{pm} et à un courant I_{pm} , que l'on peut également voir sur la courbe $I = f(U)$. Il y a un rapport entre la tension et le courant du panneau pour obtenir une puissance maximale.

2.4.2.8 Influence de l'éclairement :

À température constante, la caractéristique $I = f(U)$ dépend évidemment fortement de l'éclairement. Sur la courbe de la (figure 2.13) on remarque que le courant de court-circuit augmente avec l'éclairement $G_1 > G_2$ alors que la tension à vide varie peu.

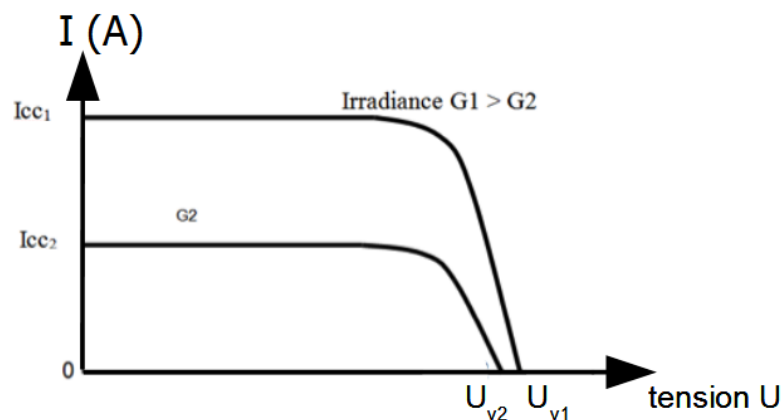


Figure 2.13
Courbe $I(V)$ d'une cellule pour deux valeurs d'irradiance. [10]

À partir de la courbe précédente, on obtient les courbes de puissance $P = f(U)$ pour les deux éclaircissements. On note que la puissance maximale délivrée par la cellule augmente avec l'éclairement.





Figure 2.14
Courbe $P(V)$ d'une cellule pour deux valeurs d'irradiances. [10]

2.4.2.9 Influence de température

Lorsque la température des cellules photovoltaïques augmente, la puissance et la tension du panneau solaire diminuent, tandis que le courant (intensité) augmente, cela est dû à un phénomène d'agitation thermique qui se produit dans les cellules. La variation de la caractéristique courant-tension et puissance en fonction de la température est illustrée à la (Figure 2.15).



Lecture : à une température du panneau solaire de 75°C, la puissance est de 79.5% de la puissance nominale (inscrite sur la plaque constructeur ou dans la spécification). La tension 84% et le courant 102.5%.

Figure 2.15

La variation de la caractéristique I(V) et P en fonction de la T.

Source : jade-technologie.2021

2.5 Types de défauts des panneaux solaires

Les panneaux solaires peuvent subir une variété de défauts qui compromettent leur efficacité et leur durabilité. Ces défauts peuvent être classifiés en deux catégories principales : défauts électriques et défauts physiques.

- **Défauts électriques**

Ces problèmes affectent la performance électrique des panneaux solaires et incluent :

Points chauds : Ces zones surchauffées sont souvent causées par l'ombrage, la saleté ou des défauts électriques internes, pouvant endommager les cellules photovoltaïques.

Corrosion : La corrosion des connexions électriques peut réduire leur efficacité, augmentant la résistance et diminuant la production d'énergie.

Défaillances de l'onduleur : Les onduleurs, qui convertissent le courant continu produit par les panneaux en courant alternatif utilisable, peuvent faillir, affectant toute la production énergétique du système. [11]

- **Défauts physiques**

Ces défauts concernent la structure physique des panneaux, y compris les cellules et le cadre :

Micro-fissures : Petites fissures dans les cellules qui peuvent survenir suite à un stress thermique ou mécanique, réduisant l'efficacité des cellules.

Délamination : Séparation des couches d'encapsulation des cellules photovoltaïques ou du verre protecteur, pouvant permettre l'infiltration d'eau et d'autres éléments.

Jaunissement : L'exposition aux UV peut causer un jaunissement du matériau d'encapsulation, réduisant la transmission de lumière aux cellules et diminuant la performance globale. [12]

2.6 *Convertisseur CC-CC Boost*

Un convertisseur boost ou élévateur, également connu sous le nom de step-up converter, est un dispositif d'électronique de puissance qui peut augmenter la tension de niveau bas à un niveau plus élevé, tout en diminuant le courant en conséquence, en respectant la loi de conservation de l'énergie. Le convertisseur boost est utilisé pour optimiser la conversion de l'énergie provenant des panneaux photovoltaïques. En ajustant la tension de sortie, le convertisseur boost contribue à maintenir l'efficacité énergétique du système, en s'assurant que le moins d'énergie possible est perdue lors du processus de conversion.

2.6.1 Modélisation d'un convertisseur CC-CC Boost

Le convertisseur CC-CC Boost est un système qui transmet la tension de sortie à un niveau de tension plus élevée en augmentant la tension entrée du convertisseur. La (figure 2.16) montre la forme du circuit de base d'un convertisseur CC-CC Boost.




Figure 2.16
Circuit électrique d'un convertisseur Boost

Inductance (L) : Stocke l'énergie sous forme de champ magnétique lorsqu'un courant la traverse. La relation entre la tension V_L , l'inductance L , et la variation du courant $\frac{di}{dt}$ est donnée par.

$$V_L = L \cdot \left(\frac{di}{dt} \right) \quad (2.5)$$

Capacité (C) : Stocke l'énergie sous forme de champ électrique. La tension à travers le condensateur V_c , est liée à la charge stockée Q et à la capacité C par.

$$V_c = \frac{Q}{C} \quad (2.6)$$

Diode (D) : Permet le passage du courant dans un seul sens, bloquant le retour de courant lorsqu'elle est polarisée en inverse.

Transistor (interrupteur) : Gère le flux d'énergie à travers l'inducteur en s'ouvrant et en se fermant à une fréquence élevée, contrôlée par le signal PWM (modulation de largeur d'impulsion) qui est ajusté par l'algorithme MPPT pour maintenir l'opération au MPP.

Charge (R) : Représente la consommation ou le stockage d'énergie par le système.

La dynamique du convertisseur boost peut être décrite par les équations d'état suivantes, qui s'appliquent lorsque l'interrupteur est fermé (état ON) et ouvert (état OFF). [13]

État ON (S fermé) :

$$V_L = V_{pv} - V_0 \quad (2.7)$$

$$\frac{di_L}{dt} = \frac{V_{pv} - V_0}{LV_0} \quad (2.8)$$

$$V_C = V_0 \quad (2.9)$$

$$I_C = C \frac{dV_0}{dt} \quad (2.10)$$

$$I_D = 0 \text{ (car la diode est bloquée)}$$

État OFF (interrupteur ouvert) :

$$V_L = -V_0 \quad (2.11)$$

$$\frac{di_L}{dt} = \frac{-V_0}{L} \quad (2.12)$$

$$I_C = I_L = -I_0 \quad (2.13)$$

$$V_C = V_0 \quad (2.14)$$

$$I_D = I_L \text{ (la diode conduit)}$$

Où

V_{pv} est la tension des panneaux solaires.

V_0 est la tension de sortie du convertisseur.

I_L est le courant à travers l'inductance.

I_C est le courant à travers le condensateur.

I_0 est le courant de charge.

Ces équations sont utilisées pour déterminer le comportement dynamique du convertisseur et pour concevoir le contrôleur MPPT qui ajustera le rapport cyclique du signal PWM pour maximiser la puissance de sortie en fonction des conditions de fonctionnement des panneaux solaires.

2.6.2 Principe de fonctionnement d'un convertisseur Boost :

Le fonctionnement d'un convertisseur peut être expliqué en deux phases principales :

Phase d'accumulation d'énergie : Lorsque l'interrupteur est en position fermée, le courant augmente dans l'inductance, ce qui permet de stocker de l'énergie sous forme magnétique. Pendant ce temps, la diode est en état de non-conduction, isolant ainsi la charge de la source d'alimentation.

Phase de transfert d'énergie : Lorsque l'interrupteur passe à l'état ouvert, l'inductance se trouve en série avec la source de tension. Sa force électromotrice (f.é.m.) se combine alors à celle de la source, créant un effet de surtension. Le courant émis de l'inductance passe par la diode, le condensateur et la charge résistive, ce qui permet de transférer l'énergie stockée de l'inductance au condensateur. [14]

2.7 Méthode d'extraction du point de puissance maximum (MPPT)

2.7.1 Principe de fonctionnement

Les méthodes d'extraction du point de puissance maximum (MPPT) d'un panneau solaire sont basées sur la mesure de la tension et du courant du panneau solaire pour ajuster la tension jusqu'à ce que la puissance maximale soit atteinte. Le principe de cette commande est de faire varier automatiquement le rapport cyclique α en l'amenant à la valeur optimale de manière à maximiser la puissance délivrée par le panneau PV. Le suivi du point de puissance maximale (MPP) d'un réseau photovoltaïque est une étape essentielle pour optimiser la production d'énergie. Il existe plusieurs méthodes pour extraire le point de puissance maximale (MPPT) d'un panneau solaire, qui varie en termes de complexité, de nombre de capteurs requis, de mise en œuvre numérique ou analogique, de vitesse de convergence, de capacité de suivi et de rentabilité.

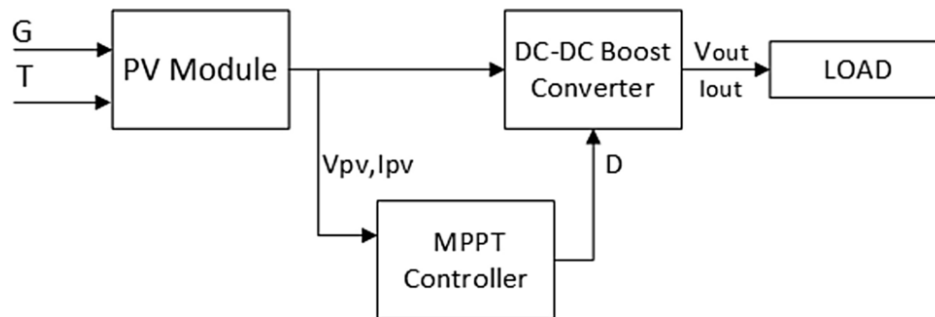


Figure 2.17
Liaison entre PV et la charge

2.7.2 Méthode de perturbation et observation (PO)

L'algorithme Perturbation et Observation (P&O) est une méthode courante pour extraire le point de puissance maximale (MPPT) d'un panneau solaire. L'algorithme P&O mesure la tension et le courant du panneau solaire, puis augmente ou diminue la tension pour observer la variation de la puissance produite. Si la puissance augmente,

l'algorithme continue d'augmenter la tension jusqu'à ce que la puissance diminue. À ce stade, l'algorithme revient à la tension précédente et commence à diminuer la tension. Si la puissance diminue, l'algorithme continue de diminuer la tension jusqu'à ce que la puissance augmente. À ce stade, l'algorithme revient à la tension précédente et commence à augmenter la tension. L'algorithme P&O continue de perturber la tension du panneau solaire de cette manière jusqu'à ce que la puissance maximale soit atteinte.

L'algorithme P&O est simple et peu coûteux, mais il peut être sensible aux variations de l'ensoleillement et peut entraîner des pertes de puissance. Des variantes de cette méthode ont été proposées pour améliorer ses performances, telles que l'algorithme P&O amélioré avec espace de recherche confiné. L'algorithme P&O est l'une des méthodes les plus courantes pour extraire le point de puissance maximale d'un panneau solaire, mais il existe d'autres méthodes plus avancées qui peuvent être plus précises et plus rapides. [15]

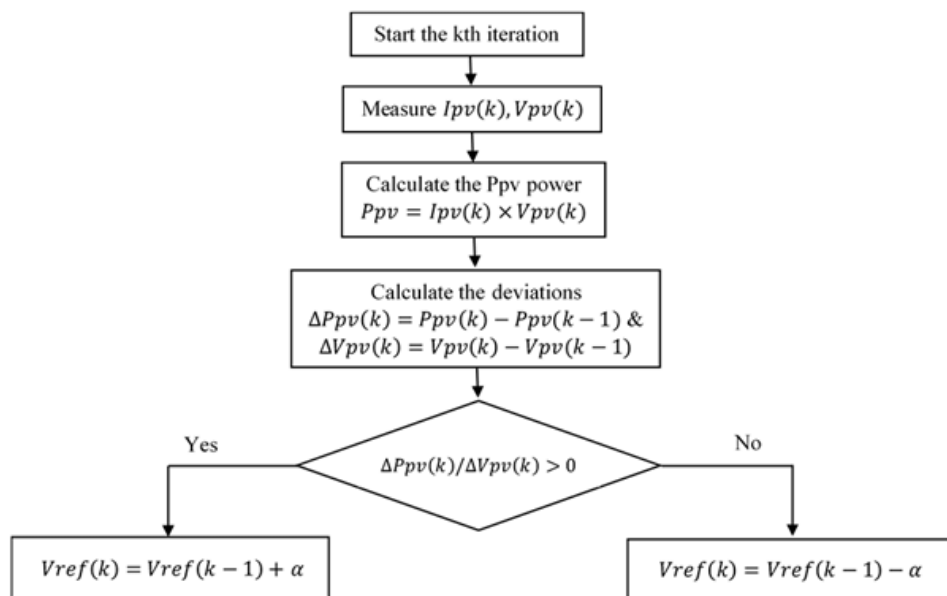


Figure 2.18
Organigramme de l'algorithme PO. [15]

Où

α : le pas de réglage utilisé pour ajuster la tension de référence.

2.8 Conclusion

Ce chapitre a fourni un aperçu approfondi des systèmes photovoltaïques, mettant en lumière l'importance des conditions environnementales telles que l'intensité lumineuse et la température sur la performance des panneaux solaires. La technique du suivi du point de puissance maximale (MPPT) a été identifiée comme essentielle pour optimiser la production d'énergie, même face à des conditions variables, permettant ainsi une exploitation maximale du potentiel de l'énergie solaire photovoltaïque. Bien que cette revue ait été centrée sur les aspects généraux du système photovoltaïque, les prochains chapitres introduiront des innovations technologiques prometteuses pour améliorer ces systèmes. Nous explorerons notamment les avancées apportées par l'utilisation des réseaux de neurones artificiels (RNA) et des réseaux de neurones convolutifs (CNN), qui représentent une évolution significative pour la gestion de l'énergie et la maintenance des installations photovoltaïques.

CHAPITRE III : APPLICATIONS DES RNA DANS LES SYSTÈMES PV

3.1 Introduction

Les réseaux de neurones artificiels (RNA) représentent une composante fondamentale de l'intelligence artificielle et de la machine learning, offrant des capacités avancées pour modéliser des relations complexes et pour traiter des volumes importants de données. Ces systèmes sont particulièrement pertinents dans le domaine des énergies renouvelables, où ils peuvent être utilisés pour optimiser la performance des systèmes photovoltaïques et pour détecter et classer efficacement les défauts des panneaux solaires.

Ce chapitre vise à explorer en détail les principes fondamentaux des RNA, en commençant par une discussion sur la structure et les fonctionnalités des réseaux de neurones, incluant le perceptron multicouche (MLP). Nous examinerons également les types de connexions et les processus d'apprentissage qui permettent à ces réseaux de s'adapter et de s'améliorer avec le temps. Une attention particulière sera accordée aux réseaux de neurones convolutifs (CNN), spécifiquement à l'architecture ResNet50, qui a révolutionné l'analyse d'image grâce à sa capacité à traiter efficacement des architectures profondes.

L'application de ces technologies à la commande MPPT (Maximum Power Point Tracking) pour l'optimisation de l'efficacité des panneaux solaires et à la détection des défauts démontre non seulement la polyvalence des RNA mais aussi leur potentiel transformateur dans le secteur des énergies renouvelables. À travers ce chapitre, nous démontrerons comment les avancées dans le domaine des réseaux de neurones peuvent être directement appliquées pour améliorer la fiabilité et la performance des systèmes photovoltaïques.

En explorant ces thèmes, ce chapitre posera les bases nécessaires pour comprendre les chapitres suivants, qui se concentreront sur l'implémentation pratique et l'évaluation de ces techniques dans des applications réelles.

3.2 L'apprentissage en profondeur « Deep Learning »

L'apprentissage en profondeur est une sous-discipline de l'apprentissage automatique qui implique des réseaux de neurones avec de nombreuses couches, ou profondeur, permettant à l'ordinateur d'opérer une hiérarchie complexe de concepts. Grâce à l'entraînement sur de grands ensembles de données et la capacité de détecter des caractéristiques à différents niveaux d'abstraction, les modèles d'apprentissage en profondeur ont considérablement avancé la capacité des ordinateurs à reconnaître des motifs et à prendre des décisions intelligentes.

L'apprentissage en profondeur a révolutionné de nombreux domaines tels que la vision par ordinateur, le traitement du langage naturel, et le jeu stratégique, où il a surpassé les performances humaines dans certains cas. Malgré sa puissance, l'apprentissage en profondeur peut être entravé par le surajustement, les exigences en données et en calcul, et la difficulté d'interpréter les modèles. [16]

3.3 Fondements de réseau de neurones artificiels

Un réseau de neurones, qui sont au cœur de l'apprentissage en profondeur, est un modèle informatique inspiré du fonctionnement des neurones dans le cerveau humain. Il est utilisé pour reconnaître des modèles, traiter des données et effectuer des tâches complexes de calcul. Ils apprennent à partir d'exemples et ajustent leurs connexions internes (poids) en fonction des entrées et des sorties désirées. Cette capacité d'apprentissage les rend très efficaces pour la reconnaissance de formes, la classification et la prédiction. [17]

Les réseaux de neurones artificiels sont une structure composée de neurones interconnectés. Ils offrent de nouvelles perspectives pour résoudre les problèmes liés

à la perception, à la mémoire, à l'apprentissage et au raisonnement. Chaque neurone artificiel est un processeur primaire. Il reçoit un certain nombre d'entrées en provenance des neurones, et chacune de ces entrées est affectée d'un poids qui détermine la force de l'interconnexion. En outre, chaque neurone a une sortie individuelle qui se ramifie pour alimenter un certain nombre de neurones en aval. Les réseaux de neurones artificiels (RNA) ne s'appuient pas sur une base de connaissances préprogrammée comme les systèmes experts. De ce point de vue, les RNA peuvent être qualifiés de représentants les plus caractéristiques de l'intelligence artificielle. [18]




Figure 3.1
Structure d'un neurone artificiel. [17]

L'un des principaux défis associés aux réseaux neuronaux artificiels (RNA) est qu'il n'existe pas de méthode normalisée pour déterminer le nombre de couches cachées et de neurones par couche. Ce qui les distingue, c'est leur capacité à calculer à partir de données d'entrée observées pour créer une cartographie précise de la relation entre les entrées et les sorties.

La conception de l'algorithme d'apprentissage adaptatif du réseau a constitué une avancée cruciale dans le développement des RNA. L'algorithme fondamental, connu

sous le nom de méthode de rétropropagation de l'erreur, ajuste les poids des neurones au cours des itérations afin de minimiser l'erreur globale entre la sortie actuelle et la sortie attendue du réseau. Cette méthode, généralement appelée apprentissage supervisé, fournit la réponse désirée.

3.4 Structure d'interconnexion d'un réseau de neurones

3.4.1 Perceptron multicouche (PMC)

Un perceptron multicouche peut comporter une ou plusieurs couches cachées. Chaque couche est composée d'un ou plusieurs neurones. Dans un PMC, les couches sont connectées entre elles, mais les perceptrons de chaque couche ne sont pas connectés entre eux. [19]

Les neurones sont disposés en couches comme montré la (figure 3.2), il n'y a pas de connexion entre les neurones appartenant à une même couche et les connexions ne se font qu'avec les neurones des autres couches aval. En règle générale, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.




Figure 3.2
Définition des couches d'un réseau multicouche. [17]

Couche d'entrée : Il s'agit de la première couche du réseau neuronal, où les données d'entrée sont reçues. Chaque neurone de cette couche représente une caractéristique d'entrée, et le nombre de neurones dans cette couche est déterminé par la dimensionnalité des données d'entrée.

Couche(s) cachée(s) : ces couches sont situées entre les couches d'entrée et de sortie et sont responsables du traitement des données d'entrée via des connexions pondérées et de l'application de fonctions d'activation. La présence de plusieurs couches cachées caractérise les réseaux neuronaux profonds, leur permettant d'apprendre des représentations complexes des données d'entrée.

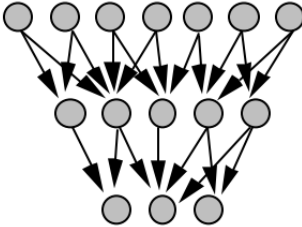
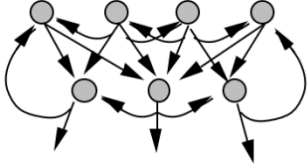
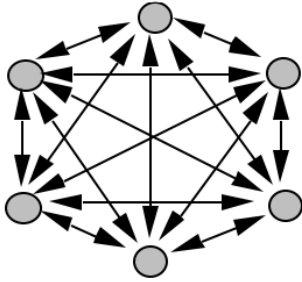
Couche de sortie : La dernière couche du réseau neuronal, où le réseau produit sa sortie. Le nombre de neurones dans cette couche dépend de la nature de la tâche, telle que la régression, la classification ou d'autres types de prédictions.[20]

3.4.2 Les types de connexions d'un réseau de neurones

Le (tableau 3.1) montre les différentes connexions d'un réseau de neurones et leurs structures.

Table 3.1
Types de connexions d'un réseau de neurones.

Source : [17]

Type	Architecture	Structure
<p>Réseau à connexions locales</p>		<p>Il s'agit d'une structure multicouche, elle conserve une certaine topologie comme la peau, chaque neurone interagit avec un petit nombre de neurones localisés dans la couche aval. Les connexions sont donc moins nombreuses que dans un réseau multicouche classique.</p>
<p>Réseau à connexions récurrentes</p>		<p>Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales.</p>
<p>Réseau à connexion complète</p>		<p>C'est la structure d'interconnexion la plus générale. Chaque neurone est connecté à tous les neurones du réseau et à lui-même.</p>

3.5 Apprentissage d'un réseau de neurones

3.5.1 Processus d'apprentissage d'un réseau de neurones

Lorsqu'un réseau de neurones est configuré pour une application spécifique, il est prêt à entamer sa phase d'apprentissage. L'apprentissage dans un réseau de neurones commence par l'attribution aléatoire des poids de connexion, qui sont des sortes de paramètres influençant la façon dont le réseau traite les informations. Le réseau reçoit ensuite des données et les fait passer à travers ses différentes couches, un processus appelé propagation avant. Durant ce processus, chaque couche du réseau utilise ses poids actuels pour calculer une sortie. Après cela, le réseau compare sa sortie calculée avec la sortie réelle souhaitée pour mesurer son erreur ou sa précision. Cette étape est cruciale car elle permet au réseau de savoir dans quelle mesure il doit s'améliorer.

Le cœur de l'apprentissage est la rétropropagation. Ici, l'erreur est utilisée pour faire des ajustements rétroactifs aux poids du réseau. En d'autres termes, le réseau apprend de ses erreurs en ajustant ses poids pour produire des résultats plus précis à l'avenir. Ce processus est généralement aidé par des méthodes d'optimisation, comme la descente de gradient, qui aident à ajuster les poids de manière efficace.

Ce cycle de propagation avant, évaluation de l'erreur, rétropropagation et ajustement des poids se répète plusieurs fois, permettant au réseau de devenir de plus en plus précis. Finalement, le réseau est testé sur de nouvelles données pour s'assurer qu'il peut bien généraliser ses apprentissages à des situations qu'il n'a pas encore rencontrées. De ce fait, les données d'entraînement, aussi appelées Training Data en anglais, doivent être préparées de manière méthodique et réfléchies.

La (figure 3.3) est un organigramme qui décrit le déroulement d'une session d'apprentissage d'un réseau de neurones. Cet organigramme illustre un cycle d'apprentissage itératif où le réseau s'améliore progressivement par l'ajout de nouvelles données d'apprentissage et l'ajustement de ses paramètres, tout en vérifiant périodiquement ses performances par simulation.

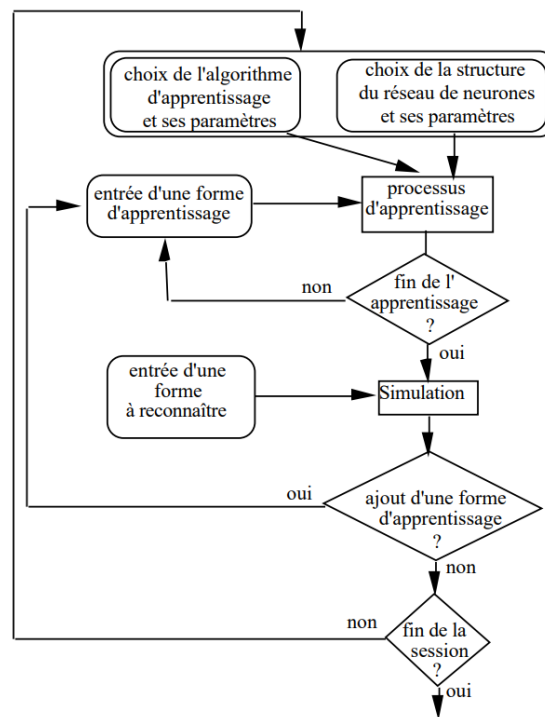


Figure 3.3
Organigramme d'une session. [17]

3.5.2 Types d'apprentissage

Les réseaux de neurones apprennent et s'améliorent grâce à divers types d'apprentissage.

- Apprentissage supervisé : Ce type d'apprentissage implique l'utilisation de données étiquetées pour entraîner le réseau de neurones. Les entrées sont associées à des sorties attendues, et le réseau apprend à produire les sorties correctes en ajustant ses paramètres en fonction des erreurs entre les sorties réelles et les sorties attendues
- Apprentissages non supervisés : contrairement à l'apprentissage supervisé, l'apprentissage non supervisé ne nécessite pas de données étiquetées. Le réseau de neurones cherche à découvrir des modèles ou des structures

intrinsèques dans les données d'entrée sans avoir des sorties attendues prédéfinies. Cela peut inclure des tâches telles que la classification automatique, la réduction de dimensionnalité ou la détection d'anomalies

- Apprentissage par renforcement : dans ce type d'apprentissage, le réseau de neurones apprend à prendre des décisions en interagissant avec un environnement dynamique. Il reçoit des récompenses ou des pénalités en fonction de ses actions, ce qui lui permet d'ajuster son comportement pour maximiser les récompenses à long terme. Cela est couramment utilisé dans des domaines tels que les jeux, la robotique et la gestion des ressources.

Dans le cadre de cette étude, nous opterons pour la méthode d'apprentissage supervisé. Cette décision est prise en raison de la nature des données que nous utiliserons, lesquelles sont collectées directement auprès de la NASA. La (figure 3.4) montre un schéma détaillé d'un apprentissage superviser.

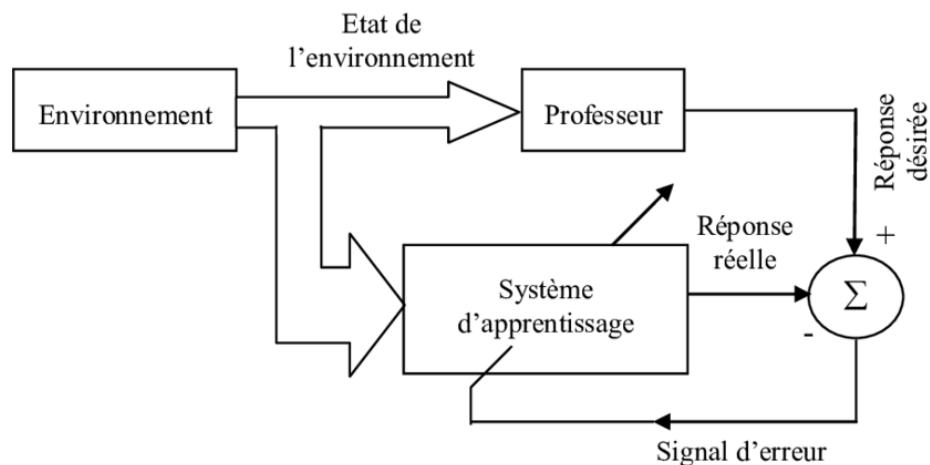


Figure 3.4
Schéma d'un apprentissage supervisé. [21]

3.6 Réseau de neurones de propagation avant (feedforward)

Plusieurs types et architectures de réseaux neuronaux artificiels existent, notamment les réseaux récurrents Elman [22], les réseaux de neurones autoorganisés (ou cartes

de Kohonen), et les réseaux de neurones de type Extreme Learning Machine [23]. Les réseaux neuronaux feedforward sont toutefois les plus couramment utilisés, en raison de leur simplicité et de leur facilité de mise en œuvre. Dans ces réseaux, l'information circule uniquement dans un sens, en commençant par les nœuds d'entrée qu'ils sont dans notre cas la température T et l'ensoleillement G , en passant par les couches cachées et en aboutissant aux nœuds de sortie qui est la tension au point de puissance maximum V_{mpp} . L'absence de cycles ou de boucles dans le réseau le rend facile à utiliser.




Figure 3.5
Illustration d'un réseau de neurones feed-forward

Outre la sélection du type de réseau neuronal, le choix d'une fonction d'erreur et d'une fonction d'activation pour les neurones est également crucial. Ces choix sont généralement influencés par le type de données traitées par le réseau.

3.7 Algorithme de rétropropagation « error back-propagation »

La rétropropagation est une méthode utilisée pour entraîner les réseaux de neurones multicouches, en particulier ceux avec des fonctions de transfert non linéaires différentiables. Cette technique est une extension de la règle d'apprentissage de Widrow-Hoff. Elle fonctionne en utilisant des paires de vecteurs d'entrée et de sortie

cible pour entraîner le réseau, de sorte que le réseau puisse apprendre à approximer une fonction qui relie les entrées aux sorties désirées. [24]

Ce processus commence par l'initialisation aléatoire des poids des connexions neuronales. Lors de chaque itération d'entraînement, le réseau traite d'abord les données d'entrée, les propageant à travers ses différentes couches pour produire une sortie. Cette sortie est ensuite comparée à la sortie cible, ou valeur attendue, permettant de calculer l'erreur du réseau. L'étape cruciale de la rétropropagation commence ici : l'erreur calculée est propagée en sens inverse à travers le réseau, de la sortie vers l'entrée. Tout au long de ce processus, les poids des connexions neuronales sont ajustés pour minimiser l'erreur. Cette mise à jour est réalisée en utilisant des techniques comme la méthode de l'erreur quadratique moyenne, qui mesurent la différence entre les sorties prédites du réseau et les sorties réelles. Ce cycle d'entraînement - propagation avant, calcul de l'erreur, et propagation arrière avec ajustement des poids - est répété sur de nombreuses itérations. Le nombre d'itérations nécessaire pour atteindre une convergence satisfaisante dépend de divers facteurs tels que la taille et la complexité du réseau, la nature du problème abordé, la méthode d'apprentissage adoptée, et la taille du jeu de données d'entraînement. À travers ces itérations, le réseau apprend progressivement à réduire l'écart entre ce qu'il prédit et ce qu'il est censé prédire, affinant ainsi sa capacité à effectuer la tâche pour laquelle il est entraîné.

3.8 Réseau de Neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) représentent une catégorie. Le premier CNN a été créé en 1989 par Yann LeCun. Il a été formé pour reconnaître des caractères manuscrits et des digits. Les CNNs ont été créés à partir d'un réseau de neurones formé de plusieurs couches. Chaque couche est formée de neurones qui sont connectés aux neurones de la couche suivante. Ils sont entraînés en fournissant des images et en demandant au réseau de les classer. Le réseau apprend les

caractéristiques des images au fur et à mesure qu'il les voit. Leur architecture unique est conçue pour automatiquement et efficacement reconnaître les motifs spatiaux tels que les bords et les textures dans les images, ce qui les rend idéaux pour des applications de vision par ordinateur comme la classification d'images, la détection d'objets, et bien plus. [4]

3.8.1 Architecture typique d'une CNN

Une CNN est composée de plusieurs types de couches :

Couches convolutives : Elles filtrent l'entrée pour créer des cartes de caractéristiques qui capturent des informations essentielles de l'image.

Couches de pooling (sous-échantillonnage) : Ces couches réduisent la dimensionnalité des cartes de caractéristiques pour diminuer le nombre de paramètres et le calcul, tout en conservant les caractéristiques importantes.

Couches entièrement connectées (fully connected) : À la fin d'une CNN, ces couches utilisent les caractéristiques extraites pour classer l'entrée dans différentes catégories selon l'apprentissage.




Figure 3.6
Architecture typique d'un CNN. [25]

Cette figure illustre l'architecture standard d'une CNN, montrant le flux de traitement d'une image depuis l'entrée jusqu'à la sortie. Le CNN est donc composé d'un enchaînement de ces trois types de couches qui permettent d'extraire automatiquement les caractéristiques discriminantes d'une image pour la tâche de classification.

Cette structure particulière, inspirée du cortex visuel biologique, confère à la CNN une grande puissance pour les tâches visuelles comme la reconnaissance d'objets, la détection de défauts, etc. [26]

3.8.2 Composants clés des CNNs

- **Couche de convolution :**

La couche de convolution est le pilier des CNNs, effectuant le traitement initial des images d'entrée. Les filtres, ou kernels, glissent sur l'image et effectuent une opération de convolution pour produire des cartes de caractéristiques (feature maps). Ces filtres sont entraînés pour détecter des éléments spécifiques tels que les bords, les angles ou d'autres motifs visuels. Le résultat est une collection de feature maps qui représente une version transformée et plus informative de l'image originale.

- **Couche de pooling (sous-échantillonnage) :**

Suit généralement une couche de convolution, la couche de pooling réduit les dimensions spatiales (largeur et hauteur) des feature maps entrantes. Le pooling le plus courant est le max pooling, qui divise la feature map en blocs et conserve le maximum de chaque bloc. Cette réduction dimensionnelle concentre l'information et confère au réseau une certaine invariance à la translation, tout en réduisant la complexité computationnelle pour les couches suivantes.

- **Couche entièrement connectée (Fully-Connected) :**

Après plusieurs itérations de convolution et de pooling, les features extraites sont aplanies en un vecteur unique et passées à travers une ou plusieurs couches entièrement connectées. Ces couches combinent les features de haut niveau extrait par les couches précédentes pour effectuer la classification. Chaque neurone dans une couche entièrement connectée à une connexion à toutes les activations de la couche précédente, ce qui permet au réseau d'apprendre des combinaisons complexes de features pour classer l'image d'entrée.

Dans un contexte de classification, la dernière couche entièrement connectée a souvent un nombre de neurones correspondant au nombre de classes cibles et utilise une fonction d'activation softmax pour convertir les activations en probabilités de classe. Ainsi, si nous classifions des images en tant que propre ou défectueux, le réseau produira un vecteur de probabilités indiquant la confiance du modèle quant à la catégorie à laquelle appartient chaque image. [26]

3.8.3 Exemples d'architectures de réseaux de neurones convolutifs (CNN)

Les CNN sont devenues l'épine dorsale de nombreuses applications de traitement d'images grâce à leur capacité à apprendre des caractéristiques visuelles à partir de données. Plusieurs architectures de CNN ont été développées, chacune avec ses spécificités et ses domaines d'application. Voici quelques exemples notables :

LeNet-5 : Pionnier des CNNs, utilisé pour la reconnaissance de caractères manuscrits et de chiffres. [27]

AlexNet : L'architecture qui a remporté le concours ImageNet en 2012, prouvant l'efficacité des CNNs dans les tâches de reconnaissance d'images à grande échelle. [28]

VGGNet : Se distinguent par sa profondeur et l'utilisation de petits filtres de convolution, offrant une meilleure performance dans la classification d'images. [29]

GoogleNet (Inception) : Introduit le concept de modules inception, permettant au réseau de choisir la meilleure taille de filtre de convolution à chaque couche. [30]

MobileNet : optimisé pour les appareils mobiles, il fournit des modèles efficaces en termes de calcul pour des applications embarquées. [31]

EfficientNet : Utilise une méthode d'échelle composée pour uniformiser le dimensionnement de la profondeur, de la largeur et de la résolution du réseau. [32]

Chacune de ces architectures a contribué à l'avancement de la reconnaissance et du traitement d'images, et a ses propres avantages et cas d'usage. Pour notre projet, nous avons opté pour l'architecture ResNet50 [33], connue pour son approche innovante de connexion résiduelle et sa capacité à former des réseaux très profonds sans perdre en performance. ResNet50 offre un équilibre entre profondeur, complexité et précision, ce qui le rend idéal pour notre application de détection des défauts sur les panneaux solaires. Cette architecture sera détaillée dans la section suivante.

3.9 L'architecture ResNet50

ResNet50 est une architecture de réseau de neurones convolutifs introduite par Kaiming He et ses collègues qui a révolutionné la perception de la profondeur des réseaux. Le "50" fait référence au nombre de couches de neurones, indiquant un modèle assez profond qui a été prouvé pour obtenir d'excellents résultats sur des jeux de données d'images très complexes comme ImageNet.

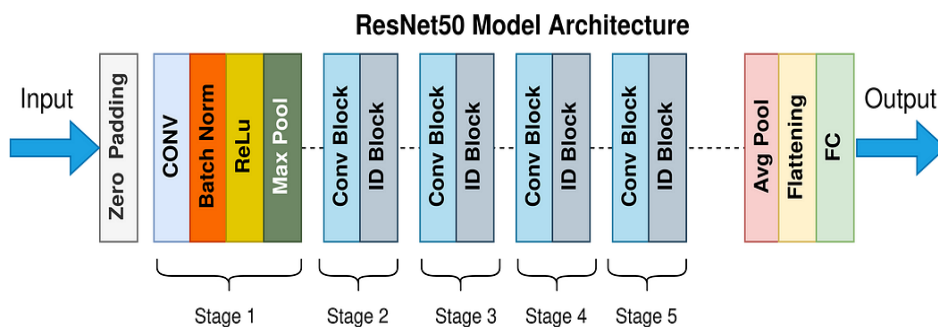


Figure 3.7
Architecture ResNet50. [33]

Cette figure illustre le flux de données à travers l'architecture ResNet50, en commençant par le prétraitement initial jusqu'à la classification finale :

(1) Zero Padding : prépare l'entrée pour la convolution en ajoutant des zéros autour des bords de l'image pour permettre l'application du filtre de convolution sans réduire la taille de l'image.

(2) CONV (Convolution) : Applique les filtres de convolution pour extraire les caractéristiques de bas niveau de l'image.

(3) Batch Norm (Batch Normalization) : normalise les activations des neurones pour accélérer l'apprentissage en réduisant le problème des changements de distribution interne (Internal Covariate Shift).

(4) ReLU (Rectified Linear Unit) : introduit de la non-linéarité dans le processus d'apprentissage, permettant au réseau de capturer des relations complexes.

(5) Max Pool : Réduit la dimensionnalité spatiale des caractéristiques tout en préservant les caractéristiques les plus importantes grâce à l'opération de pooling maximum.

(6) Conv Block / ID Block : les blocs de convolution résiduelle et les blocs d'identité forment le cœur de ResNet50. Les blocs de convolution contiennent des couches de convolution avec des connexions résiduelles, tandis que les blocs d'identité passent les activations directement au travers avec peu ou pas de changement.

(7) Avg Pool : Réduit davantage la dimensionnalité en effectuant un pooling moyen, qui sert de préparation à la classification.

(8) Flattening : transforme la matrice tridimensionnelle résultante du pooling moyen en un vecteur unidimensionnel pour faciliter la classification finale.

(9) FC (Fully Connected Layer) : Utilise les caractéristiques aplaties pour déterminer la classe de sortie avec une couche entièrement connectée qui utilise souvent la fonction d'activation softmax pour la classification multi-classe.

3.9.1 ResNet50 dans la détection des défauts des panneaux solaires :

Pour la détection des défauts des panneaux solaires, ResNet50 peut être entraîné pour reconnaître des modèles visuels indiquant différents types de défauts. Grâce à son apprentissage en profondeur, il peut différencier avec précision les anomalies des conditions normales, ce qui est essentiel pour le diagnostic et la maintenance préventive des installations photovoltaïques.

Les études montrent que ResNet50 atteint une précision de pointe sur des jeux de données benchmark, dépassant les architectures précédentes. Cette précision, associée à des techniques comme le transfer learning, où le modèle pré-entraîné sur ImageNet est ajusté pour des tâches spécifiques, permet de réaliser des systèmes de détection très efficaces avec relativement peu de données d'entraînement spécifiques au domaine. [34]

3.9.2 Avantages et inconvénients de l'architecture ResNet50

Dans cette section, nous évaluons l'architecture ResNet50 en détaillant ses points forts ainsi que ses limitations potentielles. Bien que ResNet50 ait été largement adopté pour sa capacité à atteindre une précision élevée dans des tâches complexes de vision par ordinateur, il est essentiel de reconnaître les défis associés à son utilisation. Le tableau suivant offre un aperçu comparatif des principaux avantages et inconvénients de cette architecture, fournissant ainsi un guide pour déterminer son applicabilité à divers scénarios de projet.

Table 3.2
Avantages et inconvénients de l'architecture ResNet50

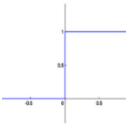
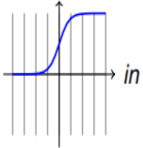

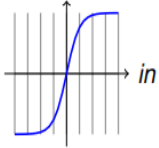
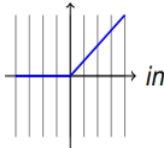
Avantages de ResNet50	Inconvénients de ResNet50
Apprentissage en profondeur efficace sans dégradation des performances.	Complexité computationnelle élevée.
Connexions résiduelles qui facilitent la propagation du gradient et optimisent l'entraînement.	Gestion de la mémoire importante due à la profondeur du réseau.
Excellente base pour le transfer learning, permettant des ajustements efficaces pour de nouvelles tâches.	Risque de surajustement, particulièrement sur des petites datasets.
Versatilité pour diverses tâches de vision par ordinateur, prouvée par de nombreux benchmarks.	Recherche d'hyperparamètres peut-être complexe et chronophage.
Performances de pointe sur des benchmarks tels qu'ImageNet.	Peut-être excessif pour des tâches plus simples où des modèles plus légers suffiraient.

En résumé, ResNet50 est un choix robuste pour les applications nécessitant une analyse d'image avancée. Sa conception lui permet de capturer la hiérarchie de caractéristiques nécessaires pour des tâches de classification d'image précises et complexes, ce qui en fait une pièce maîtresse pour la détection des défauts des panneaux solaires.

3.10 Fonction d'activation

Une fonction d'activation est une fonction mathématique (comme la fonction « cosinus » ou « racine carrée ») qui intervient dans tous les neurones d'un réseau de neurones (artificiels, convolutifs, récurrents, etc.).

Table.1.3
Quelques fonctions d'activation d'un réseau de neurones

Nom	Allure graphique	Équation
<p>Seuil : Le modèle le plus conforme à la réalité biologique</p> <p>Pas de problème d'apprentissage</p>		$g(x)=1 \text{ si } x \geq 0$ $\text{sinon } g(x)=0$
<p>Sigmoïde : adapté à la rétropropagation.</p> <p>Contrairement à la fonction linéaire, la sortie de la fonction d'activation va toujours être dans une plage de [0,1].</p>		$g(x) = \frac{1}{1+e^{-x}}$
<p>Linéaire : adapté aux modèles impliquant une rétropropagation due au différentiabilité de la fonction d'activation</p>		$g(x)=x$
<p>Tangente hyperbolique : La seconde fonction d'activation la plus utilisée :</p> <p>Elle permet de borner les valeurs</p> <p>Elle est « anti-symétrique »</p>		$g(x) = \tanh(x)$ $= \frac{e^x - e^{-x}}{e^x + e^{-x}}$
<p>ReLU (rectified linear unit) : $g(x) = \max(0, x)$</p> <p>Adapté à la rétropropagation.</p> <p>L'activation des neurones est éparse et efficace, ce qui réduit les couts de réalisation.</p>		$g(x)=x \text{ si } x > 0$ $\text{Sinon } g(x)=0$

Les fonctions d'activation effectuent des opérations mathématiques affines sur les signaux générés par les entrées. Cette combinaison affine est déterminée par le vecteur de poids associés à chaque neurone, dont les valeurs sont déterminées dans la phase d'apprentissage. Il existe plusieurs formes possibles de la Fonction d'activation. Les plus courantes sont présentées dans le (tableau 3.3).

3.11 Conclusion

En conclusion, ce chapitre a démontré que l'application des Réseaux de Neurones Artificiels offre des méthodes innovantes et efficaces pour améliorer les systèmes photovoltaïques. Les Perceptrons multicouches (PMC) pour l'optimisation de la commande MPPT et les Réseaux de Neurones Convolutifs (CNN), notamment ResNet50, pour la détection et la classification des défauts des panneaux solaires, illustrent la polyvalence de ces technologies. Ces approches ne se contentent pas d'optimiser la performance énergétique, mais contribuent également à une maintenance plus prédictive et efficace, renforçant la durabilité et la fiabilité des installations solaires.

Les PMC ont été essentiels pour affiner le contrôle du MPPT, ajustant les paramètres en temps réel en fonction des variations environnementales. D'autre part, ResNet50 a apporté une précision significative dans la reconnaissance des défauts grâce à sa capacité à analyser des images complexes, ce qui est crucial pour la maintenance proactive des panneaux. Ensemble, ces technologies marquent une avancée significative dans l'automatisation et l'efficacité des systèmes photovoltaïques, préparant le terrain pour des avancées futures dans le domaine des énergies renouvelables.

Cette base solide ouvre des perspectives prometteuses pour les chapitres suivants, où nous explorerons l'implémentation pratique et l'évaluation détaillée de ces modèles dans des applications spécifiques, démontrant ainsi leur impact potentiel sur l'efficacité et la gestion des ressources énergétiques.

CHAPITRE IV : OPTIMISATION DE LA COMMANDE MPPT PAR RNA

4.1 Introduction

Dans cette étude, nous nous concentrons sur la commande MPPT (Maximum Power Point Tracking) d'un panneau solaire Canadian Solar de 295W. L'objectif principal est d'optimiser le suivi du Point de Puissance maximale (MPP) pour améliorer l'efficacité énergétique du panneau, un enjeu crucial pour augmenter le rendement des installations solaires photovoltaïques face aux défis énergétiques actuels. Pour atteindre cet objectif, nous avons choisi d'implémenter et de comparer deux méthodes de commande distinctes : la méthode perturber et observer (PO), largement utilisée pour sa simplicité et son efficacité, et un réseau de neurones artificiels (RNA), représentant une approche plus moderne et potentiellement plus précise. Cette comparaison vise à évaluer la performance de chaque méthode dans des conditions réelles d'utilisation et à déterminer laquelle des deux offre la meilleure optimisation du MPP en termes de rapidité de réponse et de précision.

4.2 Modélisation du système photovoltaïque

4.2.1 Conception de la modélisation du système photovoltaïque

Nous avons initié notre étude en utilisant MATLAB Simulink pour modéliser le panneau solaire Canadian Solar 295W et un convertisseur boost. Le choix de MATLAB Simulink pour cette modélisation se justifie par sa robustesse et sa flexibilité dans la simulation de systèmes dynamiques et intégrés, permettant une représentation précise des interactions entre les différents composants du système. Cette modélisation nous permet de simuler le comportement du système dans différentes conditions d'irradiance et de température, en tenant compte des caractéristiques spécifiques du panneau solaire.

4.2.2 Caractéristique I-V et P-V pour le module Canadian Solar 295P

Ce modèle soit conçu pour étudier le comportement d'un système PV sous différentes conditions et pour optimiser sa production d'énergie grâce à l'algorithme MPPT.




Figure 4.1
Caractéristique I-V et P-V pour le module CS3K-295P

La (figure 4.1) illustre les courbes I-V (courant-tension) et P-V (puissance-tension) pour notre module solaire de type "Canadian Solar Inc. CS3K-295P", opérant à une température de cellule standard de 25 degrés Celsius. Ces courbes sont tracées sous différentes conditions d'irradiance, allant de 0,5 kW/m² à 1 kW/m², pour démontrer comment le module réagit à un spectre d'intensités lumineuses.

Courbe I-V : Elles indiquent la relation entre le courant généré par le module solaire et la tension aux bornes de celui-ci pour divers niveaux d'irradiance. Comme l'irradiance augmente, la courbe se déplace vers le haut, indiquant un courant plus élevé produit par le module. Ces courbes sont essentielles pour comprendre comment le module réagit aux variations de lumière et pour déterminer la capacité de production de courant dans diverses conditions environnementales.

Courbes P-V : Ces courbes illustrent la puissance électrique produite par rapport à la tension pour les mêmes intervalles d'irradiance. Le pic de chaque courbe correspond au point de puissance maximale (MPP), qui est crucial pour l'optimisation de la production d'énergie. Le MPP est marqué par les points rouges sur les courbes, démontrant le rendement optimal du module solaire en termes de conversion de l'énergie solaire en électricité à chaque niveau d'irradiance.

Les conditions environnementales telles que la température et l'angle d'incidence de la lumière peuvent également affecter les performances du module et donc modifier l'emplacement du MPP sur ces courbes. L'analyse de ces courbes permet de paramétrer de manière plus précise l'algorithme MPPT, garantissant ainsi que le système PV opère au plus près du MPP même lors des fluctuations des conditions d'ensoleillement ou de température.

4.3 Commande MPPT avec la méthode perturbée et observez (PO)

Au début de notre étude, nous avons implémenté la méthode Perturber et observé (PO) pour optimiser le suivi du Point de Puissance maximale (MPP) du panneau solaire. Cette technique consiste à appliquer des perturbations continues à la tension ou au courant du panneau, tout en observant les variations de la puissance produite. Les ajustements successifs des perturbations permettent au système de se rapprocher progressivement du MPP, visant ainsi à maximiser l'efficacité de la capture d'énergie solaire. La simulation du schéma général avec la méthode P&O s'illustre comme suit :

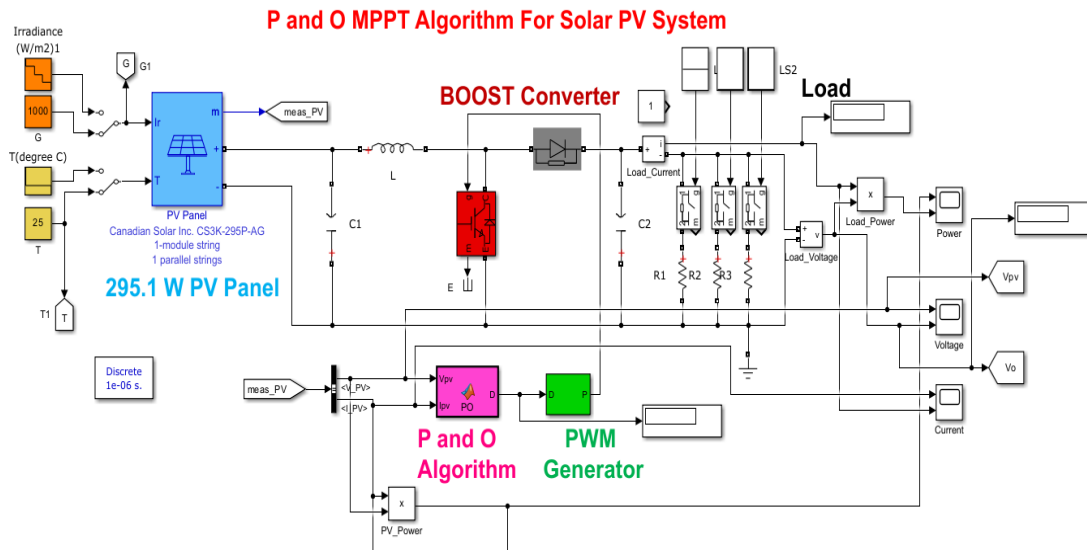


Figure 4.2
Modélisation de la commande MPPT avec la méthode (PO)

Dans la (figure 4.2), nous présentons les éléments essentiels de notre système photovoltaïque équipé de la commande MPPT via la méthode perturber et observer (PO). Les composants clés sont décrits comme suit :

Panneau PV : Le cœur de notre système est un panneau photovoltaïque de 295 watts fourni par Canadian Solar Inc. Ce modèle spécifique a été choisi pour sa représentativité dans les applications standards de l'industrie.

Entrées d'irradiance et de température : Ces entrées permettent la simulation du comportement du panneau PV face à des conditions climatiques variables, simulant ainsi de manière réaliste les défis environnementaux auxquels le système peut être confronté.

Convertisseur BOOST : Ce composant est crucial pour élever la tension générée par le panneau PV afin d'atteindre une utilisation optimale dans le système électrique global.

Algorithme P et O : L'algorithme de perturber et observer est au cœur de la régulation. Il ajuste dynamiquement la tension du panneau PV pour maintenir le fonctionnement du système au Point de Puissance maximale (MPP), indépendamment des fluctuations environnementales.

Générateur PWM : basé sur les sorties de l'algorithme P et O, ce générateur produit un signal de modulation de largeur d'impulsion qui commande le convertisseur BOOST pour une optimisation fine de la tension.

Charge : La charge connectée illustre la consommation électrique du système, pouvant représenter une variété de besoins énergétiques.

Les paramètres de la méthode PO ont été méticuleusement réglés pour maximiser la réactivité du système et assurer un suivi précis du MPP. Bien que cette méthode offre une adaptabilité dynamique aux changements de conditions environnementales, elle a certaines limites, notamment une sensibilité aux perturbations qui peuvent affecter la stabilité du suivi du MPP.

4.4 Commande MPPT avec un Réseau de Neurones Artificiels (RNA)

L'intégration des Réseaux de Neurones Artificiels (RNA) dans la commande MPPT ouvre la voie à une régulation plus adaptative et prédictive pour les systèmes photovoltaïques. S'appuyant sur les fondations établies dans les chapitres précédents, cette section se concentre sur l'implémentation et la validation d'un RNA pour le suivi précis du Point de Puissance maximale (MPP), même dans les conditions variables d'ensoleillement et de température typiques des environnements réels.

4.4.1 Acquisition et prétraitement des données

L'efficacité d'un Réseau de Neurones Artificiels (RNA) en tant que stratégie de commande MPPT dépend largement de la qualité des données d'entraînement utilisées. Pour cette raison, la phase d'acquisition est cruciale pour les données pertinentes. Nous avons sélectionné des données de température (T) et d'irradiance

(G) sur une période de six mois, obtenues grâce à la collaboration avec un site confidentiel de la NASA, avec un point de collecte situé à l'Université du Québec en Abitibi-Témiscamingue. Ces données couvrent un éventail de conditions environnementales, offrant ainsi un entraînement robuste pour le RNA face aux variations que pourrait rencontrer le panneau solaire Canadian Solar 295W.

Avant d'introduire ces données dans le processus d'apprentissage, une étape de prétraitement est essentielle. Elle implique la normalisation des valeurs de température et d'irradiance, qui permet d'uniformiser les échelles de mesure pour ces variables. Ce prétraitement est fondamental pour équilibrer l'influence des différents paramètres d'entrée et pour optimiser la convergence du processus d'apprentissage du RNA

4.4.2 Architecture et configuration du réseau de neurones

L'architecture d'un Réseau de Neurones Artificiels est un facteur déterminant dans sa capacité à modéliser des relations complexes et à faire des prédictions précises. Pour notre application de commande MPPT, nous avons conçu le RNA avec une architecture simple, mais efficace, décrite visuellement dans la Figure 4.3.




Figure 4.3
Schéma structural de réseau

Couche d'entrée : Le réseau commence par une couche d'entrée constituée de deux neurones, correspondant aux deux variables d'entrée cruciales : la température (T) et l'irradiance (G).

Couche cachée : La couche suivante est une couche cachée comprenant dix neurones. Cette couche est la clé de l'extraction de motifs et de la détection des nuances dans les données d'entraînement. Elle utilise des poids (W) et des biais (b) pour transformer les entrées de manière non linéaire.

Fonction d'activation : Les neurones de la couche cachée sont équipés d'une fonction d'activation sigmoïde, qui aide à introduire la non-linéarité dans le processus d'apprentissage et permet au RNA de capturer des relations complexes entre les données d'entrée et la sortie.

Couche de sortie : Enfin, une couche de sortie avec un seul neurone produit la valeur de sortie du réseau. Cette valeur représente la tension optimale au MPP que le système cherche à atteindre.

Cette structure a été choisie pour sa capacité à offrir une bonne généralisation tout en restant suffisamment agile pour être formée efficacement. Le choix du nombre de couches et de neurones a été guidé par des expérimentations préliminaires, qui ont montré que cette configuration offrait un bon compromis entre la complexité et la performance du modèle.

4.4.3 Entraînement et validation du RNA

Une fois l'architecture du RNA établie, le réseau doit être entraîné et validé afin de s'assurer qu'il prédit avec précision le Point de Puissance maximale (MPP) pour notre panneau solaire Canadian Solar 295W.

- **Division des données :**

Pour l'entraînement, la validation et les tests de notre RNA, nous avons réparti les données collectées en trois ensembles distincts : 70% pour l'entraînement, 15% pour la validation et 15% pour les tests. Cette répartition est conçue pour fournir un équilibre entre la quantité de données utilisées pour apprendre les modèles et la quantité réservée pour évaluer leur performance et leur capacité à généraliser. Un tel ratio est couramment utilisé dans les pratiques de machine learning pour maximiser l'efficacité de l'apprentissage tout en prévenant le surajustement.

- **Entraînement du RNA :**

L'entraînement est l'étape où le RNA apprend à partir des données fournies. Nous avons utilisé l'algorithme de rétropropagation d'erreur Levenberg-Marquardt pour son efficacité reconnue dans les réseaux de taille modeste. Voici les étapes de cet entraînement détaillé :

Propagation avant (Forward Propagation) : Les données d'entraînement normalisées sont introduites dans le réseau, et la sortie prédite est générée en appliquant les poids et biais actuels.

Calcul de la fonction de coût : Nous mesurons l'erreur en calculant la différence entre la sortie prédite et la valeur réelle de tension V_{mp} , en utilisant une fonction de coût adaptée.

Rétropropagation du gradient : L'erreur est propagée en arrière dans le réseau, et les gradients sont calculés pour chaque poids et biais selon la règle de la chaîne.

Mise à jour des paramètres : Les poids et biais sont ajustés en fonction des gradients obtenus, en suivant un taux d'apprentissage défini, pour minimiser progressivement la fonction de coût.

Répétition : Cette procédure est répétée pour de multiples cycles d'entraînement, chaque itération affinant les paramètres du modèle pour une meilleure prédiction de la tension V_{mp} .

Cette méthode systématique d'ajustement des poids et biais du réseau permet d'atteindre une performance optimale en termes de prédiction du MPP, même dans des conditions environnementales variables.

- **Validation du RNA :**

La phase de validation est cruciale pour vérifier la capacité du RNA à généraliser à des données non vues auparavant. Cela implique l'utilisation d'un ensemble de données distinct de l'ensemble d'entraînement.

Validation croisée : Nous appliquons la validation croisée pour évaluer la fiabilité des prédictions du RNA.

Optimisation des hyperparamètres : Sur la base des performances de validation, nous ajustons les hyperparamètres pour améliorer la généralisation du modèle.

Évaluation des performances : Le modèle est ensuite évalué sur l'ensemble de tests pour s'assurer qu'il prédit le MPP avec précision stable.

La validation permet d'ajuster finement le RNA pour qu'il ne se spécialise pas trop sur les données d'entraînement (un phénomène connu sous le nom de surajustement), mais qu'il conserve plutôt une bonne performance sur des données inédites, reflétant sa capacité à fonctionner dans des conditions réelles.

4.4.4 Modélisation et simulation dans MATLAB Simulink

Pour évaluer l'efficacité du Réseau de Neurones Artificiels (RNA) dans la commande MPPT, nous avons adapté notre modèle Simulink existant, initialement conçu pour la méthode PO. Ce modèle reproduit fidèlement l'ensemble du système PV, mais avec

une modification clé : l'algorithme perturbé et observé a été remplacé par notre modèle RNA.

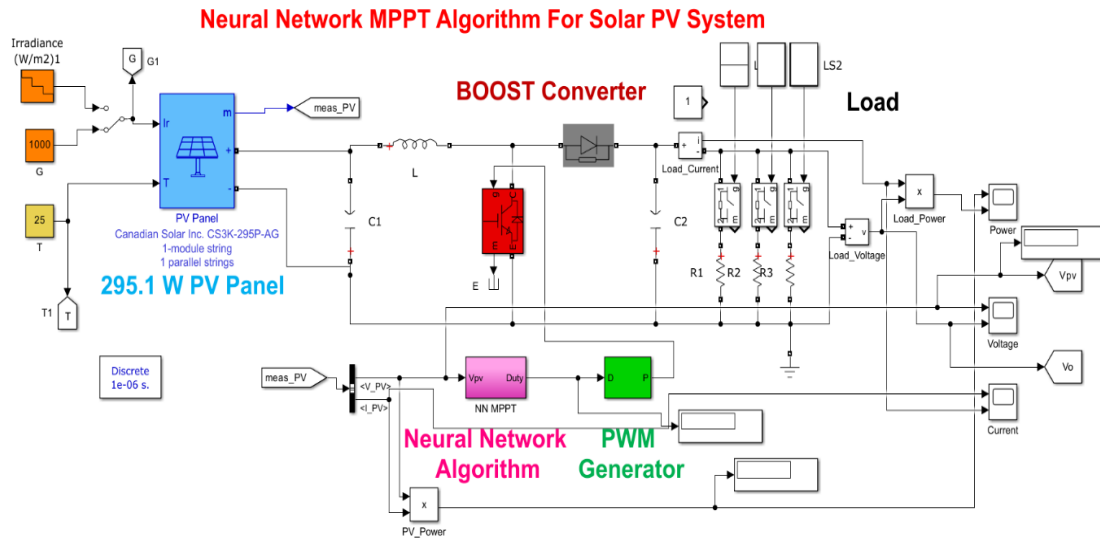


Figure 4.4
Modélisation de la commande MPPT avec la méthode (RNA)

Le nouveau modèle Simulink représenté par (la figure 4.4) intègre le RNA comme le composant principal de la commande MPPT. Tous les autres éléments, tels que le panneau PV, le convertisseur Boost et le générateur PWM, restent inchangés pour permettre une comparaison directe des performances entre les deux méthodes de MPPT.

- **Fonctionnement du modèle RNA :**

Le RNA est mis en œuvre en tant que fonction MATLAB au sein de Simulink, prenant en entrée les données de température et d'irradiance pour prédire le cycle optimal pour le convertisseur Boost. Cette intégration nous permet d'évaluer avec précision l'efficacité du RNA à suivre le MPP par rapport à la méthode PO classique.

- **Simulation et évaluation :**

Les simulations conduites sont identiques à celles utilisées pour la méthode PO, assurant ainsi une comparaison équitable. Nous mesurons l'efficacité du système en observant la tension de sortie et la puissance générée, en particulier sa capacité à s'ajuster aux fluctuations des conditions environnementales simulées.

- **Validation et optimisation :**

À travers une série de tests rigoureux, le RNA démontre sa capacité à optimiser la commande MPPT. Ces tests valident l'approche et identifient les paramètres optimaux pour le RNA, garantissant que la performance est au moins équivalente, sinon supérieure, à celle obtenue avec l'algorithme PO.

La mise en œuvre du RNA au sein du modèle Simulink représente une étape significative vers un système de commande MPPT plus intelligent et adaptable, capable de répondre dynamiquement aux conditions variables de fonctionnement des systèmes photovoltaïques.

4.4.4.1 Intégration du RNA dans le système de commande MPPT

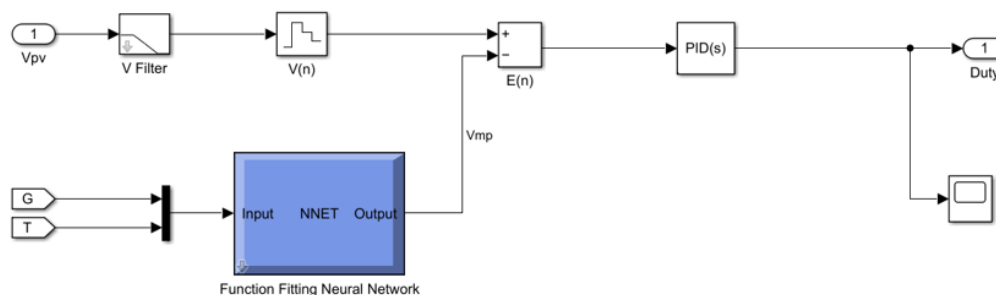


Figure 4.5
Schéma bloc de RNA

(La figure 4.5) présente le schéma bloc de notre modèle Simulink intégrant le RNA au sein du système de commande MPPT. Le RNA est utilisé ici pour estimer le voltage optimal du point de puissance maximale (V_{mp}) à partir des mesures

d'irradiance (G) et de température (T). Cette estimation est ensuite filtrée et comparée à la tension réelle du panneau PV (V_{pv}) pour calculer l'erreur ($E(n)$), qui est un signal d'entrée pour le contrôleur PID. Le contrôleur ajuste le devoir de cycle (Duty) du signal PWM, qui régule le convertisseur Boost et optimise ainsi la production d'énergie du panneau.




Figure 4.6
Schéma bloc de RNA de l'intérieur

La (figure 4.6) décompose l'architecture interne du RNA, illustrant les relations entre les couches de neurones. On peut y voir la couche d'entrée qui reçoit les signaux de processus, une couche cachée qui effectue les transformations non linéaires, et la couche de sortie qui produit le signal prédit (V_{mp}). Cette configuration illustre le flux des données à travers le réseau, depuis les entrées jusqu'à la sortie prédite.

Ces schémas sont cruciaux pour comprendre comment le RNA a été conçu pour s'adapter aux spécificités du système photovoltaïque. Ils offrent également un aperçu de la manière dont les signaux sont traités et utilisés pour influencer la performance du système en temps réel. L'intégration réussie du RNA dans le modèle Simulink démontre notre capacité à simuler des algorithmes de commande MPPT avancés, et à prévoir leur comportement avant l'implémentation pratique.

4.4.4.2 Configuration du contrôleur PID pour la commande MPPT

La précision de la commande MPPT dans notre système photovoltaïque est améliorée par l'implémentation d'un contrôleur PID, dont la configuration est cruciale pour répondre efficacement aux variations des conditions d'ensoleillement.

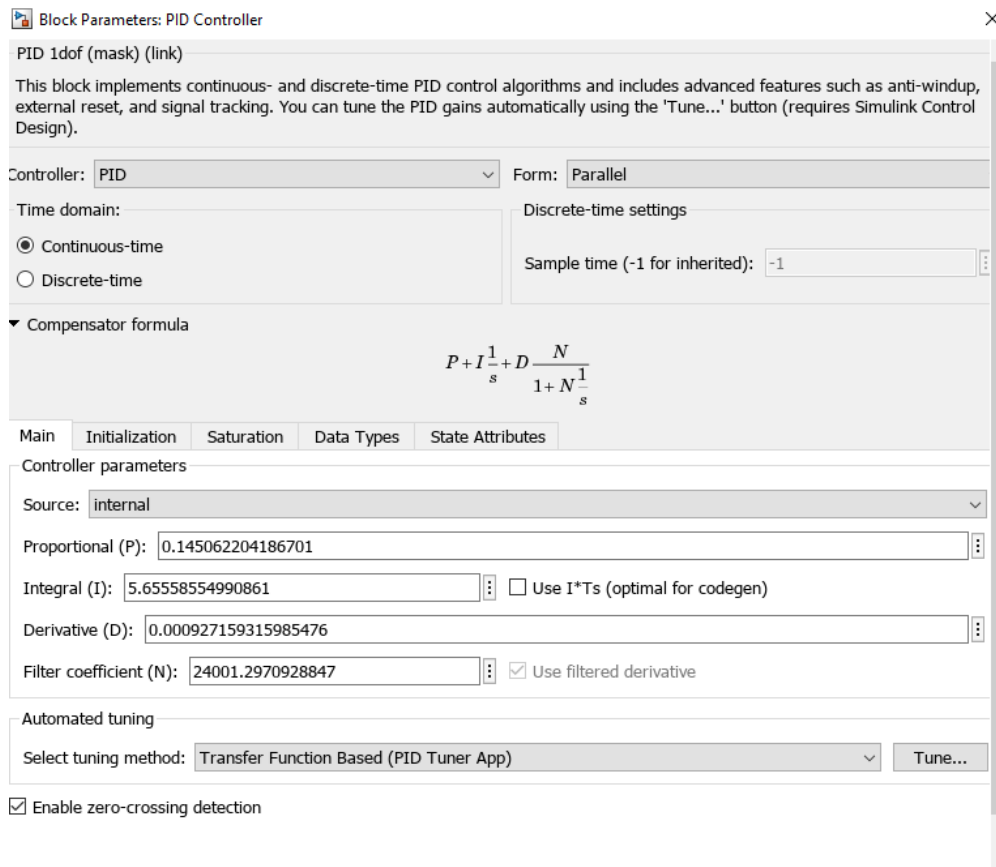


Figure 4.7
Configuration du contrôleur PID

La configuration du contrôleur PID, présentée dans la (Figure 4.7), a été minutieusement réglée pour offrir la meilleure réponse du système :

Mode temporel : Continu, adapté à la nature des signaux dans les applications photovoltaïques, où les changements environnementaux se produisent de manière fluide et continue.

Forme du contrôleur : Parallèle, ce qui permet un ajustement indépendant des actions proportionnelle, intégrale et dérivative, offrant ainsi une flexibilité essentielle pour la régulation du système PV.

Fonction de transfert du compensateur : La fonction de transfert représentée par l'équation (4.1), dotée d'un filtre sur le terme dérivatif, minimise les effets du bruit et des perturbations à haute fréquence, ce qui est primordial pour maintenir la stabilité du système.

$$P + I \frac{1}{S} + D \frac{N}{1 + N \frac{1}{S}} \quad (4.1)$$

Où :

P : Terme proportionnel.

I : Terme, intégral.

D : Terme dérivatif.

N : Coefficient du filtre.

S : Variable de Laplace dans le domaine de la fréquence.

Dotée d'un filtre sur le terme dérivatif, minimise les effets du bruit et des perturbations à haute fréquence, ce qui est primordial pour maintenir la stabilité du système.

Le (tableau 4.1) détaille les gains spécifiques pour chaque élément du PID, qui ont été obtenus après plusieurs cycles d'ajustements et d'optimisation. Cette fine calibration assure que le contrôleur PID réagit avec précision aux changements rapides inhérents aux systèmes photovoltaïques.

Table 4.1
Gains du contrôleur PID

Paramètres	Valeurs
Proportional (P)	0.145062204186701
Integral (I)	5.6558554990861
Derivative (D)	0.000927159315985476
Filter Coefficient (N)	24001.2970928847

L'inclusion de cette configuration PID est nécessaire non seulement pour la transparence et la reproductibilité de la recherche, mais également pour fournir une compréhension complète de l'efficacité du système de commande.

4.4.5 Évaluation des performances du modèle RNA

4.4.5.1 Régression du modèle RNA

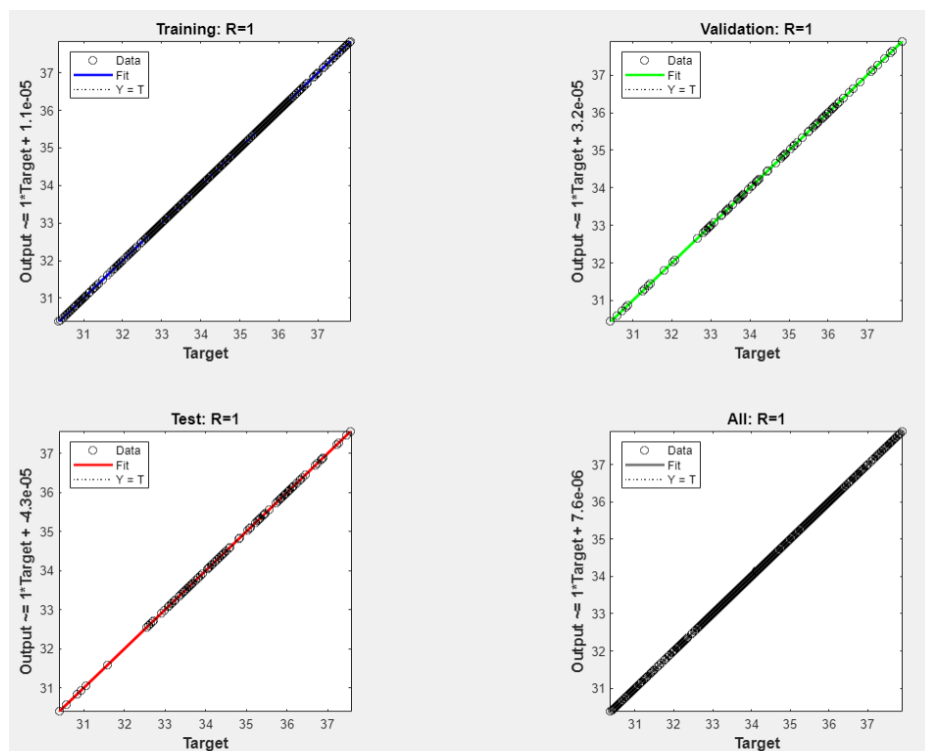


Figure 4.8
Performance du modèle RNA

La (figure 4.8) illustre les performances de notre modèle RNA à travers différents ensembles de données dans une vue composite. Chaque sous-graphique montre la corrélation entre les prédictions du modèle (Output) et les valeurs réelles (Target) pour les phases distinctes de l'entraînement, de la validation, et du test, ainsi que pour l'ensemble des données.

Entraînement (en haut à gauche) : Les points bleus représentent les prédictions lors de la phase d'entraînement, montrant une excellente corrélation comme le démontre la proximité avec la ligne noire idéale ($Y=T$).

Validation (en haut à droite) : Les points verts indiquent la performance sur l'ensemble de validation, avec un alignement étroit sur la ligne idéale, suggérant que le modèle généralise bien à de nouvelles données.

Test (en bas à gauche) : Les points rouges illustrent l'efficacité du modèle sur l'ensemble de tests, confirmant la capacité du modèle à maintenir la précision dans des conditions non vues précédemment.

Toutes les données (en bas à droite) : En combinant toutes les données, les points noirs donnent une vue d'ensemble de la cohérence du modèle sur l'intégralité des données. L'alignement global indique que le RNA offre une performance fiable et uniforme.

Ces graphiques mettent en évidence la capacité du modèle à prédire de manière précise le point de puissance maximale sur une gamme variée de conditions, ce qui est essentiel pour un contrôle efficace du système photovoltaïque en temps réel.

4.4.5.2 Évolution de l'Erreur Quadratique Moyenne (MSE) :




Figure 4.9
Courbes d'erreur d'apprentissage du RNA

La (figure 4.9) illustre l'évolution de l'erreur moyenne quadratique (MSE) au cours du processus d'entraînement du RNA sur 1000 époques. L'erreur décroît rapidement lors des premières époques, ce qui indique un apprentissage efficace. La courbe bleue représente l'ensemble d'entraînement, tandis que la courbe verte illustre la performance sur l'ensemble de validation, et la courbe rouge dénote l'ensemble de tests. L'intersection des courbes de validation et de test avec la ligne bleue d'entraînement vers la fin de l'entraînement suggère que le modèle est bien généralisé et ne présente pas de surajustement significatif.

La courbe de validation atteint son point le plus bas et sa meilleure performance à l'époque 1000, comme indiqué par le cercle vert. Cette performance de validation est

un indicateur essentiel de la qualité du modèle RNA, montrant qu'il a appris à bien généraliser à partir des données fournies sans mémoriser les exemples spécifiques.

La tendance de la courbe de validation et la convergence des trois courbes indiquent que le modèle a été suffisamment entraîné et qu'un nombre supplémentaire d'époques n'aurait probablement pas résulté en une amélioration significative. Cette courbe est un outil précieux pour déterminer le moment optimal pour arrêter l'entraînement, évitant ainsi à la fois le surajustement et le sous-ajustement.

4.4.5.3 Évaluation de la précision des prédictions du réseau de neurones

Nous avons réalisé une comparaison entre les valeurs réelles et les prédictions de la tension au point de puissance maximale (VMP) pour le système photovoltaïque afin d'évaluer l'efficacité de notre modèle de réseau de neurones artificiels (RNA). Comme la montre là (figure 4.10), deux ensembles de données sont représentés :




Figure 4.10
Comparaison des prédictions RNA et valeurs réelles de VMP

Les Valeurs réelles, marquées par des cercles rouges et une ligne continue rouge, représentent la tension réelle mesurée.

Les Prédictions, indiquées par des croix bleues et une ligne pointillée bleue, représentent la tension prédite par le modèle de réseau de neurones artificiels (RNA).

Les prédictions de notre modèle suivent étroitement les valeurs réelles sur un ensemble de tests de 1000 échantillons, ce qui démontre la capacité du RNA à modéliser avec précision la commande MPPT.




Figure 4.11
Corrélation entre les VMP prédites et les valeurs réelles

La (figure 4.11) montre un graphique de corrélation où chaque point représente une paire de valeurs réelles et prédites de VMP. Les points bleus sont les prédictions du réseau, et la ligne rouge pointillée représente la corrélation idéale. Si les points tombent exactement sur cette ligne, ce qui est le cas pour notre modèle (la ligne est idéale $y=x$), cela signifie que les prédictions sont parfaites. Une distribution dense des

points le long de cette ligne rouge pointillée indique une haute précision du RNA dans la prédiction de VMP.

4.5 Résultats des simulations du système photovoltaïque

Nous avons procédé à une suite de simulations pour évaluer les paramètres clés de notre système photovoltaïque. Chaque simulation a été réalisée à la fois avec la méthode perturber et observer (PO) et avec le Réseau de Neurones Artificiels (RNA). Les résultats clés sont présentés ci-dessous, en préparation pour une analyse comparative ultérieure.

4.5.1 Simulation avec la méthode perturbée et Observer (PO)

Les simulations suivantes ont été réalisées dans MATLAB Simulink pour évaluer la performance du système photovoltaïque utilisant la méthode Perturber et observer (PO) avec des conditions d'irradiation constantes de 1000 W/m^2 et une température ambiante de 25°C . Nous avons examiné le courant, la tension, la puissance et le duty cycle du système, les résultats étant représentés par des courbes bleues qui représentent le comportement du panneau solaire (PV) et des courbes rouges qui représentent la charge connectée au système.

- **Simulation de courant PO :**




Figure 4.12
Profil de courant PO

Ce graphique illustre le courant généré par le panneau solaire (courbe bleue) et le courant consommé par la charge (courbe rouge) sur une période donnée. La courbe PV illustre la génération de courant stable du panneau, tandis que la courbe de charge reflète la consommation constante de la charge, indiquant l'efficacité de la méthode PO dans le maintien de l'opération du système.

- **Simulation de tension PO :**




Figure 4.13
Profil de tension PO

La (figure 4.13) représente la tension du panneau solaire et la tension à la charge. Les résultats indiquent une tension bien régulée, cruciale pour la performance optimale des équipements connectés au système PV.

- **Simulation de puissance PO :**




Figure 4.14
Profil de puissance PO

Cette figure expose la puissance délivrée par le panneau PV et celle reçue par la charge. Une puissance stable est le résultat attendu compte tenu des conditions d'irradiation et de température constante.

- **Simulation de duty cycle PO :**




Figure 4.15
Profil de duty cycle PO

La (figure 4.15) montre le duty cycle du signal de commande envoyé au convertisseur pour ajuster la puissance fournie. La régularité du duty cycle illustre la précision de la commande PO à répondre aux besoins énergétiques de la charge.

Ces graphiques mettent en lumière la performance du système photovoltaïque sous commande PO dans des conditions optimales et stables, offrant une base de référence pour évaluer les capacités du système à suivre le MPP et à maximiser la production énergétique.

4.5.2 Simulation avec la méthode Réseau de Neurones Artificiels (RNA)

Dans un environnement identique à celui de la méthode PO simulé à une irradiance de 1000 W/m^2 et une température constante de 25°C , nous avons procédé à des simulations pour évaluer notre système photovoltaïque avec une commande MPPT basée sur le Réseau de Neurones entraînés. Voici les profils observés pour les principaux paramètres :

- **Simulation de Courant RNA :**




Figure 4.16
Profil de courant RNA

Cette figure montre les profils de courant pour le panneau solaire (courbe bleue) en parallèle avec le courant de la charge (courbe rouge). Les variations indiquent la capacité du RNA à s'ajuster rapidement aux conditions changeantes pour maximiser la production de courant.

- **Simulation de tension RNA :**




Figure 4.17

Profil de tension RNA

La (figure 4.17) affiche la tension aux bornes du panneau solaire (courbe bleue) comparées à celle de la charge (courbe rouge). Une tension stable est un bon indicateur de l'efficacité de la commande RNA à maintenir un fonctionnement optimal.

- **Simulation de puissance RNA :**




Figure 4.18
Profil puissance RNA

La (figure 4.18) représente la puissance produite par le panneau solaire (courbe bleue) et celle consommée par la charge (courbe rouge). La correspondance entre les deux indique une bonne concordance entre la production et la consommation énergétique.

- **Simulation de duty cycle RNA :**




Figure 4.19
Profil duty cycle RNA

La (figure 4.19) montre l'évolution du duty cycle délivré par la commande RNA. La réponse du duty cycle reflète l'efficacité et la précision de la commande RNA dans le suivi du MPP.

Ces résultats de simulation illustrent la réponse du système photovoltaïque sous le contrôle du RNA, offrant un aperçu de sa réactivité et de son efficacité dans des conditions idéales. Les profils stables et la réponse rapide aux variations suggèrent une performance supérieure de la commande RNA pour optimiser la sortie énergétique du panneau solaire.

4.5 Comparaison des performances des méthodes RNA et P&O

La comparaison des performances de la (MPPT) par les méthodes RNA et P&O est l'un des objectifs attendus dans ce projet en se concentrant sur la précision, la rapidité et la stabilité se ferait en analysant comment chaque méthode approche le Point de Puissance maximale théorique du système photovoltaïque sous des conditions de test variable.

4.5.1 Comparaison de la précision des méthodes RNA et P&O

Les (figure 4.20) illustre la performance des deux méthodes étudiées la méthode (PO) et la méthode (RNA) comparées aux valeurs théoriques de tension et de puissance au point de puissance maximale (VMP et PMP) en fonction de l'irradiance solaire (GG).




Figure 4.20
Comparaison des performances MPPT (méthodes RNA et PO)

Ces graphiques démontrent la précision supérieure des réseaux de neurones artificiels (RNA) pour la prédiction de la tension VMP et de la puissance PMP par rapport à la méthode traditionnelle Perturb and Observe (PO). En analysant la corrélation entre les valeurs prédites et les valeurs idéales à différents niveaux d'irradiance solaire, il est clair que le RNA présente une concordance plus étroite avec les valeurs théoriques, suggérant une meilleure performance de suivi du point de puissance maximale. Cette précision accrue du RNA est essentielle pour optimiser l'efficacité énergétique des systèmes PV, réduisant ainsi les pertes et augmentant le rendement

global de l'énergie produite. Ces résultats appuient notre choix d'utiliser un modèle RNA pour le suivi du point de puissance maximale par rapport aux méthodes conventionnelles comme la méthode P&O.

Pour valider notre choix d'utiliser la méthode RNA nous avons calculé deux métriques statistiques, l'Erreur Absolue Moyenne (MAE) et l'Erreur Quadratique Moyenne (RMSE), qui sont largement reconnues pour leur efficacité à mesurer la précision des prédictions des modèles.

MAE (Erreur Absolue Moyenne) : Le MAE mesure la différence moyenne entre les valeurs prédites et les valeurs réelles. Plus le MAE est faible, plus les prédictions du modèle sont précises. Cette métrique est particulièrement utile car elle donne une mesure directe de la performance du modèle en unités de la variable prédite.

RMSE (Erreur Quadratique Moyenne) : Le RMSE est une mesure de la dispersion des erreurs de prédiction. Il accorde une plus grande pondération aux erreurs plus importantes, ce qui en fait une métrique précieuse lorsqu'il est crucial d'éviter les grandes erreurs. Un RMSE faible indique que le modèle prédit avec précision, et ses erreurs sont minimales.

Table 4.2
Comparaison des erreurs de prédiction (méthodes RNA et PO)

Métrique/Méthode	RNA	PO
MAE	0.138	0.501
RMSE	0.15975	0.54879

Le tableau ci-dessus permet de comparer directement la performance des deux méthodes en termes de MAE et de RMSE. Elle montre clairement que la méthode RNA a des valeurs d'erreur plus faibles que la méthode P&O, ce qui suggère une meilleure précision de prédiction avec le modèle RNA.

4.5.2 Comparaison de la rapidité des méthodes RNA et P&O

Dans cette section on se concentre sur la comparaison de la rapidité avec laquelle chaque méthode réagit aux changements d'irradiance solaire, un facteur critique pour la performance globale en conditions variables. Les figures suivantes montrent la réactivité de puissance du système photovoltaïque à l'irradiance pour les deux méthodes.




Figure 4.21
L'effet de l'irradiance sur la puissance PV (méthode PO)




Figure 4.22
L'effet de l'irradiance sur la puissance PV (méthode RNA)

Notre analyse a été structurée comme suit :

Simulation des Conditions variables : Nous avons simulé le comportement du système photovoltaïque sous une série de changements d'irradiance solaire prédéfinis. (Voir les figures 4.21 et 4.22). Chaque simulation a permis de capturer la réponse dynamique de la puissance de sortie pour les méthodes RNA et P&O.

Mesure des Temps de Réponse : La rapidité a été évaluée en mesurant le temps nécessaire pour que la puissance de sortie s'ajuste à un nouveau niveau optimal après un changement d'irradiance. Ces mesures ont été prises directement à partir des données de simulation, en notant le temps écoulé entre l'application du changement d'irradiance et la stabilisation de la puissance de sortie à un nouveau point de puissance maximale.

Table 4.3 :
Comparaison de la rapidité des méthodes RNA et PO

Irradiance (G)	Temps de Réponse RNA (s)	Temps de Réponse P&O (s)
800 W/m ²	0,006	0,02
600 W/m ²	0,014	0,0197
400 W/m ²	0,014	0,0166
200 W/m ²	0,034	0,085

Les résultats de notre analyse ont révélé des différences significatives dans la rapidité de réponse entre les deux méthodes MPPT. (Voir le tableau 4.3)

Réseaux de Neurones Artificiels (RNA) : Cette méthode a démontré une capacité exceptionnelle à ajuster rapidement la puissance de sortie aux changements d'irradiance, reflétant une réactivité supérieure et une adaptation plus immédiate aux conditions environnementales fluctuantes.

Perturb and Observe (P&O) : bien que fiable, la méthode P&O a montré des temps de réponse globalement plus longs comparés à RNA, indiquant une adaptation plus lente aux variations d'irradiance solaire.

La comparaison des temps de réponse met en évidence l'avantage des réseaux de neurones artificiels en termes de rapidité d'adaptation aux changements d'irradiance, un atout considérable pour maximiser l'efficacité énergétique des systèmes photovoltaïques dans des environnements dynamiques. La méthode RNA offre une promesse significative pour améliorer la réactivité du MPPT, tandis que la méthode P&O, bien qu'un peu plus lente, reste une option fiable dans des contextes où la rapidité d'ajustement est moins critique.

4.5.3 Comparaison de la stabilité des méthodes RNA et P&O

Nous avons clôturé notre étude comparative par l'analyse de la stabilité des approches étudiée. Cette analyse visait à déterminer quelle méthode offre une réponse plus stable face aux variations d'irradiance solaire, définissant des niveaux de $G=200$, $G=400$ et $G=600$ avec une température constante de 25°C .

Notre démarche pour évaluer la stabilité a impliqué trois étapes clés :

Collecte des Données : Nous avons utilisé MATLAB Simulink pour simuler le comportement du système photovoltaïque sous différentes irradiances, enregistrant la puissance de sortie pour les méthodes RNA et P&O. Chaque simulation a été conçue pour refléter les changements d'irradiance, permettant au système de passer par une période d'adaptation.

Mesure de l'Amplitude et de la Durée des Oscillations : À partir des données simulées, nous avons mesuré l'amplitude des oscillations de puissance (en watts) et la durée de ces oscillations (en millisecondes) pour chaque méthode et chaque niveau d'irradiation. Ces mesures ont été effectuées en utilisant l'outil Data Cursor de Simulink, identifiant les photos et les creux significatifs des réponses de puissance après un changement d'irradiance.

Calcul de la Variance de la Puissance : Nous avons également calculé la variance des valeurs de puissance autour de leur moyenne pour chaque méthode et niveau d'irradiance présentée par (l'équation 4.2), fournissant une mesure quantitative de la dispersion de la puissance et, par extension, de la stabilité de la méthode.

$$\sigma^2_p = \frac{1}{n} \sum_{i=1}^n (P_i - P)^2 \quad (4.2)$$

Où :

n : le nombre total de valeurs de puissance mesurées.

P_i : la i -ème valeur de puissance.

P : la moyenne des valeurs de puissance.

Table 4.4
Comparaison de la stabilité des méthodes RNA et PO

Irradiance	Méthode MPPT	Amplitudes des oscillations (W)	Durée des Oscillations (ms)	Variance de la Puissance (W²)
G=600W/m ²	RNA	25,86	12,893	1988,889
G=400W/m ²	RNA	33,72	7,789	536,262
G=200W/m ²	RNA	17,08	32,476	61,779
G=600W/m ²	P&O	26,46	23,571	4269,43
G=400W/m ²	P&O	19,64	11,571	3086,04
G=200W/m ²	P&O	23,77	39,414	2970,90

Les résultats obtenus révèlent des différences notables entre les deux méthodes. Pour la méthode RNA, nous avons observé des amplitudes d'oscillation généralement plus faibles et des durées d'oscillation plus courtes à travers les différents niveaux d'irradiance, indiquant une tendance à une stabilisation plus rapide du système après des changements d'irradiance. En comparaison, la méthode P&O a montré des variances de puissance plus élevées, surtout à des irradiances supérieures, suggérant une plus grande dispersion dans la réponse de puissance et vraisemblablement une stabilité moindre.

4.6 Conclusion

En conclusion, ce chapitre a présenté une analyse comparative approfondie des performances de deux méthodes de commande MPPT : la méthode traditionnelle perturber et observer (P&O) et une approche innovante basée sur un Réseau de Neurones Artificiels (RNA). À travers l'évaluation des deux méthodes, nous avons

démontré la supériorité de la méthode RNA en termes de précision, rapidité, et stabilité dans la prédiction du MPP sous différentes conditions de test.

La consistance des performances du RNA à travers une variété de scénarios d'irradiance souligne son potentiel pour améliorer la production énergétique des systèmes photovoltaïques.

Le succès de la méthode RNA dans notre étude suggère des directions prometteuses pour les futurs travaux de recherche, notamment le développement de stratégies de commande intelligentes et adaptatives pour les systèmes photovoltaïques. L'intégration de telles approches pourrait significativement améliorer la fiabilité et l'efficacité des systèmes d'énergie renouvelable, en s'adaptant dynamiquement aux conditions environnementales changeantes.

En définitive, l'adoption de techniques avancées de commande MPPT telles que le RNA pourrait transformer le paysage des technologies photovoltaïques, en rendant l'exploitation de l'énergie solaire plus efficace et plus rentable, contribuant ainsi à une transition énergétique plus durable.

CHAPITRE V : DÉTECTION DES DÉFAUTS SUR LES PPV AVEC CNN

5.1 Introduction

La performance optimale des installations photovoltaïques est essentielle pour maximiser le rendement énergétique des panneaux solaires. Cependant, divers facteurs tels que l'accumulation de neige, la présence de défauts physiques ou électriques, et même la propreté des surfaces, peuvent affecter considérablement l'efficacité des panneaux. Face à ces enjeux, l'adoption de techniques avancées de détection et de classification des défauts devient cruciale. Ce chapitre se consacre à l'étude de l'application des Réseaux de Neurones à Convolution (CNN) pour la reconnaissance et la classification automatique des différentes conditions de surface des panneaux solaires. En exploitant la puissance de l'apprentissage profond, nous visons à démontrer comment les CNN peuvent être utilisées efficacement pour améliorer les procédures de maintenance et optimiser la performance des installations solaires.

5.2 Objectifs de la détection de défauts

La performance des panneaux solaires est fortement influencée par leur état de surface. L'accumulation de saletés ou l'apparition de défauts peut entraîner une baisse notable de l'efficacité énergétique. Dans ce contexte, ce chapitre vise à développer une méthode fiable basée sur les réseaux de neurones à convolution (CNN) pour identifier et classier automatiquement les états des panneaux solaires en quatre catégories : propres, couverts de neige, avec défaut électrique, ou avec défaut physique. L'objectif est de tirer profit de la capacité des CNN à extraire des caractéristiques pertinentes à partir des images pour une détection précise et efficiente des anomalies, optimisant ainsi la maintenance et la performance des installations photovoltaïques.

5.3 Facteurs impactant la performance des panneaux solaires

La performance optimale des panneaux solaires est cruciale pour maximiser la production d'électricité. Plusieurs facteurs environnementaux et techniques peuvent influencer cette performance, parmi lesquels :

Variations de l'Ensoleillement : La capacité des panneaux solaires à générer de l'électricité repose sur leur exposition à la lumière solaire. Des conditions telles que le ciel couvert, la saison hivernale, ou encore la pollution de l'air peuvent réduire significativement l'intensité solaire reçue, entraînant une baisse de la production énergétique.

Effet de la Température : Bien que contre-intuitifs, les panneaux solaires fonctionnent moins efficacement sous des températures élevées. La chaleur excessive provoque une augmentation de l'activité électronique au sein des cellules, diminuant ainsi l'efficacité de conversion de l'énergie solaire en électricité.

Ces deux facteurs, abordés en détail dans le chapitre 4, illustrent l'importance d'une gestion et d'une maintenance efficaces des systèmes photovoltaïques. La diminution de l'ensoleillement et les hausses de température ne sont pas seulement des défis météorologiques ; elles soulignent également la nécessité d'adopter des technologies avancées, comme les méthodes d'optimisation de la commande MPPT assistées par réseaux de neurones, pour améliorer la résilience et l'efficacité des installations solaires face à ces variations.

Outre ces éléments, d'autres facteurs peuvent également jouer un rôle dans la réduction de l'efficacité des panneaux, incluant l'accumulation de saletés et débris, la dégradation naturelle des matériaux, et les problèmes techniques tels que les défaillances de l'onduleur. Ces aspects renforcent l'importance d'une surveillance continue et d'interventions de maintenance préventive pour préserver la performance des panneaux solaires sur le long terme.

5.4 Impact des contaminants et dommages sur les performances des PPV

La performance des panneaux solaires peut être affectée négativement par divers facteurs environnementaux et incidents physiques, tels que :

Accumulation de saleté et débris : Les dépôts de poussière, feuilles, et autres débris sur la surface des panneaux solaires bloquent la pénétration de la lumière solaire, réduisant ainsi leur efficacité énergétique. Un entretien régulier est crucial pour éliminer ces obstacles et maintenir la production électrique à son niveau optimal.

Couverture de neige : Bien que la neige puisse naturellement fondre et s'écouler des panneaux, une accumulation excessive nécessite souvent une intervention manuelle pour rétablir l'exposition solaire complète des panneaux.

Dommages mécaniques : Les conditions météorologiques extrêmes, telles que la grêle ou les vents forts, peuvent causer des dommages physiques aux panneaux, compromettant leur intégrité structurelle et fonctionnelle.

Dommages électriques : Les événements comme les surtensions dues à la foudre peuvent endommager les composants électriques des panneaux solaires, nécessitant des réparations ou des remplacements pour éviter une baisse de la production d'énergie.

Ces facteurs soulignent l'importance d'une surveillance et la maintenance proactives des installations solaires pour garantir leur longévité et leur rendement énergétique. Les dommages et contaminations non seulement réduisent l'efficacité des panneaux solaires, mais peuvent aussi entraîner des coûts de réparation élevés et des pertes de production d'énergie à long terme.

5.5 Intégration des CNN dans la maintenance préventive

L'utilisation des réseaux de neurones à convolution (CNN) pour la détection et la classification précises des défauts représente une approche novatrice en matière de maintenance préventive. Par l'analyse d'images, les CNN permettent d'identifier

rapidement les anomalies sur les panneaux, facilitant une intervention ciblée et efficace.

Exemple : Une CNN détectant une accumulation excessive de neige sur un panneau peut déclencher une alerte de maintenance, permettant un nettoyage immédiat et évitant une réduction prolongée de la production d'énergie. Cette approche minimise les interruptions et maximise la performance des installations solaires.

Cette méthodologie met en lumière l'importance d'adopter des technologies avancées pour une gestion optimisée des systèmes photovoltaïques, assurant ainsi leur durabilité et leur rendement optimal.

5.6 Méthodologie de détection des défauts

5.6.1 Choix des données

Les données pour cette partie du projet ont été soigneusement sélectionnées à partir de Kaggle, une plateforme réputée pour ses riches ressources en ensembles de données pour la science des données. L'ensemble spécifique choisi comprend des images JPG de panneaux solaires réparties en quatre catégories significatives pour l'étude : propre (193 images), couvert de neige (123 images), défaut électrique (122 images), et défaut physique (90 images), pour un total de 528 images. Cette sélection vise à couvrir un large éventail de conditions communes affectant la performance des panneaux solaires.



Figure 5.1
Échantillon des conditions des panneaux solaires

Cette figure illustre un échantillon des différentes catégories de conditions de surface des panneaux solaires utilisées pour l'entraînement du modèle. Chaque image est un exemple typique des catégories 'propre', 'couvert de neige', 'défaut électrique' et 'défaut physique', fournissant ainsi un aperçu visuel des défis que le modèle doit relever pour une classification précise et efficace.

5.6.2 Préparation des données

Avant l'entraînement, une série de procédures de prétraitement a été appliquée aux images pour les adapter aux exigences du modèle ResNet50. Cela comprenait le redimensionnement de toutes les images à 224x224 pixels, conformément à l'entrée standard de ResNet50. De plus, une augmentation des données a été réalisée pour enrichir notre ensemble d'entraînement par des techniques telles que la rotation, le zoom, et le retournement horizontal, ainsi que des ajustements de la luminosité. Cette étape est cruciale pour développer un modèle robuste capable de généraliser à partir de l'ensemble d'entraînement et performant bien sur de nouvelles données inédites.

5.6.3 Environnement de développement et ressources matérielles

L'ensemble des travaux présentés dans ce chapitre a été exécuté sur une station de travail haute performance, essentielle pour gérer les calculs intensifs nécessaires aux réseaux de neurones à convolution. Le matériel utilisé est constitué d'un ordinateur équipé d'un processeur 12e génération Intel® Core™ i7-12700 avec une fréquence de base de 2.10 GHz et une carte graphique NVIDIA GeForce GTX 1070, appuyée par une mémoire vive conséquente de 32,0 Go. Le système d'exploitation Windows 10 entreprise, en architecture 64 bits, a offert une plateforme stable et fiable pour le développement et l'entraînement des modèles d'apprentissage profond.

Cet équipement a non seulement permis l'exécution efficace de l'entraînement des modèles CNN, mais a également garanti une vitesse de traitement adéquate pour les opérations d'augmentation de données et d'évaluation des performances. La disponibilité de cette station de travail sophistiquée a été déterminante pour atteindre les résultats énoncés précédemment et a assuré la conduite des expérimentations dans des conditions optimales.

5.6.4 Sélection de l'architecture du réseau ResNet50

Après avoir abordé le choix et la préparation des données, cette section se concentre sur le choix de l'architecture du réseau neuronal utilisé pour la détection des défauts des panneaux solaires. ResNet50, une architecture profonde de réseau de neurones à convolution (CNN), a été sélectionnée pour ses performances exceptionnelles dans des tâches de classification d'images complexes.

ResNet50 est particulièrement reconnu pour sa capacité à apprendre efficacement sur de très profondes architectures sans souffrir de la disparition ou de l'explosion du gradient, grâce à l'introduction de connexions résiduelles. Ces connexions permettent au signal de contourner certaines couches, facilitant ainsi l'apprentissage en profondeur et améliorant la précision de la classification.

L'utilisation de ResNet50 pour ce projet est motivée par plusieurs facteurs :

Sa prédominance dans les compétitions de vision par ordinateur, attestant de sa robustesse et de son efficacité.

Sa capacité à traiter efficacement les images de différentes catégories de défauts sur les panneaux solaires, tirant parti de sa profondeur pour extraire des caractéristiques discriminantes complexes.

La disponibilité d'un modèle pré-entraîné, permettant d'utiliser le transfert d'apprentissage pour accélérer le processus d'entraînement et améliorer la précision sur notre ensemble de données spécifique.

L'architecture ResNet50 est une conception révolutionnaire qui a marqué un tournant dans le domaine de la vision par ordinateur grâce à sa capacité à apprendre efficacement de profonds réseaux neuronaux. La (figure 5.2) ci-dessus montre un extrait de l'architecture, commençant par la couche d'entrée d'image et suivie par une succession de couches convolutives, de normalisation par lots, de couches d'activation ReLU, et de pooling.

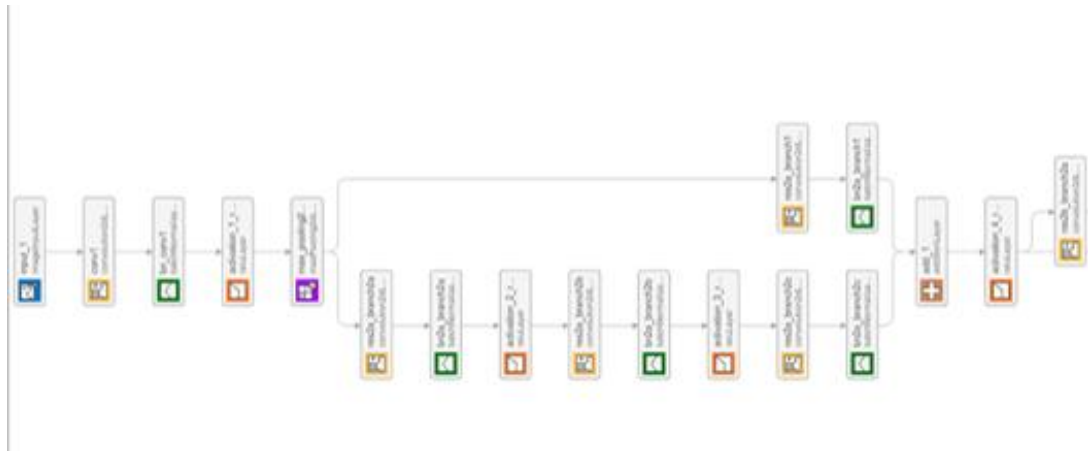


Figure 5.2
Extrait de l'architecture ResNet50

Les blocs résiduels, qui sont le cœur de ResNet50, permettent au signal d'être transmis à travers des couches supplémentaires sans perte d'informations grâce aux connexions de saut ("skip connections"). Ces connexions sont cruciales car elles permettent d'éviter le problème de la disparition ou de l'explosion du gradient qui est commun dans les réseaux très profonds. Dans notre implémentation, ces blocs résiduels sont adaptés pour traiter les nuances subtiles et les caractéristiques discriminantes des images de panneaux solaires, assurant une classification précise entre les états propre, couvert de neige, défaut électrique et défaut physique.

5.7 Entraînement et validation du modèle

5.7.1 Adaptation de l'architecture ResNet-50

Pour la détection des défauts sur les panneaux solaires, le choix d'un modèle performant et précis est primordial. ResNet-50, reconnu pour son architecture de réseau résiduel profond, sert de fondation à notre solution. Cependant, pour l'adapter à notre cas d'utilisation spécifique, plusieurs modifications ont été apportées :

- Chargement du Modèle Pré-entraîné :

Le modèle ResNet-50, préalablement entraîné sur un vaste ensemble de données d'images (ImageNet), a été chargé comme point de départ. Cela nous permet de tirer parti du transfert d'apprentissage, où les connaissances acquises sur un problème peuvent être transférées pour résoudre un problème similaire.

- Personnalisation des Couches :

La couche de classification originale de ResNet-50, conçue pour 1000 classes, a été remplacée par une nouvelle couche entièrement connectée (`new_fc`) adaptée à nos quatre catégories de défauts.

La dernière couche de classification (`new_classoutput`) a également été modifiée pour fournir les prédictions de classe spécifiques à notre projet.

- Ajustement des Paramètres :

Des taux d'apprentissage spécifiques pour la nouvelle couche entièrement connectée ont été définis (`WeightLearnRateFactor` et `BiasLearnRateFactor`), augmentant la vitesse à laquelle le modèle apprend les caractéristiques de nos données d'entraînement.

- Finalisation de l'Architecture :

Ces modifications ont abouti à un graphe de couches personnalisé (`lgraph`), qui a été utilisé pour configurer notre modèle final avant l'entraînement.

Cette adaptation ciblée nous permet d'exploiter la puissance du réseau ResNet-50 tout en le rendant applicable à la classification de défauts spécifiques aux panneaux solaires.

5.7.2 Définition des paramètres d'entraînement

Une fois l'architecture de ResNet-50 adaptée à notre contexte, la définition précise des paramètres d'entraînement est cruciale pour assurer un apprentissage efficace et

une convergence adéquate. Voici les paramètres clés que nous avons définis pour notre processus d'entraînement :

- MiniBatchSize :

Le MiniBatchSize a été fixé à 16, un équilibre entre la capacité de calcul et l'efficacité de l'entraînement, permettant une mise à jour des poids fréquente tout en conservant suffisamment d'exemples pour une généralisation adéquate.

- MaxEpochs :

Un nombre total de 60 époques (MaxEpochs) a été sélectionné pour permettre au modèle de parcourir à plusieurs reprises l'ensemble de données d'entraînement, favorisant ainsi l'apprentissage des caractéristiques discriminantes des défauts.

- InitialLearnRate :

Le taux d'apprentissage initial a été réglé à 0.0001. Ce paramètre est essentiel car il influence la magnitude des ajustements effectués sur les poids du réseau à chaque itération. Un taux trop élevé pourrait empêcher la convergence, tandis qu'un taux trop bas pourrait ralentir l'entraînement.

- LearnRateSchedule :

Nous avons opté pour une planification piecewise du taux d'apprentissage, avec des chutes (LearnRateDropFactor de 0.1) tous les 20 époques (LearnRateDropPeriod). Cette stratégie permet d'ajuster le taux d'apprentissage en fonction de l'évolution de l'entraînement, réduisant le taux à mesure que le modèle se rapproche de la convergence.

- Regularization and Momentum :

La régularisation L2 (L2Regularization) a été fixée à $1e-4$ pour aider à prévenir le surajustement, et le Momentum a été réglé à 0.9 pour accélérer les mises à jour dans la bonne direction.

- ValidationData et ValidationFrequency :

L'utilisation d'un ensemble de validation (augimdsVal) et la fréquence de validation (ValidationFrequency de 10) nous permettent de surveiller la performance du modèle sur des données non vues pendant l'entraînement et d'effectuer des ajustements si nécessaire.

- Verbose et Plots :

La sortie détaillée (Verbose) et les graphiques de progression de l'entraînement (Plots) fournissent un retour visuel en temps réel de la performance et de l'évolution de l'apprentissage, aidant à diagnostiquer les problèmes potentiels rapidement.

Ces paramètres ont été choisis après plusieurs itérations d'essais et erreurs, en veillant à l'équilibre entre un entraînement rapide et la prévention du surajustement. L'ajustement fin de ces paramètres est un processus itératif qui dépend fortement de la nature des données et des objectifs de performance spécifiques au projet.

5.7.3 Visualisation des résultats d'entraînement

L'efficacité de l'apprentissage et l'évolution du modèle au fil des itérations peuvent être visualisées à l'aide d'une courbe de progression d'entraînement. Ci-dessous, la (figure 5.3) montre à la fois la précision et la perte pour les ensembles d'entraînement et de validation sur un nombre spécifié d'itérations.




Figure 5.3
Courbes de l'entraînement du réseau ResNet-50

La courbe bleue représente la précision d'entraînement, qui montre comment le modèle apprend à classer avec succès les différentes conditions des panneaux solaires à partir des images de l'ensemble d'entraînement. La courbe rouge montre la perte d'entraînement, qui diminue de façon stable, indiquant que le modèle devient de plus en plus performant à chaque itération. La ligne noire représente la précision de validation, qui s'élève à 96,15%, révélant l'aptitude du modèle à généraliser ce qu'il a appris à de nouvelles données. En bas, nous observons également la perte de validation, tracée en noire, qui est essentielle pour comprendre comment le modèle évalue sa performance sur l'ensemble de validation à chaque étape de l'entraînement. Cette perte de validation est un bon indicateur de l'overfitting ou du underfitting et doit idéalement présenter une tendance à la baisse similaire à celle de la perte d'entraînement.

5.8 Analyse des résultats d'entraînement et de validation




Figure 5.4
Courbe de précision d'entraînement et de validation

Cette figure illustre la courbe de précision d'entraînement (courbe rouge) et la courbe de précision de validation (courbe bleue) au fil des époques. On observe une augmentation constante de la précision d'entraînement, indiquant une bonne adaptation du modèle aux données.




Figure 5.5
Courbe de perte d'entraînement et de validation

(La figure 5.5) montre la courbe de perte pour l'entraînement (courbe rouge) et pour la validation (courbe bleue) montre une diminution continue, ce qui indique que le modèle affine sa capacité de prédiction et réduit l'erreur de classification. La convergence des deux courbes suggère que le modèle ne surapprend pas et qu'il est bien régularisé.

5.9 Présentation des résultats de test

5.9.1 Résultats quantitatifs de la classification

Après avoir mis en place et entraîné notre modèle de classification utilisant l'architecture ResNet-50, il est essentiel d'évaluer de manière quantitative sa performance. Cette évaluation nous permet de mesurer l'exactitude des prédictions du modèle pour chacune des catégories de panneaux solaires que nous avons identifiées.

À cet effet, nous avons utilisé des métriques de classification comme montre (la figure 5.6) pour offrir une perspective complète de la capacité du modèle à différencier entre les panneaux propres, couverts de neige, présentant un défaut électrique ou un défaut physique.

```

Training finished: Max epochs completed.
Précision globale du test: 93.51%

```

Class	Precision	Recall	F1Score
{'Couvert de neige' }	1	0.88889	0.94118
{'Défaut physique' }	0.92308	0.92308	0.92308
{'Défaut électrique'}	1	0.88235	0.9375
{'propre' }	0.87879	1	0.93548

```

Macro Average Precision: 95.05%
Macro Average Recall: 92.36%
Macro Average F1 Score: 93.43%
Weighted Average Precision: 94.14%
Weighted Average Recall: 93.51%
Weighted Average F1 Score: 93.52%
Micro Average Precision: 93.51%
Micro Average Recall: 93.51%
Micro Average F1 Score: 93.51%

```

Figure 5.6
Performances de classification sur l'ensemble de tests

L'évaluation des performances sur l'ensemble de tests a produit des résultats significatifs, avec une précision globale du test de 93.51%. Cette métrique démontre l'efficacité du modèle à classer correctement les différentes conditions des panneaux solaires en situation de test.

- **Analyse des performances de classification standard**

Le tableau suivant résume les résultats obtenus à travers différentes métriques :

Table 5.1
Métriques de performance par classe

Classe	Précision (%)	Rappel (%)	Score F1 (%)
Couvert de neige	1	0.8889	0.94118
Défaut physique	0.92308	0.92308	0.92308
Défaut électrique	1	0.88235	0.9375
Propre	0.87879	1	0.93548

La Précision : C'est la proportion des identifications positives qui étaient effectivement correctes. Elle est définie par la formule suivante :

$$\text{Précision} = \frac{TP}{TP+FP} \quad (5.1)$$

Où :

TP = le nombre de vrais positifs.

FP = le nombre de faux positifs.

La précision répond à la question : "Parmi toutes les instances classées comme positives, combien l'étaient réellement ?"

Le Rappel : Également connu sous le nom de sensibilité ou de taux de vrais positifs, c'est la proportion des vrais positifs par rapport au nombre total de cas qui sont réellement positifs. Il est calculé par :

$$\text{Rappel} = \frac{TP}{TP+FN} \quad (5.2)$$

Où :

FN = le nombre de faux négatifs.

Le rappel répond à la question : "Parmi toutes les instances qui sont réellement positives, combien ont été identifiées correctement par le modèle ?"

Le Score F1 : C'est la moyenne harmonique de la précision et du rappel. Il prend en compte à la fois les faux positifs et les faux négatifs. Le score F1 est calculé par :

$$\text{F1 Score} = 2 \frac{\text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}} \quad (5.3)$$

Il est particulièrement utile lorsque les classes sont déséquilibrées. Le score F1 peut être interprété comme une mesure de l'exactitude du test, où une valeur de 1 représente une précision et un rappel parfaits, et une valeur de 0 indique que le test a échoué.

(Le tableau 5.1) présente la précision, le rappel et le score F1 pour chaque catégorie de défaut analysée. Ces métriques fournissent un aperçu détaillé de la performance du modèle, avec une précision élevée indiquant un faible taux de faux positifs et un rappel élevé signalant une capture réussie des cas positifs réels. Le score F1, étant une moyenne harmonique de la précision et du rappel, donne une mesure globale de la rigueur et de la robustesse de la classification.

- **Statistiques Micro et Macro**

Table 5.2
Stats Micro et Macro

Métrique	Valeur (%)
Précision moyenne macro	95.05
Rappel moyen macro	92.36
Score F1 moyenne macro	93.43
Précision moyenne pondérée	94.14
Rappel moyen pondéré	93.51
Score F1 moyen pondéré	93.52
Précision moyenne micro	93.51
Rappel moyen micro	93.51
Score F1 moyenne micro	93.51

Macro Average : la macro-moyenne calcule la moyenne arithmétique des métriques pour chaque classe indépendamment, puis prend la moyenne de ces valeurs. Cela ne prend pas en compte l'imbalance entre les classes, où :

$$\text{Macro precision} = \frac{1}{N} \sum \text{précision de chaque classe} \quad (5.4)$$

$$\text{Macro recall} = \frac{1}{N} \sum \text{rappel de chaque classe} \quad (5.5)$$

$$\text{Macro F1 score} = \frac{1}{N} \sum \text{F1 de chaque classe} \quad (5.6)$$

Où N est le nombre de classes.

Moyenne pondérée : La moyenne pondérée tient compte de l'imbalance entre les classes en pondérant les métriques de chaque classe par le nombre d'observations dans cette classe, où :

$$\text{Weighted precision} = \sum (\text{Proportion de chaque classe} \times \text{Précision de cette classe}) \quad (5.7)$$

$$\text{Weighted recall} = \sum (\text{Proportion de chaque classe} \times \text{Rappel de cette classe}) \quad (5.8)$$

$$\text{Weighted F1 score} = \sum (\text{Proportion de chaque classe} \times \text{F1 de cette classe}) \quad (5.9)$$

La "proportion de chaque classe" est calculée comme le nombre d'observations dans la classe divisé par le total des observations.

Micro Average : la micro-moyenne calcule les métriques globales en comptabilisant la somme totale des vrais positifs, de faux positifs, et des faux négatifs, où :

$$\text{Micro precision} = \frac{\sum TP}{\sum TP + \sum FP} \quad (5.10)$$

$$\text{Micro recall} = \frac{\sum TP}{\sum TP + \sum FN} \quad (5.11)$$

$$\text{Micro F1 score} = 2 \times \frac{\text{Micro precision} \times \text{Micro recall}}{\text{Micro precision} + \text{Micro recall}} \quad (5.12)$$

Où TP représente les vrais positifs, FP les faux positifs et FN les faux négatifs.

(Le tableau 5.2) synthétise les métriques de performance qui reflètent la capacité du modèle à généraliser sur l'ensemble des classes. La précision macro de 95.05% indique que le modèle a une forte probabilité de prédire correctement les défauts sur une gamme équilibrée de classes, traitant toutes les classes avec la même importance sans considération de leur fréquence dans l'ensemble de données. Par ailleurs, le rappel macro de 92.36% montre que le modèle a une bonne capacité à détecter tous les cas pertinents à travers les différentes classes. Le score F1 macro, combinant ces deux aspects, affirme que le modèle équilibre efficacement la précision et le rappel.

Les valeurs pondérées prennent en compte la répartition inégale des classes dans l'ensemble de données, avec une précision de 94.14% et un rappel de 93.51%, suggérant que le modèle est performant même lorsque des classes sont plus représentées que d'autres. Ceci est crucial pour des applications pratiques où certaines conditions de défaut peuvent être plus communes.

Finalement, les métriques micro donnent une perspective sur la performance globale du modèle en traitant toutes les instances de classification collectivement. Ici, les valeurs de précision, de rappel, et du score F1 sont identiques à 93.51%, reflétant la force du modèle dans la classification de chaque image individuellement, indépendamment de sa classe.

5.9.2 Évaluation de la matrice de confusion




Figure 5.7
Matrice de Confusion des Classifications des PPV

La matrice de confusion comme montre (la figure 5.7) présente une représentation visuelle détaillée des performances de classification du modèle. Chaque rangée correspond à la classe réelle des panneaux solaires, tandis que chaque colonne représente les prédictions faites par le modèle. Les valeurs sur la diagonale principale (cases bleues) illustrent le nombre de prédictions correctes pour chaque classe, révélant une performance élevée du modèle avec une précision globale de 93,51%.

Les éléments hors de la diagonale (cases roses) représentent les erreurs de classification, où le modèle a prédit une classe différente de la réalité. Ces données sont essentielles pour identifier les spécificités des performances du modèle pour chaque catégorie de défauts et pour orienter les améliorations futures.

5.9.3 Analyse des courbes ROC

L'aire sous la courbe ROC (AUC - Area Under the Curve) est une technique d'évaluation pour les systèmes de classification binaire. Elle est utilisée pour mesurer la qualité des prédictions d'un modèle, sans se fixer un seuil spécifique. La courbe ROC (Receiver Operating Characteristic) elle-même est un graphique représentant la performance d'un système de classification à tous les seuils de classification. Cette courbe trace le taux de vrais positifs (sensibilité) en fonction du taux de faux positifs (1-spécificité) pour différents seuils de décision.

Une AUC de 1 indique un modèle parfait qui classe correctement toutes les instances positives et négatives.

Une AUC de 0.5 suggère une performance équivalente à une classification aléatoire, sans capacité discriminante.

Une AUC entre 0.5 et 1 indique une capacité de classification utile, où une valeur plus élevée signifie une meilleure performance.




Figure 5.8
Courbes ROC pour la classification des états des panneaux

Les courbes ROC présentées par (la figure 5.8) illustrent l'excellente capacité du modèle à différencier entre les panneaux solaires propres, couverts de neige, et ceux présentant des défauts électriques ou physiques. Les valeurs de l'AUC sont extrêmement proches de l'idéal, avec 1 pour les catégories 'propre' et 'couvert de neige', et 0.99 pour les défauts électriques et physiques. Ces scores témoignent d'une haute fiabilité du modèle dans la détection et la classification précise des états des panneaux solaires, minimisant efficacement le risque d'erreur dans l'identification des conditions. Ces résultats sont particulièrement prometteurs pour l'application en conditions réelles où la distinction précise entre ces états est cruciale pour la maintenance et l'optimisation de la performance des installations photovoltaïques.

5.10 Discussion sur la qualité de la classification

5.10.1 Interprétation visuelle des prédictions




Figure 5.9
Exemples de classification des panneaux solaires par le modèle CNN

La figure ci-dessus illustre une sélection de 24 images testées par le modèle CNN, mettant en évidence la capacité du modèle à classifier correctement les conditions des panneaux solaires. Les prédictions exactes sont marquées en vert, tandis que les erreurs de classification sont signalées en rouge.

Le modèle de classification a démontré une capacité notable à identifier correctement les divers états de surface des panneaux. La majorité des classifications sont exactes, comme en témoignent les images étiquetées "Correct", où l'état prédit concorde avec l'état réel. Ceci indique une forte précision dans des conditions variées, y compris des

panneaux propres, couverts de neige, ou présentant des défauts physiques et électriques.

Cependant, quelques erreurs sont observables, où le modèle a mal classifié l'état de certains panneaux. Par exemple, un panneau avec un défaut physique a été incorrectement classifié comme propre. Ces erreurs, bien que relativement peu nombreuses, mettent en évidence l'importance de continuer à affiner le modèle pour améliorer sa robustesse et sa précision.

Ces visualisations servent non seulement à valider la matrice de confusion et la précision des métriques numériques que nous avons obtenues, mais offrent également une compréhension intuitive de la manière dont le modèle traite les données visuelles et prend des décisions de classification. Cela renforce la confiance dans l'utilisation du modèle pour des applications de surveillance et de maintenance automatisée des installations photovoltaïques.

5.10.2 Évaluation pratique

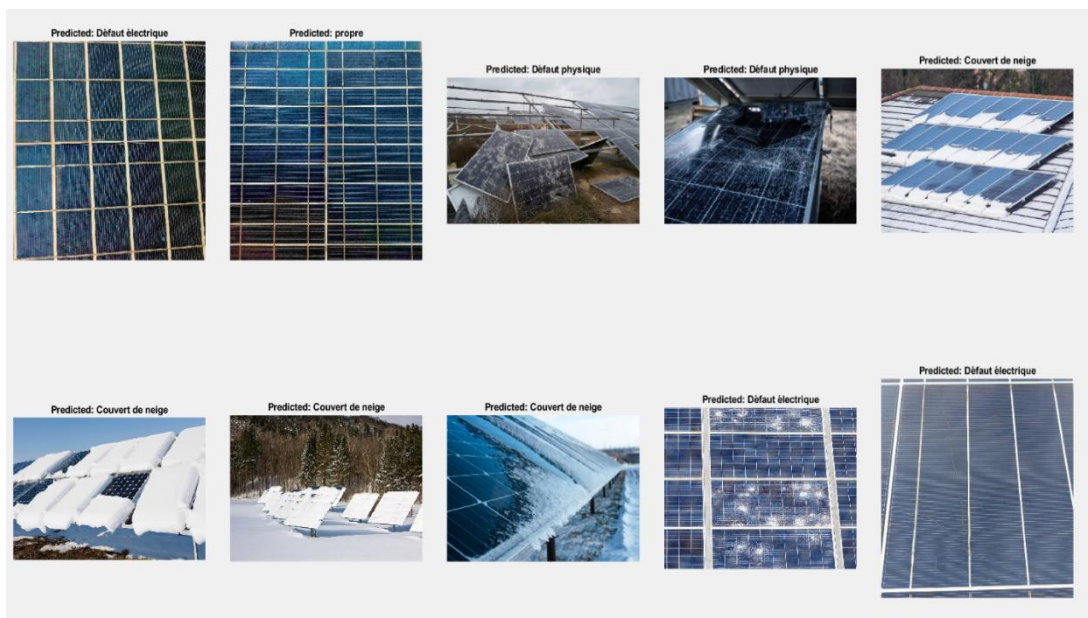


Figure 5.10
Tests sur des panneaux non vus par le modèle

Après avoir évalué notre modèle sur plusieurs paramètres quantitatifs tels que la précision, le rappel et le score F1, nous avons procédé à des tests sur des images de panneaux solaires non vues précédemment par le modèle pour valider nos résultats (figure 10). Cette démarche vise à simuler une application en conditions réelles, où le modèle serait confronté à des données variées et inédites. Les prédictions correctes dans chaque catégorie mettent en évidence la robustesse du modèle et sa capacité à généraliser les caractéristiques apprises à des situations nouvelles. Cette capacité de généralisation est essentielle pour le déploiement de solutions de maintenance prédictive dans le domaine photovoltaïque, où les conditions opérationnelles peuvent varier considérablement.

Néanmoins, les quelques erreurs de classification observées lors de ces tests soulignent le besoin d'une amélioration continue, qui pourrait passer par l'enrichissement du jeu de données d'entraînement ou l'ajustement fin des hyperparamètres du réseau.

5.10.3 Comparaison avec les méthodes traditionnelles

Afin de mettre en évidence les performances de notre modèle ResNet50, nous avons tenté une étude comparative avec d'autres travaux relatifs, comme le montre le (tableau 3). Ce tableau compare les résultats de notre modèle à ceux obtenus dans des études antérieures, toutes axées sur la détection et la classification des défauts des panneaux solaires. En examinant les métriques clés telles que la précision, le rappel et le score F1, il est notable que notre modèle, bien qu'il traite un nombre supérieur de classes de défauts (quatre contre deux), maintient des performances élevées avec une précision de 94,14 %, un rappel de 93,51 % et un score F1 de 93,52 %. Ces résultats démontrent non seulement la robustesse de notre modèle dans la gestion de tâches complexes, mais reflètent également son potentiel pour améliorer significativement la fiabilité et l'efficacité des processus de diagnostic des systèmes photovoltaïques. Par cette comparaison, nous illustrons l'avancée significative que représente notre modèle

dans le domaine de la vision par ordinateur appliquée à l'énergie solaire, soulignant son importance pratique pour les opérateurs et les mainteneurs de panneaux solaires.

Table 5.3
Étude comparative avec travaux relatifs

Étude	Année	Nombre de classes	Précision (%)	Rappel (%)	Score F1 (%)	reference
VGG19	2019	2	88.42	-	88.39	[35]
Light CNN	2019	2	92.02	92.5	92	[36]
ResNet50	2022	12	88.540	75	85.7	[37]
Xception	2022	12	91.399	100	100	
SeFNet	2023	2	94.9	93.85	94.29	[38]
SeMaCNN	2023	2	94.6	-	91.1	[39]
Notre modèle ResNet50	2024	4	94,14	93,51	93,52	

5.11 Quelques stratégies de maintenance préventive

Pour prolonger la longévité et optimiser l'efficacité des panneaux solaires, il est crucial d'adopter des pratiques de maintenance préventive. Voici quelques recommandations pour protéger les panneaux solaires contre les dommages environnementaux et mécaniques :

Nettoyage régulier : Il est conseillé de nettoyer régulièrement les panneaux solaires pour enlever la saleté, les débris et les fientes d'oiseaux qui peuvent obstruer la réception de la lumière du soleil. Ce geste simple peut améliorer de manière significative la production énergétique et l'efficacité des panneaux.

Installation stratégique : Installez les panneaux solaires dans des endroits protégés contre les risques comme la grêle et les vents forts. Envisagez des ajouts structurels

qui peuvent offrir une protection supplémentaire contre ces menaces environnementales.

Inspections professionnelles : Planifiez des inspections régulières par des professionnels qualifiés pour détecter les premiers signes d'usure ou tout problème potentiel. La détection précoce par des évaluations professionnelles peut prévenir l'escalade de petits problèmes en réparations plus importantes et coûteuses.

En intégrant ces mesures préventives, nous pouvons maintenir l'état opérationnel des panneaux solaires et prolonger leur durée de vie utile, complétant ainsi nos efforts pour détecter et traiter les défauts par des méthodes technologiques avancées.

5.12 Conclusion

Au terme de ce chapitre dédié à la détection des défauts sur les panneaux solaires par le biais des réseaux de neurones à convolution (CNN), nous avons pu établir l'efficacité supérieure de cette approche par rapport aux méthodes traditionnelles. L'analyse détaillée a révélé que l'emploi de modèles avancés tels que le ResNet-50 fournit non seulement une précision remarquable dans la classification des états des panneaux solaires, mais offre aussi une capacité d'adaptation et d'amélioration continue face à des données variées et complexes.

Nous avons exploré la méthodologie de préparation et d'augmentation des données, l'adaptation de l'architecture du ResNet-50 pour répondre à nos besoins spécifiques, et la mise en œuvre du processus d'entraînement. Les résultats obtenus montrent une performance impressionnante en termes de précision et de robustesse, ce qui renforce l'intérêt pour les applications pratiques de maintenance prédictive et d'optimisation des rendements des installations photovoltaïques.

Les résultats quantitatifs et les métriques de classification démontrent que les techniques d'apprentissage profond peuvent surpasser les attentes et transformer radicalement les opérations de surveillance des installations solaires. Cette étude

constitue une étape significative vers l'automatisation complète de la détection des défauts, promettant une réduction des coûts de maintenance et une amélioration de la production énergétique des panneaux solaires.

Ainsi, ce chapitre souligne la viabilité et la pertinence des CNN dans le contexte de l'énergie solaire, tout en ouvrant des perspectives prometteuses pour de futures recherches et applications industrielles visant à accroître la fiabilité et l'efficacité des systèmes photovoltaïques.

CONCLUSION

Ce projet a exploré l'intégration de techniques avancées d'intelligence artificielle pour améliorer la gestion et l'efficacité des systèmes photovoltaïques. Grâce à l'application des réseaux de neurones artificiels (RNA) pour optimiser le point de puissance maximale (MPPT) et des réseaux de neurones convolutifs (CNN) pour la détection des défauts, nous avons pu adresser deux des principaux défis associés à l'utilisation de l'énergie solaire : maximiser la production d'énergie et minimiser les pertes dues à des défauts non détectés.

Les résultats obtenus confirment que les RNA peuvent surpasser les méthodes traditionnelles telles que la méthode de Perturbation et Observation (P&O) en termes de précision, rapidité et stabilité dans la régulation du MPPT. Parallèlement, l'utilisation des CNN a montré une grande efficacité dans la reconnaissance et la classification des défauts variés des panneaux solaires, ce qui permet une maintenance plus proactive et une augmentation de la durée de vie des installations.

Ce travail ouvre la voie à de futures recherches qui pourraient explorer des modèles d'intelligence artificielle encore plus sophistiqués ou élargir l'application de ces technologies à d'autres aspects de la gestion des systèmes énergétiques renouvelables. En outre, l'intégration continue de ces innovations technologiques promet de rendre les systèmes photovoltaïques plus attractifs pour les consommateurs et les investisseurs, en contribuant efficacement à la transition vers une économie plus durable et à faible émission de carbone.

En conclusion, ce projet a non seulement confirmé l'efficacité des approches basées sur l'IA pour améliorer les performances des systèmes photovoltaïques, mais a également démontré leur potentiel pour révolutionner la gestion de l'énergie solaire

RÉFÉRENCES BIBLIOGRAPHIQUES

- [1] IRENA, «Renewable capacity statistics 2023,» International renewable energy agency , Abu Dhabi, 2023.
- [2] IEA, «Renewable 2022 Analysis and forecast to 2027,» International Energy Agency, Paris, 2022.
- [3] Hydro-Québec, «L'énergie solaire photovoltaïque - Hydro-Québec,» fevrier 2021. [En ligne]. Available: <https://www.hydroquebec.com/data/developpement-durable/pdf/fiche-solaire-2021.pdf>.
- [4] É. Blent, «Réseaux convolutifs (CNN) : comment ça marche ?,» *Machine Learning*, le 20 juin 2022.
- [5] Adrien, «Efficacité des panneaux solaires: le pérovskite dépasse le silicium,» *Nature energy*, 2024.
- [6] « Historique de la cellule photovoltaïque,» *Resources multimedia enseignement de la technologie* .
- [7] G. Boyle, « Power for a Sustainable Future,» *Renewable Energy*, 2004.
- [8] ZEROUALI, Mohammed, ZOUIRECH, Salaheddine, EL OUGLI, Abdelghani, et al. Improvement of conventional mppt techniques P&O and INC by integration of fuzzy logic. In : 2019 7th International Renewable and Sustainable Energy Conference (IRSEC). IEEE, 2019. p. 1-6.

- [9] A. Mahmoudi, «Réalisation d'un convertisseur DC/DC dans une chaîne de conversion d'énergie photovoltaïque,» 2017.
- [10] iutenligne, «Panneaux Photovoltaïques.,» 2021.
- [11] J. A. H. L. & B. C. Tsanakas, «Faults and Failures in Photovoltaic Modules: Analysis and Evaluation.,» chez *Renewable and Sustainable Energy Reviews.*, 2016.
- [12] A. S. T. & D. E. D. Skoczek, «The Performance of PV Modules and Possible Degradation over Time.,» chez *Proceedings of the 24th European Photovoltaic Solar Energy Conference*, 2009.
- [13] HART, Daniel W. et HART, Daniel W. Power electronics. New York : McGraw-Hill, 2011.
- [14] Fabienne Chartier, H. L. Le hacheur de type BOOST.. 2016
- [15] A. F. & D. F. & D. B. Toure, «Application of Artificial Neural Networks for Maximal Power Point Tracking,» *International Journal of Sustainable and Green Energy*, 2021.
- [16] I. B. Y. & C. A. Goodfellow, Deep Learning, MIT Press., 2016.
- [17] TOUZET, Claude. *les réseaux de neurones artificiels, introduction au connexionnisme*. Ec2, 1992.
- [18] B. a. H. H. L Bouselham, «Comparative study of different mppt methods for,» *Renewable and Sustainable Energy Conference (IREC)*, pp. 1-5, 2015.
- [19] B. b. Nasser, «ETUDE ET MODELISATION DE LA COMMANDE MPPT,» 2021.


- [20] L. I. o. g. a. d. L'IA au sein de l'entreprise, «L'IA au sein de l'entreprise Libérer les opportunités grâce aux données,» 2021.
- [21] C. Brousseau, « CARACTERISATION LARGE BANDE DE FREQUENCE : APPLICATION AU RADAR ET AU SONDAGE DE CANAL.,» 2005.
- [22] T. T. Y. M. J.-i. T. a. K. K. A. Nishioka, «Description of uniaxial, biaxial, and planar elongational viscosities of polystyrene melt by the K-BKZ model,» *A. Nishioka, T. Takahashi, Y. Masubuchi, J.-i. Takimoto, and K. Koyama, "Description of uniaxial, biaxial, a Journal of Non-Newtonian Fluid Mechanics*, pp. 287-301.
- [23] D. L. a. F. Erchiqui., «Experimental and theoretical study of the thermoformability of industrial polymers.,» *Journal of Reinforced plastics and composites*, pp. 230-239, 2000.
- [24] M. Cilimkovic, «Réseaux de neurones et algorithme de rétro-propagation.,» vol. 15, 2015.
- [25] G. X. e. X. F. Zixia Yuan, «Réseau neuronal artificiel pour le diagnostic des défauts des systèmes solaires photovoltaïques,» *Laboratoire clé de Guizhou de technologie intelligente dans les systèmes électriques, Collège de génie électrique, Université de Guizhou, Guiyang 550025, Chine, 2022.*
- [26] Blent, É. (2022). Réseaux convolutifs (CNN) : comment ça marche ? Machine Learning.
- [27] Y. B. L. B. Y. e. a. LeCun, «Gradient-Based Learning Applied to Document Recognition.,» pp. 2278-2324, 1998.
- [28] A. S. I. e. H. G. E. Krizhevsky, «ImageNet Classification with Deep

- Convolutional Neural Networks,» 2012.
- [29] K. e. Z. A. Simonyan, «Very Deep Convolutional Networks for Large-Scale Image Recognition.,» 2014, p. 1409.1556..
- [30] C. L. W. J. Y. e. a. Szegedy, «Going Deeper with Convolutions.,» 2015.
- [31] A. G. Z. M. C. B. e. a. Howard, «MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,» 2017, p. 704.04861..
- [32] M. e. L. Q. V. Tan, «EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.,» 2019.
- [33] X. Z. S. R. e. J. S. Kaiming He, «Deep Residual Learning for Image Recognition,» chez *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR).*, 2016.
- [35] S. Deitsch *et al.*, “Automatic classification of defective photovoltaic module cells in electroluminescence images,” *Solar Energy*, vol. 185, pp. 455–468, Jun. 2019, doi: 10.1016/j.solener.2019.02.067.
- [36] M. W. Akram *et al.*, “CNN based automatic detection of photovoltaic cell defects in electroluminescence images,” *Energy*, vol. 189, p. 116319, Dec. 2019, doi: 10.1016/j.energy.2019.116319.
- [37] H. Tella, M. Mohandes, B. Liu, S. Rehman, and A. Al-Shaikhi, “Deep Learning System for Defect Classification of Solar Panel Cells,” in *2022 14th International Conference on Computational Intelligence and Communication Networks (CICN)*, IEEE, Dec. 2022, pp. 448–453. doi: 10.1109/CICN56167.2022.10008277.
- [38] X. Zhao, C. Song, H. Zhang, X. Sun, and J. Zhao, “HRNet-based automatic

identification of photovoltaic module defects using electroluminescence images,” *Energy*, vol. 267, p. 126605, Mar. 2023, doi: 10.1016/j.energy.2022.126605.

- [39] A. Korovin *et al.*, “Anomaly detection in electroluminescence images of heterojunction solar cells,” *Solar Energy*, vol. 259, pp. 130–136, Jul. 2023, doi: 10.1016/j.solener.2023.04.059.

ANNEXE I : FICHE TECHNIQUE DU PPV CS3K-295P







KuPower

HIGH EFFICIENCY POLY MODULE




CS3K-295 | 300 | 305 | 310P

(1000 V / 1500 V)


MORE POWER

- 
Low power loss in cell connection
- 
Low NMOT: 42 ± 3 °C
Low temperature coefficient (Pmax): -0.36 % / °C
- 
Better shading tolerance
- 
High PTC rating of up to: 93.10 %

MORE RELIABLE

- 
Lower hot spot temperature
- 
Minimizes micro-crack impacts
- 
Heavy snow load up to 6000 Pa,
wind load up to 4000 Pa*

* For detailed information, please refer to the Installation Manual.



MBB
SBB

*Black frame product can be provided upon request.

25
years

linear power output warranty*

12
years

enhanced product warranty on materials and workmanship*







*According to the applicable Canadian Solar Limited Warranty Statement.

MANAGEMENT SYSTEM CERTIFICATES

ISO 9001:2015 / Quality management system
ISO 14001:2015 / Standards for environmental management system
OHSAS 18001:2007 / International standards for occupational health & safety

PRODUCT CERTIFICATES*

IEC 61215 / IEC 61730: VDE / CE / CQC / MCS / INMETRO
UL 1703 / IEC 61215 performance: CEC listed (US)
UL 1703: CSA / IEC 61701 ED2: VDE / IEC 62716: VDE / IEC 60068-2-68: SGS
Take-e-way









* As there are different certification requirements in different markets, please contact your local Canadian Solar sales representative for the specific certificates applicable to the products in the region in which the products are to be used.


CANADIAN SOLAR INC. is committed to providing high quality solar products, solar system solutions and services to customers around the world. No. 1 module supplier for quality and performance / price ratio in IHS Module Customer Insight Survey. As a leading PV project developer and manufacturer of solar modules with over 40 GW deployed around the world since 2001.

CANADIAN SOLAR INC.
545 Speedvale Avenue West, Guelph, Ontario N1K 1E6, Canada, www.canadiansolar.com, support@canadiansolar.com

ENGINEERING DRAWING (mm)



CS3K-300P / I-V CURVES



ELECTRICAL DATA | STC*

CS3K	295P	300P	305P	310P
Nominal Max. Power (Pmax)	295 W	300 W	305 W	310 W
Opt. Operating Voltage (Vmp)	32.5 V	32.7 V	32.9 V	33.1 V
Opt. Operating Current (Imp)	9.08 A	9.18 A	9.28 A	9.37 A
Open Circuit Voltage (Voc)	39.1 V	39.3 V	39.5 V	39.7 V
Short Circuit Current (Isc)	9.57 A	9.65 A	9.73 A	9.81 A
Module Efficiency	17.8%	18.1%	18.4%	18.7%
Operating Temperature	-40°C - +85°C			
Max. System Voltage	1500V (IEC/UL) or 1000V (IEC/UL)			
Module Fire Performance	TYPE 1 (UL 1703) or Class C (IEC 61730)			
Max. Series Fuse Rating	30 A			
Application Classification	Class A			
Power Tolerance	0 - + 10 W			

* Under Standard Test Conditions (STC) of irradiance of 1000 W/m², spectrum AM 1.5 and cell temperature of 25°C.

MECHANICAL DATA

Specification	Data
Cell Type	Poly-crystalline
Cell Arrangement	120 [2 X (10 X 6)]
Dimensions	1675 X 992 X 35 mm (65.9 X 39.1 X 1.38 in)
Weight	18.5 kg (40.8 lbs)
Front Cover	3.2 mm tempered glass
Frame	Anodized aluminium alloy
J-Box	IP68, 3 bypass diodes
Cable	4.0 mm² (IEC), 12 AWG (UL)
Cable Length (Including Connector)	Portrait: 400 mm (15.7 in) (+) / 280 mm (11.0 in) (-); landscape: 1160 mm (45.7 in)*
Connector	T4 series or H4 UTX or MC4-EVO2
Per Pallet	30 pieces
Per Container (40' HQ)	840 pieces

* For detailed information, please contact your local Canadian Solar sales and technical representatives.

ELECTRICAL DATA | NMOT*

CS3K	295P	300P	305P	310P
Nominal Max. Power (Pmax)	220 W	223 W	227 W	231 W
Opt. Operating Voltage (Vmp)	30.2 V	30.4 V	30.6 V	30.8 V
Opt. Operating Current (Imp)	7.26 A	7.34 A	7.42 A	7.49 A
Open Circuit Voltage (Voc)	36.7 V	36.9 V	37.1 V	37.3 V
Short Circuit Current (Isc)	7.72 A	7.78 A	7.85 A	7.91 A

* Under Nominal Module Operating Temperature (NMOT), irradiance of 800 W/m², spectrum AM 1.5, ambient temperature 20°C, wind speed 1 m/s.

TEMPERATURE CHARACTERISTICS

Specification	Data
Temperature Coefficient (Pmax)	-0.36 % / °C
Temperature Coefficient (Voc)	-0.28 % / °C
Temperature Coefficient (Isc)	0.05 % / °C
Nominal Module Operating Temperature	42 ± 3°C

PARTNER SECTION



* The specifications and key features contained in this datasheet may deviate slightly from our actual products due to the on-going innovation and product enhancement. Canadian Solar Inc. reserves the right to make necessary adjustments to the information described herein at any time without further notice. Please be kindly advised that PV modules should be handled and installed by qualified people who have professional skills and please carefully read the safety and installation instructions before using our PV modules.

CANADIAN SOLAR INC.
545 Speedvale Avenue West, Guelph, Ontario N1K 1E6, Canada, www.canadiansolar.com, support@canadiansolar.com