

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la
Recherche Scientifique



Université Echahid Hamma Lakhdar d'El-Oued

FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE MECANIQUE

Mémoire de fin d'étude

Présenté pour l'obtention du diplôme de

MASTER ACADEMIQUE

Domaine : Sciences et Technologies

Filière : Génie Electrique

Spécialité : Reseau Electrique

Thème

**Détection et localisation des défauts dans un système
photovoltaïque base sur les réseaux neuronaux
artificiel (ANN)**

Réalisé par :

- Guedda Mohammed riadh
- Tamma abdelmajid

Encadré par :

Dr. Labbi Yacine

Année Universitaire 2024/2025



﴿ رَبَّنَا لَا تُؤَاخِذْنَا إِنْ نَسِينَا أَوْ أَخْطَأْنَا رَبَّنَا وَلَا تَحْمِلْ عَلَيْنَا إَصْرًا كَمَا حَمَلْتَهُ
عَلَى الَّذِينَ مِنْ قَبْلِنَا رَبَّنَا وَلَا تُحَمِّلْنَا مَا لَا طَاقَةَ لَنَا بِهِ وَاعْفُ عَنَّا وَارْحَمْنَا أَنْتَ
مَوْلَانَا فَانصُرْنَا عَلَى الْقَوْمِ الْكَافِرِينَ ﴾ سورة البقرة : الآية 286 .

" صدق الله العظيم "



Remerciements

Tout d'abord, je remercie dieu -ALLAH- de tout puissant de m'avoir donné le courage et la patience durant toutes ces années d'études.

je remercie Dieu Tout-Puissant pour sa bonté envers moi de m'avoir donné du courage et de la patience pendant toutes ces années scolaires.

*Je tiens à exprimer ma profonde gratitude et mes vifs remerciements à Dr : **Labbi Yacine** à l'Université Chahid Hama Lakhdar EL OUED.*

Et mes sincères remerciements aux membres du jury pour l'effort qu'ils m'ont fourni en participant à juger cette œuvre.

Nous tenons à adresser nos sincères remerciements à tous ceux qui nous ont aidés à réaliser cette thèse, ainsi qu'à tous ceux qui nous ont aidés de près ou de loin dans la réalisation de ce travail..





Dédicaces

*Tout d'abord, je tien a remercier le Tout-Puissant de
m'avoir donné le courage*

*et la patience pour arriver a ce stade afin de realiser ce
travail .*

Que je dédie :

*A ma très chère mère ,qui n'a jamais cessé de prier
pour moi. A mon très*

*cher papa ,pour ses encouragements. A mes très chers
frères.*

*À toute ma grande famille : GVEDDA. A mes amis
les plus chers, chacun avec son nom.*

*A tous mes amis gourous de la promotion
électrotechnique.*

*A la fin je dèdie très chaleureusement ce mémoire .A
tous ceux qui m'ont aidè de près ou de loin pour la réalisation
de ce travail*

MOHAMMED RIADH





Dédicaces

*Tout d'abord, je tien a remercier le Tout-Puissant de
m'avoir donné le courage*

*et la patience pour arriver a ce stade afin de realiser ce
travail .*

Que je dédie :

*A ma très chère mère ,qui n'a jamais cessé de prier
pour moi. A mon très*

*cher papa ,pour ses encouragements. A mes très chers
frères. A toute ma*

*grande famille : TAMMA. A mes amis les plus chers,
chacun avec son nom.*

*A tous mes amis gourous de la promotion
électrotechnique.*

A la fin je dèdie très chaleureusement ce mémoire .

*A tous ceux qui m'ont aidè de près ou de loin pour la
rèalisation de ce travail .*

ABD ELMAJID



الملخص

Résumé

Résumé

La transition vers les énergies renouvelables constitue un enjeu majeur pour répondre aux besoins énergétiques croissants tout en limitant l'impact environnemental. Parmi celles-ci, l'énergie solaire photovoltaïque (PV) occupe une place prépondérante. Cependant, la performance et la fiabilité des systèmes PV peuvent être affectées par divers défauts susceptibles de survenir durant leur cycle d'exploitation, entraînant une réduction de la production énergétique et une dégradation potentielle des installations. Dans ce contexte, le développement de systèmes de diagnostic avancés est essentiel pour assurer une détection précoce et précise des anomalies, garantissant ainsi une exploitation optimale et une maintenance efficace des parcs photovoltaïques.

Ce travail de recherche s'inscrit dans cette perspective et se concentre sur l'application des techniques d'intelligence artificielle, spécifiquement les réseaux de neurones artificiels (ANN), pour le diagnostic des défauts dans les systèmes PV. L'étude vise à concevoir et à évaluer un algorithme capable d'identifier et de classifier différents types de défauts à partir de l'analyse des signaux caractéristiques du système. L'approche proposée repose sur la modélisation d'un système photovoltaïque (incluant panneau PV, convertisseur DC/DC avec algorithme MPPT P&O, et charge) sous l'environnement MATLAB/Simulink, la simulation de scénarios de défauts, et l'utilisation des données générées pour l'entraînement et la validation du réseau neuronal. Les résultats obtenus visent à démontrer l'efficacité des ANN comme outil de diagnostic intelligent, contribuant à l'amélioration de la fiabilité et de la rentabilité des installations solaires photovoltaïques.

المخلص

تحظى الطاقات المتجددة، وبشكل خاص الطاقة الشمسية الكهروضوئية، بأهمية متزايدة كمصدر أساسي لتلبية احتياجات الطاقة الحديثة، نظراً لكونها مصادر غير قابلة للنضوب نظرياً وصديقة للبيئة. إلا أن أنظمة الطاقة المتجددة، بما في ذلك الأنظمة الكهروضوئية، معرضة لحدوث أعطال وتدهور في الأداء خلال فترة تشغيلها، مما يؤثر سلباً على كفاءة منشآتها وإنتاجيتها للطاقة. يستدعي ذلك ضرورة تطوير أنظمة تشخيص متقدمة وفعالة، يكون هدفها الأساسي هو تفسير المؤشرات التشغيلية للكشف الدقيق عن الأعطال، وذلك لضمان استمرارية إنتاج الطاقة بمستويات مثالية من النظام الكهروضوئي.

يستعرض هذا البحث دراسة معمقة تهدف إلى تشخيص الأعطال في نظام كهروضوئي باستخدام تقنيات الذكاء الاصطناعي. يركز هذا العمل بشكل خاص على تطوير خوارزمية تعتمد على منهجية الشبكات العصبية الاصطناعية، بهدف توفير أداة قوية لتشخيص مختلف أنواع الأعطال التي قد تحدث في الأنظمة الكهروضوئية، والمساهمة في تحسين موثوقيتها وكفاءتها التشغيلية.



Sommaire

Remerciement

Dédicace

Résumé

Table des matières

Liste des figures

Liste des tableaux

Introduction générale

A

Chapitre I : <i>Principes Fondamentaux de l'Énergie Solaire Photovoltaïque</i>	
I.1.Introduction	04
1.2. Contexte Historique	04
1.3. L'Effet Photovoltaïque	05
1.4. L'Effet Photovoltaïque	06
1.Génération de paires électron-trou	06
2.Collecte des charges	06
1.5. Constitution d'un Module Photovoltaïque	07
1.6. Modélisation Électrique d'une Cellule Photovoltaïque	09
1.6.1. Modèle Idéal	09
1.6.2. Modèle à une Diode (Modèle 1-D)	10
1.6.3. Modèle à Deux Diodes (Modèle 2-D)	10
1.6.4. Modèle de Bishop	11
1.7. Caractéristiques Électriques et Paramètres Clés	11
1.8. Poursuite du Point de Puissance Maximale (MPPT)	13
1.8.1. Algorithme Perturber et Observer (P&O)	13
1.10.1. simulation de la commande MPPT numérique « P&O »:	14
1.9. Facteurs Influent sur les Performances	16
1.9.1. Ensoleillement (Irradiance)	16
1.9.2. Température	16

1.9.3. Ombrage Partiel	17
1.10. Mécanismes de Protection des Systèmes PV	18
1.10.1. Diodes Bypass (ou de Dérivation)	18
1.10.2. Diodes de Blocage (ou Anti-retour)	19
1.11. Indicateurs de Performance	20
1.12. Avantages et Inconvénients de l'Énergie Solaire Photovoltaïque	21
I.13 Conclusion du Chapitre	23
Chapitre II: Modélisation du défaut en générateur PV et méthodes de diagnostic	
II.1 Introduction	25
II -2 Modélisation du générateur PV en condition de défaut:	25
II-2-1 Classification des défauts pour les besoins de la modélisation	25
II-2-1-1 Défauts dans le générateur photovoltaïque:	26
II-2-1-2 Défauts dans la boîte de jonction:	28
II-2-1-3 Défauts dans le système de câblage:	29
II-2-1-4 Défauts dans le système de protection:	30
II-2-1-5 Défauts dans l'onduleur:	31
II-2-1-6 Défauts dans le système d'acquisition:	32
II-3 Méthodes de Détection et de Diagnostic des Défauts dans les Systèmes Photovoltaïques (PV)	33
II-3-1-1 Méthodes de Détection et de Diagnostic des Défauts dans les Systèmes Photovoltaïques (PV)	34
II-3-1-2 Méthode de réflectométrie	34
II-3-2 Méthode électrique	35
II-3-2-1 Méthode d'analyse de la puissance produite	35
II-3-2-2 Méthode d'analyse des caractéristiques I-V et P-V	36
II-3-2-3 Méthode d'analyse du point de fonctionnement	36

II-4 Conclusion:	36
Chapitre III : Réseaux de Neurones Artificiels : Fondements, Architectures et Apprentissage	
III.1 Introduction	38
III.2 Aperçu Historique	38
III.3 Réseaux de Neurones Artificiels : Définition Générale	39
III.4 Inspiration du Modèle Biologique	40
III.5 Le Neurone Formel	40
III.6 Fonctions d'Activation	41
III.7 Principe Opérationnel	43
III.8 Architectures des Réseaux de Neurones	44
III.8.1 Réseaux à Propagation Avant (Feedforward Networks)	44
III.8.2 Réseaux Récurrents (Recurrent Neural Networks - RNN)	44
III.9. Apprentissage du Réseau de Neurones	45
III.9.1. Définition	45
III.9.2 Stratégie d'Apprentissage (Exemple : Apprentissage Supervisé)	45
III.9.3 Types d'Apprentissage	46
III.9.3.1 Apprentissage Supervisé	46
III.9.3.2 Apprentissage Non-Supervisé	47
III.10 Modèles Spécifiques de Réseaux de Neurones Artificiels	47
III.10.1 Les Perceptrons Multicouches (MLP)	48
III.11 Applications des Réseaux de Neurones Artificiels	48
III.12. Évaluation des Résultats d'Entraînement (Exemple Illustratif)	49
III.13 Avantages et Inconvénients des Réseaux de Neurones	51
III.13.1 Avantages	51
III.13.2 Inconvénients	51

III.14 Conclusion	53
Chapitre IV : Simulation et Résultats	
IV.1. Introduction	56
IV.2. Configuration de l'Environnement de Simulation et Génération des Données	56
IV.2.1. Paramètres du Panneau Photovoltaïque	57
IV.2.2. Scénarios de Défauts Modélisés:	57
IV.2.3. Génération de Données	58
IV.3. Conception et Entraînement du Réseau de Neurones Artificiels	59
IV.3.1. Prétraitement des Données	59
IV.3.2. Architecture du Réseau	59
IV.3.3. Paramètres d'Entraînement	59
IV.4. Résultats et Discussion	59
IV.4.1. Performance Globale de l'Entraînement	60
IV.4.2. Analyse de la Matrice de Confusion	60
IV.4.3. Métriques de Performance par Classe	62
IV.4.4. Analyse des Courbes ROC	64
IV.4.5. Vérification du Comportement du Réseau sur des Scénarios de Test Individuels	65
IV.4.6. Évaluation Étendue sur des Séquences de Scénarios sous Diverses Conditions d'Éclairement	67
IV.5. Conclusion du Chapitre et Perspectives	69
Conclusion générale	71
Bibliographique	

An orange scroll graphic with a darker orange border and rounded corners. It features two circular elements on the left side, resembling the ends of a rolled-up scroll.

LISTE DES FIGURES

LISTE DES FIGURES

Page

Chapitre I : Principes Fondamentaux de l'Énergie Solaire Photovoltaïque		
Figure 1.1	<i>Schéma de principe d'un système PV avec batterie</i>	06
Figure 1.2	<i>Schéma illustrant la structure d'une jonction PN et le processus de génération/séparation des charges sous éclairement</i>	07
Figure 1.3	<i>Constitution d'un module PV Schéma des plaques avec « code de danger »</i>	07
Figure 1.4	<i>Encapsulation des cellules Les camions mono cuves</i>	08
Figure 1.5	<i>Modele idéal d'une cellule P V</i>	09
Figure 1. 6	<i>Circuit équivalent d'une cellule P-Modèle 1-D Les wagons citernes</i>	10
Figure 1.7	<i>Schéma électrique équivalent d'une cellule en silicium cristallin- modèle 2-D</i>	11
Figure. 1.8	<i>Modèle de Bishop</i>	11
Figure 1.9	<i>Représentation conventionnelle de la courbe $I(V)$ et $P(V)$</i>	12
Figure 1-10	<i>Caractéristique P_{pv} (V_{pv}) et fonctionnement de la méthode Perturbation et Observation</i>	14
Figure 1-11	<i>Organigramme de la méthode Perturbation et Observation</i>	14 15
Figure 1-12	<i>Schéma block de la commande MPPT</i>	15
Figure 1-13	<i>La puissance aux bornes du GPV</i>	15
Figure 1- 14	<i>La tension aux bornes du GPV</i>	15
Figure 1-15	<i>Rapport cyclique correspondant au contrôleur MPPT P&O</i>	16
Fig 1-16	<i>influence de l''ensoleillement sur le point de puissance maximal (PPM)</i>	16
Figure 1-17	<i>influence de la temperature sur la tension de circuit ouvert (V_{co})</i>	17
Figure 1-18	<i>Courbe $I-V$ et $P-V$ dans des conditions d'ombrage partiel.</i>	18
Figure 1-19	<i>Fonctionnement du solaire PV dans des conditions d'ombrage partiel.</i>	18
Figure 1.20	<i>Module de 36 cellules protégé par deux diodes de by-pass</i>	19
Figure 1.21	<i>diode anti-retour placée à la sortie du string et avant la charge et la connexion des autres strings.</i>	19
Figure 1.22	<i>Schématisation d'un GPV élémentaire avec diodes by-pass et diode anti-retour.</i>	20

Figure 1.23	<i>Caractéristiques I-V d'une cellule solaire ensoleillée et dans l'obscurité.</i>	20
Chapitre II : Modélisation du défaut en générateur PV et méthodes de diagnostique		
Figure II.1	<i>Exemples de défauts rencontrés dans les générateurs photovoltaïque PV.</i>	27
Figure II.2	<i>Exemples de défauts rencontrés dans les boîtes de jonction.</i>	28
Figure II.3	<i>Exemples de défauts rencontrés dans le câblage</i>	30
Figure II.4	<i>Exemples de défauts de diodes by-pass</i>	31
Figure II.5	<i>Méthodes de diagnostic de défauts d'un générateur PV</i>	34
Figure II.6	<i>Exemple de la localisation de défauts par la caméra thermique.</i>	34
Figure II.7	<i>Principe de la réflectométrie pour localiser le défaut dans un string PV.</i>	35
Chapitre III : Réseaux de Neurones Artificiels : Fondements, Architectures et35 Apprentissage		
Figure III.1	<i>Exemple de neurone biologique.</i>	40
Figure III.2	<i>Schématisation de la fonction d'activation de la somme pondérée</i>	41
Figure III.3	<i>Réseau de Neurones</i>	43
Figure III.4	<i>Réseau non bouclé</i>	44
Figure III.5	<i>Réseau bouclé</i>	45
Figure III.6	<i>exemple d'apprentissage supervisé</i>	46
Figure III.7	<i>Courbe de performance produite lors de l'entraînement du réseau</i>	49
Figure III.8	<i>Diagramme de régression produit lors de l'apprentissage du réseau</i>	30
Figure III.9	<i>Les paramètres x et y tracés ensemble après en les exécutant via le réseau</i>	30
Chapitre IV : Simulation et Résultats		
Figure IV.1	<i>Schéma du modèle Simulink de base du système photovoltaïque étudiéCarte du Réseau de Transport RTC Béjaia</i>	56
Figure IV.2	<i>paramètres du bloc PV Array</i>	57
Figure IV.3	<i>Schéma de l'architecture du réseau neuronal</i>	59
Figure IV.4	<i>Courbe de performance de l'entraînement (plotperform) pour la meilleure exécution</i>	60
Figure IV.5	<i>Matrice de confusion pour l'ensemble de test avec une précision de 79.65%</i>	60
Figure IV.6	<i>Courbes ROC pour les 4 classes sur l'ensemble de test</i>	64
Figure IV.7	<i>Prédictions séquentielles du réseau neuronal pour les quatre scénarios de fonctionnement distincts sous un éclairnement de 800 W/m².</i>	66
Figure IV.8	<i>Prédictions du réseau neuronal pour l'ensemble des séquences de scénarios de fonctionnement simulés sous divers niveaux d'éclairnement (1000, 800, 600, 400, 300 W/m²).</i>	68




Liste Des Tableaux

Liste Des Tableaux

Page

Chapitre II : Modélisation du défaut en générateur PV et méthodes de diagnostique		
Tab. II.1	<i>Défauts et leurs conséquences dans un générateur</i>	26
Tab. II.2	<i>Les défauts dans la boite de jonction</i>	28
Tab. II.3	<i>Les défauts dans le système de câblage</i>	29
Tab. II.4	<i>Les défauts dans le système de protection.</i>	30
Tab. II.5	<i>Les défauts dans l'onduleur.</i>	31
Tab. II.6	<i>Les défauts dans le système d'acquisition.</i>	32
Chapitre III : Réseaux de Neurones Artificiels : Fondements, Architectures et Apprentissage		
Tabl III.1	<i>Les modèles de fonctions d'activation</i>	42
Tabl III.2	<i>Type de réseau utilisé pour chaque domaine.</i>	49
Chapitre IV : Simulation et Résultats		
Tableau IV.1	<i>Distribution des échantillons par classe</i>	58
Tableau IV.2	<i>Métriques de performance par classe (Précision, Rappel, Score-F1, Spécificité) pour l'ensemble de test.</i>	62
Tableau IV.3	<i>Résultats détaillés des prédictions du réseau neuronal pour les séquences de scénarios de test sous différents niveaux d'éclairement.</i>	68

An orange scroll graphic with a light orange background and a darker orange border. The scroll is partially unrolled, with the top and bottom edges showing a darker orange band. The text is centered on the main body of the scroll.

Notations et symboles

Liste des symboles

PV : photovoltaïque

GPV : générateur photovoltaïque

DC: Direct current

AC: Alternating current

PPM : Point de Puissance Maximale

MPPT: Maximum Power Point Tracking

Voc : Tension de circuit ouvert [V]

Icc : Courant de court-circuit [A]

E : Niveau d'éclairement (ou d'irradiation) [W/m²]

I₀ : Courant de saturation de la diode [A]

n : Le facteur de non idéalité de la jonction de la diode

K : La constante de Boltzmann

T : La température effective de la cellule [°K]

q : La charge de l'électron [C]

n_s : Nombre de cellules en série

n_p : Nombre de cellules en parallèle

G : Conductance du GPV


D : Rapport cyclique

P&O: Perturb and Observe

C_e: couple électromagnétique du moteur

C_r: couple de charge (ou couple résistant)

ω: vitesse de l'arbre du moteur

An orange scroll graphic with a light orange background and a darker orange border. The scroll is unrolled, with the top and bottom edges showing a slight curve. The text is centered on the scroll.

Introduction générale

INTRODUCTION GÉNÉRALE

Au cours des dernières décennies, la transition énergétique mondiale a été marquée par une évolution remarquable vers l'utilisation des sources d'énergie renouvelables pour la production d'électricité. Cette dynamique s'explique principalement par les prévisions d'épuisement progressif des ressources énergétiques conventionnelles fossiles, ainsi que par une prise de conscience accrue des impératifs environnementaux. Dans ce contexte, le développement des énergies renouvelables, et notamment de l'énergie solaire photovoltaïque (PV), est activement encouragé à l'échelle internationale.

L'énergie solaire PV, grâce à son caractère renouvelable et son faible impact environnemental, occupe une place prépondérante, trouvant application dans un large éventail de contextes. Pour assurer la viabilité économique et la compétitivité de ces systèmes, une exploitation optimale des modules photovoltaïques, opérant continuellement à leur point de puissance maximale (MPP), est primordiale.

Cependant, la performance et la fiabilité des systèmes PV peuvent être sévèrement compromises par divers défauts susceptibles de survenir durant leur cycle d'exploitation. Ces anomalies, qu'elles affectent les panneaux solaires (par exemple, ombrage partiel, circuits ouverts/courts), les convertisseurs de puissance DC/DC ou les algorithmes MPPT, entraînent une réduction du rendement énergétique et des pertes de production. La détection et le diagnostic précoces et précis de ces défauts sont donc essentiels. Face aux limites des méthodes traditionnelles, les approches basées sur l'intelligence artificielle, et plus particulièrement les réseaux de neurones artificiels (RNA), offrent des perspectives prometteuses.

Face à cette problématique, ce mémoire se propose de développer et d'évaluer une méthodologie de classification et de diagnostic des défauts pour un système photovoltaïque interconnecté à un convertisseur DC/DC, doté d'un algorithme MPPT de type "Perturbation et Observation" (P&O) et alimentant une charge. L'approche envisagée repose sur l'utilisation des réseaux de neurones artificiels, implémentée et testée au sein de l'environnement de simulation MATLAB/Simulink. Un modèle de base du système PV a été utilisé, sur lequel des modifications paramétriques spécifiques ont été introduites pour simuler divers scénarios de défauts, incluant l'ombrage partiel, un défaut de résistance série. Les données de tension, courant et éclairement (V , I , E) ont été collectées pour ces différents scénarios sous des conditions d'éclairement variables.

L'objectif principal est de concevoir un système intelligent, basé sur un réseau de neurones de type Perceptron Multicouches (MLP) entraîné avec l'algorithme Levenberg-Marquardt, capable d'identifier avec une précision significative ces différents types de défauts simulés. Les résultats obtenus, atteignant une précision de test de l'ordre de 79.65%, démontrent l'efficacité de l'approche et sa contribution potentielle à l'amélioration de la supervision et de la maintenance des installations PV.

Ce travail de recherche est structuré en quatre chapitres principaux. Le premier chapitre sera consacré à une étude théorique approfondie des systèmes photovoltaïques, incluant leurs composants, leur modélisation, les algorithmes MPPT, ainsi qu'une classification des défauts courants. Le deuxième chapitre introduira les fondements des réseaux de neurones artificiels, leur architecture, leurs algorithmes d'apprentissage, et leurs applications dans le diagnostic des systèmes PV. Le troisième chapitre décrira la méthodologie de modélisation du système PV étudié sous MATLAB/Simulink, la simulation des différents scénarios de défauts (ombrage, résistances série), et la constitution de la base de données (V, I, E) nécessaire à l'apprentissage du réseau neuronal. Enfin, le quatrième chapitre présentera la conception du système de diagnostic, l'entraînement du réseau de neurones (MLP avec trainlm), l'analyse des résultats de simulation obtenus (incluant les matrices de confusion et les précisions par classe), ainsi qu'une discussion sur les performances (atteignant ~80% de précision de test) et les limites de l'approche proposée. Une conclusion générale synthétisera les contributions de cette étude et esquissera des perspectives pour de futurs travaux.

Chapitre I

Principes Fondamentaux de l'Énergie Solaire Photovoltaïque

1.1. Introduction Générale

L'exploitation des énergies renouvelables, définies comme celles issues de ressources naturelles se renouvelant rapidement à l'échelle humaine, est devenue un axe majeur des stratégies énergétiques mondiales. Ces ressources englobent divers phénomènes naturels tels que le rayonnement solaire, le vent, les marées, ou encore la chaleur géothermique [1]. Parmi celles-ci, l'énergie solaire photovoltaïque (PV) occupe une place prépondérante. Elle repose sur la conversion directe de l'énergie lumineuse contenue dans le rayonnement solaire (photons) en énergie électrique. Ce processus est réalisé au moyen de dispositifs semi-conducteurs appelés cellules photovoltaïques, sensibles aux longueurs d'onde du spectre visible et proche infrarouge.[2]

Typiquement, les cellules PV sont associées électriquement en série et/ou en parallèle pour atteindre les niveaux de tension et de courant souhaités, puis encapsulées dans une structure protectrice (généralement sous verre) pour former un module photovoltaïque [3]. Plusieurs modules peuvent ensuite être interconnectés pour constituer un générateur photovoltaïque (ou champ PV), capable de fournir une puissance significative compatible avec les applications visées, qu'elles soient connectées au réseau ou autonomes.[4]

Ce chapitre introductif a pour objectif de présenter les concepts fondamentaux relatifs à l'énergie solaire photovoltaïque. Il aborde successivement le contexte historique, le principe physique de l'effet photovoltaïque, la structure et le fonctionnement d'une cellule et d'un module PV. Il explore également les différentes approches de modélisation électrique, les caractéristiques de fonctionnement, les facteurs environnementaux influents, les techniques d'optimisation (MPPT) et de protection, ainsi que les indicateurs de performance des systèmes PV. Une mention particulière sera faite au potentiel et au développement de cette énergie en Algérie.

1.2. Contexte Historique

L'histoire de l'effet photovoltaïque remonte à 1839, lorsque le physicien français Edmond Becquerel observa qu'une petite quantité d'électricité était produite lorsque certains matériaux étaient exposés à la lumière. Bien qu'Albert Einstein ait fourni une explication théorique des mécanismes sous-jacents en 1905 (basée sur l'effet photoélectrique, ce qui lui valut le prix Nobel en 1921), l'effet photovoltaïque est resté pendant longtemps une curiosité de laboratoire.

Dans les années 1870, Heinrich Hertz étudia cet effet dans des solides comme le sélénium. Malgré des rendements très faibles (de l'ordre de 1%), le sélénium fut rapidement adopté par les photographes pour la fabrication de luxmètres.[8]

Des progrès significatifs furent réalisés à partir des années 1950, notamment grâce aux travaux des équipes des Bell Laboratories. En 1954, ils fabriquèrent la première cellule solaire au silicium cristallin avec un rendement de 4% (rapidement porté à 6%), en utilisant le procédé de tirage Czochralski, initialement développé pour l'industrie des semi-conducteurs. Cette dernière a d'ailleurs largement contribué au développement technologique des cellules solaires.

L'évolution de la taille des cellules PV a suivi celle des "wafers" (tranches de silicium) de l'industrie microélectronique : passant de diamètres de 5,08 cm (2 pouces) au début des années 70, à 7,62 cm (3 pouces) à la fin des années 70, puis 10,16 cm (4 pouces) au début des années 80. Une étape importante fut la mise au point de la croissance de lingots de silicium multi-cristallin de forme parallélépipédique, permettant d'obtenir des plaquettes carrées (wafers) de 10 cm de côté, atteignant aujourd'hui couramment des tailles de 12,5 cm, 15,6 cm, voire plus [8].

1.3. L'Effet Photovoltaïque

L'effet photovoltaïque est le phénomène physique fondamental permettant la conversion directe de l'énergie lumineuse en énergie électrique au sein d'un matériau semi-conducteur. Le silicium (Si) est le matériau le plus couramment utilisé, mais d'autres comme le germanium (Ge), l'arséniure de gallium (GaAs), le tellurure de cadmium (CdTe) ou le CIGS (Cuivre Indium Gallium Sélénium) sont également employés.

Pour qu'une conversion efficace ait lieu, le matériau semi-conducteur doit être structuré de manière à former une jonction, le plus souvent une jonction p-n. Celle-ci est créée en mettant en contact deux zones du même semi-conducteur dopées différemment : une zone dopée de type n (excès d'électrons libres, par dopage avec des atomes pentavalents comme le phosphore pour le silicium) et une zone dopée de type p (excès de trous, équivalents à un déficit d'électrons, par dopage avec des atomes trivalents comme le bore pour le silicium). À l'interface de ces deux zones se crée une "zone de charge d'espace" (ZCE) ou "zone de déplétion", où règne un champ électrique interne permanent [3]. C'est ce champ électrique qui est essentiel pour séparer les charges photogénérées.

1.4. L'Effet Photovoltaïque

Le fonctionnement d'une cellule photovoltaïque repose sur trois mécanismes essentiels se déroulant au sein du matériau semi-conducteur structuré en jonction p-n (voir Figure 1.1, adaptée de la Figure 5 originale) :




Figure 1.1 : Schéma de principe d'un système PV avec batterie

Absorption des photons : Lorsque la cellule est exposée à la lumière, les photons incidents pénètrent dans le matériau. Si l'énergie d'un photon ($E = h\nu$, où h est la constante de Planck et ν la fréquence de la lumière) est supérieure ou égale à la largeur de la bande interdite (gap d'énergie, E_g) du semi-conducteur, le photon peut être absorbé par le matériau. Cette absorption excite un électron de la bande de valence vers la bande de conduction.


1.Génération de paires électron-trou : L'absorption d'un photon d'énergie suffisante crée une paire électron-trou. L'électron passe dans la bande de conduction, devenant un porteur de charge mobile, tandis qu'un "trou" (une charge positive équivalente) est laissé dans la bande de valence, également mobile. Ces porteurs créés par la lumière sont appelés "photoporteurs."

2.Collecte des charges : Les paires électron-trou générées doivent être séparées et collectées pour produire un courant électrique externe.

- Les paires générées dans la zone de charge d'espace (ZCE) sont immédiatement séparées par le champ électrique interne : les électrons sont dirigés vers la zone n et les trous vers la zone p. Cela crée un "photocourant de génération."
- Les paires générées en dehors de la ZCE (dans les zones neutres n et p) peuvent diffuser aléatoirement. Si un porteur minoritaire (un trou dans la zone n ou un électron dans la zone p) atteint la ZCE avant de se recombiner, il est alors "balayé" par le champ électrique vers la zone où il devient majoritaire. Cela crée un "photocourant de diffusion."

Le courant total généré par la cellule (photocourant, I_{ph}) est la somme de ces deux contributions. Lorsque les bornes de la cellule sont connectées à une charge externe, ce

photocourant circule, fournissant de l'énergie électrique. Simultanément, un courant de diode "sombre" (I_d), dû à la polarisation de la jonction p-n, circule en sens opposé, réduisant le courant net débité par la cellule ($I = I_{ph} - I_d$).



(Figure 1.2 : Schéma illustrant la structure d'une jonction PN et le processus de génération/séparation des charges sous éclairement)

1.5. Constitution d'un Module Photovoltaïque

Une cellule PV unique délivre une tension faible (environ 0,5-0,6 V pour le silicium) et un courant dépendant de sa surface et de l'éclairement. Pour obtenir des niveaux de puissance utilisables, les cellules sont assemblées en modules.

- **Interconnexion des cellules** : Les cellules sont généralement connectées en série pour augmenter la tension de sortie du module. De fines bandes métalliques conductrices (rubans, souvent en cuivre étamé) relient la face avant (contact négatif, généralement une grille collectrice) d'une cellule à la face arrière (contact positif, souvent pleine) de la cellule suivante (Figure 1.2, adaptée de Figure 13 originale). Des connexions en parallèle peuvent aussi être utilisées (plus rarement au niveau module, plus souvent au niveau des chaînes de modules) pour augmenter le courant.




Figure 1.3: Constitution d'un module PV

- **Encapsulation** : Les cellules interconnectées sont fragiles et sensibles à l'environnement (humidité, oxygène, variations de température, chocs). Elles sont donc

encapsulées pour assurer leur protection et leur durabilité (typiquement 25 ans ou plus). Le procédé typique (Figure 1.3, adaptée de Figure 14 originale) implique de "sandwicher" les cellules entre:

- Une plaque de verre trempé en face avant : assure la protection mécanique contre les impacts (grêle, etc.) et la pénétration de la lumière, souvent traitée antireflet.
- Des feuilles d'encapsulant (généralement de l'EVA - Éthylène Acétate de Vinyle) : polymère thermoplastique transparent qui adhère aux cellules, au verre et au film arrière lors d'un processus de laminage sous vide et à chaud, assurant l'isolation électrique et la protection contre l'humidité et la corrosion.
- Un film arrière ("backsheet") : assure la protection de la face arrière et l'isolation électrique. Souvent un polymère multicouche (ex: Tedlar de DuPont, ou alternatives comme le PET, PVDF). Parfois, du verre est aussi utilisé en face arrière (modules bi-verre).

• **Cadre** : La plupart des modules sont équipés d'un cadre en aluminium qui rigidifie la structure, facilite la manipulation et le montage, et protège les bords du laminé. Un joint d'étanchéité est souvent présent entre le laminé et le cadre.

• **Boîte de jonction** : Située à l'arrière du module, elle contient les connexions électriques de sortie (câbles et connecteurs) et intègre souvent des diodes de by-pass (voir section 1.10.1).

Plusieurs modules sont ensuite connectés en série pour former des "chaînes" (strings) afin d'atteindre la tension requise par le système (ex: onduleur), et ces chaînes peuvent être mises en parallèle pour augmenter le courant total du générateur PV.





Figure 1.4: Encapsulation des cellules

1.6. Modélisation Électrique d'une Cellule Photovoltaïque

Pour analyser, simuler et concevoir des systèmes PV, il est essentiel de disposer de modèles mathématiques décrivant le comportement électrique de la cellule PV, notamment sa caractéristique courant-tension (I-V). Plusieurs modèles, de complexité variable, existent dans la littérature [23].

1.6.1. Modèle Idéal

Le modèle le plus simple représente la cellule PV comme une source de courant (I_{ph}), générant un courant proportionnel à l'éclairement solaire, en parallèle avec une diode (D) représentant la jonction p-n (Figure 1.4, adaptée de Figure 11.7 originale). L'équation courant-tension est:

$$I = I_{ph} - I_d = I_{ph} - I_0 \cdot [\exp(V / (n \cdot V_t)) - 1] \quad (\text{Eq. 1.1, adaptée de Eq. 1.2})$$

où:

- I et V sont le courant et la tension de sortie de la cellule.
- I_{ph} est le photocourant généré.
- I_d est le courant de la diode.
- I_0 est le courant de saturation inverse de la diode.
- n (ou 'a' dans le texte original) est le facteur d'idéalité de la diode (typiquement entre 1 et 2).
- $V_t = kT/q$ est la tension thermique (k : constante de Boltzmann, T : température absolue, q : charge élémentaire).

Ce modèle néglige les pertes internes.




Figure 1.5: Modèle idéal d'une cellule P V

(Figure 1.4 : Schéma électrique du modèle idéal d'une cellule PV. Inspiré de Figure 11.7 originale.)

1.6.2. Modèle à une Diode (Modèle 1-D)

Ce modèle, largement utilisé et souvent considéré comme une référence par les constructeurs, améliore le modèle idéal en ajoutant deux résistances pour tenir compte des pertes réelles (Figure 1.5, adaptée de Figure 1.VII originale):

- Une **résistance série (R_s)** : représente les résistances des contacts métalliques, des couches semi-conductrices, et des interconnexions. Elle provoque une chute de tension, surtout à fort courant.
- Une **résistance parallèle (R_p) ou shunt (R_{sh})** : représente les courants de fuite à travers la jonction ou sur les bords de la cellule, dus aux défauts ou impuretés. Elle affecte surtout le comportement à faible tension.

L'équation implicite courant-tension devient:

$$I = I_{ph} - I_0 * [\exp((V + I*R_s) / (n * V_t)) - 1] - (V + I*R_s) / R_p \text{ (Eq. 1.2, adaptée de Eq. 1.3)}$$

Ce modèle offre un bon compromis entre précision et complexité pour la plupart des applications.




Figure 1.6: Circuit équivalent d'une cellule P-Modèle 1-D

1.6.3. Modèle à Deux Diodes (Modèle 2-D)

Pour une modélisation plus fine, notamment pour certains types de cellules ou dans des conditions spécifiques, le modèle à deux diodes est utilisé (Figure 1.6, adaptée de Figure 1.VIII originale). Il représente plus précisément les différents mécanismes de recombinaison des porteurs de charge dans la cellule en utilisant deux diodes en parallèle:

- La première diode (facteur d'idéalité $n_1 \approx 1$) modélise la recombinaison par diffusion dans les régions neutres.
- La seconde diode (facteur d'idéalité $n_2 \approx 2$) modélise la recombinaison dans la zone de charge d'espace.

L'équation devient plus complexe:

$$I = I_{ph} - I_{01} * [\exp((V + I*R_s) / (n_1 * V_t)) - 1] - I_{02} * [\exp((V + I*R_s) / (n_2 * V_t)) - 1] - (V + I*R_s) / R_p \text{ (Eq. 1.3)}$$

où I_{01} , I_{02} , n_1 , n_2 sont les paramètres des deux diodes. Ce modèle est plus précis mais nécessite la détermination de plus de paramètres [6].




Figure 1. 7 : Schéma électrique équivalent d'une cellule en silicium cristallin- modèle 2-D

1.6.4. Modèle de Bishop

Le modèle de Bishop [21] est une extension du modèle à une diode qui prend en compte l'effet d'avalanche pouvant survenir lorsque la cellule est polarisée en inverse (cas de l'ombrage partiel, voir section 1.9.3). Il introduit un terme multiplicateur non linéaire $M(V_j)$ dépendant de la tension aux bornes de la jonction ($V_j = V + I \cdot R_s$), qui modélise l'augmentation du courant de fuite due à la multiplication par avalanche (Figure 1.7, adaptée de Figure II.4 originale). L'équation s'écrit:

$$I = I_{ph} - I_0 \cdot [\exp(V_j / (n \cdot V_t)) - 1] - (V_j / R_p) \cdot M(V_j) \quad (\text{Eq. 1.4, adaptée de Eq. II.9})$$

avec $M(V_j) = 1 / (1 - (V_j / V_{br})^m)$ où V_{br} est la tension d'avalanche (breakdown voltage) et m est un exposant. Ce modèle est pertinent pour l'étude des effets de l'ombrage.




Figure. I.8. Modèle de Bishop.[21]

La nature implicite des équations des modèles non-idéaux (1-D, 2-D, Bishop) nécessite généralement l'utilisation de méthodes numériques itératives (ex: Newton-Raphson) pour calculer le courant I pour une tension V donnée, ou vice-versa [22].

1.7. Caractéristiques Électriques et Paramètres Clés

Le comportement d'une cellule ou d'un module PV est décrit par ses caractéristiques courant-tension (I-V) et puissance-tension (P-V) ($P=V \cdot I$). La Figure 1.8 (adaptée de Figure 1.19 originale) montre une courbe I-V typique et la courbe P-V correspondante. Plusieurs

paramètres clés, généralement spécifiés par les fabricants dans des Conditions de Test Standard (STC : éclairement 1000 W/m^2 , température de cellule 25°C , spectre solaire AM1.5), permettent de caractériser les performances:

- Courant de Court-Circuit (I_{sc}) : Courant maximal débité par la cellule lorsque la tension à ses bornes est nulle ($V=0$). Il est directement proportionnel à l'éclairement.
- Tension de Circuit Ouvert (V_{oc}) : Tension maximale aux bornes de la cellule lorsque le courant débité est nul ($I=0$, circuit ouvert). Elle dépend logarithmiquement de l'éclairement et diminue significativement avec l'augmentation de la température.
- Point de Puissance Maximale (MPP) : Point de fonctionnement sur la courbe I-V où la puissance délivrée ($P = V * I$) est maximale (P_{max}). Les coordonnées de ce point sont V_{mpp} (tension au MPP) et I_{mpp} (courant au MPP). $P_{max} = V_{mpp} * I_{mpp}$.
- Facteur de Forme (FF - Fill Factor) : Ratio entre la puissance maximale réelle (P_{max}) et la puissance "idéale" rectangulaire ($V_{oc} * I_{sc}$). $FF = P_{max} / (V_{oc} * I_{sc}) = (V_{mpp} * I_{mpp}) / (V_{oc} * I_{sc})$ (Eq. 1.5, adaptée de Eq. I.6). Il mesure la "qualité" de la courbe I-V, son caractère plus ou moins rectangulaire. Un FF élevé (typiquement 0,75-0,85 pour le silicium cristallin) indique de faibles pertes internes.
- Rendement de Conversion (η) : Ratio entre la puissance électrique maximale délivrée par la cellule (P_{max}) et la puissance lumineuse incidente (P_{inc}) sur sa surface (A). $\eta = P_{max} / P_{inc} = (V_{oc} * I_{sc} * FF) / (E * A)$ (Eq. 1.6), où E est l'éclairement (puissance lumineuse par unité de surface, ex: W/m^2). Le rendement indique l'efficacité avec laquelle la cellule convertit l'énergie solaire en énergie électrique.




Figure 1.9 : Représentation conventionnelle de la courbe I(V) et P(V)[31]

1.8. Poursuite du Point de Puissance Maximale (MPPT)

Comme le montre la courbe P-V (Figure 1.8), il existe un unique point de fonctionnement (V_{mpp} , I_{mpp}) où la cellule ou le module PV délivre sa puissance maximale (P_{max}). Cependant, la position de ce MPP dépend fortement des conditions environnementales, principalement l'éclairement et la température (voir section 1.9). Pour maximiser l'énergie produite par le système PV dans des conditions variables, il est nécessaire d'adapter en permanence la charge vue par le générateur PV afin qu'il fonctionne toujours à son MPP. C'est le rôle de l'algorithme de Maximum Power Point Tracking (MPPT).

Le MPPT est généralement implémenté dans un convertisseur électronique de puissance (le plus souvent un convertisseur DC-DC) placé entre le générateur PV et la charge (ou le réseau via un onduleur). Le contrôleur MPPT ajuste le rapport cyclique (ou un autre paramètre de commande) du convertisseur pour faire varier la tension et le courant de fonctionnement du générateur PV, cherchant activement et suivant le MPP [11, 12].

1.8.1. Algorithme Perturber et Observer (P&O)

L'algorithme P&O est l'une des méthodes MPPT les plus couramment utilisées en raison de sa simplicité et de son efficacité raisonnable [7]. Son principe est le suivant (Figure 1.9, adaptée de Figure I-21, et Figure 1.10, adaptée de Figure I-22):

1. Mesurer la tension (V_{pv}) et le courant (I_{pv}) instantanés du générateur PV.
2. Calculer la puissance instantanée ($P_{pv} = V_{pv} * I_{pv}$).
3. Introduire une petite perturbation (augmentation ou diminution) de la tension de référence (V_{ref}) du convertisseur (ou de son rapport cyclique).
4. Mesurer la nouvelle puissance ($P_{pv}(k)$) et la comparer à la puissance précédente ($P_{pv}(k-1)$).
5. Si la puissance a augmenté ($\Delta P > 0$), la perturbation a rapproché le point de fonctionnement du MPP. On maintient donc la même direction de perturbation pour le prochain cycle.
6. Si la puissance a diminué ($\Delta P < 0$), la perturbation a éloigné le point de fonctionnement du MPP (ou l'a dépassé). On inverse alors la direction de perturbation pour le prochain cycle.
7. Le processus est répété périodiquement, ce qui fait osciller légèrement le point de fonctionnement autour du MPP réel.




Figure I-10: Caractéristique Ppv (Vpv) et fonctionnement de la méthode Perturbation et Observation




Figure I-11: Organigramme de la méthode Perturbation et Observation[22]

1.10.1. simulation de la commande MPPT numérique « P&O »:

• Les conditions idéales conventionnelles sont très rarement remplies dans la pratique, et la variation de ces conditions est aléatoire et imprévisible. Le changement de l'ensoleillement et de la température influe directement sur les caractéristiques courant-tension et puissance-tension. C'est pour cela l'intégration d'une commande MPPT est obligatoire. [23]

- **Simulation de la méthode MPPT:**




Figure I-12: Schéma block de la commande MPPT




Figure I -13: La puissance aux bornes du GPV




Figure I - 14 : La tension aux bornes du GPV




Figure I-15: Rapport cyclique correspondant au contrôleur MPPT P&O

D'autres algorithmes MPPT existent (Conductance Incrémentale, Tension Constante, etc.), chacun avec ses avantages et inconvénients en termes de vitesse de convergence, de précision, de complexité et de comportement sous éclairage variable ou partiel.

1.9. Facteurs Influent sur les Performances

Les caractéristiques électriques et la puissance délivrée par un module PV sont fortement influencées par les conditions environnementales [20].

1.9.1. Ensoleillement (Irradiance)

L'éclairement solaire (mesuré en W/m^2) a un impact majeur et quasi linéaire sur le courant généré (I_{ph} , et donc I_{sc} et I_{mpp}). La tension (V_{oc} , V_{mpp}) varie peu (logarithmiquement) avec l'éclairement. Par conséquent, la puissance maximale (P_{max}) est approximativement proportionnelle à l'éclairement (Figure 1.14, adaptée de Figure I-17 originale).




Fig I-16: influence de l'ensoleillement sur le point de puissance maximal (PPM)

1.9.2. Température

La température de la cellule a un effet significatif, principalement sur la tension. La tension de circuit ouvert (V_{oc}) et la tension au MPP (V_{mpp}) diminuent de manière quasi

linéaire lorsque la température augmente (typiquement $-0,3\%$ à $-0,4\%$ par $^{\circ}\text{C}$ pour le silicium cristallin). Le courant de court-circuit (I_{sc}) augmente très légèrement avec la température, mais cet effet est négligeable par rapport à la diminution de la tension. En conséquence, la puissance maximale (P_{max}) diminue notablement avec l'augmentation de la température (typiquement $-0,4\%$ à $-0,5\%$ par $^{\circ}\text{C}$) (Figure 1.15, adaptée de Figure I-18 originale). Le maintien des modules à une température la plus basse possible est donc bénéfique pour la production d'énergie.




Figure I-17 : influence de la température sur la tension de circuit ouvert (V_{co})

1.9.3. Ombrage Partiel

L'ombrage, même partiel, d'une ou plusieurs cellules dans un module ou d'un module dans une chaîne série peut avoir des conséquences très négatives. Lorsqu'une cellule est ombragée, son courant généré (I_{ph}) diminue fortement. Comme le courant est le même dans toute la chaîne série, la cellule ombragée peut être forcée de fonctionner en polarisation inverse pour laisser passer le courant généré par les cellules bien éclairées. Cette polarisation inverse peut atteindre des tensions élevées, dissipant de la puissance ($P = V * I < 0$) sous forme de chaleur. Cela peut entraîner un échauffement localisé important ("point chaud" ou "hot spot"), qui peut endommager irrémédiablement la cellule ou le module (dégradation de l'encapsulant, voire risque d'incendie).[7]

De plus, l'ombrage partiel crée des caractéristiques I-V et P-V complexes avec plusieurs maxima locaux de puissance (Figure 1.16, adaptée de Figure I-20 originale), ce qui peut perturber le fonctionnement des algorithmes MPPT standards et réduire significativement la puissance totale extraite. L'utilisation de diodes bypass est essentielle pour atténuer ces problèmes (voir section 1.10.1).




Figure I-18: Courbe I-V et P-V dans des conditions d'ombrage partiel[20].




Figure I-19: Fonctionnement du solaire PV dans des conditions d'ombrage partiel[20].

1.10. Mécanismes de Protection des Systèmes PV

Pour assurer la sécurité, la fiabilité et la longévité des systèmes PV, divers dispositifs de protection sont nécessaires. Deux types de diodes jouent un rôle crucial :

1.10.1. Diodes Bypass (ou de Dérivation)

Les diodes bypass sont connectées en parallèle inverse aux bornes d'une cellule ou (plus couramment) d'un groupe de cellules en série à l'intérieur d'un module (souvent intégrées dans la boîte de jonction). Leur rôle est de fournir un chemin alternatif au courant lorsque la cellule ou le groupe de cellules est ombragé ou défaillant [39]. Si une cellule ombragée commence à se polariser en inverse, la tension inverse à ses bornes augmente. Lorsque cette tension atteint le seuil de conduction de la diode bypass (environ 0,6-0,7 V), la diode devient passante et dévie le courant de la chaîne autour de la cellule/groupe ombragé. Cela limite la tension inverse aux bornes de la cellule ombragée, prévenant ainsi l'échauffement excessif (hot spot)

et minimisant la perte de puissance de l'ensemble de la chaîne (Figure 1.18, adaptée de Figure 1.15 originale). Typiquement, un module contient 2 à 4 diodes bypass.




Figure 1.20: Module de 36 cellules protégé par deux diodes de bypass

(Figure 1.18 : Schéma d'un module PV avec des cellules en série et des diodes bypass protégeant des groupes de cellules. Inspirée de Figure 1.15 originale.)

1.10.2. Diodes de Blocage (ou Anti-retour)

Les diodes de blocage sont connectées en série avec chaque chaîne de modules, principalement dans les systèmes où plusieurs chaînes sont mises en parallèle [39]. Leur fonction est d'empêcher le courant de circuler en sens inverse dans une chaîne, par exemple:

- La nuit, pour éviter que les batteries (dans un système autonome) ne se déchargent à travers les modules.
- En journée, pour empêcher qu'une chaîne fortement éclairée ne débite du courant dans une chaîne voisine moins productive (ex: ombragée ou dégradée), ce qui entraînerait des pertes et un risque d'échauffement pour la chaîne réceptrice.

La diode de blocage ne laisse passer le courant que dans le sens de la production (de la chaîne vers la charge commune) (Figure 1.19, adaptée de Figure 1.16 et Figure 2.2 originales). Elles introduisent une légère chute de tension et donc une petite perte de puissance, mais sont essentielles pour la protection dans les systèmes multi-chaînes ou avec batteries.




Figure I.21: diode anti-retour placée à la sortie du string et avant la charge et la connexion des autres strings.




Figure 1.22 : Schématisation d'un GPV élémentaire avec diodes by-pass et diode anti-retour.




Figure 1.23 : Caractéristiques I-V d'une cellule solaire ensoleillée et dans l'obscurité.

1.11. Indicateurs de Performance

Au-delà des paramètres intrinsèques (V_{oc} , I_{sc} , FF, η) mesurés en STC, l'évaluation de la performance réelle d'une installation PV sur le terrain nécessite des indicateurs globaux qui tiennent compte de l'ensemble des facteurs et des pertes. L'Indice de Performance (ou Performance Ratio, PR) est l'un des plus utilisés [4]. Il compare l'énergie réellement produite par le système (E_{out}) sur une période donnée à l'énergie qu'il aurait théoriquement pu

produire (E_{ref}) dans les mêmes conditions d'ensoleillement et de température s'il fonctionnait avec son rendement nominal (STC).

$$PR = E_{out} / E_{ref} = E_{out} / (\Sigma (H * A * \eta_{STC}))$$

où H est l'irradiation solaire reçue sur le plan des modules (en kWh/m²), A la surface des modules, et η_{STC} le rendement nominal. Le PR est exprimé en pourcentage et reflète l'ensemble des pertes du système (température, câblage, onduleur, salissure, ombrage, indisponibilité, etc.). Un PR élevé (typiquement 75-85% pour des systèmes bien conçus et entretenus) indique une bonne qualité globale de l'installation [4]. Les facteurs environnementaux (température, ombrage, salissure) et techniques (qualité des composants, conception, installation) influencent directement le PR [4].

1.12. Avantages et Inconvénients de l'Énergie Solaire Photovoltaïque

L'énergie solaire photovoltaïque présente de nombreux atouts, mais aussi quelques limitations.

Avantages [Adapté de la section 1.1 du texte original]:

- **Énergie propre et renouvelable** : La production d'électricité PV n'émet pas de gaz à effet de serre ni de polluants atmosphériques en fonctionnement. Le soleil est une ressource inépuisable à l'échelle humaine.
- **Fiabilité et faible maintenance** : Les modules PV sont statiques (pas de pièces mobiles) et très fiables, avec des durées de vie garanties souvent de 25 ans. La maintenance est généralement limitée au nettoyage périodique.
- **Modularité et disponibilité géographique** : Les systèmes PV peuvent être dimensionnés pour une large gamme de puissances (du W au GW) et installés presque partout où il y a du soleil, y compris dans des zones isolées non connectées au réseau.
- **Production décentralisée** : L'électricité peut être produite au plus près du lieu de consommation, réduisant les pertes de transport et de distribution.
- **Silence de fonctionnement** : Les modules PV fonctionnent silencieusement.
- **Réduction de la vulnérabilité énergétique** : Contribue à la diversification du mix énergétique et à la sécurité d'approvisionnement.

Inconvénients [Adapté de la section "En ce qui concerne les inconvénients"]:

- **Intermittence et variabilité** : La production dépend directement de l'ensoleillement, qui varie au cours de la journée, des saisons, et selon les conditions météorologiques. Cela pose des défis pour l'équilibre offre-demande d'électricité.

- **Nécessité de stockage (pour certaines applications) :** Pour assurer une alimentation continue (la nuit, par temps couvert) dans les systèmes autonomes, un stockage d'énergie (batteries) est nécessaire, augmentant le coût et la complexité. Pour les systèmes connectés au réseau, la flexibilité du réseau ou d'autres sources est sollicitée.
- **Coût d'investissement initial :** Bien que les coûts aient considérablement baissé, l'investissement initial pour une installation PV reste significatif, même si la rentabilité à long terme est souvent assurée par l'absence de coût de combustible.
- **Rendement de conversion limité :** Les rendements commerciaux des modules silicium sont typiquement de 15-22%, bien que des technologies plus avancées atteignent des valeurs supérieures. La limite théorique (Shockley-Queisser) pour une jonction simple est d'environ 33%.
- **Occupation d'espace :** Les grandes centrales PV nécessitent une surface au sol importante, ce qui peut entrer en compétition avec d'autres usages (agriculture, biodiversité). L'intégration sur les toitures et les façades (BIPV) est une solution partielle.
- **Impact environnemental du cycle de vie :** Bien que propre en fonctionnement, la fabrication des modules PV requiert de l'énergie et des matériaux (silicium purifié, métaux, verre, polymères), et la gestion de leur fin de vie (recyclage) est un enjeu croissant.

Malgré ces inconvénients, le marché photovoltaïque mondial est en pleine expansion, tiré par la baisse des coûts, les politiques de soutien et la prise de conscience environnementale [22]. La recherche continue vise à améliorer les rendements, réduire les coûts et l'impact environnemental, et développer des solutions d'intégration et de gestion de l'intermittence.

1.13. Conclusion du Chapitre

Ce premier chapitre a permis de poser les bases de l'énergie solaire photovoltaïque. Partant d'une introduction générale et d'un rappel historique, nous avons détaillé le principe physique de la conversion photovoltaïque au sein d'une jonction p-n. La structure typique d'un module PV et les différentes approches pour modéliser électriquement son comportement ont été présentées. Les caractéristiques électriques fondamentales (I-V, P-V) et les paramètres clés qui en découlent (V_{oc} , I_{sc} , P_{max} , FF, η) ont été définis. L'importance cruciale de l'optimisation du point de fonctionnement via les algorithmes MPPT, ainsi que l'influence prépondérante des facteurs environnementaux (éclairage, température, ombrage) sur les performances, ont été soulignées. Les mécanismes essentiels de protection par diodes (bypass et blocage) ont été expliqués. Enfin, les principaux avantages et inconvénients de cette technologie ont été résumés.

La compréhension de ces principes fondamentaux est indispensable pour aborder l'analyse, la conception, la simulation et le diagnostic des systèmes photovoltaïques, qui feront l'objet des chapitres suivants de ce mémoire.

Chapitre II:

Modélisation du défaut en générateur PV et méthodes de diagnostique

II -1 introduction:

Nous décrivons dans cette partie les différents défauts et anomalies associés à une installation photovoltaïque.

Au cours de son fonctionnement, une installation PV peut être éventuellement soumise à différents défauts et conditions de fonctionnement anormales. Les défauts et les anomalies apparus varient d'une installation à une autre en fonction de sa conception, installation, opération et maintenance.

II -2 Modélisation du générateur PV en condition de défaut:

II-2-1 Classification des défauts pour les besoins de la modélisation

Une compréhension et une prédiction fiables des performances des systèmes photovoltaïques (PV) dans des conditions de fonctionnement non optimales, incluant les situations de défaut, nécessitent une approche systématique pour classifier les défaillances potentielles. En s'appuyant sur l'analyse des retours d'expérience opérationnelle et des modes de défaillance courants observés dans les installations PV.

les défauts prédominants ont été recensés et catégorisés selon le composant ou le sous-système principalement affecté. Cette classification conduit à l'identification de six catégories principales:

- Défauts au sein du générateur photovoltaïque.
- Défauts relatifs à la boîte de jonction.
- Défauts émanant du système de câblage.
- Défaillances au niveau du système de protection.
- Dysfonctionnements de l'onduleur.
- Anomalies dans le système d'acquisition de données.

Au sein de chaque catégorie, les types de défauts spécifiques sont ensuite caractérisés plus en détail. Cette caractérisation inclut leur conséquence principale sur le fonctionnement du système, une évaluation de leur niveau de criticité (typiquement classé comme faible (1), moyen (2) ou élevé (3)), une estimation de leur fréquence d'occurrence (également : faible (1), moyenne (2) ou élevée (3)), ainsi que la phase la plus probable de leur apparition (Origine : C - Conception ; I - Installation ; E - Exploitation). Cette description détaillée, qui sera présentée ultérieurement sous forme de tableaux, fournit une base structurée pour la sélection et la simulation des scénarios de défauts pertinents pour cette étude. En complément, des exemples visuels illustrent certains des défauts abordés."

II-2-1-1 Défauts dans le générateur photovoltaïque:

Dans un générateur photovoltaïque on trouve différents défauts et ils sont représentés dans le tableau suivant :

Défauts	Conséquences	Cri.	Occ.	Ori.
Dégradation des modules par vandalisme	Diminution des performances, non Fonctionnement de l'installation	3	2	E
Mauvaise orientation et/ou Inclinaison des modules	Ombrage, diminution des performances	2	3	C,I
Module mal ou pas ventilé	Echauffement	2	2	I,C
Module mal fixé	Déplacement du module, diminution Des performances	2	2	I,C
Modules non câblée	Perte d'étanchéité, détérioration des cellules, diminution du shunt, diminution des performances	2	2	I,C
Corrosion du cadre des modules	Perte d'étanchéité, détérioration des Cellules	3	1	E
Foudre	Détérioration des modules	3	1	E
Tempête	Module arraché, cassé	3	1	E
Pénétration de l'humidité	Hot spot, augmentation du courant de fuite, corrosion, perte d'adhérence et d'isolation, diminution de la résistance De CC à la terre	3	1	E
Foudre sur l'installation	Destruction des modules	3	1	E
Modules de performances Différentes	Diminution des performances du champ	1	3	I,C
Ombrage partiel (feuilles d'arbre, déjections)	Hot spot, détérioration de cellules	2	1	E
Inclinaison des modules trop faible	Stagnation d'eau, dépôt de terre, prolifération de champignons, problème d'étanchéité	2	1	C,I

Important courant de fuite	Echauffement	2	1	E
Echauffement des modules Par la boîte de connexion	Décollement du Tedlar, diminution des performances	2	1	C,I
Nid d'insectes sur les Modules	Diminution des performances	2	1	E
Panneaux inaccessibles	Nettoyage impossible	1	2	C,I
Module produisant moins que prévu	Diminution des performances	1	1	E
Apparition de bulles à la surface des modules	Diminution des performances	1	1	E

Tab. II.1 :Défauts et leurs conséquences dans un générateur




Fig. II.1:Exemples de défauts rencontrés dans les générateurs photovoltaïque PV

II-2-1-2 Défauts dans la boîte de jonction:

Le tableau suivant présente les défauts rencontrés dans la boîte de jonction

Défauts	Conséquences	Cri.	Occ.	Ori.
Absence de parafoudre ou Protection foudre inadaptée	Destruction en cas de foudre	3	2	C,I
Presse-étoupe mal serré	Corrosion des contacts, rupture du circuit électrique	2	3	I
Liaison de mise à la terre non fixée ou sectionnée	Pas de mise à la terre	2	2	I
Boîte de jonction sans presse-étoupe	Pas d'étanchéité, corrosion des contacts, rupture du circuit électrique	2	2	I
Presse-étoupe en caoutchouc	Corrosion des contacts, rupture du circuit électrique	2	2	C,I
Infiltration d'eau par les vis de fixation	Corrosion des contacts, rupture du circuit électrique	2	2	I
Boîte de jonction non repérée	Problème pour contrôle et maintenance	1	3	I
Déconnexion des soudures	Arc électrique, incendie, diminution des performances	2	1	E,I
Liaison sans protection	Destruction de la liaison	2	1	C,I
Pénétration de l'eau ou de l'humidité	Corrosion des connexions, des diodes, des bornes, incendie	2	1	I

Tab. II.2: Les défauts dans la boîte de jonction.



Fig. II.2 : Exemples de défauts rencontrés dans les boîtes de jonction

II-2-1-3 Défauts dans le système de câblage:

Un récapitulatif de défauts rencontré dans le système de câblage est donné dans le tableau suivant :

Défauts	Conséquences	Cri.	Occ.	Ori.
Mauvais dimensionnement des Câbles	Chute de tension > 3%, échauffement	2	3	C
Connexion desserrée ou cassée	Arc électrique, incendie, destruction de la boîte de jonction, destruction de diodes	2	3	I,E
Principe de câblage en goutte d'eau non respecté	Mauvais câblage	2	3	I
Câbles non fixes	Boucle de câblage, circuit ouvert	2	2	I
Mauvais câblage	Court-circuit, claquage des diodes anti-retour, destruction des connecteurs (circuit ouvert), aléas de Fonctionnement sur disjoncteur	2	2	I
Toron	Boucle électromagnétique	2	2	I
Câbles d'arrivée des sous Champs entamés lors du dénudage	Mauvais câblage, faux contacts, circuit ouvert, arc électrique	2	2	I
Câble mal dénudé	Mauvais câblage, faux contacts, circuit ouvert, arc électrique	2	2	I
Absence de graisse de silicone	Humidité	2	2	I
Bornes rouillées	Faux contacts, circuit ouvert, arc électrique	2	2	E
Câbles non fixes	Boucle de câblage, circuit ouvert	2	1	I
Boîte de connexion décollée	Connexion des cellules en série endommagée	2	1	I

Tab. II.3: Les défauts dans le système de câblage.



Fig. II.3:Exemples de défauts rencontrés dans le câblage

II-2-1-4 Défauts dans le système de protection:

Les différents défauts qu'on trouve dans le système de protection est donné dans le tableau suivant :

Défauts	Conséquences	Cri.	Occ.	Ori .
Protections inappropriées ou mal dimensionnées	Court-circuit ,hots pot, incendie, arrêt de l'installation	2	2	C
Interrupteur, disjoncteur inapproprié	Arc électrique, incendie, destruction à l'ouverture	3	1	C
Disjoncteur différentiel non conforme à la norme	Non déclenchement, tension entre neutre et terre	3	1	C
Armoire électrique posée à même le sol à l'extérieur	Dysfonctionnement en cas de pluie	3	1	C,I
Pas de possibilités de sectionnement extérieur au coffret	Problème de sécurité	1	3	C
Mauvaise dissipation de la chaleur des diodes	Echauffement	2	1	C,I
Sous dimensionnement des diodes de by-pass	Hots pot, destruction des diodes, échauffement de la boîte de jonction	2	1	C
Diode mal connectée	Non fonctionnement des diodes, absence de protection contre les courants inverses	2	1	I,E

Inversion de la polarité des diodes au montage	Non fonctionnement des diodes, court circuit, hots pot	2	1	I,E
Phénomènes de résonance	Non fonctionnement des fusibles et des Protections de surtension	2	1	C
Vieillissement des disjoncteurs	Non fonctionnement des disjoncteurs	1	1	E

Tab. II.4: Les défauts dans le système de protection.




Fig. II.4:Exemples de défauts de diodes by-pass

II-2-1-5 Défauts dans l'onduleur:

Le tableau ci-dessous montre les défauts rencontrés dans l'onduleur:

Défauts	Conséquences	Cri.	Occ.	Or i.
Dégradation à cause la chaleur	Détérioration de l'onduleur, des connexions	3	2	E, C,I
Faux contact	Arrêt de l'onduleur	3	2	I
Surtension	Déconnexion de l'onduleur	3	2	C
Fusible fondu	Arrêt de l'onduleur	3	2	E,I
Onduleur sous dimensionné	Destruction de l'onduleur	2	3	C
Défaut d'isolement	Détérioration de l'onduleur	3	1	C,I
Onduleur installé dans un Lieu non étanche	Panne de l'onduleur	3	1	I,C
Onduleur mal fixé	Chute de l'onduleur	3	1	I
Onduleur sur dimensionné	Perte de puissance, diminution des performances	3	1	C

Mauvais choix de la tension nominale d'entrée	Diminution des performances	2	1	C
Onduleur non mis à la terre	Disjoncteur différentiel non actif	1	2	I
Perte de la mémoire (mauvaise manipulation du technicien)	Perte des données	1	1	E
Afficheur de cristaux liquide endommagé ou illisible	Pas d'information sur le fonctionnement	1	1	E

Tab. II.5: Les défauts dans l'onduleur.**II-2-1-6 Défauts dans le système d'acquisition:**

Le tableau suivant donne les défauts rencontrés dans le système d'acquisition :

Défauts	Conséquences	Cri.	Occ.	Or i.
Coupure de courant	Perte de données	1	3	E
Son de d'ensoleillement non câblé	Mesure impossible	1	3	I
Défaut de paramétrage	Enregistrement de fausses données	1	3	I
Mauvais câblage des shunts de mesure	Mesure impossible ou erronée	1	3	I
Carte électronique mal positionnée	Touches inactives, défaut de commande	1	2	I
Non configuré pour l'acquisition des données	Pas de donnée enregistrée	1	2	I
Armoire fermée par le service de maintenance ou Présence d'un code	Lecture des données par l'exploitant impossible	1	2	E,I
Bornier de mesures et de sonde de Température trop proches	Câblage difficile, risque de court circuit	1	1	C,I
Acquisition de données vierge	Aucune information enregistrée	1	1	E

Mesure de données non nulles alors que système PV à l'arrêt	Fiabilité des données	1	1	E
---	-----------------------	---	---	---

Tab. II.6: Les défauts dans le système d'acquisition. [27].

II-3 Méthodes de Détection et de Diagnostic des Défauts dans les Systèmes Photovoltaïques (PV)

Les performances et la fiabilité des systèmes photovoltaïques peuvent être compromises par diverses anomalies. Celles-ci résultent principalement des conditions environnementales des contraintes d'exploitation ou encore de défauts inhérents à la fabrication. Ces anomalies peuvent affecter l'ensemble de la chaîne de conversion énergétique, depuis les modules PV jusqu'aux convertisseurs de puissance, en passant par le câblage et les dispositifs de protection .[28]

À l'instar de nombreux systèmes industriels, la mise en œuvre de systèmes de surveillance et de diagnostic est devenue cruciale pour les installations PV. Leur rôle est essentiel pour le contrôle continu du fonctionnement et la détection précoce des défauts, contribuant ainsi à la maintenance de la performance et à la sécurité de l'installation.[28]

Dans ce contexte, la recherche a conduit au développement de multiples méthodes de diagnostic spécifiquement adaptées aux centrales photovoltaïques. Ces méthodes se distinguent les unes des autres par plusieurs caractéristiques clés, notamment : la rapidité avec laquelle une anomalie est détectée, l'optimisation des données d'entrée requises pour le diagnostic, et la sélectivité, qui réfère à la capacité de la méthode à différencier et identifier correctement les divers types de défauts.

De manière générale, ces approches de diagnostic peuvent être classifiées en deux grandes catégories: [29]

Méthodes non électriques [30, 31] : Ces techniques sont principalement employées pour détecter des défauts observables physiquement, tels que la décoloration, le brunissement ('browning'), l'encrassement ou les salissures de surface, l'apparition de points chauds ('hot spots'), les bris de cellules ou de verre, ainsi que la délamination des modules.

Méthodes électriques : Exploitant les mesures de grandeurs électriques ces méthodes visent à détecter et diagnostiquer les défauts affectant les modules, les chaînes ou l'ensemble du générateur PV. Elles sont particulièrement utiles pour identifier les défauts d'arc électrique, les défauts de mise à la terre, les défaillances de diodes bypass, les circuits ouverts, les courts-circuits, etc.

La figure ci-après [Figure II-5] illustre la classification de ces différentes méthodes de diagnostic."




Figure II-5: Méthodes de diagnostic de défauts d'un générateur PV.

II-3-1-1 Méthodes de Détection et de Diagnostic des Défauts dans les Systèmes Photovoltaïques (PV)

Les performances et la fiabilité des systèmes photovoltaïques peuvent être compromises par diverses anomalies. Celles-ci résultent principalement des conditions environnementales des contraintes d'exploitation ou encore de défauts inhérents à la fabrication. Ces anomalies peuvent affecter l'ensemble de la chaîne de conversion énergétique, depuis les modules PV




Figure II.6: Exemple de la localisation de défauts par la caméra thermique.

II-3-1-2 Méthode de réflectométrie

La réflectométrie fonctionne sur le même principe que celui d'un radar : une impulsion ou un signal est transmis dans le champ PV à diagnostiquer. N'importe quelle discontinuité (fissure, défaut, court-circuit, circuit ouvert) se comporte comme un obstacle à cette impulsion

incidente et provoque une réflexion. Puis de mesurer les échos retournés. Le retard et l'amplitude des échos sont utilisés pour obtenir des informations sur la localisation, la caractérisation et éventuellement la prédiction du défaut. Elle a seulement besoin d'un point d'accès, qu'il demande une précision dans leur détermination. Néanmoins, elle est adaptée pour les réseaux de topologie complexes. Aussi, elle peut être intégrée dans les systèmes de contrôle. Cependant, la détection précoce de défauts d'un champ PV nécessite un traitement de données puissant avec un échantillonnage très rapide, ce qui augmente la complexité et le coût du système de diagnostic.

Cette méthode a été utilisée par [33-34], et par "T. Takashima et al" [35]. Dans le but de détecter le défaut de type "circuit ouvert", "court-circuit" et "augmentation de l'impédance de la connectique", dans un string photovoltaïque.




Figure II.7: Principe de la réflectométrie pour localiser le défaut dans un string PV.

II-3-2 Méthodes électriques

Les données d'entrée pour ces méthodes sont les paramètres électriques (courant, tension et puissance). Quatre principaux types de méthodes ont été proposées dans la littérature sur laquelle nous nous concentrons dans ce paragraphe.

II-3-2-1 Méthode d'analyse de la puissance produite

Elle est appliquée par [36-37]. Elle est efficace pour déterminer si un champ PV fonctionne normalement ou non. Cette méthode utilise l'irradiation solaire et les données de température des modules pour prédire la sortie du panneau photovoltaïque avec un modèle de circuit équivalent. Deux indicateurs correspondant aux pertes thermiques et aux pertes de puissance sont définis.

L'algorithme de détection reconnaît un fonctionnement défectueux du système lorsque les pertes mesurées sont beaucoup plus élevées que les pertes simulées. Des indicateurs basés sur les rapports des valeurs de courant et de tension simulées et mesurées sont alors utilisés pour identifier les défauts de chaîne ou les défauts d'ombrage [38].

II-3-2-2 Méthode d'analyse des caractéristiques I-V et P-V

Le recueil de grandeurs mesurées (courant et tension) à différents points du champ photovoltaïque permet de détecter et de localiser précisément l'emplacement du défaut à l'aide Des capteurs placés dans le champ PV .Plusieurs études sont menées dans ce cadre par différents auteurs [39,40,41].

II-3-2-3 Méthode d'analyse du point de fonctionnement

Cette méthode repose sur l'analyse et la comparaison du point de puissance maximale actuel de l'installation PV et celui attendu [42-43]. Cette méthode offre la possibilité de détecter automatiquement la présence d'un défaut sans interrompre le système.

II-4 Conclusion:

Dans ce chapitre, nous démontrons une approche pour modéliser les systèmes PV défectueux pour divers défauts et distorsions associés à l'installation PV. Nous avons également décrit les différentes méthodes de diagnostic des systèmes photovoltaïques où leur rôle est de surveiller le fonctionnement des cellules photovoltaïques afin de détecter, identifier et diagnostiquer les dysfonctionnements affectant ces performances et leur sécurité. .

Chapitre III

**Réseaux de Neurones Artificiels
: Fondements, Architectures et
Apprentissage**

III.1.Introduction

Ce chapitre fournit une exposition détaillée des Réseaux de Neurones Artificiels (RNA), une catégorie d'algorithmes d'apprentissage automatique dont les paradigmes computationnels s'inspirent des mécanismes neuronaux intrinsèques au cerveau biologique. Les RNA se sont distingués par leur capacité à modéliser des relations complexes, souvent fortement non-linéaires, présentes au sein de vastes ensembles de données. Cette caractéristique les rend particulièrement adaptés à des tâches exigeantes telles que la classification, la régression, et la reconnaissance de formes, rencontrées dans de nombreux domaines de l'ingénierie. Dans le contexte spécifique de cette thèse, qui vise à développer une méthode de classification et de diagnostic des défauts pour un système photovoltaïque (PV) intégrant un convertisseur DC/DC et un algorithme MPPT P&O, l'utilisation de Réseaux de Neurones Récurrents (RNN) est envisagée. Par conséquent, une compréhension approfondie des principes fondamentaux régissant les RNA est primordiale. Ce chapitre a pour objectif d'établir ces bases conceptuelles, en commençant par un aperçu historique et l'exploration de leur inspiration biologique. Il procédera ensuite à la description du modèle mathématique du neurone formel, des diverses fonctions d'activation employées, et des architectures de réseaux prédominantes, incluant les réseaux à propagation avant (non-bouclés) et les réseaux récurrents (bouclés). Les stratégies et typologies d'apprentissage fondamentales, notamment supervisé et non-supervisé, seront également élucidées. Finalement, la présentation de modèles spécifiques, de leurs domaines d'application caractéristiques, ainsi qu'une illustration de l'évaluation des résultats d'entraînement, permettront de consolider les connaissances théoriques nécessaires à l'application subséquente des RNN à la problématique de diagnostic de défauts étudiée.

III.2. Aperçu Historique

Le développement des réseaux de neurones artificiels trouve ses origines au milieu du XXe siècle, avec des contributions pionnières jetant les bases théoriques et computationnelles du domaine.

- 1943: W. McCulloch et W. Pitts proposent un modèle mathématique simplifié du neurone biologique, établissant un premier cadre formel pour les unités de calcul neuronal [Source si applicable].
- 1949: D. Hebb, dans son ouvrage "The Organization of Behavior", postule une règle d'apprentissage fondamentale (apprentissage Hebbian), suggérant que la force d'une

connexion synaptique augmente si les neurones pré- et post-synaptiques sont activés simultanément [Source Hebb].

- 1958: F. Rosenblatt développe le Perceptron, un modèle de neurone artificiel capable d'apprentissage, et démontre son théorème de convergence pour les problèmes linéairement séparables [Source Rosenblatt].
- 1960: B. Widrow et M. Hoff introduisent l'Adaline (Adaptive Linear Element) et la règle d'apprentissage LMS (Least Mean Squares), posant les bases de nombreux algorithmes d'apprentissage adaptatif [Source Widrow & Hoff].
- 1969: M. Minsky et S. Papert publient "Perceptrons", une analyse critique mettant en lumière les limitations fondamentales du Perceptron simple (incapacité à résoudre des problèmes non linéairement séparables comme le XOR), ce qui entraîna une période de ralentissement de la recherche dans le domaine [Source Minsky & Papert].
- 1972: T. Kohonen propose des modèles de mémoires associatives auto-organisatrices, précurseurs des cartes auto-organisatrices (SOM) [Source Kohonen].
- 1982: J. Hopfield introduit les réseaux de Hopfield, des réseaux récurrents avec une dynamique basée sur une fonction d'énergie, garantissant la convergence vers des états stables et ravivant l'intérêt pour les architectures récurrentes.[1]

Ces jalons historiques illustrent l'évolution progressive des concepts, des modèles mathématiques aux algorithmes d'apprentissage, qui constituent aujourd'hui le fondement des RNA modernes.

III.3. Réseaux de Neurones Artificiels : Définition Générale

Un Réseau de Neurones Artificiel (RNA) peut être défini comme un système de traitement de l'information dont la structure et le fonctionnement s'inspirent des réseaux neuronaux biologiques. Il s'agit d'un construit computationnel composé d'un grand nombre d'unités de traitement simples, interconnectées et organisées en couches, appelées neurones artificiels ou nœuds. Chaque neurone opère de manière essentiellement parallèle et locale, traitant les signaux qu'il reçoit via ses connexions pondérées. L'ensemble du réseau forme un système capable d'apprendre à partir de données pour réaliser des tâches spécifiques, telles que la reconnaissance de formes, la classification, la prédiction ou le contrôle, sans nécessiter une programmation explicite des règles de la tâche. La capacité du réseau à exécuter ces fonctions émerge de l'ajustement adaptatif des forces des connexions (poids synaptiques) durant une phase d'apprentissage basée sur des exemples.

III.4. Inspiration du Modèle Biologique

Les RNA tirent leur inspiration conceptuelle de la structure et du fonctionnement du système nerveux central, et plus particulièrement du cerveau humain. Ce dernier est constitué de milliards de cellules nerveuses, les neurones biologiques, interconnectées via des jonctions appelées synapses.




Figure III.1: Exemple de neurone biologique.

Un neurone biologique typique (Figure III.2) reçoit des signaux électriques ou chimiques via ses dendrites. Ces signaux sont intégrés au niveau du corps cellulaire (Soma). Si l'excitation cumulée dépasse un certain seuil, le neurone génère un potentiel d'action, un signal électrique qui se propage le long de son axone unique. Cet axone se ramifie ensuite pour transmettre le signal à d'autres neurones via les synapses.

Un aspect crucial est la plasticité synaptique : la force ou l'efficacité d'une synapse peut être modifiée en fonction de l'activité neuronale passée. Cette plasticité est considérée comme le substrat biologique de l'apprentissage et de la mémoire. Les RNA tentent de capturer certains de ces principes fondamentaux : traitement distribué et parallèle, sommation pondérée des entrées, seuil d'activation, et modification adaptative des poids synaptiques comme mécanisme d'apprentissage.

III.5. Le Neurone Formel

Le neurone formel, ou neurone artificiel, est une abstraction mathématique simplifiée du neurone biologique. Il constitue l'unité de traitement élémentaire d'un RNA. Son fonctionnement se décompose typiquement en deux étapes principales :

1. Agrégation des entrées : Le neurone reçoit plusieurs signaux d'entrée (provenant soit de neurones de la couche précédente, soit de sources externes). Chaque entrée x_i est associée à un poids synaptique w_i , représentant la force de la connexion. Le neurone calcule la somme

pondérée de ses entrées, à laquelle s'ajoute souvent un terme de biais b (ou seuil). Cette somme, appelée potentiel d'activation a , est donnée par:

$$a = (\sum w_i * x_i) + b$$

2.Fonction d'activation : Le potentiel d'activation a est ensuite transformé par une fonction d'activation f (également appelée fonction de transfert) pour produire la sortie y du neurone:

$$y = f(a) = f((\sum w_i * x_i) + b)$$




Figure III.2: Schématisation de la fonction d'activation de la somme pondérée

Le biais b permet de décaler la fonction d'activation sur l'axe des abscisses, augmentant ainsi la flexibilité du modèle. Les poids w_i et le biais b sont les paramètres ajustables du neurone, déterminés lors de la phase d'apprentissage.

III.6. Fonctions d'Activation

La fonction d'activation f joue un rôle crucial en introduisant une non-linéarité dans le modèle neuronal. Sans non-linéarité, un réseau multicouche se comporterait comme un simple réseau monocouche, limitant considérablement sa capacité à modéliser des relations complexes. Idéalement, une fonction d'activation doit être différentiable (pour permettre l'utilisation d'algorithmes d'apprentissage basés sur le gradient) et capable d'introduire les non-linéarités nécessaires.

Plusieurs types de fonctions d'activation existent, présentant diverses propriétés mathématiques (Tableau III.1):

- **Linéaire :** $f(a) = a$. Utilisée principalement dans la couche de sortie pour des tâches de régression.

• **À Seuil (Heaviside)** : $f(a) = 1$ si $a \geq \text{seuil}$, 0 sinon. Historiquement importante, mais non différentiable au seuil.

• **Sigmoïde Logistique** : $f(a) = 1 / (1 + \exp(-s*a))$. Produit une sortie entre 0 et 1, interprétable comme une probabilité. Différentiable, mais peut souffrir de saturation du gradient.

• **Tangente Hyperbolique (tanh)** : $f(a) = (\exp(a) - \exp(-a)) / (\exp(a) + \exp(-a))$. Similaire à la sigmoïde mais produit une sortie entre -1 et 1. Souffre également de saturation.

• **Rectified Linear Unit (ReLU)** : $f(a) = \max(0, a)$. Computationnellement efficace, évite la saturation pour les valeurs positives, mais peut souffrir du problème des "neurones mourants". Des variantes existent (Leaky ReLU, ELU, etc.).

• **Gaussienne** : Utilisée dans certains types de réseaux comme les RBF (Radial Basis Function networks).

Fonction de Heaviside	
Fonction Linéaire sans saturation	
Fonction linéaire avec seuil	
Fonction a seuils multiples	
Fonction sigmoïde $\frac{1}{1 + e^{-s}} = F1(s)$	
Fonction sigmoïde $f2(s) = \frac{1 - e^{-s}}{1 + e^{-s}}$	
Fonction de stochastique	

Tableau III.1: Les modèles de fonctions d'activation.[48]

Le choix de la fonction d'activation dépend de l'architecture du réseau, de la nature de la tâche (classification, régression) et des propriétés souhaitées pour l'apprentissage. Les fonctions non linéaires, en particulier sigmoïde, tanh et ReLU (et ses variantes), sont les plus couramment employées dans les couches cachées des réseaux profonds.

III.7. Principe Opérationnel

Le principe fondamental de fonctionnement d'un RNA repose sur sa capacité à apprendre des motifs et des relations à partir de données d'exemples. Essentiellement, le réseau agit comme un système d'inférence statistique ou de reconnaissance de formes. Durant une phase d'apprentissage (entraînement), le réseau est exposé à un ensemble de données. Les paramètres internes (poids et biais) sont ajustés itérativement pour minimiser une fonction d'erreur (ou fonction coût) qui mesure l'écart entre les sorties produites par le réseau et les sorties désirées (dans le cas de l'apprentissage supervisé).

Une fois entraîné, le réseau peut être utilisé pour traiter de nouvelles données d'entrée qu'il n'a jamais vues auparavant. Il effectue alors une propagation avant ("forward pass") : les données d'entrée traversent le réseau couche par couche, chaque neurone calculant sa sortie en fonction des entrées pondérées reçues et de sa fonction d'activation. La sortie finale du réseau représente alors une prédiction, une classification, ou une autre forme d'inférence basée sur les motifs appris durant l'entraînement.

Le processus peut être résumé comme suit:

1. Phase d'Apprentissage : Ajustement des poids et biais basé sur un jeu de données d'entraînement pour minimiser une fonction coût.

2. Phase d'Inférence/Prédiction : Utilisation du réseau entraîné pour générer des sorties (prédictions/classifications) pour de nouvelles données d'entrée, en se basant sur les paramètres appris.




Figure III.3: Réseau de Neurones.

III.8. Architectures des Réseaux de Neurones

L'architecture d'un RNA, c'est-à-dire la manière dont les neurones sont organisés et interconnectés, détermine en grande partie ses capacités de traitement. On distingue principalement deux grandes familles d'architectures :

III.8.1. Réseaux à Propagation Avant (Feedforward Networks)

Ces réseaux, également appelés réseaux non-bouclés, sont caractérisés par un flux d'information unidirectionnel, depuis la couche d'entrée vers la couche de sortie, en passant par une ou plusieurs couches cachées. Il n'y a pas de connexions de rétroaction (cycles) dans le graphe de connexion. Le Perceptron Multicouches (MLP) est l'exemple le plus courant de ce type d'architecture. La sortie du réseau à un instant donné dépend uniquement de l'entrée présentée à cet instant. Ces réseaux sont bien adaptés aux problèmes de classification statique et de régression.




Figure (III.4) Réseau non bouclé

(Insérer Figure III.5 ici)

Figure III.5: Schéma d'une architecture de réseau de neurones à propagation avant (Feedforward) avec une couche d'entrée, une couche cachée et une couche de sortie [30].

III.8.2. Réseaux Récurrents (Recurrent Neural Networks - RNN)

Contrairement aux réseaux feedforward, les réseaux récurrents possèdent des connexions de rétroaction, formant des cycles dans le graphe de connexion. Ces boucles permettent à l'information de persister au sein du réseau, lui conférant une forme de "mémoire" interne. L'état interne du réseau à un instant t dépend non seulement de l'entrée à l'instant t , mais aussi de l'état interne (ou des sorties) aux instants précédents. Cette capacité à traiter des séquences et à modéliser des dépendances temporelles rend les RNN particulièrement adaptés aux tâches impliquant des données séquentielles, telles que le

traitement du langage naturel, la reconnaissance vocale, l'analyse de séries temporelles, et, potentiellement, le diagnostic de défauts basé sur l'évolution temporelle de signaux dans des systèmes dynamiques comme les systèmes PV [31].




Figure (III.5) Réseau bouclé

III.9. Apprentissage du Réseau de Neurones

L'apprentissage est le processus par lequel un RNA ajuste ses paramètres (poids w et biais b) afin d'améliorer ses performances sur une tâche donnée, en se basant sur des données d'exemples.

III.9.1. Définition

L'apprentissage neuronal est une phase d'adaptation durant laquelle le comportement du réseau est modifié itérativement pour atteindre un objectif de performance désiré. Ce processus implique la présentation répétée de données au réseau et l'application d'un algorithme d'apprentissage pour mettre à jour les paramètres. L'objectif est de minimiser une fonction coût (ou fonction d'erreur) qui quantifie la différence entre les sorties produites par le réseau et les sorties cibles (pour l'apprentissage supervisé) ou qui mesure une certaine propriété des données (pour l'apprentissage non-supervisé) [38].

III.9.2 Stratégie d'Apprentissage (Exemple : Apprentissage Supervisé)

L'apprentissage se déroule typiquement de manière itérative sur l'ensemble des données d'entraînement (parfois divisé en mini-batches). Chaque itération (ou époque, si l'ensemble complet est parcouru) implique généralement les étapes suivantes: [39]

1. Initialisation :

Les poids et biais du réseau sont initialisés (souvent avec de petites valeurs aléatoires).

2. Propagation Avant (Forward Pass) : Un exemple (ou un batch) de données d'entrée est présenté au réseau. L'activation se propage à travers les couches jusqu'à la couche de sortie pour produire une prédiction.

3. Calcul de l'Erreur : La sortie produite par le réseau est comparée à la sortie désirée (cible) correspondante. Une fonction coût (ex: Erreur Quadratique Moyenne - MSE, Entropie Croisée) mesure l'ampleur de l'erreur.

4. Rétropropagation de l'Erreur (Backward Pass) : L'erreur est propagée en sens inverse, de la couche de sortie vers les couches précédentes. L'algorithme de rétropropagation calcule le gradient de la fonction coût par rapport à chaque poids et biais du réseau.

5. Mise à Jour des Paramètres : Les poids et biais sont ajustés dans la direction opposée du gradient (descente de gradient) pour réduire l'erreur. Le taux d'apprentissage (learning rate) contrôle l'amplitude de cette mise à jour.

Ces étapes sont répétées jusqu'à ce qu'un critère d'arrêt soit atteint (ex: nombre maximal d'époques, erreur suffisamment faible, absence d'amélioration sur un jeu de validation).

III.9.3 Types d'Apprentissage

Les paradigmes d'apprentissage les plus courants sont [40] :

III.9.3.1 Apprentissage Supervisé

Dans ce cadre, le réseau apprend à partir d'un ensemble de données étiquetées, où chaque exemple d'entrée x est associé à une sortie cible correcte y . L'objectif est d'apprendre une fonction f qui approxime la relation $y = f(x)$. Le réseau ajuste ses poids pour minimiser l'erreur entre ses prédictions $f(x)$ et les cibles y . C'est le type d'apprentissage le plus utilisé pour les tâches de classification (prédire une catégorie) et de régression (prédire une valeur continue). L'exemple de reconnaissance d'images (Figure III.7) ou la traduction automatique illustrent ce paradigme.




Figure III.6 exemple d'apprentissage supervisé

Le processus typique implique:

- **a) Le Dataset** : Acquisition d'un jeu de données (X, Y) contenant des paires d'exemples (caractéristiques x et cibles y) .
- **b) Le Modèle** : Choix d'une architecture de réseau appropriée avec des paramètres initialisés aléatoirement.
- **c) La Fonction Coût** : Définition d'une métrique pour évaluer l'erreur du modèle (ex: MSE, Entropie Croisée).
- **d) L'Algorithme d'Apprentissage** : Utilisation d'un optimiseur (ex: Descente de Gradient Stochastique - SGD, Adam) pour trouver les paramètres du modèle minimisant la fonction coût en se basant sur le gradient calculé par rétropropagation [41]. L'objectif est de trouver les paramètres qui minimisent la fonction coût, reflétant ainsi une meilleure adéquation du modèle aux données.

III.9.3.2 Apprentissage Non-Supervisé

Ici, le réseau apprend à partir de données non étiquetées (X uniquement). Il n'y a pas de sortie cible explicite. L'objectif est de découvrir des structures, des régularités, ou des représentations sous-jacentes dans les données. Les tâches typiques incluent le clustering (regroupement de données similaires), la réduction de dimensionnalité (compression de l'information), l'estimation de densité, et l'apprentissage de représentations (feature learning). Des algorithmes comme les K-Means (pour le clustering) ou les Auto-encodeurs (pour la réduction de dimensionnalité et l'apprentissage de représentations) relèvent de ce paradigme. Cet apprentissage est crucial lorsque les données étiquetées sont rares ou coûteuses à obtenir.

D'autres paradigmes existent, comme l'apprentissage semi-supervisé (mélange de données étiquetées et non-étiquetées) et l'apprentissage par renforcement (apprentissage par essais et erreurs via des récompenses/pénalités).

III.10. Modèles Spécifiques de Réseaux de Neurones Artificiels

Parmi la diversité des modèles de RNA, certains sont particulièrement fondamentaux ou pertinents [52].

III.10.1 Les Perceptrons Multicouches (MLP)

- **Le Perceptron Monocouche:** Modèle historique (Rosenblatt), constitué d'une seule couche de neurones de sortie connectée directement aux entrées. Capable de résoudre uniquement les problèmes linéairement séparables.

- **Le Perceptron Multicouches (MLP):** Extension du perceptron monocouche, caractérisée par la présence d'une ou plusieurs couches cachées entre la couche d'entrée et la couche de sortie. Chaque neurone d'une couche est typiquement connecté à tous les neurones de la couche précédente (architecture "fully connected"). Grâce à l'utilisation de fonctions d'activation non linéaires dans les couches cachées, les MLP sont des approximateurs universels : ils peuvent théoriquement approximer toute fonction continue avec une précision arbitraire, à condition d'avoir suffisamment de neurones cachés. Ils sont largement utilisés pour la classification et la régression sur des données tabulaires ou vectorielles.

D'autres modèles importants incluent les Réseaux de Neurones Convolutifs (CNN), spécialisés dans le traitement de données grid-like (images), et les Réseaux de Neurones Récurrents (RNN) et leurs variantes (LSTM, GRU), conçus pour les données séquentielles, qui sont au cœur de l'application visée dans cette thèse.

III.11 Applications des Réseaux de Neurones Artificiels

Les RNA ont trouvé des applications dans une vaste gamme de domaines, exploitant leur capacité à apprendre des relations complexes à partir de données: [50]

- **Reconnaissance de Formes:** Classification d'images, reconnaissance optique de caractères (OCR), reconnaissance faciale, reconnaissance vocale.

- **Traitement du Langage Naturel (NLP):** Traduction automatique, analyse de sentiments, génération de texte, systèmes de questions-réponses.

- **Analyse de Séries Temporelles:** Prévisions financières (marchés boursiers), prévisions météorologiques, analyse de signaux biomédicaux (ECG, EEG), diagnostic de défauts basé sur l'évolution de signaux système.

- **Systèmes de Contrôle et Robotique:** Contrôle adaptatif, navigation de robots autonomes, pilotage de véhicules.

- **Bioinformatique:** Prédiction de structures protéiques, analyse de données génomiques.

- **Fouille de Données (Data Mining)** : Détection d'anomalies, systèmes de recommandation, segmentation client.

Domaine d'application	Type de RNA
Reconnaissance de formes	MLP, Hopefield, Kohonen
Mémoire Associatives	Hopefield, MLP recurents, Kohonen
Optimisation	Hopefield, ART, CNN
Approximation de fonction	MLP, RBF
Modélisation et control	MLP, MLP récurrent, FLN
Traitement d'images	CNN, Hopefield
Classification et Clustering	MLP, Kohonen, RBF, ART, PNN

Tableau III.2 : Type de réseau utilisé pour chaque domaine.

Le Tableau III.2 présente une correspondance indicative entre certains types de RNA et leurs domaines d'application privilégiés.

(Insérer Tableau III.2 ici)

Tableau III.2 : Exemples de types de RNA et leurs domaines d'application typiques.

III.12 Évaluation des Résultats d'Entraînement (Exemple Illustratif)

L'évaluation de la phase d'entraînement est cruciale pour s'assurer que le réseau a appris correctement et qu'il est capable de généraliser à de nouvelles données. Des outils comme MATLAB permettent de visualiser différentes métriques de performance durant et après l'entraînement.




Figure III.7: Courbe de performance produite lors de l'entraînement du 2:5:10:1:10:5:2 réseau. [51]

La Figure III.8 illustre l'évolution de l'erreur (MSE) au fil des époques. Idéalement, l'erreur sur les jeux d'entraînement et de validation devrait diminuer et converger. Un écart croissant entre l'erreur d'entraînement (qui continue de baisser) et l'erreur de validation (qui stagne ou augmente) est un signe de sur-apprentissage (overfitting). L'arrêt précoce ("early stopping"), basé sur la performance sur le jeu de validation (ici, arrêt à l'époque 274 après 20 époques sans amélioration de la validation), est une technique courante pour prévenir l'overfitting.




Figure III.8: Diagramme de régression produit lors de l'apprentissage du réseau[51]. (

La Figure III.9 montre les graphiques de régression. Les points devraient idéalement se situer le long de la droite $Y=T$ (sortie = cible), indiquant une bonne corrélation. Le coefficient de détermination (R) mesure la qualité de l'ajustement (une valeur proche de 1 indique une forte corrélation). Une dispersion significative ou des regroupements inattendus peuvent indiquer des problèmes dans l'apprentissage ou des caractéristiques spécifiques des données.




Figure III.9: Les paramètres x et y tracés ensemble après en les exécutant via le réseau 2:5:10:1:10:5:2[51].

(Insérer Figure III.10 ici)

Figure III.10: Visualisation des données d'entrée (paramètres x et y) traitées par le réseau 2:5:10:1:10:5:2 [51]. (Note: Caption could be more specific if the context of x and y is known)

Ces visualisations sont des outils essentiels pour diagnostiquer le processus d'apprentissage, évaluer la qualité du modèle final, et guider d'éventuels ajustements de l'architecture ou des hyperparamètres d'entraînement.

III.13 Avantages et Inconvénients des Réseaux de Neurones

Les RNA offrent des avantages significatifs mais présentent également certaines limitations.

III.13.1 Avantages

- **Apprentissage à partir de données** : Capacité à découvrir des relations complexes et non-linéaires directement à partir de données brutes ou peu prétraitées.
- **Pouvoir d'approximation universelle** : Aptitude théorique (pour certaines architectures comme les MLP) à approximer n'importe quelle fonction continue.
- **Généralisation** : Capacité, si bien entraînés et régularisés, à performer correctement sur des données non vues durant l'entraînement.
- **Robustesse au bruit** : Tolérance relative aux données bruitées ou incomplètes grâce à leur nature distribuée.
- **Parallélisme inhérent** : Potentiel d'implémentation matérielle parallèle pour une exécution rapide.
- **Adaptabilité** : Facilité de ré-entraînement pour s'adapter à de nouvelles données ou à des changements dans l'environnement.

III.13.2 Inconvénients

- **Besoin important de données** : Les modèles complexes, en particulier les réseaux profonds, requièrent souvent de grandes quantités de données (souvent étiquetées) pour un entraînement efficace et pour éviter l'overfitting.
- **Coût computationnel** : L'entraînement de réseaux profonds peut être très exigeant en termes de ressources de calcul (temps CPU/GPU, mémoire).

- **Problème de la "boîte noire"** : Il peut être difficile d'interpréter le raisonnement interne du réseau et d'expliquer comment il parvient à une décision spécifique, ce qui peut être problématique pour des applications critiques.
- **Sensibilité aux hyperparamètres** : La performance dépend fortement du choix de l'architecture (nombre de couches, de neurones), de la fonction d'activation, de l'algorithme d'optimisation, du taux d'apprentissage, et d'autres hyperparamètres, dont le réglage optimal requiert souvent une expertise et de nombreuses expérimentations (ex: validation croisée).
- **Risque de sur-apprentissage (Overfitting)** : Tendance à mémoriser les données d'entraînement au détriment de la capacité de généralisation sur de nouvelles données. Des techniques de régularisation (ex: dropout, L1/L2, arrêt précoce) sont nécessaires pour mitiger ce risque.
- **Absence de méthodologie systématique pour la conception** : Le choix de la topologie optimale reste largement empirique.

III.14 Conclusion

Ce chapitre a présenté une revue approfondie des concepts fondamentaux sous-jacents aux Réseaux de Neurones Artificiels. En partant de leur inspiration biologique et de leur évolution historique, nous avons disséqué les composantes essentielles telles que le neurone formel, la diversité des fonctions d'activation, et l'importance des poids synaptiques ajustables. Les principales architectures de réseaux, notamment les structures feedforward et les architectures récurrentes cruciales pour le traitement séquentiel, ont été décrites. Une attention particulière a été accordée aux mécanismes d'apprentissage, en détaillant les paradigmes supervisé et non-supervisé ainsi que les étapes algorithmiques de l'entraînement, notamment la rétropropagation de l'erreur et la descente de gradient. La présentation de modèles emblématiques comme le Perceptron Multicouches et l'évocation des applications variées des RNA ont souligné leur polyvalence et leur puissance en tant qu'outils d'apprentissage automatique. Les capacités intrinsèques des RNA pour l'extraction de connaissances à partir de données complexes et leur potentiel de généralisation ont été mis en balance avec leurs défis inhérents, tels que le besoin en données, l'interprétabilité limitée, et la sensibilité aux hyperparamètres. Ce chapitre établit ainsi le socle théorique et conceptuel indispensable pour aborder, dans les chapitres ultérieurs de cette thèse, la conception, l'implémentation et l'évaluation de Réseaux de Neurones Récurrents spécifiquement dédiés à la tâche exigeante de classification et de diagnostic des défauts au sein du système photovoltaïque étudié.

Chapitre IV

Simulation et Résultats

IV.1. Introduction

Ce chapitre est consacré à la mise en œuvre pratique et à l'évaluation de l'approche proposée pour le diagnostic des défauts dans les systèmes photovoltaïques (PV) basée sur les réseaux de neurones artificiels (RNA). Après avoir établi le cadre théorique et la méthodologie de modélisation dans les chapitres précédents, nous présentons ici la démarche expérimentale suivie, depuis la génération des données de simulation jusqu'à l'entraînement et la validation du réseau neuronal. L'objectif principal est d'évaluer la capacité du modèle RNA développé à identifier et classifier correctement différents types de défauts simulés, en se basant sur les caractéristiques électriques du système PV (tension, courant et éclairement). Les résultats obtenus seront analysés en détail, notamment en termes de précision de classification et de matrices de confusion, afin de valider l'efficacité de la méthode proposée.

IV.2. Configuration de l'Environnement de Simulation et Génération des Données

La première étape de notre travail expérimental a consisté à générer un ensemble de données représentatif des différents états de fonctionnement (normal et défectueux) du système photovoltaïque. Pour ce faire, nous avons utilisé l'environnement de simulation MATLAB/Simulink. Un modèle Simulink de base a été développé pour représenter un système PV typique, composé de panneaux solaires, d'un convertisseur DC/DC de type Boost, d'un algorithme de suivi du point de puissance maximale (MPPT) de type Perturbation et Observation (P&O), et d'une charge résistive. La Figure IV.1 illustre la structure générale de ce modèle de simulation. Les différents scénarios de défauts ont été implémentés en modifiant spécifiquement certains paramètres ou composants au sein de ce modèle de base, comme détaillé ultérieurement.




Figure IV.1 : Schéma du modèle Simulink de base du système photovoltaïque étudié

IV.2.1 Paramètres du Panneau Photovoltaïque

Les simulations ont été réalisées en utilisant un modèle de panneau PV "User-defined" dans Simulink. Les paramètres clés de ce module, configurés pour représenter un panneau typique et illustrés en Figure IV.2, sont les suivants (à 25°C et 1000 W/m²):

- Puissance Maximale (Pmax): 59.85 W
- Nombre de cellules par module (Ncell): 36
- Tension de circuit ouvert (Voc): 21.1 V
- Courant de court-circuit (Isc): 3.8 A
- Tension au point de puissance maximale (Vmpp): 17.1 V
- Courant au point de puissance maximale (Imp): 3.5 A
- Courant photogénéré IL (Iph): 3.8128 A
- Courant de saturation de la diode I0: 2.5245e-10 A
- Facteur d'idéalité de la diode (n): 0.97494
- Résistance shunt Rsh (Rp): 153.5644 Ohms
- Résistance série Rs: 0.38572 Ohms
- Coefficient de température de Voc: -0.38 %/°C
- Coefficient de température d'Isc: 0.065 %/°C

Model parameters			
Maximum Power (W)	59.85	Cells per module (Ncell)	36
Open circuit voltage Voc (V)	21.1	Short-circuit current Isc (A)	3.8
Voltage at maximum power point Vmp (V)	17.1	Current at maximum power point Imp (A)	3.5
Temperature coefficient of Voc (%/deg.C)	-0.38	Temperature coefficient of Isc (%/deg.C)	0.065
		Light-generated current IL (A)	3.8128
		Diode saturation current I0 (A)	2.5245e-10
		Diode ideality factor	0.97484
		Shunt resistance Rsh (ohms)	153.5644
		Series resistance Rs (ohms)	0.38572

Figure IV.2: paramètres du bloc PV Array

Ces paramètres définissent les caractéristiques électriques du panneau PV utilisé comme base pour toutes les simulations.

IV.2.2 Scénarios de Défauts Modélisés:

En se basant sur le modèle général illustré en Figure IV.1, quatre scénarios de fonctionnement distincts ont été simulés:

1. Fonctionnement Normal: Le système PV opère dans des conditions idéales, sans modification des paramètres nominaux du modèle.
2. Défaut de Type 1 - Ombrage Partiel: Ce défaut est simulé en modifiant un paramètre d'entrée du modèle pour représenter une réduction de l'irradiance effective atteignant l'un des panneaux PV à 40% de l'irradiance ambiante (E).

3. Défaut de Type 2 - Résistance Série Faible: Ce scénario est implémenté en introduisant une résistance série additionnelle de 3 Ohms dans le circuit du panneau PV au sein du modèle.

4. Défaut de Type 3 - Résistance Série Modifiée: Pour ce cas, une résistance série additionnelle d'une valeur de 6 Ohms est intégrée au modèle.

Ces modifications spécifiques permettent de générer des signatures électriques distinctes pour chaque condition de fonctionnement.

IV.2.3 Génération de Données

Pour chaque scénario, des simulations ont été exécutées sous différentes conditions d'éclairement solaire (E) : 1000, 800, 600, 400, et 300 W/m², avec une température de cellule constante de 25°C. La génération de ces données pour chaque scénario et sous chaque condition d'éclairement a été automatisée à l'aide d'un script développé sous MATLAB. Les signaux de tension (V), courant (I) et l'éclairement (E) ont été enregistrés. Le temps d'arrêt de chaque simulation a été configuré à 0.1 secondes avec un pas d'échantillonnage de 1e-3 s.

Chaque échantillon est un vecteur [V, I, E] avec une étiquette de classe (0: Normal, 1: Ombrage 0.4, 2: SR 3 Ohms, 3: SR 6 Ohms). L'ensemble de données global comprenait [ex: 3015 ou 2814] échantillons. La distribution des échantillons par classe est présentée dans le Tableau IV.1.

--- Formatted Table for Thesis (Tableau IV.1) ---

Classe de Défaut/Fonctionnement	Nombre	Pourcentage
Normal (Classe 0)	804	26.67 %
Ombrage 0.4 (Classe 1)	804	26.67 %
Résistance Série 3 Ohms (Classe 2)	603	20.00 %
Résistance Série 6 Ohms (Classe 3)	804	26.67 %
Total des Échantillons	3015	100.00 %

Inputs_normalized 3015x3 double

	1	2	3
1	-2.0154	1.6977	1.3366
2	-1.9252	1.6842	1.3366
3	-1.8774	1.6824	1.3366
4	-1.8702	1.6820	1.3366
5	-1.8600	1.6817	1.3366
6	-1.8066	1.6800	1.3366
7	-1.7147	1.6768	1.3366
8	-1.6288	1.6736	1.3366
9	-1.5871	1.6720	1.3366
10	-1.5825	1.6717	1.3366
11	-1.5696	1.6714	1.3366
12	-1.5119	1.6695	1.3366
13	-1.4194	1.6662	1.3366
14	-1.3381	1.6632	1.3366
15	-1.3023	1.6618	1.3366
16	-1.2997	1.6616	1.3366
17	-1.2838	1.6612	1.3366
18	-1.2220	1.6591	1.3366
19	-1.1295	1.6558	1.3366
20	-1.0530	1.6530	1.3366

Tableau IV.1: Distribution des échantillons par classe

IV.3 Conception et Entraînement du Réseau de Neurones Artificiels

Un Perceptron Multicouches (MLP), implémenté avec patternnet, a été utilisé.

IV.3.1 Prétraitement des Données

Les données d'entrée (V, I, E) ont été normalisées par Z-score. Les étiquettes de sortie (0, 1, 2, 3) ont été converties au format "one-hot encoding".

IV.3.2 Architecture du Réseau

L'architecture du réseau neuronal utilisée est:

- Couche d'entrée: 3 neurones (V, I, E).
- Couches cachées:
 - o Première couche : 30 neurones (tansig).
 - o Deuxième couche : 20 neurones (tansig).
- Couche de sortie: 4 neurones (softmax implicite).

La Figure IV.3 illustre cette architecture.




Figure IV.3: Schéma de l'architecture du réseau neuronal

IV.3.3 Paramètres d'Entraînement

L'ensemble de données a été divisé (70% entraînement, 15% validation, 15% test). Les paramètres d'entraînement configurés étaient:

- Algorithme (trainFcn): trainlm.
- Fonction de performance (performFcn): crossentropy.
- Nombre maximal d'époques : 120.
- Nombre maximal d'échecs de validation (max_fail): 6.

IV.4 Résultats et Discussion

L'entraînement a été effectué avec les données générées reflétant les défauts d'ombrage à 0.4 et de résistance série à 6 Ohms.

IV.4.1 Performance Globale de l'Entraînement

La courbe de performance de l'entraînement est montrée en Figure IV.4.




Figure IV.4: Courbe de performance de l'entraînement (plotperform) pour la meilleure exécution

Le réseau a atteint une performance de validation optimale de 0.0544 à l'époque 120. Les précisions globales obtenues sont:

- Précision d'entraînement : 86.12%
- Précision de validation : 82.30%
- Précision de test : 79.65%

IV.4.2 Analyse de la Matrice de Confusion

La matrice de confusion pour l'ensemble de test (Figure IV.5) détaille la performance par classe.

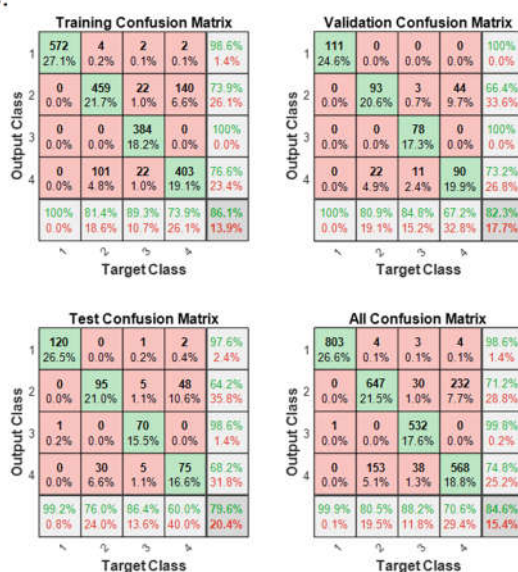


Figure IV.5: Matrice de confusion pour l'ensemble de test avec une précision de 79.65%

L'analyse de la Figure IV.5 montre:

- Classe 1 (Normal): Précision de 97.6%.
- Classe 2 (Ombrage 0.4): Précision de 64.2%, confusion principale avec la Classe 4.
- Classe 3 (SR 3 Ohms): Précision de 98.6%.
- Classe 4 (SR 6 Ohms): Précision de 68.2%, confusion principale avec la Classe 2.

La performance détaillée du classificateur sur l'ensemble de test est visualisée à travers la matrice de confusion présentée en Figure IV.5. Cette figure illustre également les matrices de confusion pour les ensembles d'entraînement, de validation et l'ensemble complet des données. L'analyse de la matrice de confusion de l'ensemble de test (Test Confusion Matrix), qui affiche une précision globale de 79.65%, révèle les points suivants pour chaque classe cible (où Classe 1 correspond à l'étiquette originale 0, Classe 2 à 1, etc.):

- Classe 1 (Normal - étiquette originale 0): Le modèle identifie correctement 120 des échantillons normaux. Seulement 3 échantillons normaux ont été incorrectement classifiés (1 comme Classe 3 et 2 comme Classe 4), résultant en un rappel (Recall/Sensitivity) de 97.6% pour cette classe, ce qui indique une excellente capacité à détecter l'état de fonctionnement normal.

- Classe 2 (Ombrage 0.4 - étiquette originale 1): Pour ce type de défaut, 95 échantillons ont été correctement classifiés. Cependant, une confusion notable subsiste, principalement avec la Classe 4 (SR 6 Ohms), où 48 échantillons d'ombrage ont été incorrectement identifiés comme étant un défaut de résistance série de 6 Ohms. De plus, 5 échantillons ont été confondus avec la Classe 3. Le rappel pour cette classe est de 64.2%.

- Classe 3 (SR 3 Ohms - étiquette originale 2): Le modèle démontre une performance exceptionnelle pour ce défaut, classifiant correctement 70 échantillons. Un seul échantillon de cette classe a été mal classé (comme Classe 1). Cela se traduit par un rappel de 98.6%, indiquant une très haute fiabilité dans la détection de ce type de défaut.

- Classe 4 (SR 6 Ohms - étiquette originale 3): Le classificateur a correctement identifié 75 échantillons de ce défaut. Le principal défi pour cette classe reste la confusion avec la Classe 2 (Ombrage 0.4), avec 30 échantillons de SR 6 Ohms incorrectement classifiés comme défaut d'ombrage. Cinq autres échantillons ont été confondus avec la Classe 3. Le rappel pour cette classe est de 68.2%.

En résumé, les ajustements des paramètres des défauts (ombrage à 0.4 et résistance série à 6 Ohms) ont permis d'obtenir une bonne précision globale. Les classes "Normal" et "SR 3 Ohms" sont diagnostiquées avec une très haute fiabilité. Bien que la séparation entre les défauts "Ombrage 0.4" et "SR 6 Ohms" se soit améliorée par rapport aux configurations

antérieures, une confusion significative persiste entre ces deux derniers, ce qui constitue le principal axe d'amélioration potentiel.

IV.4.3 Métriques de Performance par Classe

Pour une évaluation plus approfondie et détaillée des capacités de classification du réseau neuronal entraîné, les métriques de Précision, Rappel (ou Sensibilité), Score-F1 et Spécificité ont été calculées pour chaque classe sur l'ensemble de test. Ces métriques, qui offrent un aperçu plus nuancé que la simple exactitude globale, sont résumées dans le Tableau IV.2.

Tableau IV.2 : Métriques de performance par classe (Précision, Rappel, Score-F1, Spécificité) pour l'ensemble de test.

Classe (Étiquette Originale)	Précision	Rappel (Sensibilité)	Score-F1	Spécificité
Normal (0)	0.9917	0.9756	0.9836	0.9970
Shading 0.4 (1)	0.7600	0.6419	0.6960	0.9013
SR 3 Ohms (2)	0.8642	0.9859	0.9211	0.9711
SR 6 Ohms (3)	0.6000	0.6818	0.6383	0.8538

L'analyse du Tableau IV.2 révèle plusieurs aspects importants concernant la performance du classificateur :

- **Classe "Normal (0)" et Classe "SR 3 Ohms (2)"** : Ces deux classes affichent des performances exceptionnelles sur toutes les métriques.
 - ✓ Pour la classe **Normal (0)**, une Précision de 0.9917 indique que lorsque le modèle prédit un fonctionnement normal, il est correct dans la quasi-totalité des cas. Le Rappel de 0.9756 signifie que le modèle identifie correctement 97.56% de tous les échantillons réellement normaux. La Spécificité très élevée (0.9970) montre que le modèle commet très peu d'erreurs en classifiant incorrectement un état défectueux comme étant normal. Le Score-F1, à 0.9836, confirme l'excellent équilibre entre Précision et Rappel.
 - ✓ De même, la classe **SR 3 Ohms (2)** obtient un Rappel remarquable de 0.9859, indiquant que le modèle est extrêmement efficace pour détecter ce type de défaut lorsqu'il est présent. Sa Précision de 0.8642 est également très bonne, et

le Score-F1 de 0.9211 est le plus élevé parmi les classes de défaut, soulignant une classification robuste et fiable pour ce scénario.

- **Classe "Shading 0.4 (1)"** : Cette classe présente des défis plus importants pour le classificateur.
 - ✓ La **Précision de 0.7600** est respectable, signifiant que 76% des prédictions de "Shading 0.4" sont correctes.
 - ✓ Cependant, le **Rappel de 0.6419** est significativement plus bas. Cela indique que le modèle ne parvient à identifier correctement que 64.19% des cas réels de défaut d'ombrage ($RD1=0.4$). Une proportion notable de ces défauts est manquée ou classifiée à tort, principalement comme défaut de type SR 6 Ohms (Classe 3 originale), comme observé dans la matrice de confusion (Figure IV.5).
 - ✓ Le **Score-F1 de 0.6960** reflète cet déséquilibre entre une Précision modérée et un Rappel plus faible. La Spécificité de 0.9013 reste bonne, indiquant que le modèle ne confond pas souvent les autres défauts avec celui-ci.
- **Classe "SR 6 Ohms (3)"** : Cette classe montre également des performances mitigées, similaires à celles du défaut d'ombrage.
 - ✓ La **Précision de 0.6000** est la plus faible parmi toutes les classes, ce qui signifie que lorsque le modèle prédit un défaut de SR 6 Ohms, il n'a raison que dans 60% des cas. Un nombre important d'autres défauts (principalement l'ombrage) sont incorrectement classifiés comme SR 6 Ohms.
 - ✓ Le **Rappel de 0.6818** est légèrement meilleur que celui de la classe d'ombrage, indiquant que le modèle détecte 68.18% des instances réelles de ce défaut.
 - ✓ Le **Score-F1 de 0.6383** est le plus bas, ce qui est cohérent avec la Précision plus faible et le Rappel modéré, et souligne la difficulté persistante du modèle à distinguer ce défaut de manière fiable, notamment par rapport au défaut d'ombrage. La Spécificité de 0.8538 est acceptable.

En conclusion, l'analyse des métriques par classe confirme les observations issues de la matrice de confusion. Le modèle excelle dans l'identification des conditions normales et du défaut de résistance série de 3 Ohms. Les défis majeurs persistent dans la distinction entre le défaut d'ombrage (facteur 0.4) et le défaut de résistance série de 6 Ohms. Bien que les ajustements des paramètres de défaut aient amélioré la séparabilité globale, conduisant à une précision globale de test de près de 80%, le chevauchement résiduel des caractéristiques électriques entre ces deux derniers types de défauts limite la performance individuelle de leur

classification. Des travaux futurs pourraient se concentrer sur l'ingénierie de caractéristiques supplémentaires ou l'utilisation d'architectures de modèles plus sophistiquées pour tenter de mieux résoudre ces ambiguïtés.

IV.4.4 Analyse des Courbes ROC

Les courbes caractéristiques de fonctionnement du récepteur (ROC - Receiver Operating Characteristic) pour chaque classe sur l'ensemble de test sont illustrées en Figure IV.6. Ces courbes tracent le taux de vrais positifs (Sensibilité ou Rappel) en fonction du taux de faux positifs (1 - Spécificité) pour différents seuils de classification. La Figure IV.6 présente quatre graphiques ROC distincts, correspondant aux ensembles de données d'entraînement, de validation, de test, ainsi qu'à l'ensemble des données combinées. Notre analyse se concentrera principalement sur les courbes ROC de l'ensemble de test.




Figure IV.6: Courbes ROC pour les 4 classes sur l'ensemble de test

L'analyse des courbes ROC pour l'ensemble de test (Figure IV.6, graphique en bas à gauche) révèle ce qui suit :

- Classe 1 (Normal - étiquette originale 0, représentée par la courbe bleue) et Classe 3 (SR 3 Ohms - étiquette originale 2, représentée par la courbe vert clair/turquoise) : Ces deux classes affichent les meilleures performances. Leurs courbes ROC respectives

sont les plus proches du coin supérieur gauche du graphique, indiquant une excellente capacité de discrimination entre ces états et les autres. Cela corrobore les très hautes précisions et rappels observés pour ces classes dans la matrice de confusion.

- Classe 2 (Ombrage 0.4 - étiquette originale 1, représentée par la courbe vert olive) et Classe 4 (SR 6 Ohms - étiquette originale 3, représentée par la courbe magenta/rouge foncé) : Ces classes présentent des courbes ROC qui s'écartent davantage du point idéal (coin supérieur gauche). Bien qu'elles soient nettement au-dessus de la diagonale (indiquant une performance supérieure à une classification aléatoire), leur positionnement reflète les difficultés de classification et la confusion observée précédemment entre ces deux types de défauts. L'aire sous la courbe (AUC) pour ces classes serait inférieure à celle des classes 1 et 3.

Globalement, les courbes ROC confirment les conclusions tirées de la matrice de confusion : le modèle est très performant pour distinguer les conditions normales et le défaut de résistance série de 3 Ohms, tandis que la distinction entre le défaut d'ombrage (0.4) et le défaut de résistance série de 6 Ohms reste plus difficile, bien que le classificateur démontre toujours une capacité de discrimination utile.

IV.4.5 Vérification du Comportement du Réseau sur des Scénarios de Test Individuels

Afin d'illustrer la réponse du classificateur neuronal entraîné à des conditions de fonctionnement distinctes, des simulations individuelles ont été menées pour chacun des quatre états étudiés (normal, ombrage partiel avec un facteur de 0.4, défaut de résistance série de 3 Ohms, et défaut de résistance série de 6 Ohms). Ces simulations ont été effectuées sous un éclairage de $E = 800 \text{ W/m}^2$ et une température de cellule de 25°C . Un point de données caractéristique $[V, I, E]$, correspondant aux valeurs finales de la simulation, a été extrait pour chaque scénario. Après normalisation, ces points ont été soumis au réseau neuronal pour classification.

Les prédictions obtenues pour chaque cas sont les suivantes :

- Fonctionnement Normal (Attendu: 0) → Prédit: 0 (**Correct**)
- Ombrage 0.4 (Attendu: 1) → Prédit: 1 (**Correct**)
- SR 3 Ohms (Attendu: 2) → Prédit: 3 (**Incorrect**)
- SR 6 Ohms (Attendu: 3) → Prédit: 3 (**Correct**)

La Figure IV.7 offre une représentation graphique de ces prédictions séquentielles.




Figure IV.7 : Prédictions séquentielles du réseau neuronal pour les quatre scénarios de fonctionnement distincts sous un éclairage de 800 W/m².

La matrice de confusion agrégée pour ces quatre instances de test (Lignes=Classe Réelle, Colonnes=Classe Prédite ; Classes 0,1,2,3) est :

```

Prédit:  0   1   2   3
Réel 0 [   1   0   0   0 ]
Réel 1 [   0   1   0   0 ]
Réel 2 [   0   0   0   1 ]  <-- Erreur
Réel 3 [   0   0   0   1 ]

```

Cette analyse ciblée révèle que le réseau identifie correctement trois des quatre états. L'erreur de classification unique concerne le défaut de résistance série de 3 Ohms (Classe 2), confondu avec le défaut de résistance série de 6 Ohms (Classe 3). Cette observation ponctuelle, bien que basée sur un nombre limité d'instances, suggère une similitude potentielle des signatures électriques [V, I, E] de ces deux défauts sous les conditions de test spécifiques, rendant leur discrimination ardue pour le modèle actuel. Il convient de réitérer que la performance globale du réseau sur l'ensemble de test (79.65%) constitue une évaluation plus robuste de sa capacité de généralisation.

IV.4.6 Évaluation Étendue sur des Séquences de Scénarios sous Diverses Conditions d'Éclairement

Pour sonder davantage la robustesse et la capacité de généralisation du classificateur neuronal, une évaluation plus étendue a été conduite. Celle-ci impliquait la simulation de séquences de scénarios de test sous une gamme de niveaux d'éclairement solaire, variant de 1000 W/m² à 300 W/m². Pour chaque niveau d'éclairement, les quatre états de fonctionnement fondamentaux (normal, ombrage partiel à 0.4, défaut de résistance série de 3 Ohms, et défaut de résistance série de 6 Ohms) ont été simulés dans un ordre aléatoire afin de refléter une plus grande variabilité des conditions opérationnelles. La température des cellules a été maintenue constante à 25°C. Comme précédemment, un point de données caractéristique [V, I, E] a été extrait à la fin de chaque simulation individuelle, normalisé, et ensuite classifié par le réseau neuronal entraîné.

L'ensemble des résultats de ces tests séquentiels, incluant les valeurs de tension, courant, éclairement, ainsi que les classes attendues et prédites pour chaque instance, est compilé dans le Tableau IV.3.

Tableau IV.3 : Résultats détaillés des prédictions du réseau neuronal pour les séquences de scénarios de test sous différents niveaux d'éclairement.

Valeur de E (W/m ²)	Nom du Scénario	Étiquette Attendue	Étiquette Prédite	V Collecté (V)	I Collecté (A)	Correct?
1000	Shading 0.4	1	1	16.06	3.5484	true
1000	SR 6 Ohms	3	3	16.17	3.5524	true
1000	Normal Operation	0	0	34.289	3.4815	true
800	SR 3 Ohms	2	3	27.253	2.6936	false
800	Shading 0.4	1	1	16.756	2.7462	true
800	Normal Operation	0	0	34.049	2.8196	true
800	SR 6 Ohms	3	3	22.493	2.4013	true
600	Shading 0.4	1	1	16.366	2.1093	true
600	SR 3 Ohms	2	2	28.741	2.0588	true
600	Normal Operation	0	0	34.054	2.1151	true
600	SR 6 Ohms	3	3	24.771	1.9104	true
400	Normal Operation	0	0	26.448	1.4881	true
400	SR 6 Ohms	3	3	26.354	1.3798	true

400	Shading 0.4	1	1	16.167	1.4162	true
400	SR 3 Ohms	2	2	26.276	1.4722	true
300	SR 3 Ohms	2	3	19.861	1.1202	false
300	SR 6 Ohms	3	3	19.934	1.116	true
300	Normal Operation	0	2	20.019	1.1234	false
300	Shading 0.4	1	1	16.346	1.0449	true

Une représentation graphique consolidée de l'ensemble de ces prédictions séquentielles est fournie en Figure IV.8, illustrant la performance du classificateur sur la totalité des cas testés dans cette évaluation étendue.




Figure IV.8 : Prédications du réseau neuronal pour l'ensemble des séquences de scénarios de fonctionnement simulés sous divers niveaux d'éclairement (1000, 800, 600, 400, 300 W/m²).

L'analyse globale des **19 points de test** présentés dans le Tableau IV.3 et illustrés par la Figure IV.8 indique une performance globale notable du réseau. Le classificateur a atteint une **précision globale de 84.21%** sur cet ensemble de tests séquentiels et variés.

La matrice de confusion agrégée pour ces 19 instances de test spécifiques est la suivante (Lignes=Classe Réelle, Colonnes=Classe Prédite ; Classes 0,1,2,3) :

Matrice de Confusion Globale pour les Séquences de Test (19 instances):

Prédit: 0 1 2 3
Réel 0 [4 0 1 0] (Classe 0 - Normal)
Réel 1 [0 5 0 0] (Classe 1 - Ombrage 0.4)
Réel 2 [0 0 2 2] (Classe 2 - SR 3 Ohms)
Réel 3 [0 0 0 5] (Classe 3 - SR 6 Ohms)

L'examen de cette matrice de confusion globale révèle que :

- L'état normal (Classe 0) et le défaut d'ombrage (Classe 1) sont identifiés avec une grande fiabilité dans la majorité des conditions d'éclairement testées.


- Le défaut de résistance série de 3 Ohms (Classe 2) est correctement identifié dans la moitié des cas (2 sur 4 instances valides), étant confondu avec le défaut de résistance série de 6 Ohms (Classe 3) dans les autres cas, notamment à des niveaux d'éclairement plus élevés ou plus faibles.
- Le défaut de résistance série de 6 Ohms (Classe 3) est correctement identifié dans toutes ses instances.

Cette évaluation étendue confirme la robustesse générale du classificateur neuronal. La capacité du modèle à maintenir une performance élevée (près de 85%) malgré la randomisation de l'ordre des défauts et la variation significative de l'éclairement est un indicateur positif de son potentiel d'application. Les erreurs de classification persistantes, principalement pour le défaut SR 3 Ohms sous certaines conditions d'éclairement, suggèrent des pistes d'amélioration future, telles que l'enrichissement du jeu de données d'entraînement avec plus d'exemples de ces cas limites ou l'exploration de caractéristiques additionnelles.

IV.5 Conclusion du Chapitre et Perspectives

Ce chapitre a présenté l'application d'un réseau neuronal artificiel pour le diagnostic des défauts dans un système photovoltaïque simulé. L'utilisation des caractéristiques de tension, courant et éclairement, avec des paramètres de défauts ajustés (ombrage avec un facteur de 0.4 et une résistance série de 6 Ohms), a permis d'atteindre une précision de test globale de **79.65%**.

Cette étude souligne l'importance de la caractérisation précise des défauts pour améliorer la séparabilité des données. Les résultats actuels constituent une contribution significative vers le développement de systèmes de diagnostic intelligents pour les installations PV. Les perspectives futures incluent l'exploration de caractéristiques d'entrée plus discriminantes et la validation sur des données expérimentales réelles.

A decorative orange scroll graphic with a light orange background and a darker orange border. The scroll is partially unrolled, with the top and bottom edges showing a darker orange band. The text is centered on the main body of the scroll.

Conclusion générale

Conclusion générale


Ce mémoire a porté sur le développement d'un système de diagnostic des défauts pour les installations photovoltaïques (PV) basé sur les réseaux de neurones artificiels (RNA). L'objectif principal était de concevoir un algorithme capable de classifier avec précision plusieurs types de défauts à partir de l'analyse des signaux électriques caractéristiques (tension V , courant I , et éclairement E).

La méthodologie a impliqué la modélisation d'un système PV sous MATLAB/Simulink, incluant un convertisseur DC/DC et un algorithme MPPT P&O. Des scénarios de fonctionnement normal et de défauts (ombrage partiel avec un facteur de 0.4, résistances série de 3 Ohms et de 6 Ohms) ont été simulés sous diverses conditions d'éclairement pour générer un jeu de données d'entraînement. Une attention particulière a été accordée à l'ajustement des paramètres de ces défauts afin d'améliorer la séparabilité des classes.

Un réseau de neurones de type Perceptron Multicouches (MLP), entraîné avec l'algorithme Levenberg-Marquardt, a été utilisé comme classificateur. Les résultats expérimentaux sont prometteurs, avec une précision de classification globale sur l'ensemble de test atteignant 79.65%. L'analyse détaillée a montré une excellente identification des conditions normales et du défaut de résistance série de 3 Ohms. Bien que la distinction entre le défaut d'ombrage et celui de résistance série de 6 Ohms se soit améliorée, une confusion résiduelle subsiste, indiquant des similitudes persistantes dans leurs signatures électriques sous certaines conditions.

Ce travail confirme le potentiel des RNA comme outil de diagnostic intelligent pour les systèmes PV, en utilisant des mesures électriques accessibles. Il souligne également l'importance cruciale d'une caractérisation et d'une différenciation adéquates des scénarios de défauts lors de la phase de génération de données pour optimiser la performance du classificateur.

Les perspectives d'amélioration incluent l'exploration de caractéristiques d'entrée plus discriminantes, l'utilisation d'architectures de réseaux potentiellement plus complexes, et, de manière indispensable, la validation du système sur des données expérimentales réelles. En définitive, cette étude fournit une base solide pour le développement de systèmes de diagnostic fiables, contribuant à l'amélioration de l'efficacité et de la rentabilité des installations photovoltaïques.

A decorative orange scroll graphic with a light orange gradient fill and a darker orange border. The scroll is unrolled in the center, with the word 'Bibliographie' written in a bold, black, serif font. The top and bottom edges of the scroll are slightly curved, and there are small circular details at the corners where the scroll folds.

Bibliographie

BIBLIOGRAPHIE

- [1] GASSAB Samir. (2019). Gestion d'énergie d'une centrale à énergie renouvelable hybride dédiée à l'alimentation d'un site isolé. Thèse de doctorat. Université Ferhat Abbas – Sétifl
- [2] Besson, Pierre, (2016). Compréhension des comportements électrique et optique des modules photovoltaïques à haute concentration, et développement d'outils de caractérisations adaptés. Thèse de doctorat. Université de Lyon.
- [3] Bandou, Farida, (2016). Contribution à l'analyse des performances électriques et thermiques des modules photovoltaïques de différentes technologies. Thèse de doctorat. Université Mouloud Mammeri.
- [4] Bouakra, Abdellah, (2016). Impact et régulation de la tension à la suite d'insertion d'énergie renouvelable dans les réseaux de distribution électrique. Thèse de doctorat. Université du Québec en Abitibi-Témiscamingue.
- [5] : M.Orgeret, «Les piles solaires, le composent et ces applications» Préface de F.Allest.
- [6] Licence EEA Module U6 Énergie et convertisseurs d'énergie, Université de Savoie.
- [7] Structure des différentes couches d'un générateur photovoltaïque. [Online].
- [8] disponible:<https://terresolaire.com/comprendre-le-solaire/panneauxphotovoltaïques/>
- [9] fabrication/. [Consulté: 19-Mar-2019].
- [10] disponible:<https://terresolaire.com/comprendre-le-solaire/panneauxphotovoltaïques/>
- [11] fabrication/. [Consulté: 19-Mar-2019].
- [12] A. Goetzberger, C. Hebling, and H.-W. Schock, "Photovoltaic materials, history, status
- [13] and outlook," Mater. Sci. Eng. R Reports, vol. 40, no. 1, pp. 1–46, 2003.
- [14] AMARA Karima , Mémoire de Magister contribution à l'étude de conception d'une centrale photovoltaïque de puissance (IMW) interconnectée au réseau de distribution électrique moyenne tension , UMMTO 2014/2015
- [15] O. Gergaud, B. Multon, H. Ben Ahmed « Analysis and Experimental Validation of Various Photovoltaic System Models » 7th International ELECTRIMACS Congress, Montréal, Août 2002.
- [16] Marcelo Gradella Villalva, Jonas Rafael Gazoli, and Ernesto Ruppert Filho, "Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays", IEEE TRANSACTIONS ON POWER ELECTRONICS, VOL. 24, NO. 5, MAY 2009.
- [17] « Cellule Solaire : ModeleSpice -Fiche technique » , I.U.T. de Nimes, 5 fevrier 2008

- [18] Marcelo GradellaVillalva, Jonas Rafael Gazoli, and Ernesto RuppertFilho, “ Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays ”, IEEE TRANSACTIONS ON POWER ELECTRONICS, VOL. 24, NO. 5, MAY 2009
- [19] Long Bun : «Détection et localisation de défaut pour un système PV » 2006. [22] : Akihiro«Design and simulation of photovoltaic water pumping system» faculty of California polytechnic state university, Sanluisobispom September 2005.
- [20] L. PROTIN, S. ASTIER, « Convertisseur photovoltaïques», Techniques de l’Ingénieur, Réf : D 3360, (1997).
- [21] S. Petibon « Nouvelles architectures distribuées de gestion et de conversion de l’énergie pour les applications photovoltaïques » Université de Toulouse, 2009.
- [22] Krim Med lamine et Debbah Housseem Eddine « Etude par simulation d’un générateur photovoltaïque » Département Électrotechnique UNIVERSITÉ BADJI MOKHTAR – ANNABA Année Universitaire :2018
- [23] Structure des différentes couches d’un générateur photovoltaïque. [Online].
- [24] disponible:<https://terresolaire.com/comprendre-le-solaire/panneauxphotovoltaïques/fabrication/>. [Consulté: 19-Mar-2019].
- [25] fabrication/. [Consulté: 19-Mar-2019].
- [26] C. CABAL, « Optimisation Energétique de l’Etage d’Adaptation Electronique Dédie à la Conversion Photovoltaïque », Thèse de Doctorat, Université Paul Sabatier, Toulouse III, France, 2008
- [27] M.S.Fateh. Modélisation d’un système multi générateurs photovoltaïques interconnectés au réseau électrique. Mémoire de Magister, Université FERHAT ABBAS DE SETIF, 2011.
- [28] J. Ferrieux, f. Forest, « alimentations a découpage convertisseurs a résonance: principes composants modélisation ». Paris, france: dunod, 1999.
- [29] Mr. Belaout Abdesslam, Etude et diagnostic des défauts fréquents aux systèmes photovoltaïques (PV) par emploi de la caractéristique courant-tension, Thèse de magister Option : Instrumentation, UNIVERSITE – SETIF-1- U-S-1 (ALGERIE), 28/10/2014.
- [30] <https://www.voltiati.com/explain-the-work-of-the-mppt-charge-controller/>
- [31] file:///C:/Users/aissaouinet/Downloads/MPPT%20(2).pdf
- [32] A. R. Aziz Toulait, “Modélisation et simulation sous MATALAB / SIMULINK d ’ un d ’ un système photovoltaïque adapté par une commande MPPT,” 2014.
- [33] P. Jenithaand A. Immanuel Selvakumar, Fault Detection in PV Systems, Applied S

- [34] Mr. Belaout Abdesslam, Etude et diagnostic des défauts fréquents aux systèmes photovoltaïques (PV) par emploi de la caractéristique courant-tension, Thèse de magister Option : Instrumentation, UNIVERSITE – SETIF-1- U-S-1 (ALGERIE), 28/10/2014
- [35] HAMOUDI Youness, Résolution numérique de la caractéristique I(V) et étude des paramètres d'une cellule photovoltaïque, Présenté en vue d'obtenir le diplôme de MASTER, Université Abdelhamid Ben Badis – Mostaganem, 2017-2018.
- [36] Long BUN, Détection et Localisation de Défauts pour un Système PV, thèse Pour obtenir le grade de DOCTEUR DE L'UNIVERSITÉ DE GRENOBLE, 04/11/2011.
- [37] Abdelkarim GHEZAL, ASPECTS TECHNIQUES DES PROJETS SOLAIRES PV RACCORDÉS AU RÉSEAU. FORMATION SUR LES ÉTUDES DE FAISABILITÉ TECHNICO- ÉCONOMIQUE DES PROJETS PHOTOVOLTAÏQUES RACCORDÉES AU RÉSEAU..
- [38] <http://www.ac-clermont.fr/disciplines/index.php?id=11013>
- [39] <http://www.photovoltaique.guidenr.fr/cours-photovoltaïque-autonome1/caracteristique-courant-tension-cellule-photovoltaïque.php>
- [40] Université A.MIRA de Bejaia Faculté de technologie Departement de Genie Electrique. En vue de l'obtention du diplôme de Master en Electrotechnique Option : Energies Renouvelables Thème Étude d'un système photovoltaïque
- [41] A. Mellit, G. M. Tina, S. A. Kalogirou. Fault detection and diagnosis methods for photovoltaic systems: A review. Renewable Sustainable Energy Reviews. Vol 91, pp. 1-17, 2018
- [42] G. M. Tina, F. Cosentino, C. Ventura, Monitoring and diagnostics of photovoltaic power plants. In Renewable Energy in the Service of Mankind Vol II. 2016, Springer. p. 505-516.
- [43] J. A. Tsanakas, L. D. Ha, F. Al Shakarchi. Advanced inspection of photovoltaic installations by aerial triangulation and terrestrial georeferencing of thermal/visual imagery. Renewable Energy. Vol 102, pp. 224-233, 2017
- [44] J. A. Tsanakas, L. Ha, C. Buerhop. Faults and infrared thermographic diagnosis in operating c-Si photovoltaic modules: A review of research and future challenges. Renewable
- [45] sustainable energy reviews. Vol 62, pp. 695-709, 2016.
- [46] L. Bun. Détection et localisation de défauts dans un système photovoltaïque. Thèse de Doctorat, Université de Grenoble, 2011.

- [47] M. K. Alam, F. H. Khan, J. Johnson, J. Flicker, PV arc-fault detection using spread spectrum time domain reflectometry (SSTDR). in 2014 IEEE energy conversion congress and exposition (ECCE). 2014. IEEE
- [48] G. Deans, S. McDonald, C. Baer, K. Cadien, Solar wafer emitter measurement by infrared reflectometry for process control: Implementation and results. in 2014 IEEE 40th Photovoltaic Specialist Conference (PVSC). 2014. IEEE.
- [49] T. Takashima, J. Yamaguchi, M. Ishida, Fault detection by signal response in PV module strings. in 2008 33rd IEEE Photovoltaic Specialists Conference. 2008. IEEE.
- [50] D. Gaikwad, S. Mehraeen, Reactive power considerations in reliability analysis of photovoltaic systems. in 2012 IEEE Green Technologies Conference. 2012. IEEE
- [51] W. Yi-Bo, W. Chun-Sheng, L. Hua, X. Hong-Hua, Steady-state model and power flow analysis of grid-connected photovoltaic power system. in IEEE international conference on industrial technology. 2008. IEEE.
- [52] A. Chouder, S. Silvestre. Automatic supervision and fault detection of PV systems based on power losses analysis. Energy conversion and Management. Vol 51, pp. 1929-1937, 2010; [39] Y. Liu, B. Li, Z. Cheng, Research on PV module structure based on fault detection. in Chinese Control and Decision Conference. 2010. IEEE.
- [53] X. Xu, H. Wang, Y. Zuo, Method for diagnosing photovoltaic array fault in solar photovoltaic system. in Asia-Pacific Power and Energy Engineering Conference. 2011. IEEE.
- [54] T. Jianeng, Z. Yongqiang, W. Wenshan, Fault diagnosis method and simulation analysis for photovoltaic array. in International Conference on Electrical and Control Engineering. 2011. IEEE.
- [55] M. Uoya, H. Koizumi. A calculation method of photovoltaic array's operating point for MPPT evaluation based on one-dimensional Newton–Raphson method. IEEE Transactions on Industry Applications. Vol 51, pp. 567-575, 2014
- [56] W. Xiao, M. G. Lind, W. G. Dunford, A. Capel. Real-time identification of optimal operating points in photovoltaic power systems. IEEE Transactions on industrial Electronics. Vol 53, pp. 1017-1026, 2006.
- [57] S. Michelle, «Réseaux de neurones », support de cours, (2001).
- [58] P.K. Simpson. «Artificial Neural Systems», Pergmon Press Elmsford, New York, 1989.
- [59] Mohamed Hassan Alia, Abdelhamid Rabhi, Ahmed El hajjaji and Giuseppe M. Tina, Real Time Fault Detection in Photovoltaic Systems, 8th International Conference on

Sustainability in Energy and Buildings, SEB-16, 11-13 September 2016, Turin, ITALY. Energy Procedia 111 (2017).

- [60] Mme.O.BOUKENDOUR « MODELISATION ET SIMULATION DE LA COMMANDE MPPT D'UN SYSTEME PHOTOVOLTAÏQUE A BASE DE RESEAUX DE NEURONES ARTIFICIELS » UNIVERSITE MOULOUDE MAMMERI DE TIZI-OUZOU ,2018.
- [61] A. Djokhrab, "Planification et Optimisation de Trajectoire d'un Robot Manipulateur à 6 D. D. L. par des Techniques Neuro-Floues," Thesis.UnivBiskra.Dz, 2015.
- [62] A. Zergaoui and A. Bennia, "Identification and control of an asynchronous machine using neural networks," Proc. IEEE Int. Conf. Electron. Circuits, Syst., vol. 2, pp. 1043–1046, 1999.
- [63] Bouharrag Bachir Chami Akram DETECTION ET LOCALISATION DE DEFAUTS DANS LES SYSTEMES SOLAIRES PHOTOVOLTAÏQUES A L'AIDE DE RESEAUX DE NEURONE UNIVERSITÉ MOHAMED BOUDIAF - M'SILA 2021
- [64] Loukriz .A, "optémisation de la modélisation et de la commande d'un système PV par la technique d'intelligence artificielle",Mémoir de magister,Université de M'sila,2014.
- [65] Sediri. B, « Commande MPPT à base d'un réseau de neurone artificielPour un système photovoltaïque », Mémoir de master Université Annaba, 2019.
- [66] G. Dreyfus, Les Réseaux de Neurones, Mécanique Industrielle et Matériaux, No.51, septembre 1998.
- [67] "Recurrent Neural Networks for Language Understanding" de Richard Socher
- [68] "Convolutional Neural Networks for Visual Recognition" de Fei-Fei Li, Justin Johnson et Serena Yeung
- [69] Deep Learning with Python" de François Chollet
- [70] Belhadj, B. Systèmes neuromorphiques temps réel : contribution à l'intégration de réseaux de neurones biologiquement réalistes avec fonctions de plasticité. Thèse de doctorat. Université Sciences et Technologies-Bordeaux I), 2010.
- [71] Mohamed Hassan Alia, AbdelhamidRabhi, AhmedEl hajjajiand GiuseppeM. Tina, Real Time Fault Detection in Photovoltaic Systems, 8th International Conference on Sustainability in Energy and Buildings, SEB-16, 11-13 September 2016, Turin, ITALY. Energy Procedia 111 (2017).
- [72] Bouharrag Bachir Chami Akram DETECTION ET LOCALISATION DE DEFAUTS DANS LES SYSTEMES SOLAIRES PHOTOVOLTAÏQUES A L'AIDE DE RESEAUX DE NEURONE UNIVERSITÉ MOHAMED BOUDIAF - M'SILA 2021

[73] benchehida hadja khadidja ,freha fatiha «Classification des anomalies cardiaques par utilisation des Réseaux de Neurones» mémoire master, université de Mostaganem, 2021/2022

A decorative orange scroll graphic with a light orange gradient fill and a darker orange border. The scroll is unrolled in the center, with the word "ANNEXE" written in a bold, black, serif font. The top and bottom edges of the scroll are rounded, and the sides are slightly irregular, giving it a hand-drawn appearance.

ANNEXE