République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Superieure et de la Recherche Scientifique

Université Echahid Hamma Lakhdar d'El-Oued

FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE ELECTRIQUE

Mémoire de fin d'étude

Présenté pour l'obtention du diplôme de

MASTER ACADEMIQUE

Domaine : Sciences et Technologies

Filière : Génie Electrique

Spécialité : Réseaux Electrique

Thème

Diagnostic des pannes des systèmes photovoltaïques à l'aide des réseaux de neurones artificiels (ANN)

Réalisé par :

- BARKA Youcef

Encadré par :

Dr. LABBI Yacine

Année Universitaire 2025/2026



﴿ رَبَّنَا لاَ تُؤَاخِذْنَا إِن نَّسِينَا أَوْ أَخْطَأْنَا رَبَّنَا وَلاَ تَحْمِلْ عَلَيْنَا إِصْرًا كَمَا حَمَلْتَهُ عَلَى الَّذِينَ مِن قَبْلِنَا رَبَّنَا وَلاَ تُحَمِّلْنَا مَا لاَ طَاقَةَ لَنَا بِهِ وَاعْفُ عَنَّا وَاغْفِرْ لَنَا وَارْحَمْنَا أَنتَ مَوْلاَنَا فَانصُرْنَا عَلَى الْقَوْمِ الْكَافِرِينَ﴾ **سورة البقرة : الآية286 .**

" صدق الله العظيم"



Remerciements

*Tout d'abord, Nous remercions dieu -**ALLAH**- le tout puissant de nous avoir donné le courage et la patience durant toutes ces années d'études.*

Nous tenons à exprimer toute notre gratitude et nos sincères remerciements à Monsieur

***Dr : LABBI Yacine,** Maître de conférences à L'Université Echahid Hamma Lakhdar d'El Oued, pour avoir dirigé ce travail.*

Nos sincères remerciements aux Messieurs les membres du jury pour l'honneur qu'ils nous font en participant au jugement de ce travail.

Nous tenons à remercier vivement toutes personnes qui nous ont aidé à élaborer et réaliser ce mémoire, ainsi à tous ceux qui nous aidés de prés ou de loin à accomplir ce travail.

En fin nous remercions tout particulièrement nos parents, pour leur soutien inconditionnel tout au long de ces longues années d'études.



Dédicaces

Nous dédions ce modeste travail :

A nos très chers parents qui nous ont soutenu durant toute la durée de nos études.

A nos très chères freres, sœurs et à nos grandes familles.

A tous mes amis.

A tous ceux qui nous aiment et que nous aimons

A vous.

الملخص

Résumé

Abstract

Résumé

Ce mémoire porte sur le diagnostic des défauts des systèmes photovoltaïques à l'aide des réseaux de neurones artificiels (ANN). Après une étude des principes de fonctionnement et de la modélisation des systèmes photovoltaïques, les principaux défauts pouvant affecter leurs performances ont été analysés. Une approche basée sur les réseaux de neurones artificiels a été développée afin de détecter et classifier les différents états de fonctionnement du système photovoltaïque. Les simulations réalisées sous MATLAB/Simulink ont permis d'évaluer les performances de la méthode proposée. Les résultats obtenus montrent que les réseaux de neurones artificiels constituent un outil efficace pour le diagnostic rapide et précis des défauts, contribuant ainsi à l'amélioration de la fiabilité, de la disponibilité et du rendement des installations photovoltaïques.

Mots clés : Système photovoltaïque, Diagnostic des défauts, Réseaux de neurones artificiels, Intelligence artificielle, MATLAB/Simulink, Maintenance prédictive.

Abstract

This thesis focuses on the fault diagnosis of photovoltaic systems using Artificial Neural Networks (ANN). After studying the operating principles and electrical modeling of photovoltaic systems, the main faults affecting their performance were analyzed. An ANN-based approach was developed to detect and classify different operating conditions of the photovoltaic system. MATLAB/Simulink simulations were carried out to evaluate the performance of the proposed method. The obtained results demonstrate that Artificial Neural Networks provide an efficient and accurate tool for fault diagnosis, improving the reliability, availability, and energy efficiency of photovoltaic installations.

Keywords: Photovoltaic system, Fault diagnosis, Artificial Neural Networks (ANN), Artificial Intelligence, MATLAB/Simulink, Predictive maintenance.

الملخص

تتناول هذه المذكرة تشخيص أعطال الأنظمة الكهروضوئية باستخدام الشبكات العصبية الاصطناعية. تم في البداية دراسة المبادئ الأساسية لعمل الأنظمة الكهروضوئية ونمذجتها الكهربائية، ثم التطرق إلى أهم الأعطال التي قد تؤثر على أدائها وكفاءتها. بعد ذلك تم تطوير نموذج يعتمد على الشبكات العصبية الاصطناعية للكشف عن الأعطال وتصنيف حالات التشغيل المختلفة للنظام الكهروضوئي. وقد تم إنجاز عمليات المحاكاة باستخدام برنامج **MATLAB/Simulink** لتقييم فعالية المنهجية المقترحة. أظهرت النتائج المتحصل عليها أن الشبكات العصبية الاصطناعية توفر وسيلة فعالة ودقيقة لتشخيص الأعطال، مما يساهم في تحسين موثوقية الأنظمة الكهروضوئية ورفع مردودها وتقليل تكاليف الصيانة.

الكلمات المفتاحية: النظام الكهروضوئي، تشخيص الأعطال، الشبكات العصبية الاصطناعية، الذكاء الاصطناعي، **MATLAB/Simulink**، الصيانة التنبؤية.

Sommaire

Remerciement

Dédicace

Résumé

Table des matières

Liste des figures

Liste des tableaux

Introduction générale **1**

Chapitre I : Généralités sur les systemes photovoltaïques	
I.1.Introduction	4
I.2. Le spectre solaire	4
I.3. Le principe de L'effet photovoltaïque	6
I.3.1. Histoire de cellules solaires	6
I.3.2. L'effet photovoltaïque	7
I.3.3. Absorption du rayonnement dans le matériau (Propriétés optiques des semiconducteurs)	7
I.4. La structure de la cellule solaire	8
I.4.1. L'émetteur et la base	9
I.4.2. Les contacts	9
I.4.3. La fenêtre	9
I.4.4. Couche anti reflet	9
I.5. Amélioration du rendement	10
I.5.1. Effet du confinement optique	10
I.5.2. Effet de passivation	11
I.5.3. Effet d'un champ avant ou arrière	11
I.6.Principe de fonctionnement d'une cellule photovoltaïque	12
I.7.Modélisation électrique d'une cellule photovoltaïque	14
I.7.1. Le modèle à une seule diode	14
I.7.2. Le modèle simplifié à une seule diode	15
I.7.3. Le modèle à deux diodes	17
I.7.4. Détermination des paramètres du circuit équivalent	18
I.7.4.1. Le courant de court-circuit, Icc	19
I.7.4.2. La tension de circuit ouvert, Vco	19
I.7.4.3. La réponse spectrale, SR (λ)	19
I.7.4.4. La puissance maximale, Pm	20
I.7.4.5. Le facteur de forme, FF	20

I.7.4.6. Le rendement de conversion η	20
I.8. Simulation du modèle électrique de la cellule/panneau PV sous MATLAB/Simulink	21
I.8.1. Implémentation du modèle sous Simulink	21
I.8.2. Caractéristiques I-V et P-V en conditions standards (STC)	21
I.8.3. Influence des conditions climatiques (T et G) sur les caractéristiques	22
I.8.3.1. L'influence de l'éclairement	22
I.8.3.2. L'influence de la température	23
I.8.3.3. Paramètres caractéristiques pour le diagnostic des défauts	24
I.9. Les différentes filières photovoltaïques	25
I.10. Conclusion	26
Chapitre II: Modélisation du défaut en générateur PV et methodes de diagnostique	
II.1.Introduction	28
II.2 Modélisation du générateur PV en défaut	28
II.2.1 Classification des défauts pour la modélisation	28
II.2.1.1 Défauts dans le générateur photovoltaïque	28
II.2.1.2 Défauts dans la boite de junction	31
II.2.1.3 Défauts dans le système de câblage	32
II.2.1.4 Défauts dans le système de protection	33
II.2.1.5 Défauts dans l'onduleur	34
II.2.1.6 Défauts dans le système d'acquisition	35
II.2.2. Défauts des cellules PV	36
II.2.3 Défauts des diodes PV	36
II.2.4. Défauts des câbles PV	36
II.2.5. Défaut de mismatch et d'ombrage	36
II.2.5.1. Définition	36
II.3 Méthodes de détection et de diagnostic des défauts d'un système PV	37
II.3.1 Méthodes non –électriques	38
II.3.1.1 Méthode de l'imagerie numérique infrarouge thermique	38
II.3.1.2 Méthode de réflectométrie	39
II.3.2 Méthodes électriques	40
II.3.2.1 Méthode d'analyse de la puissance produite	40
II.3.2.2 Méthode d'analyse des caractéristiques I-V et P-V	41

II.3.2.2 Méthode d'analyse des caractéristiques I-V et P-V	41
II.3.2.4. Méthodes basées sur des techniques d'intelligence artificielle IA	41
II.4. Choix de l'approche de diagnostic	45
II.5. Conclusion	46
Chapitre III : Réseaux de neurones artificiels (ANN)	
III.1 Introduction	48
III.2. Aperçu Historique	48
III.3. Réseaux de neurones artificiels	49
III.3.1. Modèle Biologique	51
III.3.2. Le Neurone Formel	52
III.3.3. Le perceptron	53
III.3.4. Fonctions de transfert	54
III.3.5. Perceptron multicouche	55
III.3.6. Erreur de rétro propagation	56
III.3.7. Algorithmes d'apprentissage	58
III.3.8. Régression	59
III.3.9. Prétraitement	60
III.3.10. Analyse de composant principales	62
III.3.11. Réseaux de neurones auto associatifs	62
III.4. Exemple théorique AANN2D	63
III.4.1. Acquisition et prétraitement des données	63
III.4.2. Construire l'AANN	64
III.4.3. Formation du réseau	64
III.4.4. Production des résultats	65
III.5 Conclusion	67
Chapitre IV : Simulation et Résultats	
IV.1.Introduction	69
IV.2. Mise en place de l'environnement de simulation et création des données	69
IV.2.1 Paramètres du Panneau Photovoltaïque	70
IV.2.2 Scénarios de Défauts Modélisés	71
IV.2.3 Génération de Données	71
IV.3 Conception et Entraînement du Réseau de Neurones Artificiels	72
IV.3.1 Prétraitement des Données	72
IV.3.2 Architecture du Réseau	72

IV.3.3 Paramètres d'Entraînement	73
IV.4 Résultats et Discussion	73
IV.4.1 Performance Globale de l'Entraînement	73
IV.4.2 Analyse de la Matrice de Confusion	74
IV.4.3 Métriques de Performance par Classe	75
IV.4.4 Analyse des Courbes ROC	77
IV.4.5 Vérification du Comportement du Réseau sur des Scénarios de Test Individuels	79
IV.4.6 Évaluation Étendue sur des Séquences de Scénarios sous Diverses Conditions d'Éclairement	81
IV.5.Conclusion	83
Conclusion générale	**85**
References Bibliographiques	

LISTE DES FIGURES

LISTE DES FIGURES

Page

Chapitre I : Généralités sur les systemes photovoltaïques		
Figure 1	*Spectre solaire*	*4*
Figure 2	*Description de l'incidence sur la terre*	*5*
Figure 3	*Répartition spectrale du rayonnement*	*6*
Figure 4	*Création du courant électrique sous l'effet de la lumière*	*7*
Figure 5	*Profondeur de pénétration et coefficient d'absorption de quelques semi-conducteurs à 300K en fonction de la longueur d'onde*	*8*
Figure 6	*La structure fondamentale d'une cellule solaire*	*10*
Figure 7	*Structure d'une cellule photovoltaïque*	*11*
Figure 8	*Structure basique d'une cellule solaire*	*12*
Figure 9	*Le principe de fonctionnement d'une cellule photovoltaïque*	*13*
Figure10	*Le modèle à une seule diode*	*14*
Figure 11	*Influence de la résistance série Rs et de la résistance parallèle Rsh*	*15*
Figure 12	*Le modèle à deux diodes pour une modélisation plus exacte*	*17*
Figure 13	*Courbe I-V simulée d'un module solaire : Le circuit équivalent simplifié*	*18*
Figure 14	*Caractéristique I(V) et P(V) d'une cellule solaire*	*20*
Figure 15	*Schéma block d'une cellule sous Matlab-Simulink*	*21*
Figure 16	*Caractéristique Ipv = f(Vpv) et Ppv = f(Vpv) sous les conditions : G = 1000 W/m2, T=25°C (à l'aide de l'outil MATLAB / Simulink)*	*22*
Figure 17	*Caractéristique I(V) d'un panneau photovoltaïque pour différents éclairements*	*22*
Figure 18	*Courbe P(V) de puissance d'un panneau photovoltaïque pour différents éclairements*	*23*
Figure 19	*Influence de la température sur la caractéristique I(V)*	*23*
Figure 20	*Influence de la température sur la caractéristique P(V)*	*24*
Figure 21	*Les différents types cellules photovoltaïques*	*26*
Chapitre II : Modélisation du défaut en générateur PV et methodes de diagnostique		
Figure 1	*Exemples de défauts rencontrés dans des générateurs PV*	30
Figure 2	*Exemples de défauts rencontrés dans des boîtes de jonction*	31
Figure 3	*Exemples de défauts rencontrés dans le système de câblage*	33
Figure 4	*Exemples de défauts de diodes de by-pass*	34
Figure 5	*Méthodes de diagnostic de défauts d'un générateur PV*	38
Figure 6	*Exemple de la localisation de défauts par la caméra thermique*	39

Figure 7	*Principe de la réflectométrie pour localiser le défaut dans un string PV*	40
Chapitre III : Réseaux de neurones artificiels (ANN)		
Figure 1	*Un réseau de neurones biologiques composé de plusieurs neurones interconnectés. Cette image est une représentation théorique à quoi pourrait ressembler un réseau de neurones biologiques*	49
Figure 2	*Un réseau de neurones artificiels composé de plusieurs neurones interconnectés. Ce n'est pas une illustration d'un véritable neurone réseau, mais les moyens d'impliquer la structure peuvent être très complexes*	50
Figure 3	*Différents types de réseaux neurones*	51
Figure 4	*Exemple de neurone biologique*	52
Figure 5	*Schématisation de la fonction d'activation de la somme pondérée*	53
Figure 6	*Le perceptron*	53
Figure 7	*Fonction du seuil. Les premières fonctions de transfert avaient seulement deux sorties possibles ; 1 ou -1*	54
Figure 8	*Fonctions de transfert différentiable en continu. Du haut jusqu'en bas : La fonction de transfert logistique*	54
Figure 9	*Un perceptron multicouche avec une couche cachée.*	55
Figure10	*L'erreur quadratique moyenne en fonction de tous les poids, w, calculés par itération*	57
Figure 11	*Une fonction f(w) essayant de trouver la valeur minimale de w, risque de se retrouver dans un minimum local au lieu du global souhaité le minimum*	58
Figure 12	*Organigramme décrivant le principe de la formation algorithmes lorsque les valeurs cibles sont connues*	59
Figure 13	*Une courbe linéaire a été tracée pour approximer les points dans le diagramme. Une courbe non linéaire a été tracée pour rapprocher les croix*	59
Figure 14	*Un exemple de sur apprentissage*	60
Figure 15	*Si l'ensemble de validation croisée diverge de la formation ensemble, cela peut être une indication de sur apprentissage, et la formation doit être arrêté*	61
Figure 16	*Un réseau de neurones auto associatif. Il doit y avoir plus de paramètres d'entrée et de sortie qu'il n'y a de neurones dans le couche de goulot d'étranglement*	62
Figure 17	*Un exemple de système de deux interdépendants paramètres, à chacun d'eux s'est ajouté du bruit blanc*	63
Figure 18	*Courbe de performance produite lors de l'entraînement du 2:5:10:1:10:5:2 réseau*	65
Figure 19	*Diagramme de régression produit lors de l'apprentissage du réseau 2:5:10:1:10:5:2.*	66
Figure 20	*Les paramètres x et y tracés ensemble après en les exécutant via le réseau 2:5:10:1:10:5:2.*	67
Chapitre IV : Simulation et Résultats		
Figure 1	*Schéma du modèle Simulink de base du système photovoltaïque étudié*	70
Figure 2	*paramètres du bloc PV Array*	71
Figure 3	*Schéma de l'architecture du réseau neuronal*	73
Figure 4	*Courbe de performance de l'entraînement (plotperform) pour la meilleure*	74

	exécution	
Figure 5	*Matrice de confusion pour l'ensemble de test avec une précision de 79.65%*	74
Figure 6	*Courbes ROC pour les 4 classes sur l'ensemble de test*	78
Figure 7	*Prédictions séquentielles du réseau neuronal pour les quatre scénarios de fonctionnement distincts sous un éclairement de 800 W/m².*	80
Figure 8	*Prédictions 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).*	82

LISTE DES TABLEAUX

LISTE DES TABLEAUX

Page

Chapitre I : Généralités sur les systemes photovoltaïques		
Tableau 1	*Les domaines spectraux du rayonnement solaire*	5
Tableau2	*L'indice de réfraction de quelques matériaux*	10
Chapitre II : Modélisation du défaut en générateur PV et methodes de diagnostique		
Tableau 1	*Les différents défauts dans le générateur PV*	29
Tableau 2	*Les différents défauts dans la boîte de jonction*	31
Tableau 3	*Les différents défauts dans le système de câblage*	32
Tableau 4	*Les différents défauts dans le système de protection*	33
Tableau 5	*Les différents défauts dans l'onduleur*	34
Tableau 6	*Les défauts dans le système d'acquisition*	35
Chapitre III : Réseaux de neurones artificiels (ANN)		
Tableau 1	*Un exemple de la façon dont les données sont randomisées avant formation Le tableau de gauche est en ordre, tandis que le tableau du droit a été randomisé*	61
Chapitre IV : Simulation et Résultats		
Tableau 1	*Distribution des échantillons par classe*	72
Tableau 2	*Métriques de performance par classe (Précision, Rappel, Score-F1, Spécificité) pour l'ensemble de test.*	76
Tableau 3	*Résultats détaillés des prédictions du réseau neuronal pour les séquences de scénarios de test sous différents niveaux d'éclairement*	81

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]

Io : 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]

ns : Nombre de cellules en série

np : Nombre de cellules en parallèle

G : Conductance du GPV

D : Rapport cyclique

P&O: Perturb and Observe

Ce: couple électromagnétique du moteur

Cr: couple de charge (ou couple résistant)

ω: vitesse de l'arbre du moteur

Introduction générale

Introduction générale

L'énergie solaire photovoltaïque occupe aujourd'hui une place importante dans la transition énergétique mondiale grâce à son caractère renouvelable, propre et durable. L'augmentation de la demande énergétique, associée aux préoccupations environnementales et à la réduction des émissions de gaz à effet de serre, a favorisé le développement rapide des systèmes photovoltaïques dans différents secteurs d'application.

Cependant, malgré leurs nombreux avantages, les installations photovoltaïques sont souvent confrontées à divers défauts et anomalies pouvant affecter leurs performances et réduire leur rendement énergétique. Ces défauts peuvent être liés aux modules photovoltaïques, aux câbles, aux diodes, aux convertisseurs ou encore aux conditions environnementales telles que l'ombrage, l'encrassement et les variations climatiques. La détection précoce de ces défauts constitue donc un enjeu majeur afin de garantir la fiabilité, la sécurité et la continuité de fonctionnement des systèmes photovoltaïques.

Dans ce contexte, les techniques d'intelligence artificielle, et particulièrement les réseaux de neurones artificiels (ANN), représentent une solution efficace pour le diagnostic automatique des défauts grâce à leur capacité d'apprentissage, de classification et de traitement de données complexes. Ces méthodes permettent d'améliorer la rapidité et la précision du diagnostic tout en réduisant les coûts de maintenance.

L'objectif principal de ce travail est de développer une approche basée sur les réseaux de neurones artificiels pour la détection et le diagnostic des défauts dans les systèmes photovoltaïques. Pour atteindre cet objectif, ce mémoire est structuré en quatre chapitres :

Le premier chapitre présente les généralités sur les systèmes photovoltaïques, leur principe de fonctionnement, leur modélisation électrique ainsi que l'influence des conditions climatiques sur leurs caractéristiques électriques.

Le deuxième chapitre est consacré à l'étude des différents défauts pouvant affecter les systèmes photovoltaïques et aux principales méthodes de détection et de diagnostic utilisées dans la littérature.

Le troisième chapitre présente les réseaux de neurones artificiels, leurs principes de fonctionnement, leurs architectures ainsi que leur utilisation dans les applications de classification et de diagnostic.

Enfin, le quatrième chapitre est dédié à la réalisation pratique du système de diagnostic basé sur les réseaux de neurones artificiels, à la présentation des simulations réalisées sous MATLAB/Simulink ainsi qu'à l'analyse et à la discussion des résultats obtenus.

Les résultats obtenus démontrent l'efficacité des réseaux de neurones artificiels pour identifier les défauts des systèmes photovoltaïques avec une précision satisfaisante, ce qui confirme leur potentiel dans les systèmes intelligents de surveillance et de maintenance prédictive.

CHAPITRE I

Généralités sur les systemes photovoltaïques

I.1 Introduction

L'énergie solaire, renouvelable et omniprésente sur la Terre, est abondante. Grâce aux progrès technologiques, son coût d'exploitation continue de baisser. Chaque jour, la Terre reçoit du soleil l'équivalent d'un an de ses besoins en énergie. Selon l'Agence Internationale de l'Énergie (AIE), une superficie de 145 000 km² (qui représente 4 % des déserts les plus secs au monde) suffirait à satisfaire tous les besoins en électricité de la Terre [1].

La technologie de l'énergie solaire photovoltaïque (PV) est l'une des solutions les plus innovantes pour la production d'électricité à l'échelle mondiale parmi les énergies renouvelables. Les atouts majeurs sont durables, accessibles mondialement, écologiques, sans coût, non polluants et requérant un minimum d'entretien [2].

I.2. Le spectre solaire

La diversité de radiations colorées qui constituent la lumière du soleil est définie par leur intervalle de longueur d'onde. Le spectre solaire est caractérisé par sa décomposition en longueurs d'onde ou en teintes [3].

La longueur d'onde des photons, grains de lumière qui constituent ce rayonnement électromagnétique, est liée à leur énergie par la relation :

$$E = hv = \frac{hc}{\lambda} \qquad (I.1)$$

υ = fréquence de l'onde électromagnétique (Hz)

h = constante de Planck, h = 6.626x10-34eV.s

C : est la vitesse de la lumière.

λ : est la longueur d'onde.

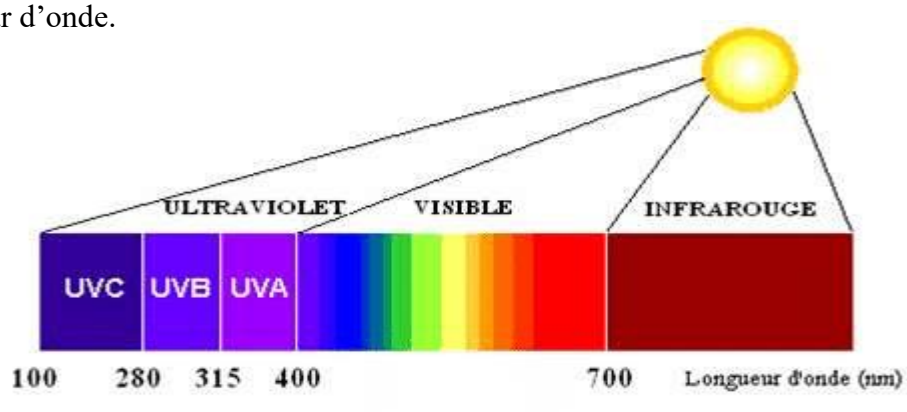


Figure I.1 : Spectre solaire [2].

Le tableau suivant explique la Figure I.1:

Tableau I.1 : Les domaines spectraux du rayonnement solaire.

Le domaine	La longueur d'onde (nm)	Energie (%)
Ultra –Violet	200 - 400	07.0
Visible	400 - 800	47.0
Infra – Rouge	800 - 1400	45.5

Un graphique standard de la distribution spectrale du rayonnement solaire extraterrestre. Selon les informations collectées par les satellites, on appelle cela AM0 [4].

Sa distribution en énergie est répartie comme suit :

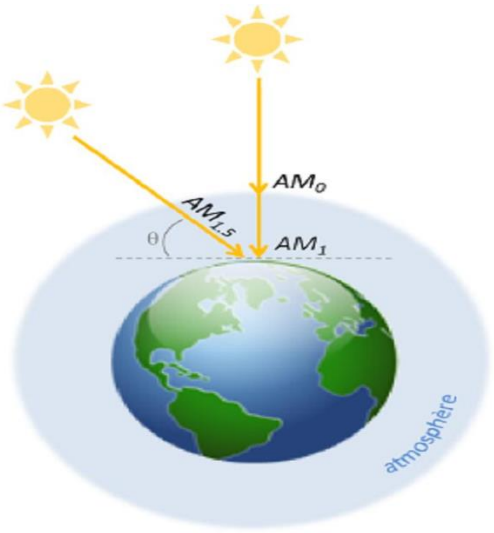


Figure I.2: Description de l'incidence sur la terre [4].

Ultraviolet UV 0.20<λ<0. 38µm 64%

Visible 0.38<λ<0. 78µm 48.0%

Infrarouge IR 0. 78<λ<10µm 45.6%

On trouve aussi deux autres formes d'illumination simulée, mentionnées dans la littérature, à savoir AM1 et AM0 (voir figure I.2). Elles correspondent respectivement à une exposition sous incidence normale à travers l'atmosphère et sans traverser l'atmosphère [5].

La figure I.3 illustre la couche standard de répartition spectrale du rayonnement solaire hors atmosphère, connue sous l'appellation AM0. La figure I.3 illustre également la diminution observée suite à la traversée d'une épaisseur d'atmosphère équivalente à une masse d'air de 1.5, ce qui correspond à une altitude solaire de 41.8° au niveau de la mer. Cette référence de spectre de ciel dégagé, notée AM 1.5, est utilisée pour mesurer les cellules photovoltaïques. Les simulateurs employés pour évaluer les modules cherchent à reproduire avec la plus grande précision possible le module. Le spectre AM 1.5 montre des bandes

d'absorption qui sont en adéquation avec les gaz atmosphériques, comme le CO2 et la vapeur d'eau. Le graphique présente également le spectre d'un corps noir ayant une température de couleur de 5900 K, qui est presque identique au spectre solaire AM0. On associe fréquemment ce corps noir au soleil, ce qui permet aux scientifiques de construire des modèles pour décrire son comportement et ses émissions de radiations [6].

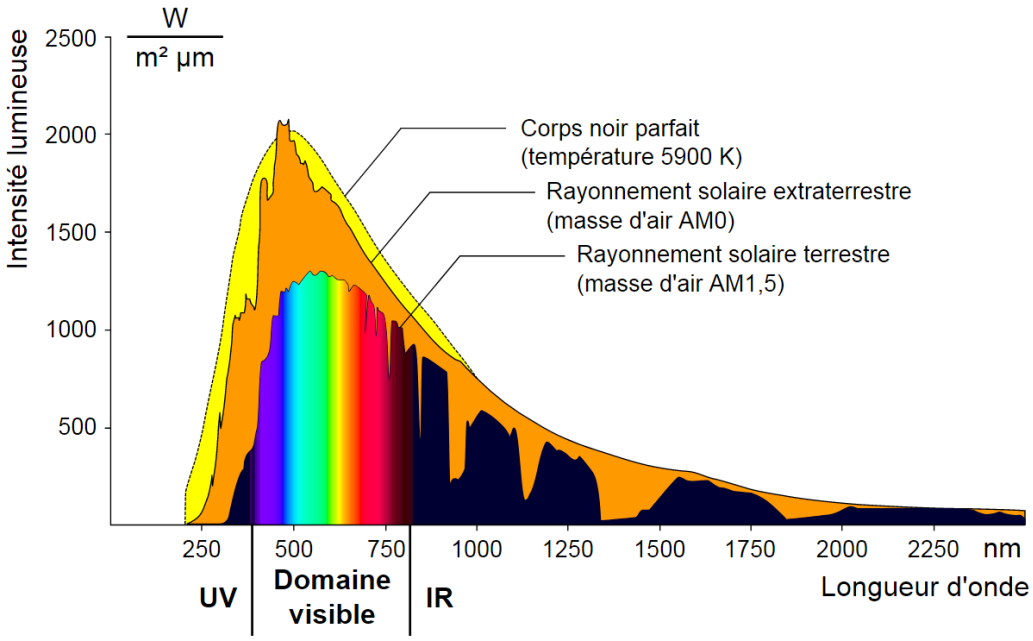


Figure I.3: Répartition spectrale du rayonnement [5].

I.3. Le principe de L'effet photovoltaïque

I.3.1. Histoire de cellules solaires

- Antoine-César Becquerel a observé les effets électriques générés par les rayons du soleil dans une pile en 1839.
- En 1905, Einstein a établi que l'énergie de ces quanta lumineux est directement liée à la fréquence de l'onde électromagnétique.
- L'usage des cellules photovoltaïques a commencé dans les années quarante. Le secteur spatial requiert une énergie dépourvue de combustible embarqué. On intensifie les recherches sur le photovoltaïque.
- En 1954, Chapin, Fuller et Pearson ont fabriqué la première cellule solaire P-N à partir de silicium monocristallin dans les laboratoires Bell. La rentabilité était de 6 %, mais elle a été vite portée à 10 %.

C'est dans les années soixante-dix avec la crise énergétique, que les cellules solaires ont connu leurs premières applications terrestres [6].

I.3.2. L'effet photovoltaïque

Le phénomène photovoltaïque consiste à convertir l'énergie solaire, sous forme de photons, en électricité grâce à un élément semi-conducteur connu sous le nom de cellule solaire. Il capte aisément la lumière, ce qui favorise la création d'un champ électrique et d'une tension électrique [7].

La surface de la cellule solaire est touchée par les rayons lumineux.

Les photons ayant une énergie égale ou supérieure à celle de la bande interdite des matériaux sont captés par le matériau semi-conducteur.

Lorsque l'énergie du photon est transmise aux électrons, des paires électron-trou sont générées.

Une cellule solaire génère un courant continu lorsque des particules sont accumulées sur ses électrodes.

Une portion du faisceau lumineux est renvoyée par la cellule solaire, tandis que l'autre est captée par la structure cristalline de semi-conducteur et transformée directement en électricité. Pour y parvenir, des paires d'électrons et de trous sont générées [8].

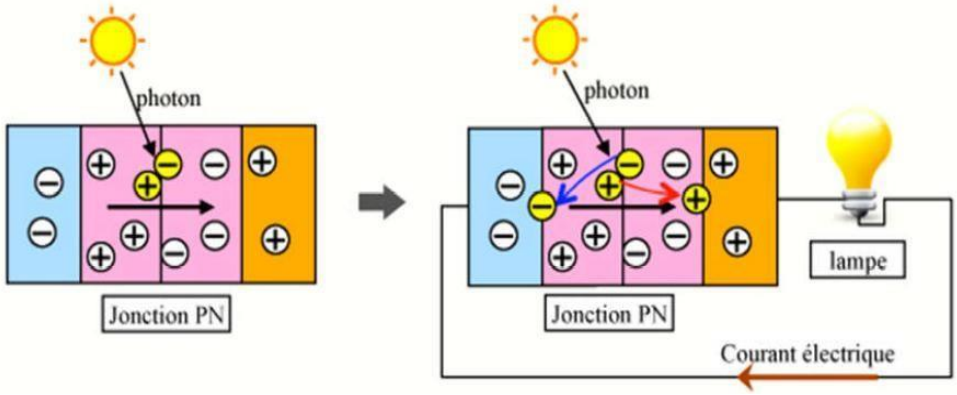


Figure I.4: Création du courant électrique sous l'effet de la lumière [8].

I.3.3. Absorption du rayonnement dans le matériau (Propriétés optiques des semi-conducteurs)

L'interaction et l'absorption des photons par un semi-conducteur sont principalement déterminées par le coefficient d'absorption. Cette valeur représente le nombre de photons absorbés par unité d'épaisseur du matériau semi-conducteur. Cela dépend également de la longueur d'onde.

Si une intensité I_i (λ) incident sur une surface de coefficient d'absorption α(λ) et coefficient de réflexion R(λ) est absorbée et devient à une profondeur x selon la loi de Bougner-Lambert [7] :

$$I(\lambda, x) = I_i(\lambda)(1 - R(\lambda)exp(-\alpha(\lambda)x) = I(\lambda, 0)exp(-\alpha(v)x) \quad \text{(I.2)}$$

Ii: l'intensité de rayonnement lumineux incident.

Les photons à faible longueur d'onde sont absorbés à la surface du semi-conducteur et ils sont à l'origine de la formation des paires électron-trou.

Alors que les photons ayant une longueur d'onde plus longue se trouvent à une certaine distance de la surface. La figure ci-dessous résume la loi de Béer-Lambert.

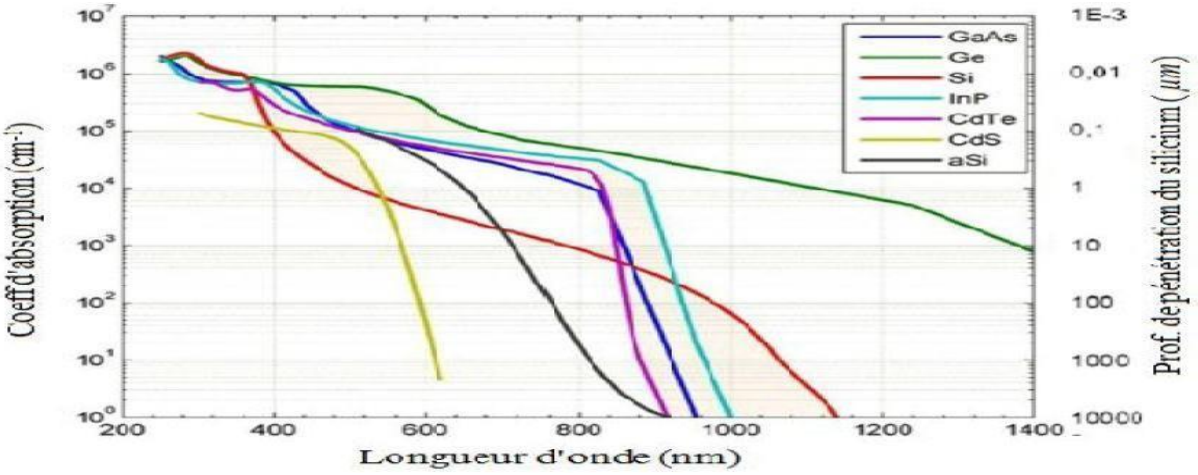


Figure I.5: Profondeur de pénétration et coefficient d'absorption de quelques semi- conducteurs à 300K en fonction de la longueur d'onde [9].

I.4. La structure de la cellule solaire

L'arrière ne pose pas de difficulté majeure pour la collecte, une couche conductrice devrait suffire. Si une certaine luminosité persiste à ce stade, une couche réfléchissante serait idéale. Cette réflexion aide à capter plus de lumière, les photons restants traversant de nouveau la jonction.

Pour que les photons parviennent à la jonction, la façade doit être assez transparente. Il est nécessaire d'utiliser un oxyde transparent conducteur (O.T.C) tel que le ZnO de faible épaisseur pour les couches fines, et une grille conductrice pour l'autre filière en général [10].

On constatera également que l'utilisation de d'autres couches minces composées de divers matériaux, qui sont appliquées à l'avant ou à l'arrière de la jonction, pourrait être envisagée, en particulier dans le cas des hétérojonctions, dans le but d'améliorer le rendement.

I.4.1. L'émetteur et la base

Les couches émetteur et base sont des couches fines à base de semi-conducteur.

La région de type n dans une cellule n-p est nommée émetteur.

La région de type p- est nommée la base.

Pour réduire l'absorption au niveau de l'émetteur, il est nécessaire que leur épaisseur soit nettement inférieure à celle de la base afin d'assurer la collecte des porteurs. [10]

Le dopage de l'émetteur devrait se situer autour de 10^{18} cm^{-3}, tandis que celui de la base doit être inférieur [10].

L'enrichissement de la base joue un rôle crucial dans l'amélioration de l'efficacité de la cellule photovoltaïque.

Un dopage léger prolonge la longévité des porteurs minoritaires, cependant il amplifie le courant d'obscurité et par conséquent réduit l'efficacité de la cellule.

I.4.2. Les contacts

Des contacts métalliques sont disposés sur le devant et l'arrière de la cellule photovoltaïque.

Ils forment une barrière de potentiel connue sous le nom de « barrière de Schottky » [11]. Le contact supérieur occupe entre 2 et 8% de la surface de la cellule solaire.

Ce contact joue un rôle dans la réduction de l'ombre et la prévention de la recombinaison. Tandis que le contact de bas en haut recouvre la partie inférieure de la cellule.

Parmi les métaux utilisés pour les contacts ohmiques des cellules solaires sont : Li, Na, K, Fe, Ni, Al, Cu, Ag, Au, Pt [12].

I.4.3. La fenêtre

La couche fenêtre est une couche qui conduit l'électricité. Elle autorise le déplacement des électrons vers les connexions électriques sans accroître la résistance des cellules assemblées en série.

Afin de permettre aux lumières de traverser les couches de la cellule solaire photovoltaïque, on doit recourir à des matières semi-conductrices dont l'énergie de gap est suffisamment élevée pour être transparentes à la lumière [13].

I.4.4. Couche anti reflet

Afin de minimiser la réverbération lumineuse à moins de 5% sur le devant de la surface de la cellule photovoltaïque, un revêtement anti-réfléchissant (anti-réflétant Cotinga CAR) est appliqué sur celle-ci [13].

La fonction de la couche anti-reflet repose sur le principe de l'interférence des rayons lumineux au sein de couches diélectriques minces [14].

Pour les cellules photovoltaïques à haut rendement, l'usage d'une double couche antireflet (comportant deux diélectriques distincts) est recommandé [15].

Par conséquent, en l'absence de la couche antireflet, la cellule solaire renvoie jusqu'à 33 % de la lumière incidente atteignant sa surface. [2].

Le tableau ci-dessous présente les matériaux employés comme couches antireflets ainsi que leurs indices de réfraction [2].

Tableau I.2: L'indice de réfraction de quelques matériaux

Matériau	N
MgF_2	1.38
CeF_3	1.65
ZrO_2	2.10
TiO2	2.62
Al_2O_3	1.76
ZnS	2.36

La structure fondamentale de la cellule solaire est schématisée à la (Fig. I-6).

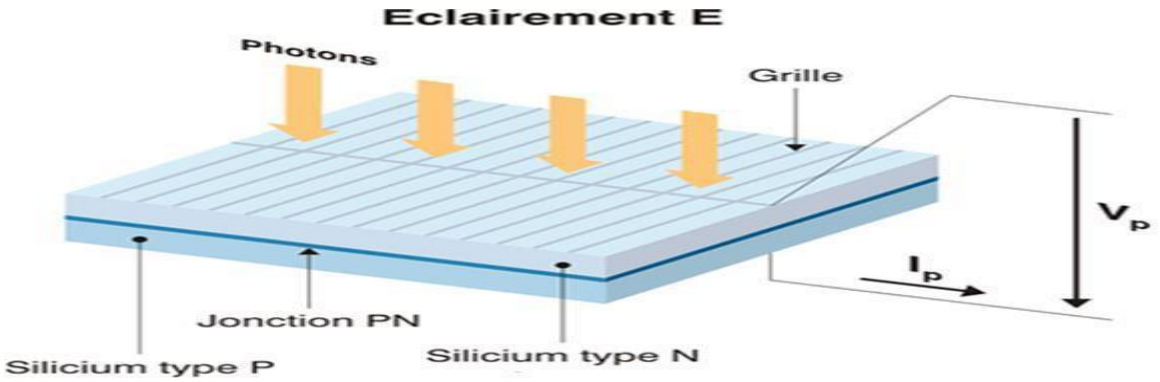


Figure I.6 : La structure fondamentale d'une cellule solaire [16].

I.5. Amélioration du rendement

Afin d'optimiser l'efficacité de la conversion photovoltaïque, plusieurs méthodes sont employées, notamment celles qui se réfèrent à la surface exposée à la lumière de la cellule, la texturation, l'application de couches anti-reflets et de passivation, ainsi que l'établissement du champ électrique devant et derrière [17].

I.5.1. Effet du confinement optique

L'optique confinée vise à minimiser les réflexions en façade avant et arrière. Les méthodes couramment employées comprennent la texturation de la surface frontale par

formation de pyramide pour générer de nombreuses réflexions lumineuses à la surface, ou l'intégration de couches anti-reflets [18].

I.5.2. Effet de passivation

L'amélioration du rendement des cellules photovoltaïques demeure dépendante de la passivation des défauts présents à la surface et dans le volume. Lors du processus de production des cellules, il existe une grande variété de méthodes de passivation. La passivation des liaisons pendantes à la surface par l'essor d'un oxyde thermique.

I.5.3. Effet d'un champ avant ou arrière

Les contacts métalliques sont à l'origine des recombinaisons qui se produisent à la surface arrière. Pour lutter contre cela et aussi créer et rassembler des paires grâce aux radiations de longue onde pour lesquelles la cellule est transparente, l'idée a été suggérée d'employer un champ électrique par le biais d'une variation du dopage ou du gap sur le côté arrière, ce qui permet de neutraliser la face arrière de la cellule.

Le champ électrique à la surface arrière BSF (Back Surface Field) est une mince couche fortement dopée. Elle est dopée (p+ ou n+) en utilisant le même genre de dopage que le substrat [20].

Dans cette région, les porteurs minoritaires injectés sont repoussés vers la jonction et contribuent au courant photoélectrique [16].

La figure suivante résume la composition d'une cellule solaire :

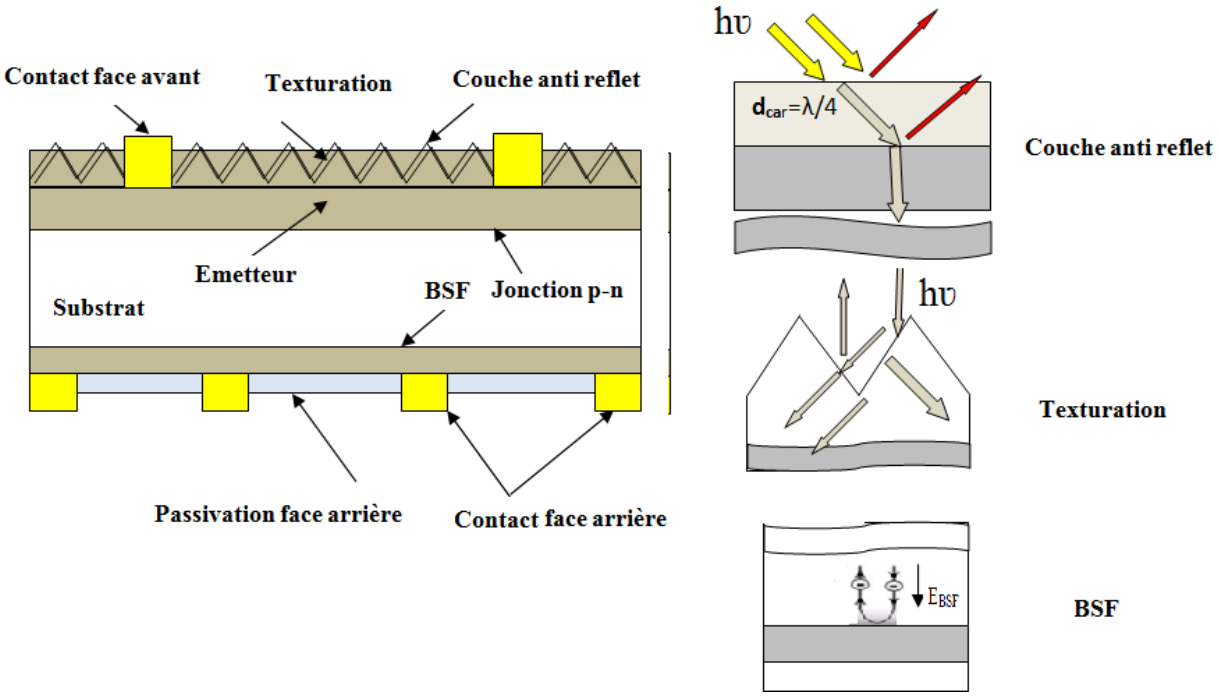


Figure I.7: Structure d'une cellule photovoltaïque [20].

I.6.Principe de fonctionnement d'une cellule photovoltaïque

La cellule photovoltaïque, aussi connue sous le nom de photopile, est le plus petit élément d'un système photovoltaïque.

Les cellules sont produites à partir de lingots de silicium. En appliquant du bore ou du phosphore sur ces lingots, on les segmente en couches minces de type P ou N [11]. On crée alors une cellule solaire en formant une jonction de type opposé, aussi appelée jonction PN. Un champ électrique près de la jonction préserve la division des charges positives et négatives.

Les cellules photovoltaïques sont constituées :

- D'une fine couche semi-conductrice.
- D'une couche anti-reflet permettant une pénétration maximale des rayons solaires.
- D'une grille conductrice sur le dessus (cathode) et d'un métal conducteur sur le dessous (anode).
- Les plus récentes possèdent même une nouvelle combinaison de multicouches réfléchissants justes en dessous du semi-conducteur, permettant à la lumière de rebondir plus longtemps dans celui-ci pour améliorer le rendement.

La Figure I.8 représente la structure basique d'une cellule photovoltaïque.

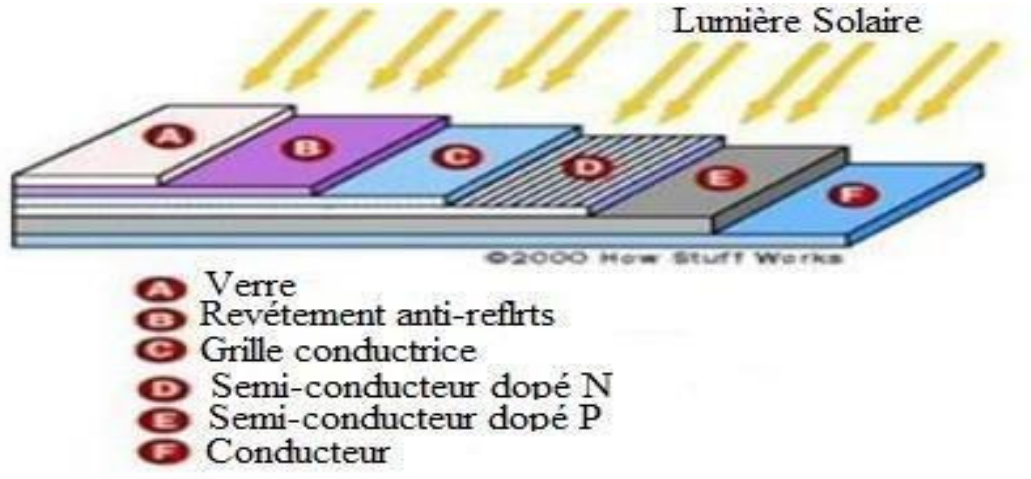


Figure I.8 : Structure basique d'une cellule solaire.

Une cellule photovoltaïque opère via l'effet photovoltaïque, un processus physique qui génère une force électromotrice dès que sa surface est soumise à la lumière. La tension générée fluctue entre 0,3 V et 0,7 V selon le matériau employé, son agencement, la température et l'usure de la cellule [12].

Une cellule PV donc est un dispositif qui permet de transformer l'énergie solaire en énergie électrique. Cette transformation est basée sur les trois mécanismes suivants [10] :

- Absorption de la lumière dans le matériau.
- Le transfert de l'énergie lumineuse aux électrons.
- La collecte des charges.

Par conséquent, le matériau utilisé dans la cellule solaire doit présenter deux niveaux d'énergie et être suffisamment conducteur pour faciliter le passage du courant, c'est pourquoi l'importance des semi-conducteurs est cruciale dans ce secteur.

Pour collecter les particules générées, il est indispensable d'avoir un champ électrique qui sépare les paires électron/trou créées.

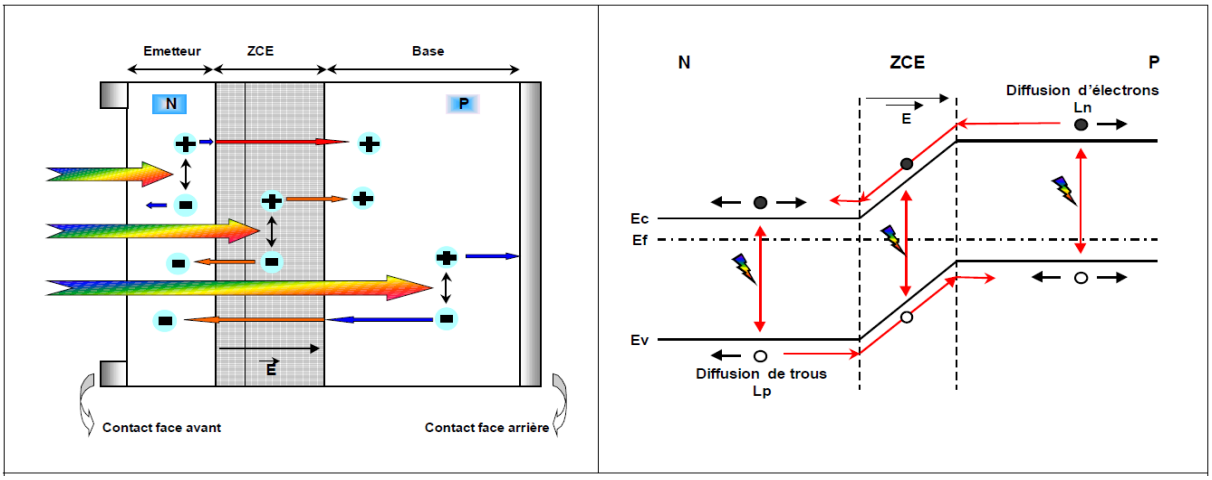


Figure I.9 : Le principe de fonctionnement d'une cellule photovoltaïque [10]

Comme l'illustre la figure ci-dessus (figure I.9), les photons incidentes génèrent des porteurs dans les régions N et P ainsi que dans la zone de charge d'espace. Le comportement des photo-porteurs variera en fonction de la région [19]:

- Quand des porteurs minoritaires arrivent dans la zone de charge d'espace de la zone N ou P, le champ électrique les « dirige » vers la zone N (pour les électrons) ou vers la zone P (pour les trous), où ils deviendront majoritaires. Une image de diffusion actuelle sera affichée.
- Dans la zone de charge de l'espace, le champ électrique sépare le duo électron/trou généré par les photons incidents : les électrons se déplacent vers la zone N tandis que les trous se dirigent vers la zone P.

Ce mouvement des porteurs de charge engendre un courant photoélectrique. Ces deux apports combinés produisent un courant total IPh. Il s'agit d'un mouvement de porteurs minoritaires. C'est en rapport avec l'intensité de la lumière [14].

I.7.Modélisation électrique d'une cellule photovoltaïque

Il existe plusieurs modèles électriques d'une cellule photovoltaïque dont deux modèles sont les plus utilisés [9] :

a) Le modèle standard (Modèle à une seule diode)

b) Le modèle à deux diodes

I.7.1. Le modèle à une seule diode

Une fois qu'ils ont atteint la zone de charge d'espace dans la région N ou P, le champ électrique les oriente vers la zone N (pour les électrons) ou la zone P (pour les trous), où ils deviendront majoritaires. Une image de diffusion sera en cours.

Le champ électrique dans la zone de déplétion perturbe le jumelage électron/trou créé par les photons incidentiels. Les électrons se déplacent vers la zone N, tandis que les trous se déplacent vers la zone P. [8]

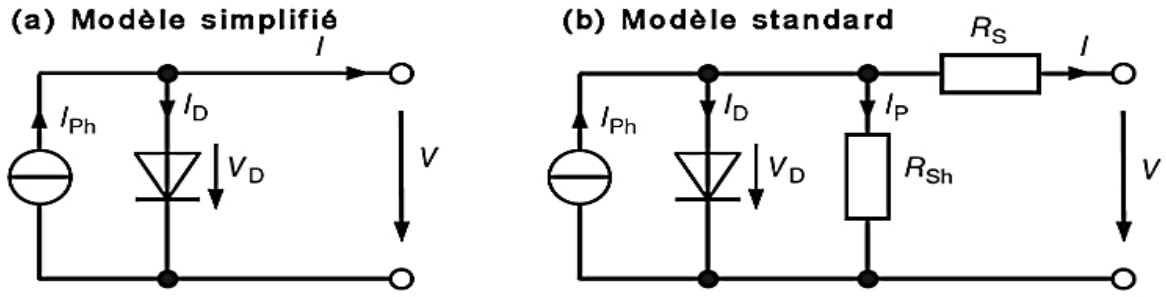


Figure I.10 : Le modèle à une seule diode [8]

Pour obtenir les courbes caractéristiques du modèle standard, le courant délivré par une cellule PV devient :

$$I = I_D - I_P \tag{I.3}$$

Ainsi, on détermine le courant à travers la résistance parallèle R_{sh} par la relation I.4 :

$$I_P = \frac{V_D}{R_{sh}} = \frac{V + I.R_s}{R_{sh}} \tag{I.4}$$

On déduit alors, une équation non linéaire qui décrit les courbes caractéristiques du modèle standard de la cellule photovoltaïque, exprimée par la formule I.5 [15]:

$$I = I_{ph} - I_s\left(e^{\frac{V+I.R_s}{mV_T}}\right) - \frac{V + I.R_s}{R_{sh}} \quad \text{(I.5)}$$

L'illustration I.11 démontre que l'accroissement de la résistance série Rs influence les courbes caractéristiques tout en provoquant une réduction notable du facteur de forme 'FF', conduisant à une baisse de l'efficacité énergétique de la cellule photovoltaïque. Il en va de même lorsque les valeurs de R_{sh} s'accroissent, influant ainsi sur la tension à circuit ouvert. Toutefois, un accroissement du courant I_P entraîne une diminution significative de la tension de la diode V_D.

Il est important de souligner que la cellule photovoltaïque agit comme une diode en l'absence de lumière. Elle ne génère pas d'électricité. Toutefois, un courant d'identification peut circuler si elle est reliée à une source de tension extérieure. (I_D le courant à travers la jonction non éclairée).

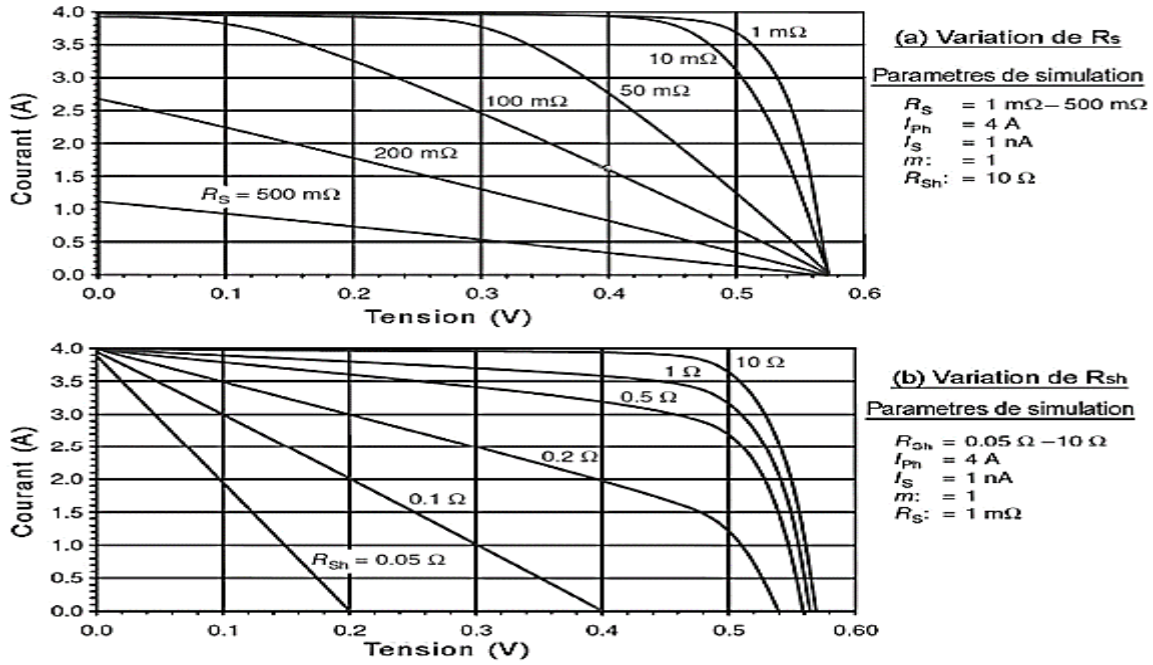


Figure I.11 : Influence de la résistance série R_s et de la résistance parallèle R_{sh} [20]

I.7.2. Le modèle simplifié à une seule diode

Dans cette recherche, le circuit équivalent employé reste simplifié. On peut avoir recours aux équations pour illustrer de manière approximative la relation entre le courant et la tension [20] :

$$I = I_{sc}\left(1 - C_1\left[exp\left(\frac{V}{C_2 V_{oc}}\right) - 1\right]\right) \quad \text{(I.6)}$$

Avec :

$$C_1 = \left(1 - \frac{I_m}{I_{sc}}\right).exp\left(-\frac{V_m}{C_2 V_{oc}}\right) \quad \text{(I.7)}$$

$$C_2 = \frac{\left(\frac{V_m}{V_{oc}} - 1\right)}{ln\left(1 - \frac{I_m}{I_{sc}}\right)} \quad \text{(I.8)}$$

I_{sc}: Courant de court-circuit du module (A),

V_{oc}: Tension de circuit ouvert du module (V),

I_m: Courant maximal dans les conditions standards (A),

V_m: Tension maximale du module dans les conditions standards (V),

L'adaptation de l'équation (1) à d'autres niveaux d'insolation et des températures, le modèle décale n'importe quel point (V_{ref}, I_{ref}) des courbes de référence I -V à un nouveau point (V_{nov}, I_{nov}) sur la base des équations suivantes :

$$\Delta T = T - T_{ref} \quad \text{(I.9)}$$

$$\Delta I = \alpha_0\left(\frac{E}{E_0}\right)\Delta T + \left(\frac{E}{E_0} - 1\right)I_{sc} \quad \text{(I.10)}$$

$$\Delta V = \beta_0 \Delta T - R_s \Delta I \quad \text{(I.11)}$$

$$I_{nov} = I_{ref} + \Delta I \quad \text{(I.12)}$$

$$V_{nov} = V_{ref} + \Delta V \quad \text{(I.13)}$$

Avec :

E: Irradiation solaire sur un plan incliné (W/m²),

E_0 : Irradiation solaire de référence (1000 W/m²),

α_0: Coefficient de température de Isc (A /°C),

β_0 : Coefficient de température de Voc (V/°C),

T : Température de la cellule photovoltaïque (° C),

T_{ref} : Température de référence de la cellule photovoltaïque (25°C).

I.7.3. Le modèle à deux diodes

Le phénomène de recombinaison engendre des pertes considérables dans une cellule photovoltaïque réelle, qu'il n'est pas possible de simuler fidèlement avec le modèle de diode. Comme illustré dans la figure I.12, suite à la prise en compte de ces pertes, une deuxième diode est intégrée au circuit [8] :

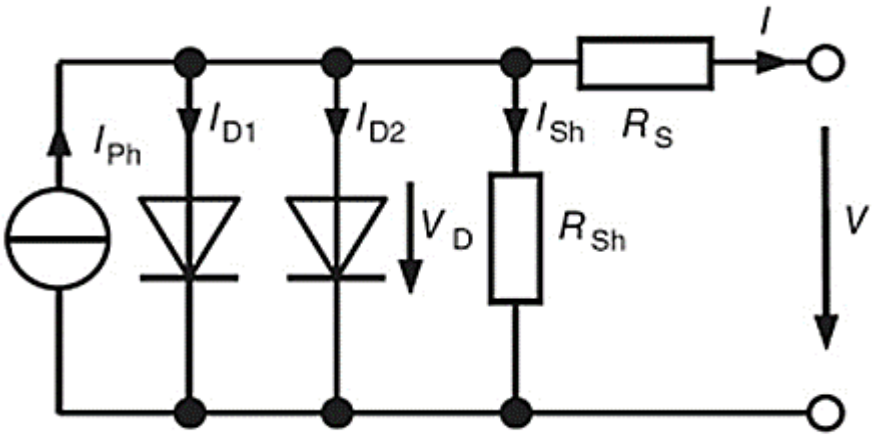


Figure I.12 : Le modèle à deux diodes pour une modélisation plus exacte [8]

Cependant, l'équation de la courbe caractéristique du modèle à deux diodes peut être décrite, par analogie à l'équation I.10, par :

$$I = I_{ph} - I_{s1}\left(e^{\frac{V+I.R_s}{m_1 V_T}} - 1\right) - I_{s2}\left(e^{\frac{V+I.R_s}{m_2 V_T}} - 1\right) - \frac{V + I.R_s}{R_{sh}} \qquad \text{(I.14)}$$

Ou*:* I_{s1} et I_{s2} sont les courants de saturation inverse de la diode 1 et de la diode 2. Le terme I_{s2} est introduit pour compenser la perte de recombinaison dans la jonction.

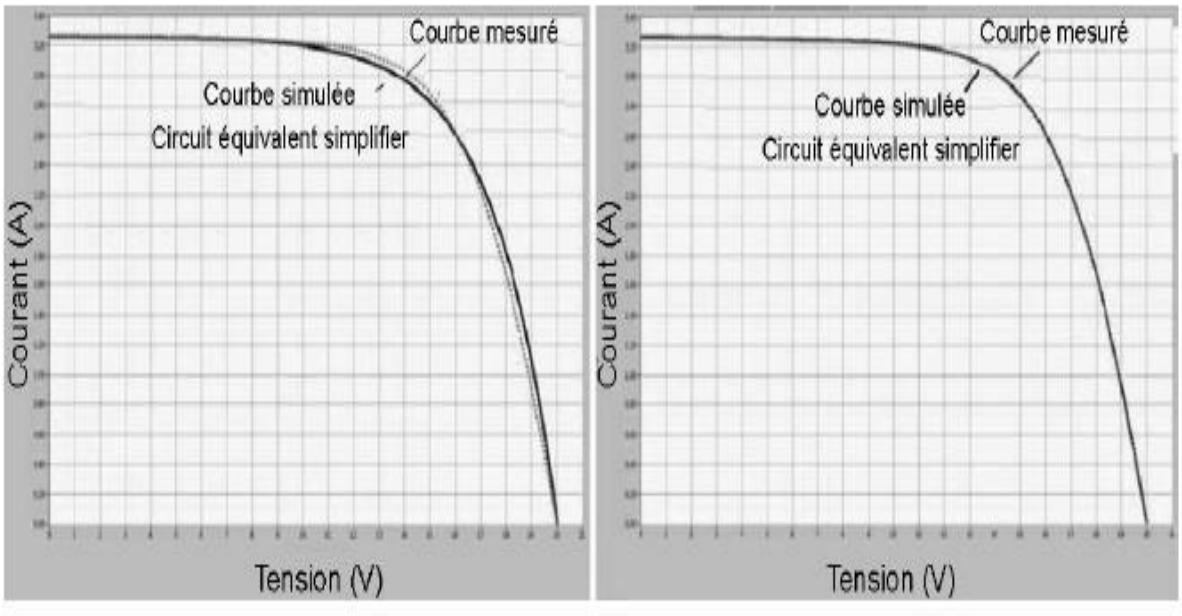
Il faut noter que le modèle à une diode est facile à manipuler, cependant il est moins précis en comparaison avec le modèle à deux diodes. La technique itérative évoquée dans [5] est la plus performante. Toutefois, lors de faibles irradiations, notamment près de la tension à circuit ouvert, sa précision se dégrade [11]. L'ajout d'une seconde diode au circuit entraîne une augmentation du nombre de paramètres à sept : le courant de saturation inverse et le facteur d'idéalité de la seconde diode sont intégrés. L'enjeu majeur réside dans l'identification de l'ensemble des paramètres du modèle.

I.7.4. Détermination des paramètres du circuit équivalent

Si la courbe (I-V) mesurée est accessible, il est possible de déterminer les paramètres du circuit équivalent simplifié à partir de celle-ci. Comme mentionné précédemment, le photo-courant I_{sh} peut être défini comme étant identique au courant de court-circuit I_{sc}. De plus, pour un facteur d'idéalité unitaire (m=1), le courant de saturation est défini selon l'équation I.4 par [1] :

$$I = I_{sc}e^{-V_{oc}/V_t} \tag{I.15}$$

Si la courbe I-V est à disposition, il est possible de déterminer les paramètres du circuit équivalent simplifié en s'en servant. Comme mentionné précédemment, le courant de court-circuit Isc est identique au courant photo Ish. De plus, pour un facteur d'idéalité unitaire (m=1), le courant de saturation peut être déterminé à partir de l'équation I.4 comme suit [10]:



Circuit équivalent simplifiée *Circuit équivalent standard*

Figure I.13 : Courbe I-V simulée d'un module solaire : Le circuit équivalent simplifié [6].

Il convient de noter que la qualité du circuit équivalent standard est la meilleure par rapport au modèle simplifié.

R_s et R_{sh} sont déterminés à partir du gradient de courbe (I-V) aux voisinages des points de court-circuit et du circuit ouvert.

Une cellule photovoltaïque est caractérisée par plusieurs paramètres cités si dessous :

I.7.4.1. Le courant de court-circuit, I_{cc}

Il s'agit du courant produit en mettant les bornes de la cellule en court-circuit (V=0). Ce courant augmente de manière linéaire en fonction de l'intensité d'illumination de la cellule, et il est également influencé par la dimension de la surface éclairée, la longueur d'onde du rayonnement, la mobilité des porteurs et la température. [5]

On peut écrire : I_{cc} (V=0) = I_{ph}

I.7.4.2. La tension de circuit ouvert, V_{co}

Comme l'indique son appellation, il s'agit de la tension aux bornes de la cellule lorsqu'elle n'est pas reliée à une charge ou lorsqu'elle est liée à une charge de résistance infinie. Elle repose principalement sur la sorte de cellule photovoltaïque (jonction PN, jonction Schottky), les matériaux utilisés pour la couche active et le type de contacts entre la couche active et l'électrode. Elle est également tributaire de l'éclairement de la cellule[10].

$$V_{co} = ln\frac{nkt}{q} \tag{I.16}$$

n : Facteur d'idéalité de la diode.

K : constante de Boltzmann (1,381.10^{-23} Joule/Kelvin).

T : Température de la jonction p-n des cellules.

q : Charge d'électron (1,602.10^{-19} C).

E : Eclairement reçu.

E_0 : Eclairement de référence.

Il peut aussi être calculé par :

$$V_{co} = \frac{nkt}{q}\ln(\frac{I_{cc}}{I_s} + 1) \tag{I.17}$$

I_{cc} : Courant continu de la cellule.

I_s : Courant de saturation de la diode.

I.7.4.3. La réponse spectrale, SR (λ)

La réponse spectrale d'une cellule solaire est le rapport du courant total généré par la cellule au courant qui peut être généré pour chaque longueur d'onde du spectre incident. Elle renseigne sur la réaction de la radiation incidente et permet de fixer la gamme d'utilisation de la cellule. [14]

I.7.4.4. La puissance maximale, P_m

La puissance débitée par une cellule solaire est maximum quand le produit (V.I) est maximum. Si V_M I_m sont la tension et le courant pour lesquels on a ce maximum, la puissance maximum est la surface du plus grand rectangle de côtés V_M et I_m.

$$P_M = I_m.V_M = (\mathrm{IV})_{max} \tag{I.18}$$

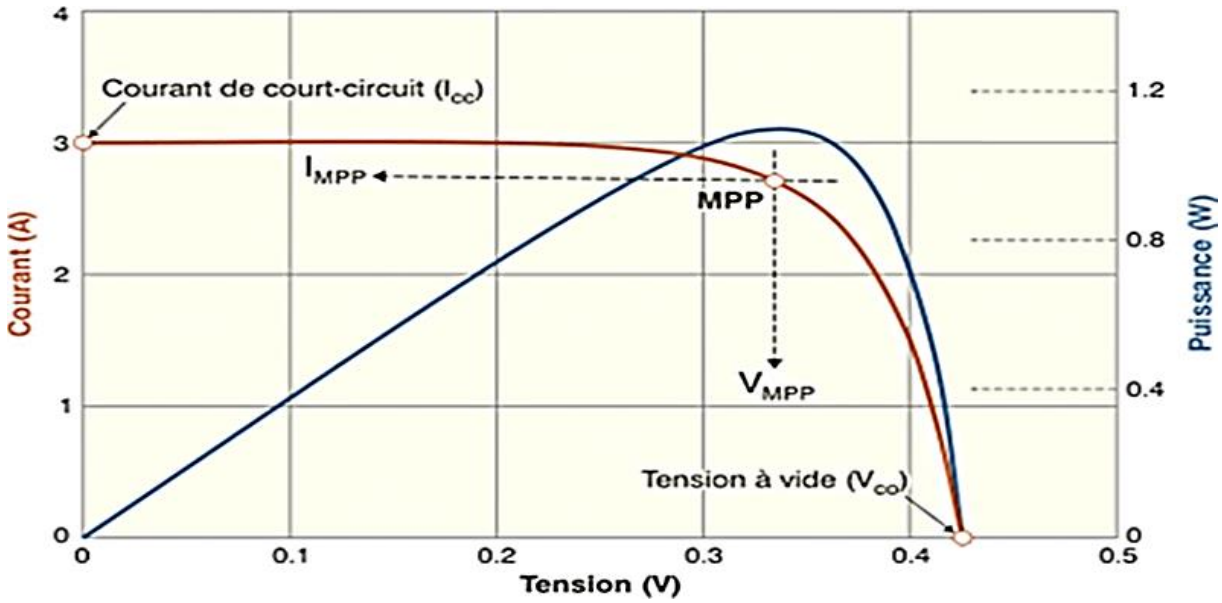


Figure I.14 : Caractéristique I(V) et P(V) d'une cellule solaire [11].

I.7.4.5. Le facteur de forme, FF

Le facteur de forme est un indicateur de la performance de la cellule et peut signaler le moment où celle-ci commence à se détériorer. Il s'agit du rapport entre la puissance qu'une cellule est théoriquement capable d'obtenir et la puissance maximale qu'elle peut réellement fournir [5].

$$FF = \frac{P_{max}}{I_{cc}.V_{co}} = \frac{I_{opt}.V_{opt}}{I_{cc}.V_{co}} \tag{I.19}$$

I.7.4.6. Le rendement de conversion η

Le rendement de conversion d'énergie est le rapport de la puissance générée et de la puissance du rayonnement solaire incident P_o. On appelle rendement rapport de la puissance maximale fournie (P_{max}) sur la puissance du rayonnement solaire incident (P_i) :

$$\eta = \frac{P_{max}}{P_i} = \frac{I_{opt}.V_{opt}}{\emptyset.S} \quad \text{(I.20)}$$

S : Surface de la cellule solaire.

Ø : Flux incident.

I.8. Simulation du modèle électrique de la cellule/panneau PV sous MATLAB/Simulink

I.8.1. Implémentation du modèle sous Simulink

Cette partie concerne la modélisation d'une cellule solaire via Simulink/Matlab, en utilisant les divers blocs présents dans Simulink pour illustrer les paramètres électriques et physiques de la cellule. Ces éléments offrent la possibilité de reproduire les attributs de performance du panneau solaire (Figure 1.5).

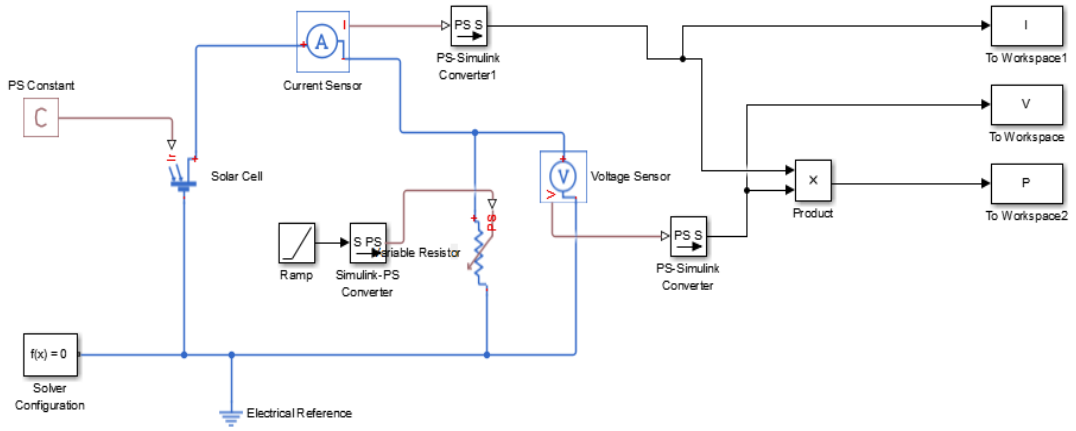
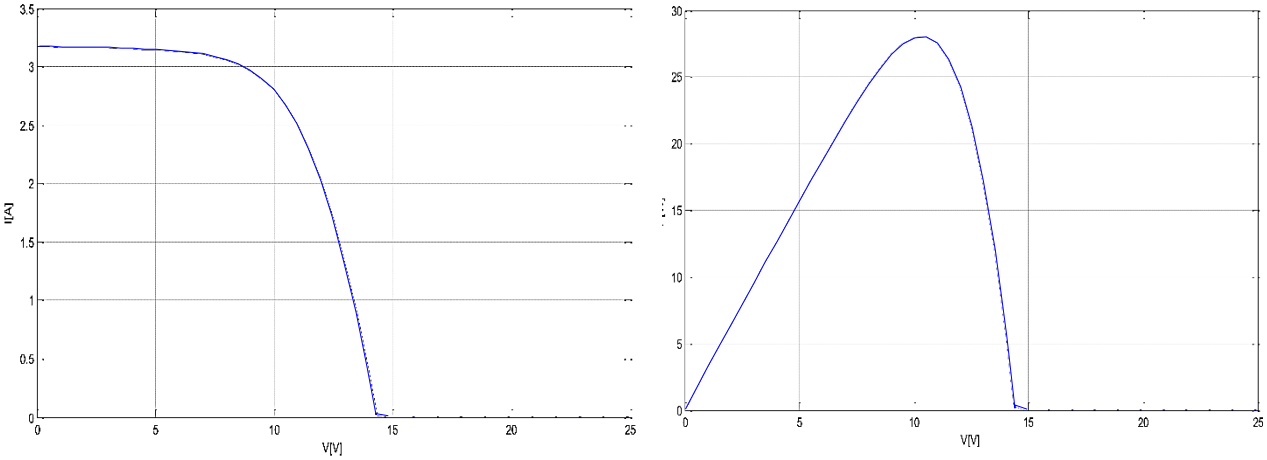


Figure I.15 : Schéma block d'une cellule sous Matlab-Simulink

I.8.2. Caractéristiques I-V et P-V en conditions standards (STC)

Nous allons étudier le fonctionnement de notre panneau solaire sous des conditions normales d'opération, c'est-à-dire avec une irradiation G = 1000 W/m2 et une température T = 25°C.

On peut noter trois aspects essentiels qui donnent les valeurs électriques du système en court-circuit (I = 8.1 A, V = 0), en circuit ouvert (I = 0, V = 32.9 V) et le point de puissance maximale de 212 W associé à (I = 7.6 A, V = 27.9 V).



a) Caractéristique I-V b) Caractéristique P-V

Figure I.16 : Caractéristique Ipv = f(Vpv) et Ppv = f(Vpv) sous les conditions : G = 1000 W/m2, T=25°C (à l'aide de l'outil MATLAB / Simulink)

I.8.3. Influence des conditions climatiques (T et G) sur les caractéristiques

I.8.3.1. L'influence de l'éclairement

Les figures I.17 et I.18 illustrent les caractéristiques I(V) et P(V), où nous avons représenté la fluctuation du courant et de la puissance en relation avec la tension pour diverses intensités d'ensoleillement. Dans la première partie des caractéristiques, le courant est proportionnel au rayonnement à ces intensités lumineuses. Cependant, la tension ne se détériore pas grandement lors de l'augmentation de la luminosité.

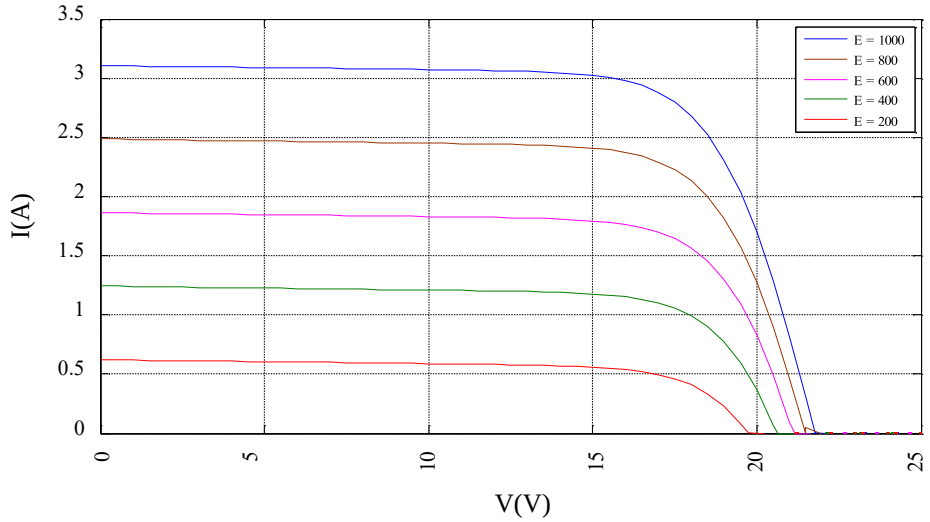


Figure I.17 : Caractéristique I(V) d'un panneau photovoltaïque pour différents éclairements

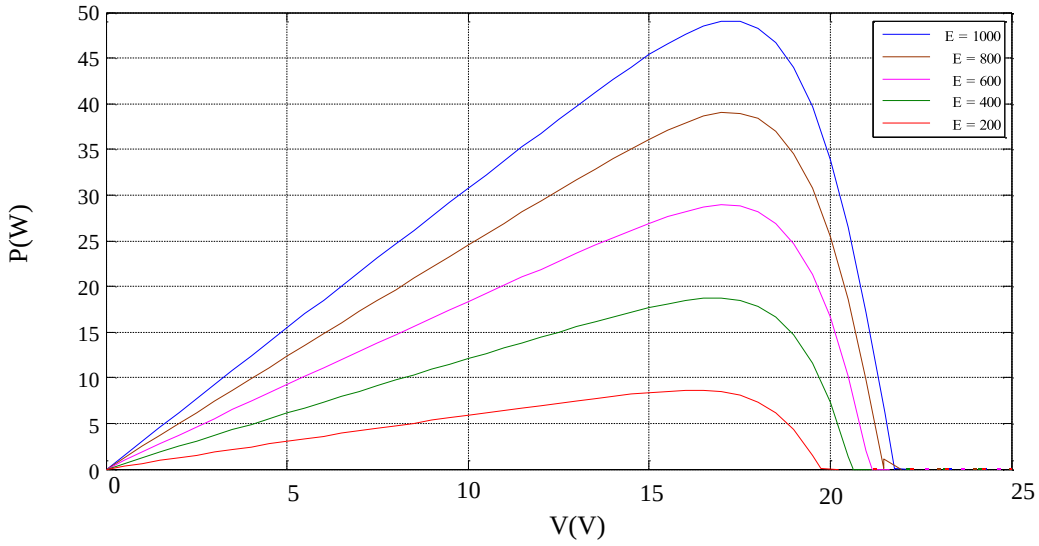


Figure I.18 : Courbe P(V) de puissance d'un panneau photovoltaïque pour différents éclairements.

I.8.3.2. L'influence de la température

L'impact de la température est très important et exige des décisions cruciales lors de la conception des systèmes.

La tension de la cellule photovoltaïque est fortement influencée par sa température. Par contre, l'impact de la température sur le courant généré par la cellule photovoltaïque est minime. On note que la tension à vide décroît alors que la température interne de la cellule s'accroît. Puisque la puissance de la cellule se définit comme le produit du courant et de la tension, on peut faire une observation similaire avec la courbe de puissance.

Ces impacts sont illustrés dans les diagrammes ci-dessous (I.19) et (I.20) qui présentent diverses courbes I(V) et P(V) pour un module à des températures variant entre 25 °C et 75 °C sous une irradiation de 1000 W/m^2.

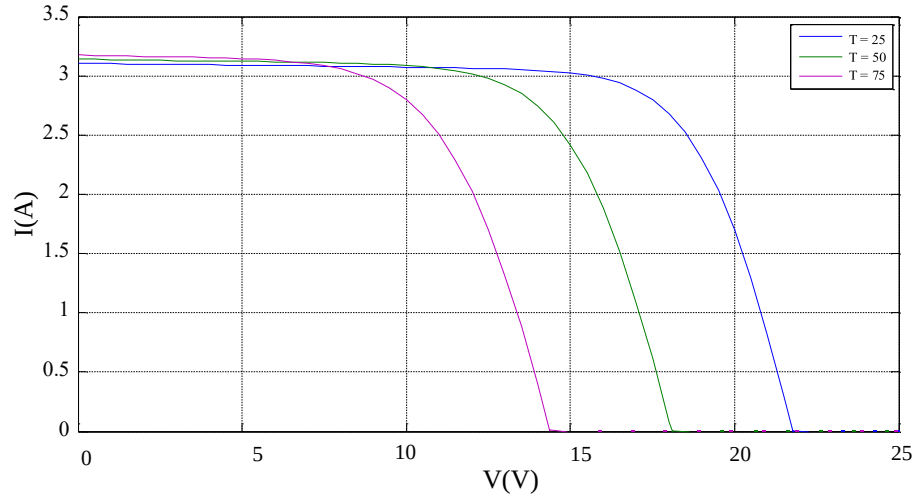


Figure I.19 : Influence de la température sur la caractéristique I(V)

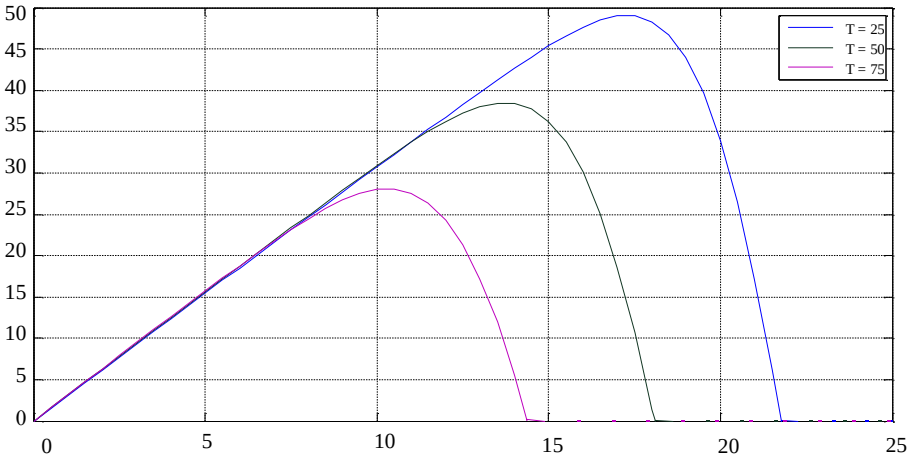


Figure I.20 : Influence de la température sur la caractéristique P(V)

I.8.3.3. Paramètres caractéristiques pour le diagnostic des défauts

Dans le domaine du photovoltaïque, l'examen des paramètres électriques spécifiques est un instrument essentiel pour identifier et diagnostiquer les anomalies susceptibles de nuire à l'efficacité d'un module ou d'un panneau solaire. Ces paramètres sont habituellement dérivés des graphes de caractéristiques courant-tension (I-V) et puissance-tension (P-V), obtenus par le biais de simulations ou de mesures expérimentales. Leur étude permet de repérer des irrégularités comme l'ombrage incomplet, la détérioration des cellules, les imperfections de liaison ou encore l'accroissement de la résistance interne du module.

L'un des paramètres clés pour le diagnostic est le courant de court-circuit (Isc), qui représente le courant maximal que peut fournir le module lorsque la tension est à zéro. Ce paramètre est largement influencé par la force du rayonnement solaire et pourrait se réduire en présence d'ombre, de salissure de la surface du module ou d'usure des cellules. Par contre, un changement inhabituel de ce courant peut signaler un souci dans les interconnexions ou dans les conditions d'irradiation.

Un autre facteur crucial est la tension à circuit ouvert (Voc), qui dénote la tension maximale lorsque le courant est inexistant. Cette tension est essentiellement fonction de la température de la cellule et des propriétés du matériau semi-conducteur. Une baisse importante de la tension en circuit ouvert pourrait signaler une hausse des pertes internes ou une détérioration du panneau photovoltaïque.

Le Point de Puissance Maximale (PPM - Maximum Power Point) est aussi un paramètre crucial pour juger les performances du système. Il représente le point d'opération où le produit de la tension et du courant atteint son maximum. L'emplacement de ce point sur la courbe I-V peut varier selon les conditions météorologiques ou l'apparition de dysfonctionnements dans

le module. Une diminution de la puissance maximale accessible pourrait indiquer une baisse de performance due au vieillissement du module, à un dysfonctionnement du système ou à l'existence d'ombres.

De plus, le facteur de forme (Fill Factor - FF) est un critère fréquemment employé pour décrire la performance d'un module photovoltaïque. On le définit comme le quotient de la puissance maximale fournie par le module et du produit entre le courant de court-circuit et la tension en circuit ouvert. Un déclin du facteur de performance signale généralement une hausse des pertes ohmiques ou des anomalies internes au dispositif.

Enfin, le contrôle de ces divers paramètres facilite l'élaboration de stratégies performantes pour le diagnostic et la maintenance prédictive des systèmes photovoltaïques. L'analyse constante des caractéristiques I-V et P-V permet une détection précoce des anomalies tout en optimisant le fonctionnement du système. Cela contribue à renforcer la fiabilité et à prolonger la durée de vie des installations photovoltaïques.

I.9. Les différentes filières photovoltaïques

Il est possible de fabriquer une cellule photovoltaïque avec divers semi-conducteurs. Actuellement, on distingue trois principales branches technologiques : le silicium cristallin, les couches minces et les cellules organiques. Le marché est réparti de manière inégale entre ces différentes filières. [19]

- **Les cellules monocristallines**
  - La première génération de photopiles.
  - Un taux de rendement excellent (12-16%) (23% en Laboratoire).
  - Une méthode de fabrication laborieuse et difficile, donc très chère.
  - Il faut une grande quantité d'énergie pour obtenir du cristal pur.
- **Les cellules poly-cristallines**
  - Coût de production moins élevé
  - Procédé nécessitant moins d'énergie
  - Rendement 11-13% (18% en Labo)
- **Les cellules amorphes (cellules de calculatrices par exemple)**
  - Coût de production bien plus bas.
  - Rendement plus bas : 8-10% (13% en labo).
  - Durée de vie plus faible.

C’est le silicium amorphe que l’on trouve le plus souvent dans les produits de consommation comme les calculatrices, les montres etc. … Toutefois, ils réagissent mieux à des températures élevées ou à une lumière diffuse.

De plus, les cellules mono et poly-cristallines sont les types de cellules les plus répandues sur le marché du photovoltaïque (environ 60% de la production).

Cellule de silicium monocristallin Cellule de silicium poly cristallin Cellule en silicium amorphe. [20]



Figure I.21 : Les différents types cellules photovoltaïques.

I.10. Conclusion

Ce chapitre se focalise sur l'exposé des éléments constitutifs d'un système photovoltaïque, ainsi que sur les propriétés électriques I-V et P-V des cellules PV qui facilitent la compréhension du mécanisme de fonctionnement d'un système photovoltaïque. Toutefois, ces systèmes présentent de nombreux défauts qui seront décrits dans le prochain chapitre.

Chapitre II

Modélisation du défaut en générateur PV et methodes de diagnostique

II.1 Introduction

Dans cette chapitre, nous examinerons les divers problèmes et irrégularités associés à une mise en place de système photovoltaïque. Pendant son exploitation, un système photovoltaïque peut être exposé à différentes anomalies et défaillances de fonctionnement. L'émergence des défauts et anomalies diffère d'une installation à l'autre, selon sa conception, son implantation, son utilisation et son entretien.

II.2 Modélisation du générateur PV en défaut

II.2.1 Classification des défauts pour la modélisation

Grâce aux retours d'expérience de l'équipe du projet, nous avons compilé les problèmes les plus fréquents rencontrés dans une installation solaire. Les anomalies collectées ont été classées selon les différentes fonctions liées aux éléments du système photovoltaïque. Nous avons formé six catégories de défauts :

- Défauts dans le générateur photovoltaïque
- Défauts dans la boîte de jonction
- Défauts dans le système de câblage
- Défauts dans le système de protection
- Défauts de l'onduleur
- Défauts dans le système d'acquisition des données

Pour chaque type de défaut, nous avons établi un tableau qui précise la nature du défaut, son principal effet, son incidence sur la production du système ou son niveau de criticité (1 : faible, 2 : moyen, 3 : fort), ainsi que sa fréquence (1 : basse, 2 : moyenne, 3 : haute). Y compris son stade initial (C : Conception ; I : Installation ; E : Exploitation).

Cette partie inclut aussi certaines représentations de défauts illustrées par des images.

II.2.1.1 Défauts dans le générateur photovoltaïque

Le tableau suivant indique une variété de défauts observables dans un générateur photovoltaïque :

Tableau II.1 : Les différents défauts dans le générateur PV

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



(a) Salissure



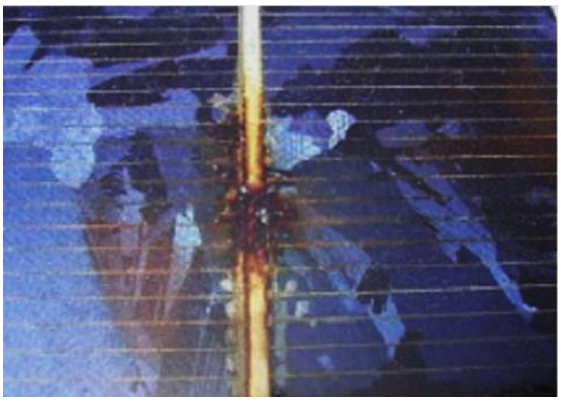
(b) Ombrage



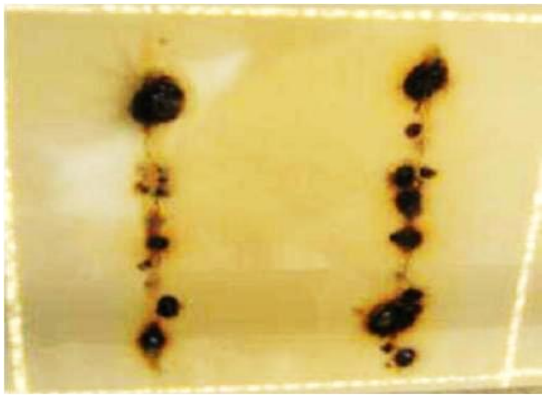
(c) Echauffement de la cellule (face-avant)



(d) Echauffement de la cellule (face arrière)



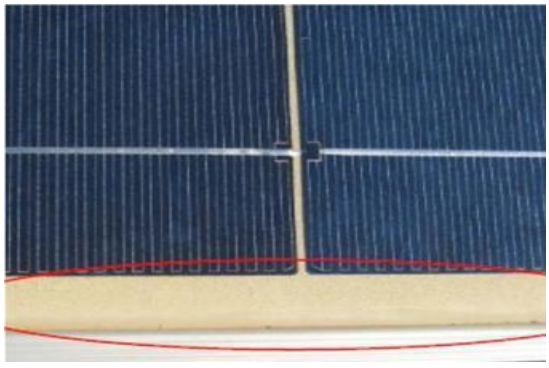
(e) Echauffement des soudures (face-avant)



(f) Echauffement des soudures (face-arrière)



(g) Dégradation de EVA



(h) défaut mécanique de la face arrière

Figure II.1 : Exemples de défauts rencontrés dans des générateurs PV. [21]

II.2.1.2 Défauts dans la boite de junction

Tableau II.2 : Les différents défauts dans la boîte de jonction

Défaut	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
Boîtier infesté d'insectes	Rupture du circuit électrique	2	1	E
Fourreaux non prévus pour usage Extérieur	Destruction de la protection	2	1	C
Liaison sans protection	Destruction de la liaison	2	1	C,I
Pénétration de l'eau ou de l'humidité	Corrosion des connexions, des diodes, desborne, incendie	2	1	I

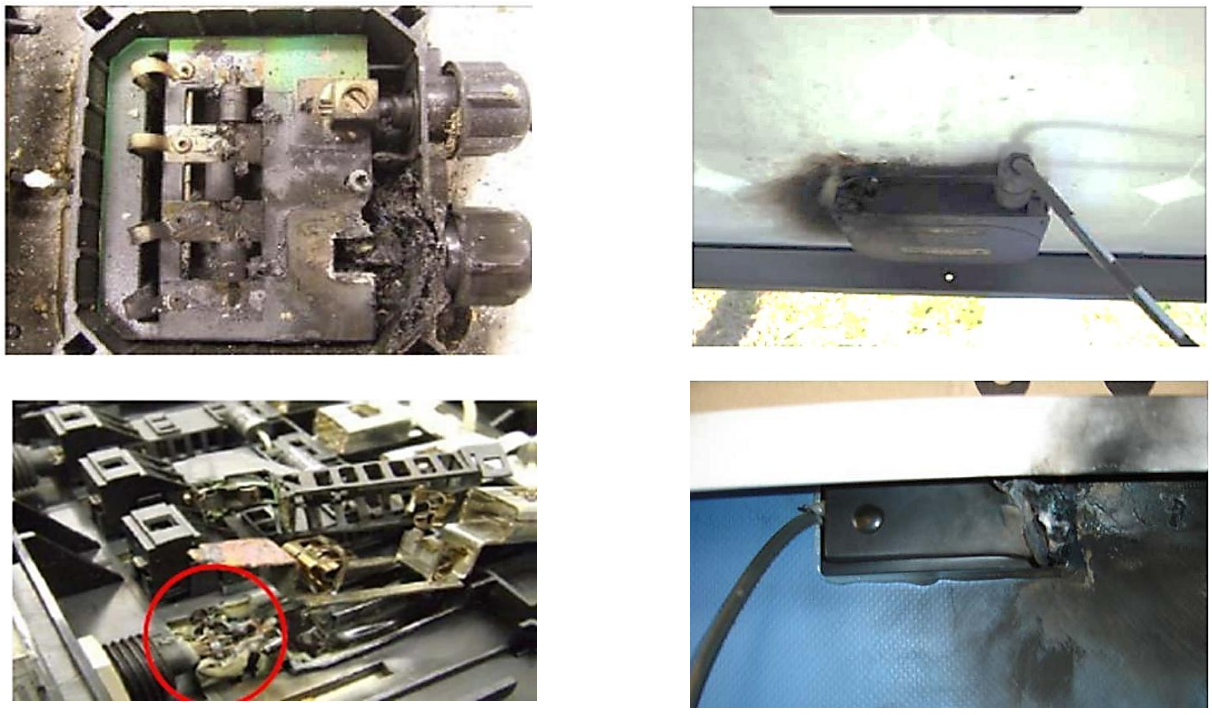


Figure II.2 : Exemples de défauts rencontrés dans des boîtes de jonction [20]

II.2.1.3 Défauts dans le système de câblage

Tableau II.3: Les différents défauts dans le système de câblage

Défaut	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 inter module de section trop faible par rapport au presse-étoupe	Corrosion des contacts, rupture du circuit Électrique	2	3	C,I
Mauvais dimensionnement des Cables	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 inter module de section trop faible par rapport au presse-étoupe	Corrosion des contacts, rupture du circuit Électrique	2	3	C,I
Bornes rouillées	Faux contacts, circuit ouvert, arc électrique	2	2	E
Câbles non fixes	Boucle de câblage, circuit ouvert	2	2	I
Mauvais câblage	Court-circuit, claquage des diodes antiretour, 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
Absence de graisse de silicone	Humidité	2	2	I
Câble mal denude	Mauvais câblage, faux contacts, circuit ouvert, arc électrique	2	2	I
Câble rongé par des rats	Faux contacts, circuit ouvert, arc électrique	2	2	E
Modification du câblage par l'usager non competent	Mauvais câblage, faux contacts, circuit ouvert, arc électrique	2	2	E
Bornes rouillées	Faux contacts, circuit ouvert, arc électrique	2	2	E
Câbles non fixes	Boucle de câblage, circuit ouvert	2	2	I
Boîte de connexion décollée	Connexion des cellules en série endommagée	2	1	E
Boîte de connexion décollée	Connexion des cellules en série endommagée	2	1	E



Figure II.3: Exemples de défauts rencontrés dans le système de câblage [22].

II.2.1.4 Défauts dans le système de protection

Tableau II.4 : Les différents défauts dans le système de protection

Défaut	Conséquences	Cri.	Occ .	Ori.
Protections inappropriate ou mal Dimensionnées	Court-circuit, hot spot, 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 électriqueposée à même le sol à l'extérieur	Dysfonctionnement en cas de pluie	3	1	C,I
Parafoudre non connecté à la terre	Pas de protection	3	1	I
Impossibilité de déconnecter les modules par branche	Problème de sécurité	1	3	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 Bypass	Hot spot, destruction des diodes, échauffement de la boîte de junction	2	1	C
Absence de protection contre les courants inverses	Hot spot, destruction des diodes, échauffe-ment 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, hot spot	2	1	I,E
Phénomènes de résonance	Non fonctionnement des fusibles et	2	1	C

	des protections de surtension			
Dégradation à cause de la lumière	Non fonctionnement des diodes de bypass	2	1	E
Echauffement des diodes placées dans un endroit mal ventilé	Température de destruction atteinte	2	1	C,I
Vieillissement des disjoncteurs	Non fonctionnement des disjoncteurs	1	1	E

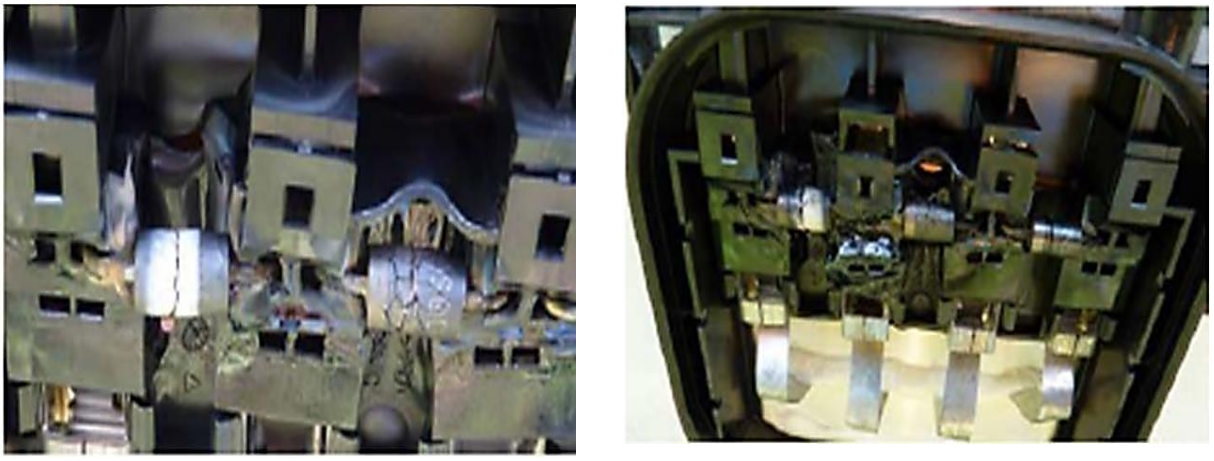


Figure II.4: Exemples de défauts de diodes de by-pass [22]

II.2.1.5 Défauts dans l'onduleur

Tableau II.5 : Les différents défauts dans l'onduleur

Défaut	Conséquences	Cri.	Occ.	Ori.
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,C,I
Foudre sur le réseau	Surtension, destruction de l'onduleur	3	2	E
Tension du générateur inférieure à la limite basse de l'onduleur	Déconnexion de l'onduleur	3	2	C
Onduleur sous dimensionné	Destruction de l'onduleur	2	3	C
Bobine des filtres, thyristors, capacités en défaut	Arrêt de l'onduleur	3	1	E,C,I
Problème d'interface avec le réseau	Découplage de l'onduleur	3	1	E
Défaut d'isolement	Détérioration de l'onduleur	3	1	C,I
Surchauffe des onduleurs	Diminution des performances	3	1	E
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 surdimensionné	Perte de puissance, diminution des performances	2	1	C
Visserie et bouton de commande Oxydés	Réglage impossible	2	1	E
Mauvais choix de la tension nominale d'entrée	Diminution des performances	2	1	C
Pile de sauvegarde HS	Perte des données	1	2	E
Témoins de défaut d'intensité allumé en permanence	Mauvaise information sur l'intensité	1	2	E,I
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 liquid endommagé ou illisible	Pas d'information sur le fonctionnement	1	1	E

II.2.1.6 Défauts dans le système d'acquisition

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

Tableau II.6 : Les défauts dans le système d'acquisition. [23].

Défauts	Conséquences	Cri.	Occ.	Or i.
Coupure de courant	Perte de données	1	3	E
Sonde d'ensoleillement non cable	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 detempérature 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

II.2.2. Défauts des cellules PV

Une cellule photovoltaïque peut, durant son utilisation, être exposée à divers défauts susceptibles de modifier radicalement ses caractéristiques. Cette liste comprend les défauts suivants : l'inversion de polarité, l'oxydation, la formation de sable, le point chaud, la détérioration de l'encapsulant, la fissure, l'impédance, le court-circuit, la rayure, le circuit ouvert, la dégradation, la surchauffe, l'humidité pénétrante, le module photovoltaïque arraché ou brisé, la déformation et l'obscurcissement. [24]

II.2.3 Défauts des diodes PV

Les diodes qui composent un champ photovoltaïque de type by-pass et anti-retour peuvent être sujettes à divers dysfonctionnements tels que : inversion de polarité, connexion incorrecte, incompatibilité, installation incorrecte, panne, diode à impédance, court-circuit, destruction, circuit ouvert, vieillissement ou absence totale ou partielle de fonctionnement.[20]

II.2.4. Défauts des câbles PV

Durant leur fonctionnement, les câbles d'un champ photovoltaïque générant un champ électrique pourraient être susceptibles à diverses sortes de défaillances telles que : l'adoucissement, la rupture du circuit électrique, la détérioration des interconnexions, le processus de corrosion entre les cellules PV, la surchauffe, l'impédance, le court-circuit, un câblage incorrect ou encore une coupure de circuit. [25]

II.2.5. Défaut de mismatch et d’ombrage

Les problèmes de décalage et d'ombrage constituent des anomalies courantes dans les systèmes photovoltaïques. Dans ce qui suit, nous allons aborder la définition de ces problèmes, leur modélisation, ainsi que la caractéristique I-V résultant de ces deux situations.[23]

II.2.5.1. Définition

Le défaut de « mismatch » se réfère à une anomalie due à l'assemblage de cellules ayant une caractéristique non identique. Cela entraînera une disparité dans leurs caractéristiques. L'absence d'ombre est une forme spécifique de défaut de décalage, car elle entraîne une

diminution de l'exposition au soleil reçue par des cellules. Deux facteurs principaux sont à l'origine du changement de ces paramètres. [26]

En premier lieu, il est possible que les cellules présentent des caractéristiques physiques distinctes en raison d'une tolérance lors du processus de production. Les fabricants de cellules ou de modules fournissent uniquement la tolérance associée à la puissance du module. Selon les fabricants, elle peut fluctuer entre +/-3% et +/-5%. [27]

II.3 Méthodes de détection et de diagnostic des défauts d'un système PV

Les irrégularités observées à divers niveaux du système photovoltaïque, qu'il s'agisse du module, des câbles et de la protection, ou encore des convertisseurs de puissance [28], trouvent leur origine dans les conditions climatiques (comme l'ombrage ou la salissure des modules), les conditions d'exploitation (notamment le vieillissement des modules PV) et les défauts de fabrication.

Comme dans tous les systèmes industriels, les systèmes de surveillance sont indispensables dans les installations photovoltaïques, car ils assurent le contrôle et l'identification des anomalies. [28].

Dans ce cadre, divers chercheurs ont suggéré plusieurs approches diagnostiques spécifiquement pour les centrales photovoltaïques. Trois caractéristiques fondamentales qui differentiates une méthode d'une autre, à savoir la vitesse de repérage de l'anomalie, l'optimisation des données d'entrée et la sélectivité (soit la faculté à différencier les divers défauts).

Ils peuvent être classés globalement en deux catégories principales [29] :

- Techniques visuelles et thermiques [30,31] (sans électricité), aptes à identifier la décoloration, le brunissement, les souillures de surface, les zones chaudes, les ruptures et la délamination.
- Techniques électriques susceptibles d'être employées pour l'identification et le diagnostic des modules photovoltaïques, des chaînes et des réseaux défaillants, y compris les défauts d'arc, les problèmes de mise à la terre, les diodes, etc. Le diagramme ci-dessous illustre les diverses techniques de diagnostic.

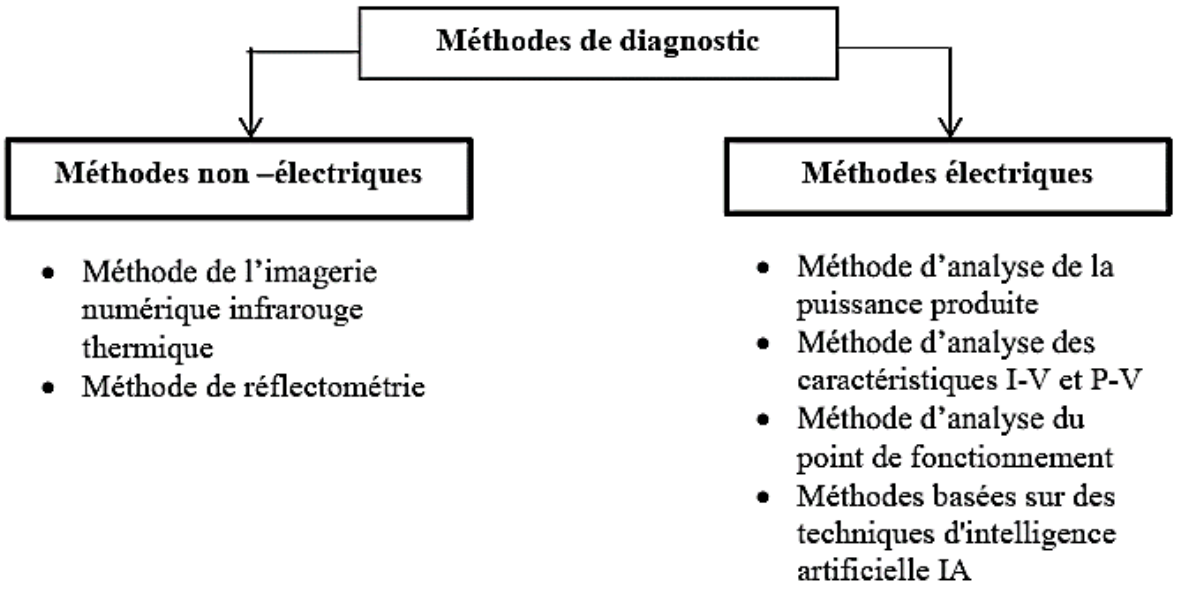


Figure II.5: Méthodes de diagnostic de défauts d'un générateur PV [31].

II.3.1 Méthodes non –électriques

On peut recourir à différentes techniques non électriques pour détecter les anomalies au niveau des cellules photovoltaïques, celles-ci pouvant être destructives ou non. Le défaut le plus fréquemment détecté à ce stade est la fissuration cellulaire. Plusieurs techniques sont employées pour son évaluation, comme les essais de flexion mécanique, la photoluminescence, l'imagerie par électroluminescence et les tests thermographiques [32, 33]. Les méthodes les plus fréquemment employées pour le diagnostic des modules photovoltaïques sont l'imagerie infrarouge et la réflectométrie.

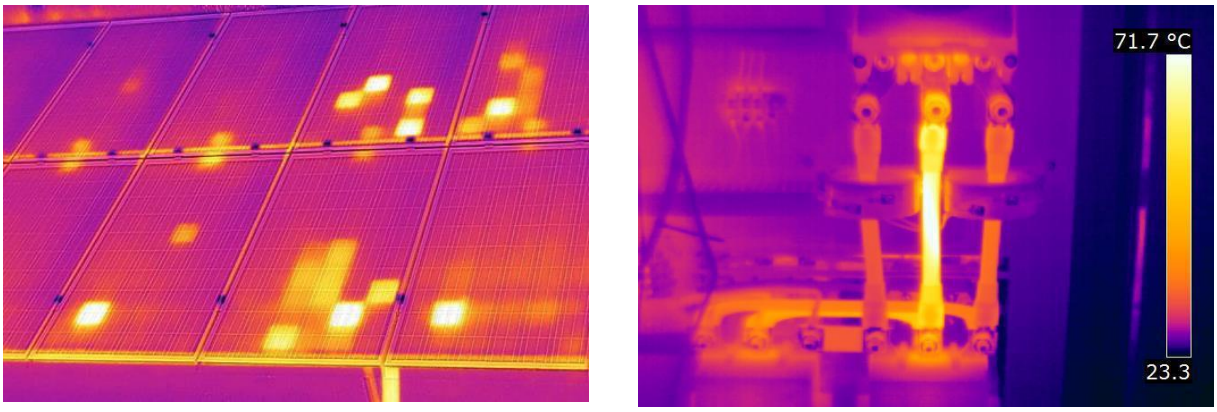
II.3.1.1 Méthode de l'imagerie numérique infrarouge thermique

On utilise des méthodes non électriques comme les contrôles visuels et l'analyse infrarouge/thermique pour identifier et situer les anomalies dans les systèmes photovoltaïques. Ces techniques ne requièrent pas de mesures électriques.

Les principales utilisations des techniques visuelles et thermiques sont l'identification de la décoloration, du brunissement, de l'encrassement, des points chauds, de la rupture et du délaminage des modules photovoltaïques [34]. Toutefois, en raison de leur caractère long et fastidieux, les inspections visuelles ne sont pas adaptées aux systèmes photovoltaïques à grande échelle.

La détection des anomalies thermiques et infrarouges se base sur l'utilisation d'appareils spécialisés comme des caméras thermiques ou infrarouges, des drones, entre autres. Le

rythme de détection est régi par la fréquence de surveillance des plantes, et ces méthodes ont prouvé leur efficacité comme le montrent les références [35]. Toutefois, ces techniques ne conviennent pas pour l'identification des anomalies dans les installations photovoltaïques de petite taille.



a) Imagerie thermique de défaut dans la surface de Panneaux.

b) Imagerie thermique de défaut de Câbles.

Figure II.6: Exemple de la localisation de défauts par la caméra thermique [36].

II.3.1.2 Méthode de réflectométrie

La réflectométrie opère selon le même concept qu'un radar : une impulsion ou un signal est envoyé dans le champ photovoltaïque à examiner. Tout type d'irrégularité (fissure, défaut, court-circuit, circuit ouvert) agit comme une barrière à cette impulsion incidente et entraîne une réflexion. Il vous est permis d'évaluer les échos renvoyés. On utilise le retard et l'amplitude des échos pour recueillir des informations sur la position, la description et éventuellement l'anticipation du défaut. Elle requiert simplement un point d'accès, qui exige une précision dans leur identification [37]. Toutefois, elle est conçue pour des réseaux ayant une topologie complexe. De plus, elle peut être incorporée dans les systèmes de contrôle. Toutefois, l'identification anticipée des anomalies dans un champ PV exige un traitement de données performant avec un échantillonnage extrêmement rapide, ce qui raise à la fois la complexité et le coût du système de diagnostic.

On a recours à cette méthode comme le montrent [38], ainsi que « T. Takashima et al. » [39]. Pour identifier les anomalies telles que « circuit ouvert », « court-circuit » et « hausse de l'impédance de la connectique » dans une chaîne photovoltaïque.

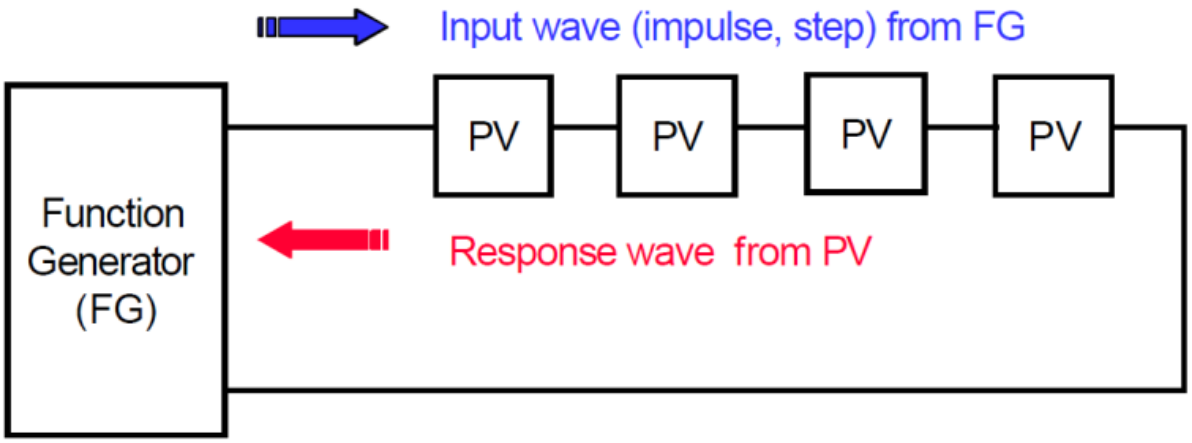


Figure II.7: Principe de la réflectométrie pour localiser le défaut dans un string PV [42].

II.3.2 Méthodes électriques

Pour ces méthodes, les paramètres électriques tels que le courant, la tension et la puissance sont utilisés comme données d'entrée. Nous mettons l'accent sur ce paragraphe sur quatre types de méthodes majeures présentées dans la littérature. [43]

II.3.2.1 Méthode d'analyse de la puissance produite

Plusieurs recherches présentes dans la littérature mettent en lumière la méthode utilisée par les onduleurs commerciaux pour identifier et situer les anomalies au sein des panneaux photovoltaïques. Généralement, cela nécessite d'examiner l'énergie et la puissance de sortie du réseau en consignant toute différence notable par rapport aux valeurs prévues. Toutefois, on peut perfectionner cette méthode en produisant des attributs additionnels qui enrichissent l'étude des grandeurs mesurées. Ces caractéristiques supplémentaires englobent la durée, l'ampleur, la fréquence et le moment précis des diminutions de puissance ou d'énergie. Ils sont préétablis pour divers défauts, permettant ainsi une identification plus précise des anomalies. Lors de l'analyse comparative, le défaut qui correspond le plus précisément à la valeur déduite des dimensions mesurées est considéré comme étant à l'origine de la diminution des valeurs des attributs. [43] a mené une étude sur la puissance générée, en examinant la diminution d'amplitude. Ceci a permis d'identifier les chaînes et les modules par chaîne susceptibles de présenter des défauts, selon des conditions opérationnelles comme l'exposition au soleil et la température.

Les travaux de recherche réalisés par [44] ont approfondi les caractéristiques supplémentaires de la décroissance énergétique. Parmi ces caractéristiques figurent l'intensité,

la durée et le moment de la chute d'énergie. Cette étude permet de repérer quatre types de dysfonctionnements :

- Pertes constantes d'énergie : dégradation, salissure, module défectueux, string défectueux.
- Pertes variables d'énergie : ombrage, température élevée, échauffement de l'onduleur, erreur de MPPT.
- Pertes totales : onduleur défectueux, défaillance du système de contrôle.
- Couverture par la neige.

Tout comme dans le cas précédent, [39] a appliqué les mêmes principes de base dans ses travaux de recherche. Toutefois, leur attention s'est portée sur des catégories spécifiques de défauts, comme suit :

- Défauts prolongés avec rendement nul : défaillance des composants, système déconnecté (longue durée).
- Défauts brefs avec rendement nul : déconnexion temporaire de l'onduleur, système déconnecté (courte durée).
- Défauts d'ombrage : ombrage.
- Défauts avec rendement non nul et pas d'ombrage : erreur de MPPT, autres défauts.

II.3.2.2 Méthode d'analyse des caractéristiques I-V et P-V

L'accumulation de données sur des grandeurs telles que le courant et la tension à divers endroits du champ photovoltaïque permet d'identifier et de situer exactement le problème grâce aux capteurs installés dans ce même champ. Différents auteurs mènent plusieurs recherches dans ce contexte [45].

II.3.2.3 Méthode d'analyse du point de fonctionnement

Cette technique se base sur l'examen et la mise en parallèle du point de puissance maximale actuel de l'installation photovoltaïque et de celui prévu [46]. Cette approche permet d'identifier automatiquement un défaut sans perturber le fonctionnement du système.

II.3.2.4. Méthodes basées sur des techniques d'intelligence artificielle IA

Dans le contexte de l'analyse de systèmes physiques complexes intégrant divers composants et descriptions, il est insuffisant de se baser uniquement sur des modèles

mathématiques en ce qui concerne la précision. Dans ces situations, des techniques d'intelligence artificielle ont été élaborées pour reproduire le processus de pensée humain, dans le but de simplifier la prise de décisions. Ces techniques ont pour objectif de rendre le processus de diagnostic plus efficace et plus aisé en le rationalisant et en le simplifiant [47].

Au cours des dernières années, l'efficacité des techniques d'intelligence artificielle pour la modélisation, le contrôle, la prévision et le pronostic dans le système PV a été validée [48].

a. Les algorithmes génétiques (AG)

Hollande a été le premier à proposer les techniques d'optimisation stochastique, connues sous le nom d'AG, en 1970 [49]. Ces algorithmes s'appuient sur la sélection naturelle et des processus génétiques pour réaliser leurs buts [50]:

- Un mécanisme de codage est utilisé pour représenter les variables du problème d'optimisation.
- Fonction de fitness - ou fonction objectif.
- Fournit le mécanisme d'évaluation de chaque chromosome et la formation de la population apte.
- Un croisement est utilisé pour combiner les chromosomes.
- Les chromosomes sont soumis à une mutation, pour garder l'espace de solution assez riche.

Les algorithmes génétiques (AG), largement considérés comme des instruments bénéfiques, ont transformé l'optimisation. Les GA, en association avec d'autres méthodes d'IA, ont été efficacement mises en œuvre dans le diagnostic des champs photovoltaïques, comme le prouve leur usage conjoint avec des réseaux de neurones pour la détection des anomalies.

En soulignant les points de données les plus essentiels dans l'espace d'entrée, les GA ont facilité la capacité du réseau de neurones à identifier ces anomalies. En ajoutant un champ PV [51], les entrées du réseau sont réduites, ce qui conduit à une réduction du temps de calcul. Par conséquent, le processus de diagnostic est accéléré et obtient une précision supérieure dans sa catégorisation.

b. Machine à vecteur de support (SVM)

Inspirées par la théorie de l'apprentissage statistique promue par VN Vapnik, les machines à vecteurs de support (SVM) représentent une méthode actuelle d'apprentissage

machine. Cette technique divise les données spatiales en deux catégories et est aussi appelée séparateurs à large marge.

Destiné à traiter les problèmes de diagnostic dans les champs photovoltaïques, comme indiqué dans [52].

Le SVM consiste à transformer la zone d'entrée initiale en un espace d'apprentissage utilisant des produits scalaires de haute dimension. Dans cette région, l'hyperplan optimal est par la suite identifié afin d'améliorer la capacité de généralisation du classificateur. Cela est accompli par l'application de la théorie de l'optimisation combinée aux principes de l'apprentissage statistique.

Les machines à vecteurs de support (SVM) ont la capacité de gérer aisément d'importants volumes de données. Leur approche d'apprentissage les rend efficaces, indépendamment de la dimensionalité des vecteurs d'entrée. C'est donc une option idéale pour la gestion de jeux de données d'une très grande taille. Les SVM présentent également des avantages notables dans les tâches de classification des défauts, car elles sont capables de traiter des données sans aucune restriction relative à leur dimensionnalité [53].

c. Logique floue (LF)

L'approche de la logique floue est une méthode organisée pour gérer les données qualitatives. C'est pourquoi beaucoup de systèmes experts optent désormais pour cette méthode plutôt que le traitement conventionnel, faisant de celle-ci une option couramment choisie dans diverses applications. La logique floue offre de multiples bénéfices comparativement aux systèmes experts classiques. Il n'est pas nécessaire que les règles de la base de connaissances soient détaillées et exactes, comme c'est le cas pour celle-ci. Plutôt, ils peuvent être adaptés pour s'appliquer à une variété plus large de situations. En outre, l'utilisation de la logique floue facilite la manipulation des contradictions présentes dans la base de données.

Quant au diagnostic des défauts, l'utilité des systèmes flous est indéniable du fait de leur capacité à se baser sur le traitement par la connaissance nécessaire pour le diagnostic. Toutefois, dans la pratique, obtenir des modèles quantitatifs précis pour un comportement complexe et non linéaire dans les systèmes défaillants peut s'avérer ardu. À titre de solution, on recourt fréquemment à des modèles flous qualitatifs. Il est crucial de prendre en considération les incertitudes potentielles issues de la caractérisation du système.

L'algorithme présenté par les auteurs dans [54] mettait l'accent sur la détection de DA (Arc Fault) au sein d'un PVS. Ils ont mis en avant la profitabilité de leur méthode, basée sur le

FL. Afin d'assurer des performances optimales, les auteurs ont suggéré de privilégier l'utilisation du détecteur avec DC-AC plutôt que comme un dispositif indépendant. Ils ont basé leur approche sur l'examen théorique de la courbe IV et employé le système de classification FL pour déceler les anomalies.

Dans les études [45], un système GCPV de 1,1 kWp côté DC a été mis en place pour détecter l'ombrage partiel sur les panneaux photovoltaïques. Le système a atteint un taux de classification supérieur à 98 %. En outre, [49] met en avant une technique fondée sur des règles floues utilisant Takagi-Sugeno-Kahn (TSKFR), qui s'attache à juxtaposer la puissance mesurée à la puissance estimée et à imposer un seuil déterminé.

C'est grâce à la persévérance qu'il a été établi que le système est capable de reconnaître plus de 90% des situations de panne, même en présence d'informations altérées. Les défauts visés sont : Cellules défectueuses, ombrage graduel et court-circuit.

d. Réseaux de neurones artificiels (RNA)

Les RNAs présentent deux attributs remarquables qui les rendent utiles pour le diagnostic des systèmes de production. Tout d'abord, ils ont la capacité d'approcher efficacement les fonctions non linéaires. En second lieu, leur compétence dans les tâches de reconnaissance de formes est démontrée par le diagnostic des champs PV mentionné dans les références [50]. Les RNA, à l'inverse des modèles conventionnels, ne se basent pas sur une modélisation mathématique du système. Plutôt que cela, l'apprentissage en réseau est appliqué afin d'enrichir le réseau avec des connaissances sur le domaine photovoltaïque. L'apprentissage implique de fournir des données au réseau en entrée, suivi d'un ajustement de ses paramètres internes afin que la sortie du réseau soit le plus proche possible de celle du système réel. L'atout majeur des RNA est qu'ils n'ont pas besoin de modèles mathématiques, ce qui les rend utilisables pour des systèmes complexes à modéliser.

Cependant, certains inconvénients subsistent :

- Afin de rendre l'apprentissage du réseau plus aisé, il est essentiel d'obtenir des informations concernant le fonctionnement du champ PV. On peut obtenir ces données soit à partir du processus réel, soit en utilisant ses modèles associés.
- Le réseau a été formé sur des scénarios spécifiques jusqu'à octobre 2023 et ne prend pas en compte toutes les situations possibles.
- L'accroissement de la complexité des systèmes entraîne une nécessité accrue de neurones dans le réseau, ce qui cause une hausse exponentielle du temps requis pour le calcul.

Bien que l'ANN ait ses limites et qu'il existe d'autres outils de classification, elle demeure la méthode la plus fréquemment employée dans les publications pour aborder des tâches nécessitant une grande précision.

Récemment, plusieurs publications ont examiné l'utilisation des réseaux de neurones artificiels (ANN) pour détecter et diagnostiquer les anomalies dans les systèmes photovoltaïques. Par exemple, une recherche [52] a prouvé l'efficacité de la méthode ANN pour identifier les anomalies dans un système photovoltaïque raccordé au réseau. L'analyse a exploré cinq méthodes distinctes de détection des pannes, y compris des situations où l'appareil d'alimentation était défaillant.

Les problèmes courants avec les dispositifs d'alimentation comprennent un équipement défectueux, une surchauffe et une sortie basse tension.

e. Réseaux de neurones flous (neuro-floue)

Bien que les réseaux de neurones génèrent des résultats numériques exacts, cela peut représenter un obstacle pour les systèmes de diagnostic qui ont besoin d'informations qualitatives. Dans les contextes où seules des informations qualitatives sont à disposition, l'association des réseaux de neurones et de la logique floue constitue une méthode pertinente. Cette combinaison mène à des réseaux de neurones flous, qui ont démontré leur efficacité dans le diagnostic des champs photovoltaïques, comme illustré dans [47]. On utilise un système neuro-flou pour fusionner les savoirs quantitatifs et qualitatifs, ce qui permet de combiner l'expression explicite des connaissances logiques floues avec la faculté d'apprentissage des réseaux de neurones.

Les auteurs ont développé une méthode de détection des anomalies neuro-flous dans les systèmes photovoltaïques, comme indiqué dans [39]. Pour mettre en œuvre cette technique, ils ont utilisé une stratégie neuro-floue pour déterminer une série de groupes de paramètres pour un module photovoltaïque dans des conditions d'opération changeantes.

Les résultats indiquent que le système de diagnostic est capable de différencier les opérations normales des opérations anormales, même en cas de bruit et de perturbations.

II.4. Choix de l’approche de diagnostic

Suite à une revue de la littérature, il s'est manifestement révélé que chaque technique mentionnée dans les écrits académiques présente tant des avantages que des inconvénients. Le choix de la méthode à appliquer pour un système donné est tributaire de ses propriétés spécifiques, des informations en notre possession et de la nature des anomalies à identifier.

Les différentes méthodes de diagnostic des pannes ne présentent pas de limites claires et leurs zones d'utilisation se recoupent fréquemment. Il est donc courant que ces méthodes opèrent conjointement afin d'offrir le diagnostic le plus exhaustif possible.

Bien qu'il existe diverses méthodes, l'ambiguïté demeure un enjeu majeur. Nous sommes donc contraints d'adopter une stratégie fondée sur les réseaux de neurones pour obtenir une solution efficace.

II.5. Conclusion

Dans ce chapitre, nous avons d'abord présenté les définitions et les termes souvent employés dans le secteur du diagnostic. Les méthodes de diagnostic évoquées dans les publications scientifiques peuvent être divisées en trois phases essentielles : la détection, la localisation et l'identification.

Par la suite, nous avons présenté un résumé des problèmes et irrégularités courants susceptibles de survenir dans les systèmes photovoltaïques. Notre étude suggère que ces insuffisances peuvent généralement être catégorisées comme provenant soit de vices de fabrication, soit d'effets des conditions climatiques et opérationnelles.

Dans notre présentation, nous avons inclus une vue d'ensemble mise à jour des diverses méthodes de diagnostic employées dans l'entretien des systèmes photovoltaïques. Ces méthodes sont élaborées pour surveiller le fonctionnement du système et pour détecter, situer et diagnostiquer tout dysfonctionnement susceptible d’influer de manière défavorable sur ses performances ou sa sécurité.

Chapitre III

Réseaux de neurones artificiels (ANN)

III.1. Introduction

Ce chapitre vous offre une introduction concise à la théorie fondamentale des réseaux de neurones artificiels, exposant le fondement sur lequel le logiciel utilisé dans cette mission a été élaboré. Précisions : les détails mathématiques ne seront pas abordés (excepté pour une courte illustration en annexe I), mais le but est de fournir une compréhension globale de la notion de réseau de neurones. On introduit ensuite la méthodologie employée lors des tests. On l'a segmenté en six sections, débutant par un exemple théorique : AANN. Cela permet de fournir une démonstration détaillée du processus d'utilisation de MATLAB pour tester un AANN, étape par étape.

III.2. Aperçu Historique

L'émergence des réseaux de neurones artificiels remonte au milieu du XXe siècle, alors que des travaux fondamentaux établissaient les bases théoriques et informatiques de ce domaine.

- **1943:** W. McCulloch et W. Pitts ont proposé un modèle mathématique simplifié du neurone, jetant ainsi les bases formelles pour les unités de traitement neuronal.
- **1949:** Dans son livre « The Organization of Behavior », D. Hebb propose une règle d'apprentissage essentielle (apprentissage selon Hebb), avançant que l'intensité d'une connexion synaptique se renforce lorsque les neurones pré- et post-synaptiques sont stimulés en même temps.
- **1958:** F. Rosenblatt élabore le Perceptron, un modèle de neurone artificiel doté de la capacité d'apprendre, et prouve son théorème de convergence concernant les problèmes qui sont séparables de manière linéaire.
- **1960:** B. Widrow et M. Hoff ont présenté l'Adaline (Élément Linéaire Adaptatif) ainsi que la règle d'apprentissage LMS (Moindres Carrés Moyens), établissant les fondations de divers algorithmes adaptatifs d'apprentissage.
- **1969:** M. Minsky et S. Papert sortent « Perceptrons », un examen approfondi soulignant les contraintes inhérentes du Perceptron simple (l'incapacité à traiter des problèmes qui ne sont pas séparables de manière non linéaire tels que le XOR), ce qui a conduit à une phase de stagnation dans les recherches du domaine.
- **1972:** T. Kohonen propose des modèles de mémoires associatives auto-organisatrices, précurseurs des cartes auto-organisatrices (SOM).

- **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.[55]

Ces repères historiques témoignent de la progression graduelle des idées, des modèles mathématiques aux algorithmes d'apprentissage, qui forment actuellement la base des réseaux de neurones actuels.

III.3. Réseaux de neurones artificiels

On peut définir un Réseau de Neurones Artificiel (RNA) comme un système de manipulation des données qui imite la structure et le mode d'opération des réseaux neuronaux biologiques. C'est une structure algorithmique constituée d'un vaste ensemble d'unités de traitement élémentaires, reliées entre elles et agencées en strates, connues sous le nom de neurones artificiels ou de nœuds. Chaque neurone fonctionne principalement de façon parallèle et locale, gérant les signaux qu'il reçoit à travers ses liaisons pondérées. Le réseau dans son ensemble constitue un mécanisme apte à acquérir des connaissances à partir de données afin d'exécuter des missions particulières, comme l'identification de formes, la catégorisation, la prévision ou le pilotage, sans avoir besoin d'une codification explicite des directives de la tâche. L'aptitude du réseau à réaliser ces tâches découle de l'adaptation progressive des intensités des connexions (poids synaptiques) lors d'une phase de formation basée sur des cas concrets [56].

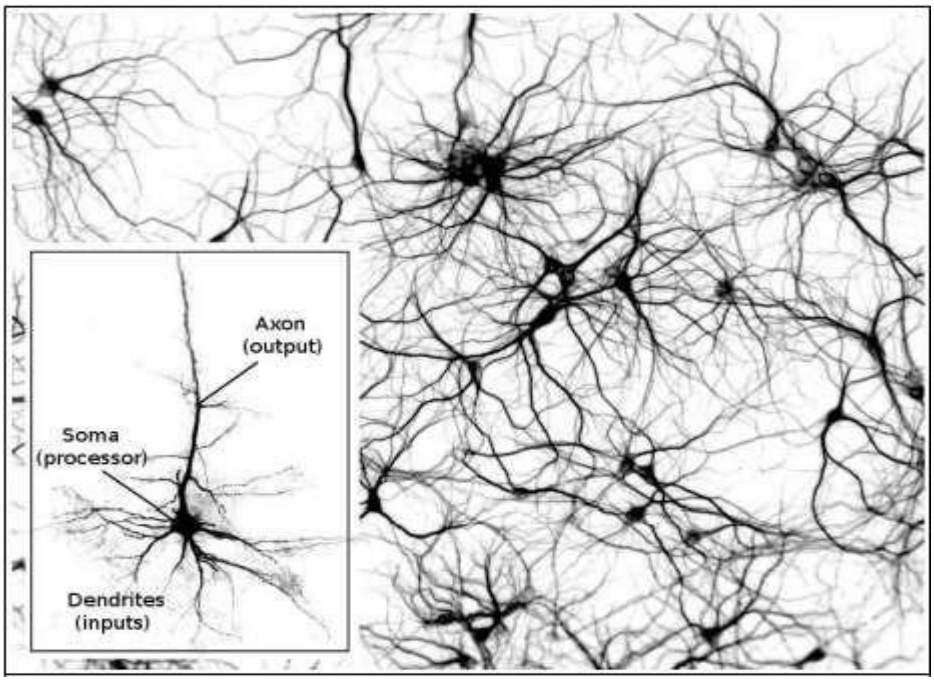


Figure III.1: Un réseau de neurones biologiques composé de plusieurs neurones interconnectés. Cette image est une représentation théorique à quoi pourrait ressembler un réseau de neurones biologiques [51].

Lorsqu'on observe un neurone (une cellule nerveuse) d'usage fréquent dans le cerveau humain, on note la présence de trois zones majeures : les dendrites, le soma et l'axone (bien que ce ne soit pas entièrement précis étant donné qu'il existe plusieurs sortes de neurones différents, cela suffira pour des raisons de simplicité). Le Soma représente le corps principal qui gère les informations qui transitent par le neurone. De multiples dendrites, qui captent les signaux (entrées) provenant d'autres cellules. Un axone, qui est considérablement plus long que les dendrites, est également relié au soma. C'est à ce moment-là que le neurone transmet des signaux (sorties) à d'autres cellules. On désigne par synapse la connexion entre deux neurones. Examinons maintenant un neurone synthétique. [55]

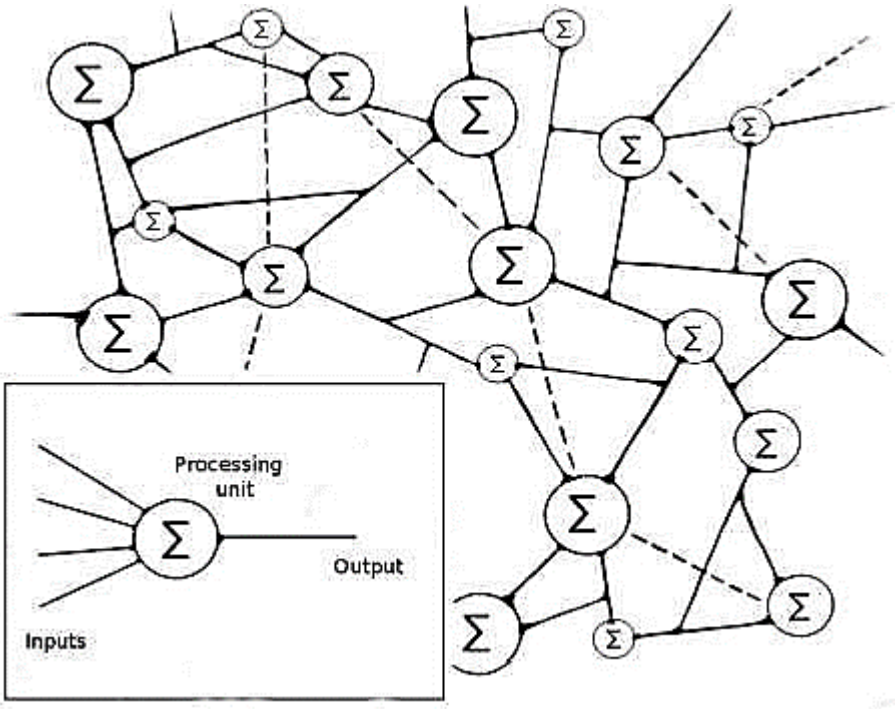


Figure III.2: Un réseau de neurones artificiels composé de plusieurs neurones interconnectés. Ce n'est pas une illustration d'un véritable neurone réseau, mais les moyens d'impliquer la structure peuvent être très complexes [55].

On distingue également trois principaux domaines ici : les entrées, le traitement unitaire et la sortie (encore une fois, cela peut être plus complexe que précédemment). Les liaisons entre un neurone et les autres sont désignées sous le terme de poids synaptiques. [56]

En règle générale, on pourrait définir les réseaux de neurones artificiels comme des ensembles de neurones interconnectés, utilisés pour l'entrée et la sortie des données, dans le but de réaliser une reconnaissance de formes. Dans ce contexte, la reconnaissance de forme désigne l'identification automatique des schémas dans les données par le biais de l'usage d'algorithmes informatiques. [57]

Il pourrait être bénéfique d'approfondir un peu plus cette dernière déclaration. Les motifs observés dans les données peuvent servir à réaliser divers objectifs, allant de la simple régression linéaire ou classification, jusqu'à l'utilisation de réseaux de neurones capables d'apprendre à jouer aux échecs. [49]

Le tableau de la page suivante donne une petite introduction aux différentes possibilités qui s'offrent à vous.

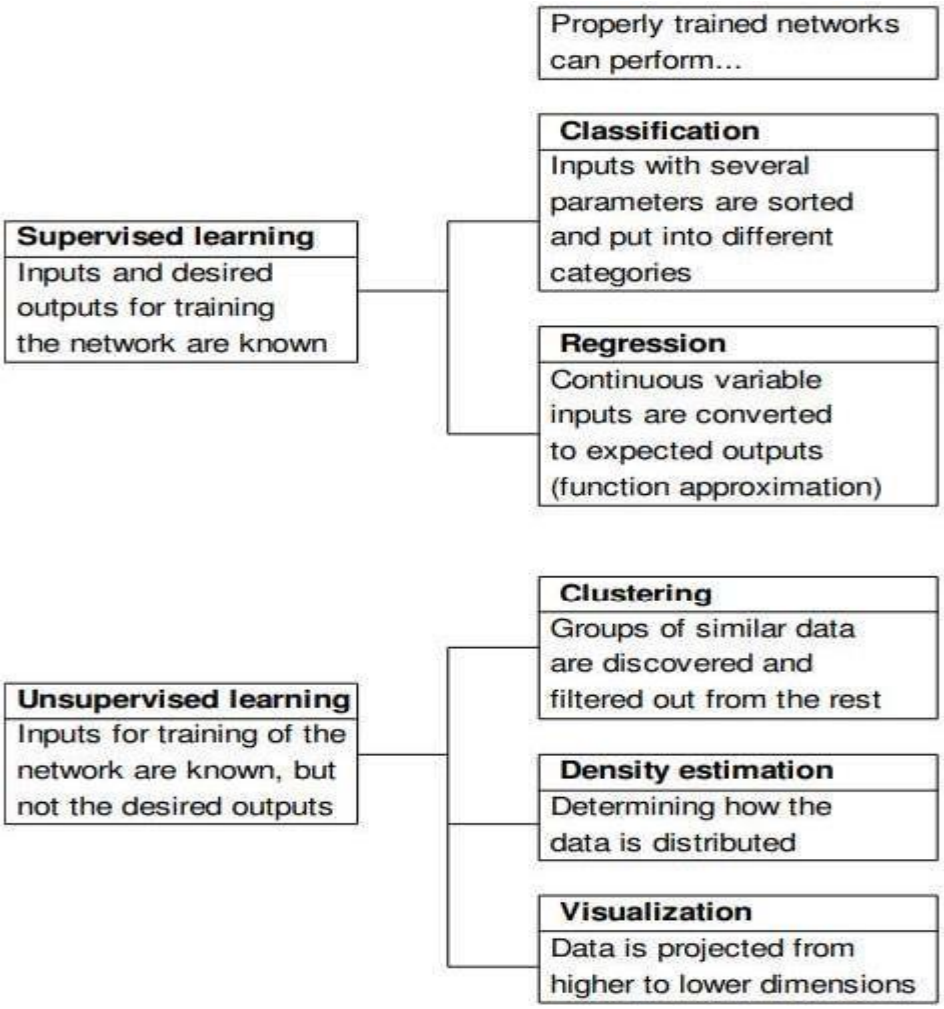


Figure III.3: Différents types de réseaux neurones [57]

Puisqu'il y a une multitude de sortes de réseaux neurones, il serait pertinent à ce stade de focaliser notre attention sur la catégorie précise de réseaux utilisés pour traiter le problème examiné dans cette thèse. Ce sont les réseaux de neurones à propagation avant multicouche. [57]

III.3.1. Modèle Biologique

Des neurones Un réseau de neurones artificiels est un modèle computationnel dérivé du modèle biologique, à savoir le cerveau humain. Il se compose d'un vaste assortiment de

cellules nerveuses connues sous le nom de neurones, et qui comprennent une composante cellulaire et une composante noyau.

La portion cellulaire, appelée Somma, se divise pour créer les dendrites [56], à travers lesquelles l'information est transmise au corps du neurone (le Somma). L'information gérée par le neurone est ensuite véhiculée le long de l'axone (qui est unique) afin d'être communiquée aux autres neurones. Il n'existe pas de connexion directe entre les neurones. L'espace ou la connexion qui divise l'axone d'un neurone et les dendrites du neurone adjacent est connue sous le nom de « Synapse ».

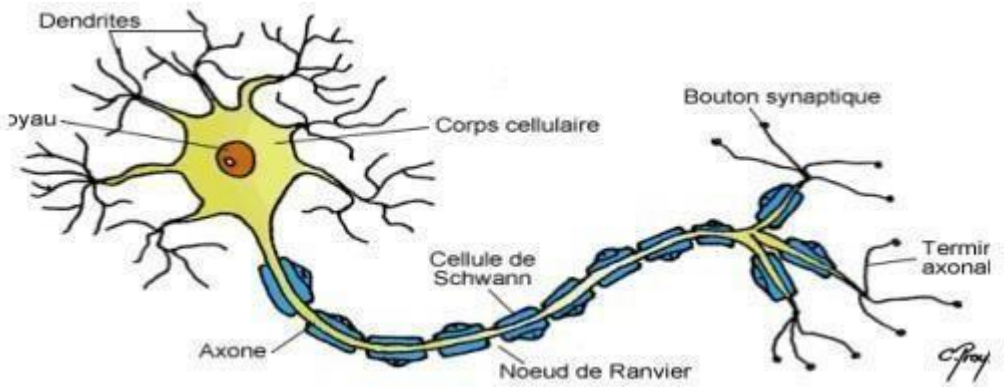


Figure III.4: Exemple de neurone biologique [56].

Les synapses disposent d'une « mémoire » qui leur permet de moduler leur fonctionnement en se basant sur leur passé d'activation entre deux neurones. C'est cette plasticité qui engendre les processus d'apprentissage.

III.3.2. Le Neurone Formel

Le neurone formel, également appelé neurone artificiel, est une version mathématique simplifiée du neurone biologique. C'est l'unité de traitement de base d'un RNA. Typiquement, son fonctionnement se divise en deux phases majeures :

a. **Agrégation des entrées :** Le neurone est alimenté par plusieurs signaux entrants (qui émanent soit de neurones situés dans la couche précédente, soit de sources extérieures). Chaque élément xi est lié à un poids synaptique wi, qui symbolise l'intensité de la liaison. Le neurone effectue un calcul de la somme pondérée de ses entrées, à laquelle il ajoute généralement un terme d'ajustement b (ou seuil). Cet appel d'activation, noté a, est exprimé par :

$$a = \left(\sum wi \times xi\right) + b \qquad \text{(III.1)}$$

b. Fonction d'activation : La sortie y du neurone est obtenue en transformant le potentiel d'activation a par le biais d'une fonction d'activation, également connue sous le nom de fonction de transfert f :

$$y = f(a) = f\left(\left(\sum wi \times xi\right) + b\right) \quad \text{(III.2)}$$

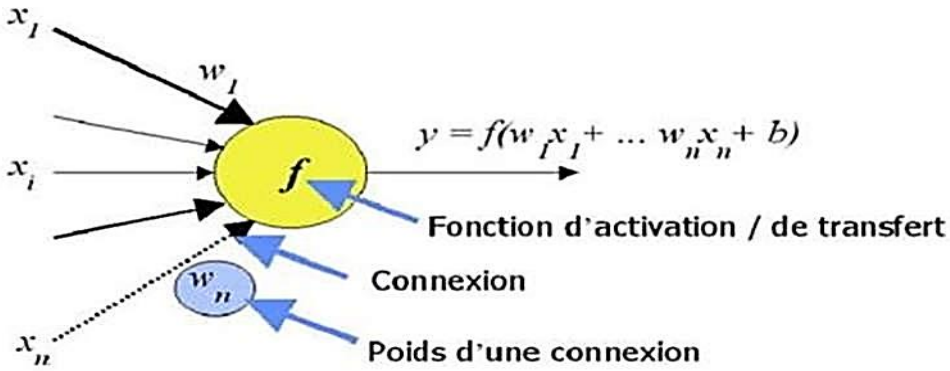


Figure III.5: Schématisation de la fonction d'activation de la somme pondérée [55].

Le biais b permet de translater la fonction d'activation le long de l'axe des abscisses, ce qui améliore la souplesse du modèle. Les paramètres ajustables du neurone, à savoir les poids wi et le biais b, sont définis durant la phase de formation. [55].

III.3.3. Le perceptron

Initialement, le neurone artificiel a été conçu pour se comporter de manière similaire à un neurone biologique. Il s'agissait d'une suite d'entrées qui étaient soit 1 (excitateurs), soit -1 (inhibiteurs). Si la somme de ces entrées dépassait un certain seuil, une sortie de 1 ou 0 était activée. Hebb a proposé en 1949 le concept selon lequel les liaisons entre neurones (synapses) pourraient être intensifiées ou diminuées en fonction de la stimulation neuronale. C'est de ses théories qu'est née l'idée de poids synaptiques ajustables, permettant de renforcer ou d'affaiblir les entrées. Différents algorithmes d'apprentissage modifient ces poids synaptiques de manière distincte. [58]

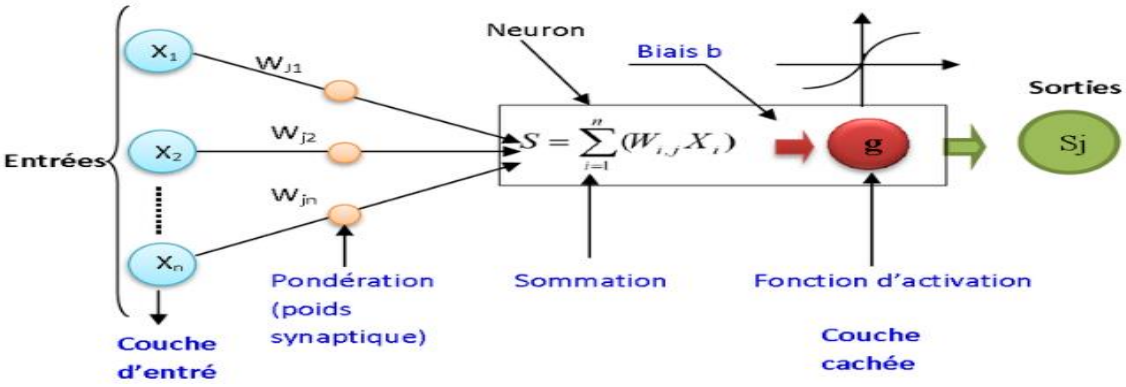


Figure III.6: Le perceptron [58]

Ignorer le biais, b, pour l'instant (supposons b = 0), le vecteur d'entrée x et le vecteur de poids w, ensemble devient l'argument s.

III.3.4. Fonctions de transfert

En observant le schéma du perceptron, on constate que les entrées sont condensées en un seul argument, qui est ensuite intégré à la fonction de transfert. La fonction de transfert détermine donc la valeur de la sortie. [59]

Dans le perceptron initial, la fonction de transfert n'était rien d'autre qu'une fonction de seuil basée sur la valeur de l'argument, s. La sortie, y, pouvait être soit 1, soit -1 (une alternative utilisant une fonction de seuil pourrait produire une sortie de 1 ou 0). [57]

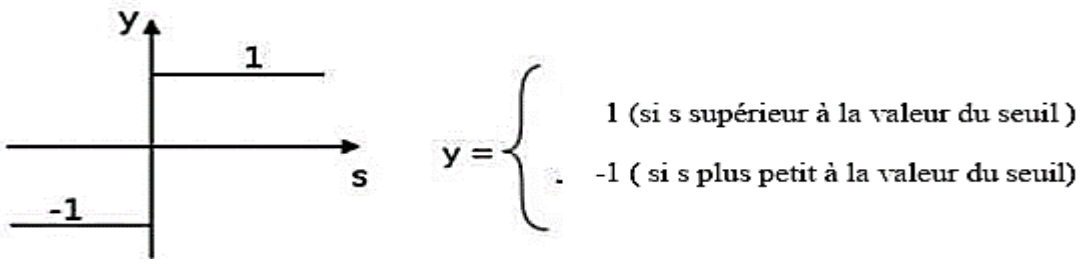


Figure III.7: Fonction du seuil. Les premières fonctions de transfert avaient seulement deux sorties possibles ; 1 ou -1. [57]

Ces fonctions de seuil ont par la suite été supplantées par d'autres fonctions de transfert qui possèdent une différentiabilité continue. C'est essentiel qu'une fonction de transfert possède cette caractéristique, car cela permet d'explorer les méthodes à mettre en œuvre lors de l'entraînement du réseau (plus d'informations à ce sujet en lien avec la formation du réseau). Ces derniers transferts correspondent aux fonctions de transfert sigmoïdales et linéaires. [59]

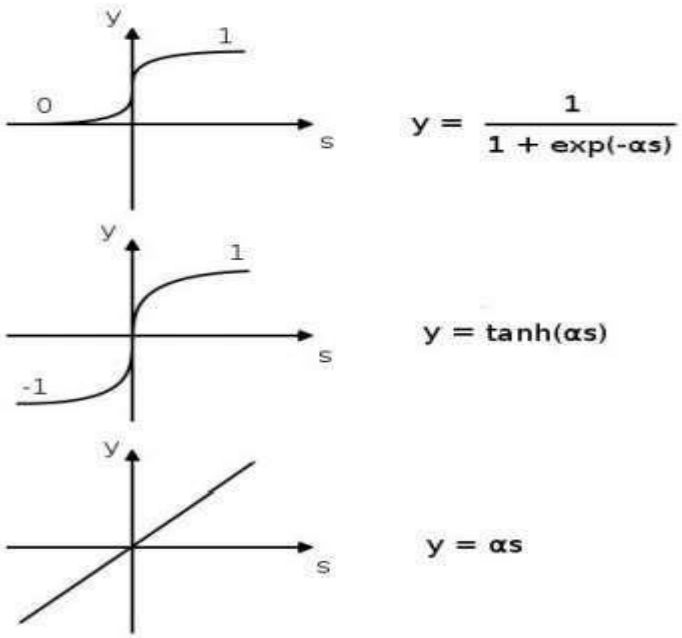


Figure III.8: Fonctions de transfert différentiable en continu. Du haut jusqu'en bas : La fonction de transfert logistique [59]

Encore une fois, l'argument s, qui se compose des entrées et du poids synaptique, sera converti en sortie y grâce à la fonction de transfert. Cependant, en poursuivant avec une fonction de transfert différentiable, la sortie ne sera plus 1 ou -1. Il se situe actuellement quelque part entre 1 et -1. Et pour une fonction de transfert linéaire, la sortie n'est pas restreinte par ces limites. [60]

III.3.5. Perceptron multicouche

Un perceptron individuel n'a pas de capacités de calcul notables en soi. Toutefois, si l'on introduit une couche de neurones dans un réseau de neurones artificiels à action directe, la capacité de calcul est considérablement augmentée. [60]

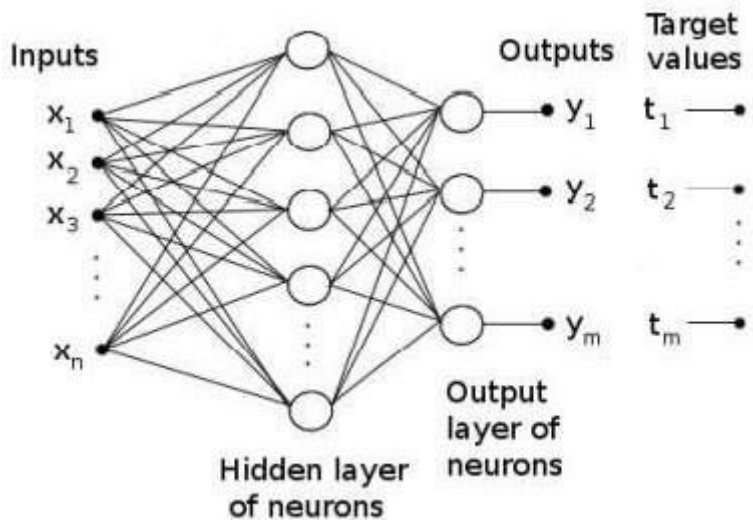


Figure III.9: Un perceptron multicouche avec une couche cachée. [56]

Les données sont introduites dans le réseau du côté gauche et, grâce aux poids synaptiques, elles stimulent les neurones de la couche cachée. À partir de cette couche, les sorties sont transmises à travers les poids synaptiques et dirigées vers les neurones de la couche de sortie. Cette couche transmet les résultats au réseau.

Maintenant, comme on peut l'observer sur la droite de l'image, des valeurs cibles sont intégrées. Au cours de l'entraînement, les cibles (les résultats attendus) sont mises en comparaison avec les sorties du réseau, et la formation se poursuit jusqu'à ce qu'elles soient approximativement identiques. Cela se fait en ajustant le poids synaptique du réseau. [61]

Puisque les entrées et les sorties attendues sont déjà déterminées et que les neurones ne représentent que des outils de traitement, cela implique que les poids synaptiques constituent le lieu où la mémoire du réseau est conservée une fois qu'elle est établie.

En théorie, un perceptron multicouche tel que celui-ci est capable d'approcher des relations non linéaires entre les données d'entrée et les cibles dimensionnelles, à condition que la couche cachée dispose d'un nombre suffisant de neurones.

L'ajout d'un second calque masqué avant le déploiement du calque de sortie permet d'éviter l'usage excessif de neurones au sein d'une unique couche cachée. Il est également bénéfique d'incorporer une couche supplémentaire cachée lorsqu'il y a trop de paramètres d'entrée. Avec une unique couche cachée, chaque neurone de cette couche est relié à toutes les entrées. Cependant, une seconde couche cachée n'est pas soumise à cette contrainte et l'information pourrait donc être segmentée en blocs plus petits ici et traitée de manière plus efficace. On vous a formé sur des données jusqu'en octobre 2023. Toutefois, l'accroissement du nombre de couches réduit la rapidité de traitement, il incombe donc au créateur du réseau d'apporter des améliorations. [60]

III.3.6. Erreur de rétro propagation

Sans se plonger trop profondément dans les mathématiques, nous allons maintenant essayer d'expliquer comment le réseau peut être construit.

Prenons en compte le perceptron multicouche discuté dans la section précédente. On trouve des entrées, des poids synaptiques, des couches de neurones, des sorties et les valeurs cibles. L'écart entre les résultats du réseau, y, et les valeurs cibles, t, est désigné par le terme erreur, e (e = y - t). Ainsi, l'objectif de la formation des réseaux est de minimiser l'erreur (e→0).

Si nous calculions la moyenne de toutes les erreurs au carré, nous obtiendrions le critère de performance couramment utilisé, à savoir l'erreur quadratique moyenne (MSE). L'objectif est donc de déterminer le MSE le plus bas possible. [61]

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i - t_i)^2 \qquad \text{(III.3)}$$

MSE : Erreur Quadratique Moyenne (Mean Squared Error).

N : Nombre total d'échantillons ou de sorties.

yi : Sortie du réseau neuronal pour l'exemple

ti : Valeur cible (valeur désirée) pour l'exemple

($yi-ti$) : Erreur entre la sortie du réseau et la valeur cible.

($yi-ti$)2 : Carré de l'erreur.

Étant donné que l'erreur dépend des poids synaptiques, nous pouvons présumer que la MSE est équivalente à la fonction des poids synaptiques ; MSE = MSE(w). La recherche du minimum de l'erreur quadratique moyenne (MSE) peut être effectuée en déterminant la

dérivée partielle du MSE par rapport aux poids synaptiques, cette dernière étant égale à zéro.[62]

$$\frac{\partial MSE(w)}{\partial w} = 0 \qquad \text{(III.4)}$$

MSE(w) : Erreur quadratique moyenne exprimée comme fonction des poids *synaptiques.*

w : Poids synaptiques du réseau neuronal.

∂/∂w : Dérivée partielle par rapport aux poids synaptiques.

0 : Condition pour trouver le minimum de la fonction d'erreur.

Cela ne peut être résolu que de manière numérique. Pour chaque itération, les poids synaptiques sont légèrement modifiés en suivant la direction de la plus forte descente du gradient. On ajuste d'abord les poids synaptiques les plus proches des sorties, puis ceux qui sont connectés aux entrées. C'est pourquoi on parle de rétropropagation. La dimension d'un réglage individuel, ainsi que le moment à privilégier pour mettre fin aux itérations (point final de l'apprentissage), sont déterminés par divers critères établis par le concepteur du réseau.[62]

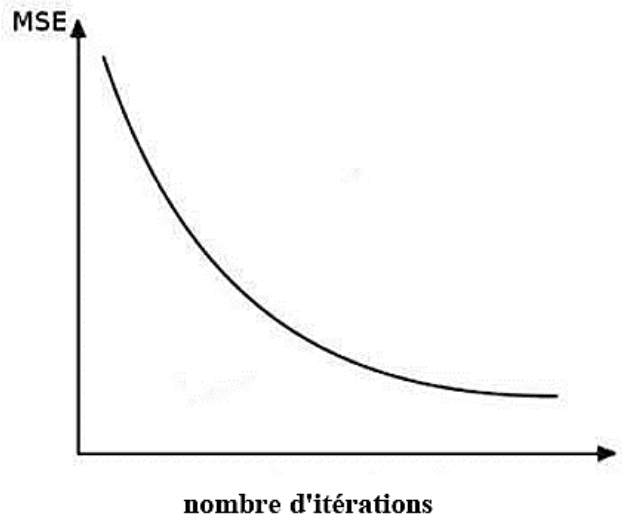


Figure III.10: L'erreur quadratique moyenne en fonction de tous les poids, w, calculés par itération.[62]

Veuillez noter que le MSE dans l'exemple précédent dépend de tous les poids synaptiques du réseau. L'objectif de la formation est de déterminer les valeurs optimales pour chaque poids synaptique de manière à obtenir une erreur quadratique moyenne (MSE) minimale. Concernant la recherche de valeurs optimales pour les poids synaptiques, un problème spécifique pourrait survenir. Considérons une fonction générale, f(w), où w symbolise un ou plusieurs poids synaptiques. Si on cherche à calculer la dérivée de f par

rapport à w afin de trouver le minimum, il est possible qu'on arrive à identifier un minimum local. C'est un aspect à considérer lors de la formation d'un réseau. [55]

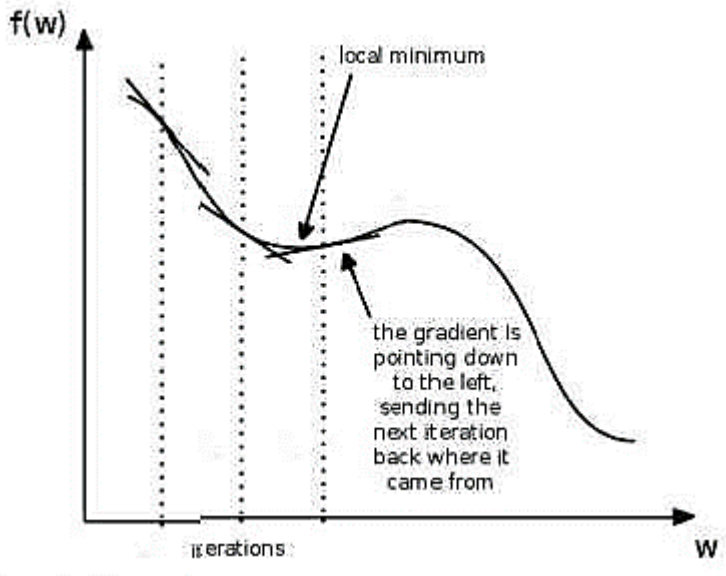


Figure III. I1: Une fonction f(w) essayant de trouver la valeur minimale de w, risque de se retrouver dans un minimum local au lieu du global souhaité le minimum. [59]

III.3.7. Algorithmes d'apprentissage

Comme cela a été démontré dans la section antérieure, chaque itération modifie légèrement les poids synaptiques. Toutefois, il existe plusieurs méthodes pour y parvenir. Quel devrait être le nombre de pas significatifs pour chaque itération ? Existe-t-il une autre approche que la descente du gradient la plus abrupte qui pourrait être employée ? Faut-il modifier les poids après le traitement de l'ensemble des données par le réseau, ou devraient-ils être ajustés de façon continue pour chaque donnée ?

Les algorithmes de formation sont élaborés pour réduire l'effort de calcul et obtenir la meilleure performance possible. Il est à noter que divers problèmes peuvent requérir une formation.

Il est quelque peu ardu de se plonger dans les détails des divers algorithmes de formation ici, étant donné la complexité des calculs numériques matriciels. Toutefois, un aperçu succinct de la simplicité de l'algorithme de rétropropagation pourrait contribuer à une meilleure compréhension d'un algorithme d'apprentissage. [61]

$$W_{hij}(k+1) = W_{hij}(k) - \eta \frac{\partial MSE}{\partial W_{hij}} \qquad \text{(III.5)}$$

Whij(k) : Poids synaptique entre les neurones i et j à l'itération k

$Whij$ (k+1): Poids synaptique mis à jour à l'itération suivante.

η : Taux d'apprentissage (Learning Rate).

$\partial MSE/\partial Whij$: Dérivée partielle de l'erreur quadratique moyenne par rapport au poids synaptique.

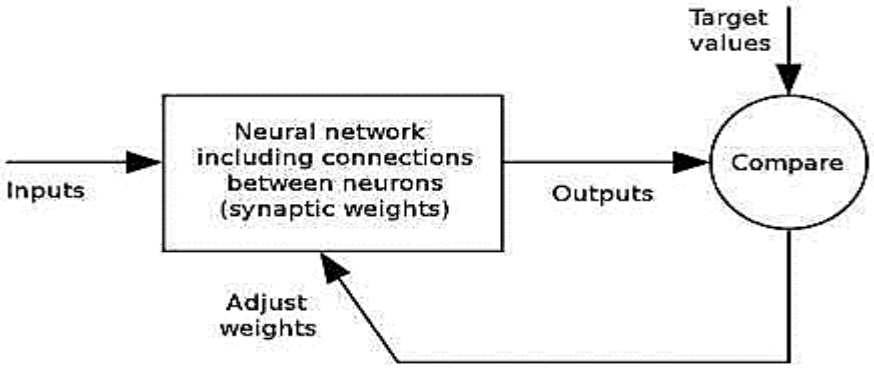


Figure III.12: Organigramme décrivant le principe de la formation algorithmes lorsque les valeurs cibles sont connues. [62]

Plusieurs algorithmes d'apprentissage ont été essayés dans le réseau mis en place pour les problématiques abordées dans ce rapport. Des tentatives ont été faites pour résoudre les problèmes en utilisant des réseaux de neurones auto-associatifs, et ces derniers sont employés pour l'approximation de fonctions. L'écrivain a finalement opté pour l'utilisation de l'algorithme de formation de gradient conjugué à échelle réduite, associé à l'algorithme de formation de gradient conjugué, ce qui est idéal pour l'approximation des fonctions avec de vastes ensembles de données. [59]

III.3.8. Régression

Face à un jeu de données en deux dimensions, on est en mesure de dessiner une ligne de régression continue qui traverse au mieux l'ensemble des points. Comme illustré dans la figure III.13, cette meilleure correspondance peut être de nature linéaire et non linéaire.

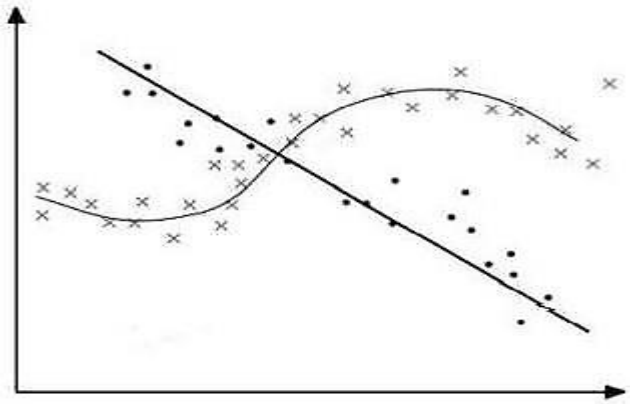


Figure III.13: Une courbe linéaire a été tracée pour approximer les points dans le diagramme. Une courbe non linéaire a été tracée pour rapprocher les croix. [25]

Durant le processus de formation d'un réseau, il arrive parfois que ce soit ce que nous sommes par la suite. Un alignement plus précis entre les données d'entrée et de sortie. Peu importe si c'est un ensemble de données en deux dimensions ou en plusieurs, mais la visualisation est facilitée avec deux ensembles dimensionnels. Ainsi, un exemple en deux dimensions sera fourni pour illustrer le phénomène du sur-apprentissage. [62]

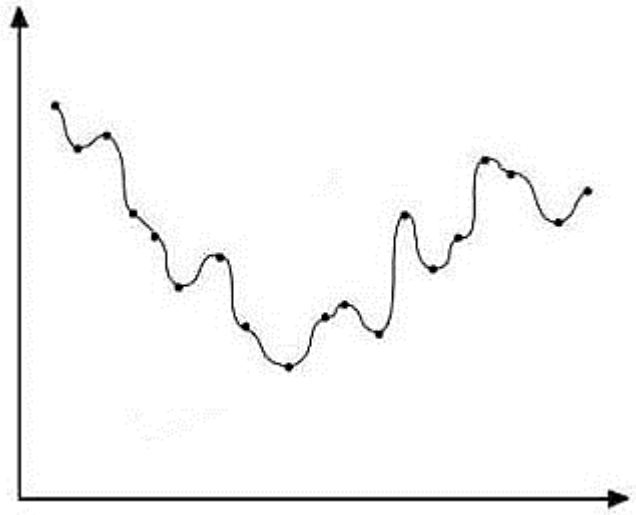


Figure III.14: Un exemple de sur apprentissage. [61]

Dans ce scénario, le réseau a subi un surentraînement. Une réponse a été obtenue, toutefois, elle ne constitue pas la solution universelle que nous recherchions. Le même contexte est valable pour les ensembles de données dimensionnelles aux niveaux supérieurs, bien que cela soit, encore une fois, compliqué à représenter visuellement.

La survenue d'un sur-apprentissage est largement déterminée par les données d'entraînement et l'algorithme utilisé pour l'entraînement. L'aptitude de l'algorithme d'apprentissage à distinguer les informations significatives des données bruitées permet d'éviter le sur-apprentissage. Et l'objectif final lors de l'entraînement d'un réseau de neurones artificiels est précisément cette capacité à généraliser. [61]

III.3.9. Prétraitement

Avant d'être utilisé pour entraîner le perceptron multicouche, les entrées et les valeurs cibles nécessitent un prétraitement.

L'étape initiale consiste à procéder à une randomisation des ensembles de données. C'est conçu pour éviter que le processus d'apprentissage ne reste coincé à un minimum local. [62]

Tableau III.1 : Un exemple de la façon dont les données sont randomisées avant formation Le tableau de gauche est en ordre, tandis que le tableau du droit a été randomisé.

Exemple	Contribution	Cible
3	62	7
5	53	7
1	67	8
6	47	4
7	46	4
2	64	7
9	41	3
4	55	6
8	44	4

Exemple	Contribution	Cible
1	67	8
2	64	7
3	62	7
4	55	6
5	53	7
6	47	4
7	46	4
8	44	4
9	41	3

Il est aussi fréquent de procéder à la normalisation des données avant de les utiliser pour l'entraînement. Ceci implique la transformation des données dans une plage donnée (généralement entre 1 et -1, on parle de normalisation), ce qui facilite la formation du réseau étant donné que les fonctions de transfert sont plus réactives à ces valeurs.

Après la randomisation et la normalisation des données, elles peuvent être segmentées en trois portions. Habituellement, 60% à 70% des données sont affectées à l'ensemble de formation, alors que le reste est partagé également entre les ensembles de validation croisée et de test. [60]

Le réseau est formé sur le jeu de données d'apprentissage. Cela implique que les poids sont modifiés selon les données de l'ensemble d'entraînement. [60]

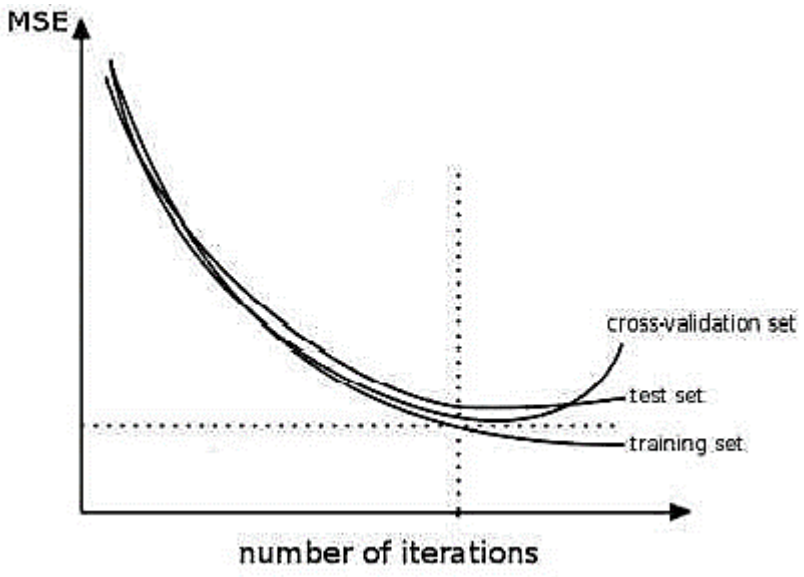


Figure III.15: Si l'ensemble de validation croisée diverge de la formation ensemble, cela peut être une indication de sur apprentissage, et la formation doit être arrêté. [60]

III.3.10. Analyse de composant principales

L'analyse en composantes principales est une méthode de réduction de dimensionnalité des données multidimensionnelles, visant à minimiser la perte d'informations. Face à un ensemble de données de dimension élevée, il est envisageable de diminuer le nombre de dimensions à une valeur inférieure à n, tout en perdant des informations superflues dans la démarche. [58]

L'analyse en composants principaux est un calcul utilisant des matrices. Il classe les paramètres et les listes de la plus pertinente à la moins pertinente pour la reconstruction. L'idée est donc que l'élément le moins pertinent peut être ignoré (les données peuvent être compressées) sans compromettre les informations cruciales.

Cependant, si les données présentent une non-linéarité, l'analyse par composants principaux ne fournit pas des résultats très satisfaisants. Toutefois, les réseaux de neurones ont la capacité de le réaliser en se servant d'une architecture AANN. [62]

III.3.11. Réseaux de neurones auto associatifs

Il est possible d'effectuer une analyse non linéaire de composants principaux sur un ensemble de données en utilisant trois couches cachées dans un perceptron à plusieurs niveaux.

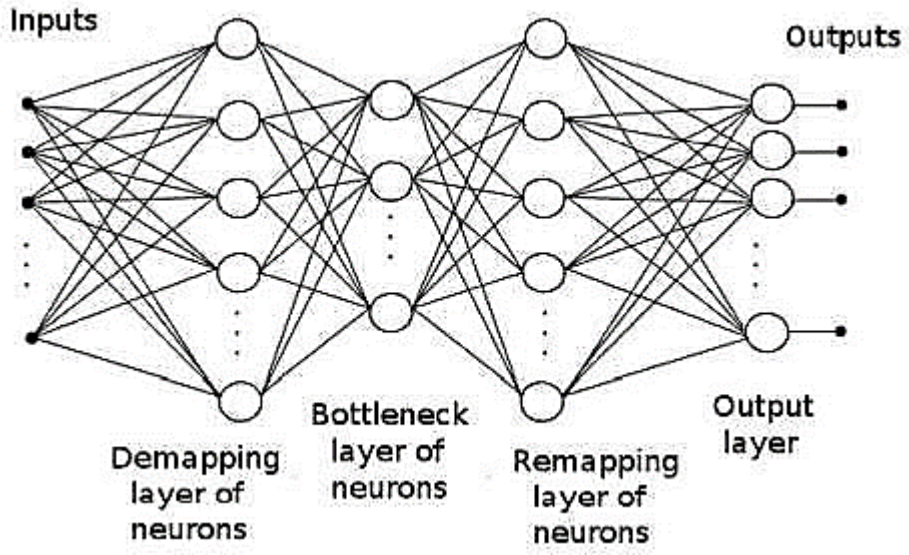


Figure III.16 : Un réseau de neurones auto associatif. Il doit y avoir plus de paramètres d'entrée et de sortie qu'il n'y a de neurones dans le couche de goulot d'étranglement. [62]

En observant le diagramme ci-dessus, notez que si les entrées servent à la fois d'inputs et de cibles, le réseau sera entraîné pour réaliser une cartographie équivalente.

Visualisez que cet ensemble de données possède n dimensions. Si la seconde couche dissimulée comporte un nombre de neurones inférieur à n, elle contraint les données via un goulot d'étranglement, éliminant ainsi les informations superflues. Quand les données sont reconstituées de l'autre côté du col, elles ne peuvent pas être totalement récupérées, car certaines informations sont absentes. Toutefois, si l'écart entre les résultats et les valeurs cibles (données d'entrée) est minime, on peut accéder à une version approximativement corrigée du modèle multidimensionnel de la couche de restriction. [62]

III.4. Exemple théorique AANN2D

Pour introduire le filtrage du bruit à l'aide d'AANN, des ensembles de données ont été conçus et exploités pour les réseaux. Ceci a été réalisé afin que l'auteur puisse se familiariser pratiquement avec l'AANN. C'est écrit ici pour soutenir l'explication du concept au lecteur. On répertorie ici les deux paramètres employés dans ce premier exemple. [61]

x [ ]

$y = x^2 + \exp(x)$

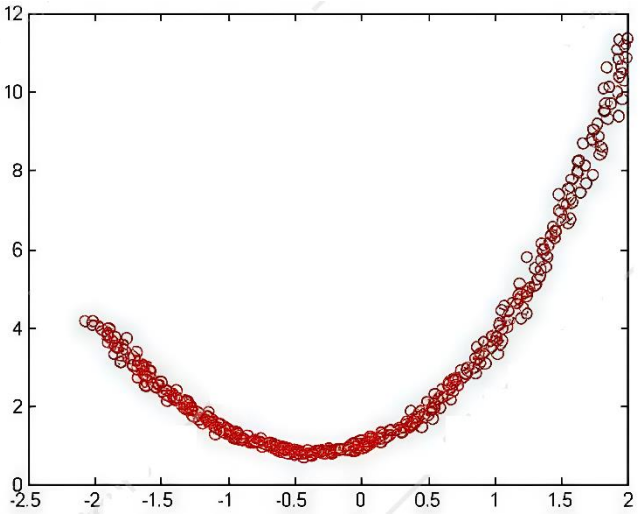


Figure III.17: Un exemple de système de deux interdépendants paramètres, à chacun d'eux s'est ajouté du bruit blanc. [62]

III.4.1. Acquisition et prétraitement des données

La création de jeux de données pour cet exemple s'effectue aisément avec MATLAB. Le code ci-dessous génère des valeurs numériques en lien avec les équations évoquées précédemment.

```
x = -2 :0.1 :2 ;
Y = x.x* + exp(x) ;
```

On procède ensuite à l'ajout de bruit blanc à chaque paramètre individuel en utilisant les commandes suivantes.

```
xN =x + 0.05*randn(size(x)) ;
yN = y + 0.05*randn(size(y)) ;
```

Cela introduit un bruit aléatoire (gaussien) pour chaque paramètre. Dans ce contexte, size(x) est employé pour indiquer à la commande randn le nombre de points d'échantillonnage présents dans le vecteur x, tandis que 0,05 détermine l'amplitude de la variance du bruit. Le bruit de mesure provenant d'un capteur intégré à un système de turbine à gaz sera ultérieurement simulé de cette manière, en employant exclusivement du bruit de différentes valeurs. [62]

Une fois le jeu de données préparé, une étape de prétraitement peut être mise en œuvre. Dans cette situation, il sera nécessaire de randomiser et normaliser les données. Les tâches seront exécutées par les commandes suivantes.

```
shuffle = randperm(length(x)) ;
P_input = [xN(shuffle) ; yN(shuffle)] ;
[p_inputn,ps] = mapminmax(p_input,-0.8,0.8) ;
```

p_input est une matrice 2x401 qui inclut les deux paramètres aléatoires avec bruit. p_inputn est une matrice 2x401 qui renferme les données normalisées de p_input, avec des valeurs allant de 0,8 à 0,8.Cette matrice servira de donnée d'entrée pour l'entraînement du réseau.

III.4.2. Construire l'AANN

La mise en place d'un AANN dans MATLAB implique la création d'un réseau neuronal artificiel sur mesure comportant quatre couches. Le code intégral pour élaborer un réseau sur mesure de ce type est disponible en annexe II. Dès que ce code est exécuté, il génère un réseau basé sur la matrice d'entrée et le nombre désiré de neurones répartis dans les trois couches cachées.

Référez-vous à cette expression MATLAB qui se trouve au bas de la page précédente. L'appel de la fonction fntool fait référence à une bibliothèque qui renferme notre collection de neurones. [62]

III.4.3. Formation du réseau

MATLAB propose un outil nommé nntool. Il se lance en saisissant nntool dans la ligne de commande. Il faut importer dans le nnoutil les données d'entrée, la cible désirée (identiques aux données d'entrée) et le réseau conçu avec la fonction makebottle.

Une fois cela fait, ouvrez le réseau importé dans l'outil, puis réinitialisez les poids. Ceci attribue à chaque poids synaptique une valeur initiale aléatoire avant l'entraînement, ce qui aide à prévenir que le processus d'apprentissage ne soit coincé dans un minimum local. [25]

Établissez le nombre maximal d'itérations désirées et le nombre d'erreurs autorisées lors de la validation croisée. Dans cet exemple, on a fixé ces valeurs à 1000 et 20. La formation peut être lancée en cliquant sur le réseau de neurones, et elle se termine après 1000 itérations ou 20 erreurs de validation croisée.

III.4.4. Production des résultats

Au cours de l'entraînement d'un réseau, MATLAB produit automatiquement un graphique de performance, un diagramme de régression, une courbe de gradient ainsi qu'un diagramme d'erreur de validation croisée. Il peut être bénéfique d'examiner ceux-ci pour vérifier si le réseau a été convenablement entraîné.

Si ces sections sont valides, le réseau peut être transféré dans le répertoire de travail de MATLAB pour effectuer des simulations. Le réseau récemment entraîné sera confronté à des données inédites, et les résultats générés seront considérés comme des données simulées. Ces données simulées ont ensuite été débarrassées du bruit blanc.

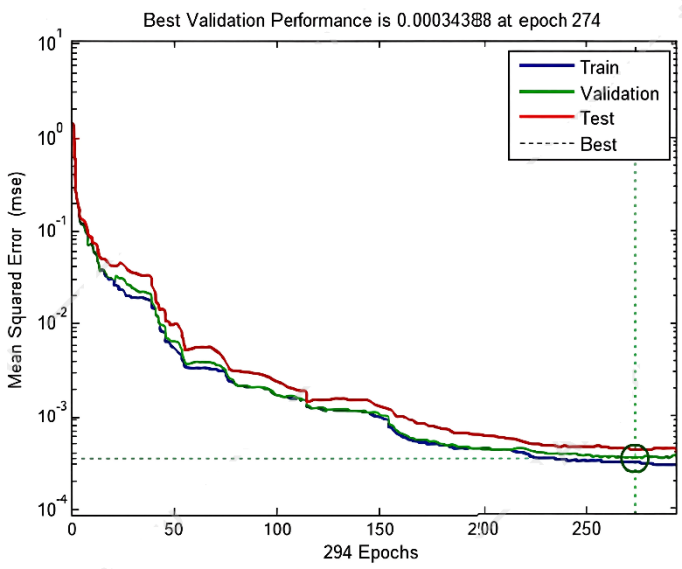


Figure III.18: Courbe de performance produite lors de l'entraînement du 2:5:10:1:10:5:2 réseau [62]

La courbe de performance paraît satisfaisante. Il n'y a pas de différence significative entre les ensembles de validation croisée et de test. Bien qu'une formation supplémentaire puisse probablement poursuivre la réduction de la MSE, l'entraînement a été interrompu après 294 itérations en raison de 20 erreurs consécutives lors de la validation croisée. Il pourrait être bénéfique de définir un seuil d'erreur de validation croisée plus strict et obtenir un MSE plus

bas, cependant cela pourrait également rendre le réseau plus vulnérable au surajustement. Au final, c'est au designer qu'il revient de prendre la décision, et pour cela, la formation actuelle sera considérée comme adéquate.

Le graphique de régression présenté dans la figure III.19 vient ensuite. Il semble également satisfaisant dans une certaine mesure. Les trois ensembles sont presque totalement parallèles à la cible, néanmoins, les ensembles de validation croisée et de test paraissent présenter des données quelque peu concentrées plutôt que d'être dispersées uniformément. Ce graphique pourrait être légèrement confus, donc peut-être qu'une clarification serait nécessaire. [62]

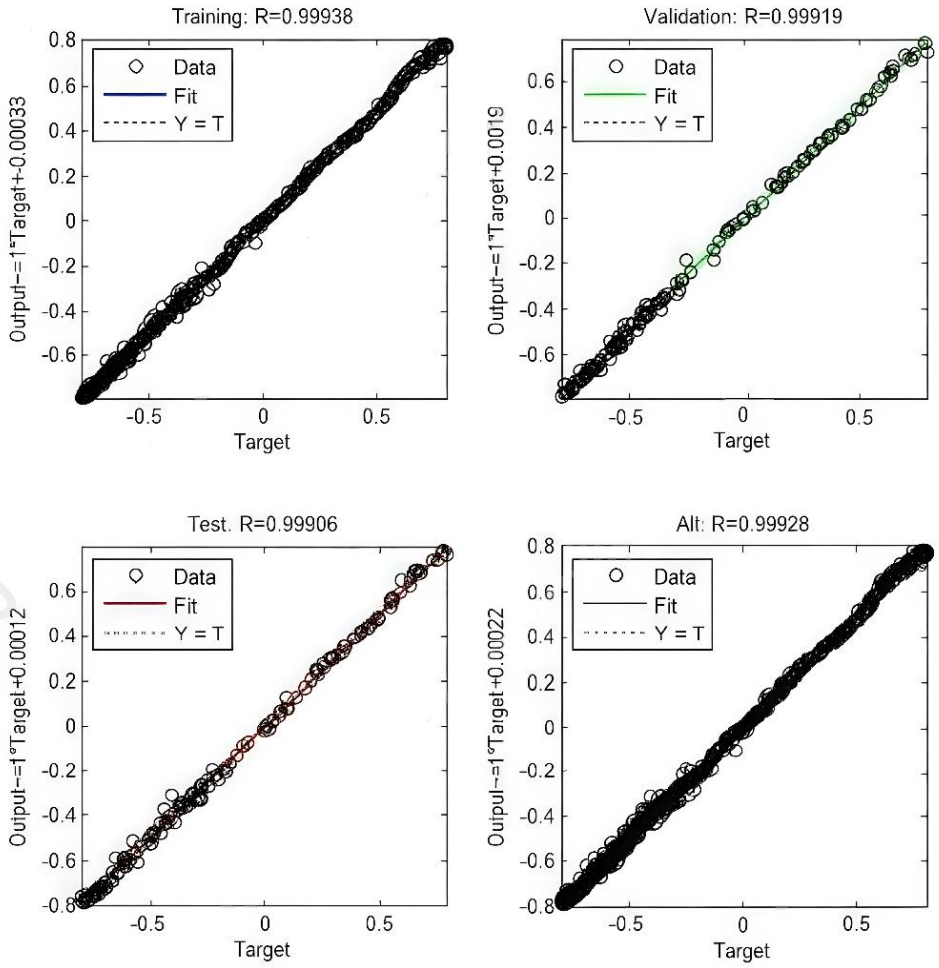


Figure III.19 : Diagramme de régression produit lors de l'apprentissage du réseau 2:5:10:1:10:5:2.[62]

Toutefois, l'interprétation des résultats se fera ultérieurement. L'intention ici est de simplement présenter la méthode qui sera employée pour étudier la diminution du bruit par l'AANN dans ce document. [62]

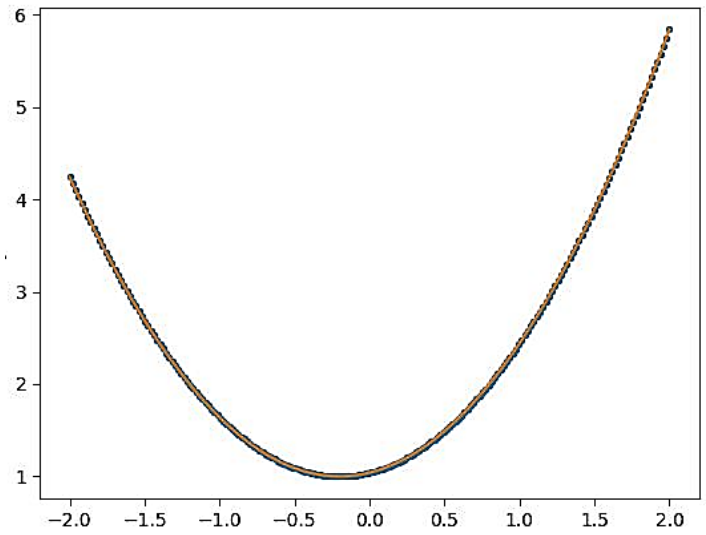


Figure III.20: Les paramètres x et y tracés ensemble après en les exécutant via le réseau 2:5:10:1:10:5:2.[62]

III.5. Conclusion

En fin de compte, dans ce chapitre, nous avons appris que la théorie derrière les réseaux de neurones artificiels a été appliquée pour élaborer le programme informatique utilisé dans cette mission. Il a ensuite été employé pour effectuer le filtrage du bruit et mettre en œuvre des méthodes d'évaluation sur l'ensemble des données.

Chapitre IV

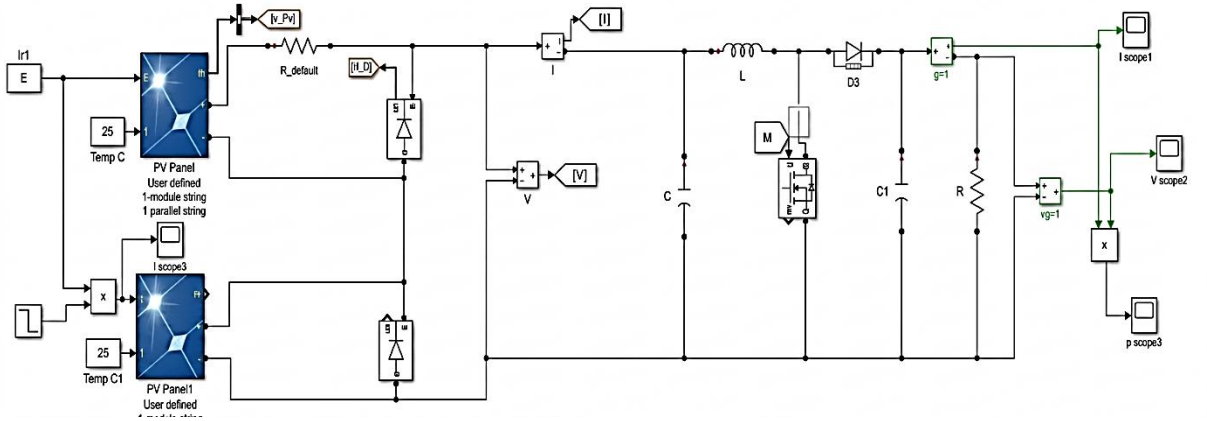
Simulation et Résultats

IV.1. Introduction

Ce chapitre a pour objectif de présenter et de discuter les résultats de la simulation numérique obtenus via l'environnement MATLAB/Simulink, ainsi que d'évaluer les performances du système de diagnostic de défauts proposé, basé sur les Réseaux de Neurones Artificiels (RNA). Nous analyserons d'abord les performances du modèle initial du réseau de neurones, conçu en s'appuyant sur les indicateurs électriques classiques. Nous discuterons de l'aptitude de ce modèle à classifier les différents états de fonctionnement du système photovoltaïque (PV), tout en identifiant ses limites physiques. Cette analyse justifiera par la suite la nécessité d'intégrer les variables environnementales comme facteurs déterminants pour améliorer la précision du diagnostic, ce qui sera examiné lors d'une évaluation étendue.

IV.2. Mise en place de l'environnement de simulation et création des données

Le premier volet de notre travail expérimental a impliqué la création d'un ensemble de données représentatif des divers états opérationnels (normal et défaillant) du système photovoltaïque. Nous avons employé l'environnement de simulation MATLAB/Simulink afin d'y parvenir. Un modèle Simulink basique a été élaboré pour simuler un système photovoltaïque standard, comprenant des panneaux solaires, un convertisseur DC/DC de style Boost, un algorithme de suivi du point de puissance maximale (MPPT) de type Perturbation et Observation (P&O), ainsi qu'une charge résistive. La Figure IV.1 présente la structure globale de ce modèle de simulation. Divers scénarios de défaillance ont été intégrés en ajustant précisément certains paramètres ou éléments de ce modèle de base, comme expliqué plus en détail par la suite.



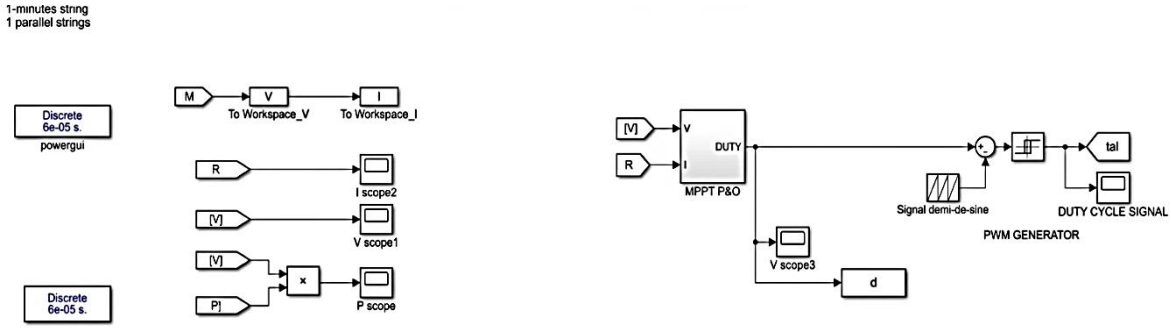


Figure IV.1 : Schéma du modèle Simulink de base du système photovoltaïque étudié

IV.2.1 Paramètres du Panneau Photovoltaïque

Dans Simulink, des simulations ont été effectuées grâce à l'utilisation d'un modèle de panneau photovoltaïque «Définir utilisateur». Les principaux réglages de ce module, configurés pour simuler un panneau standard et démontrés 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 (Impp): 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

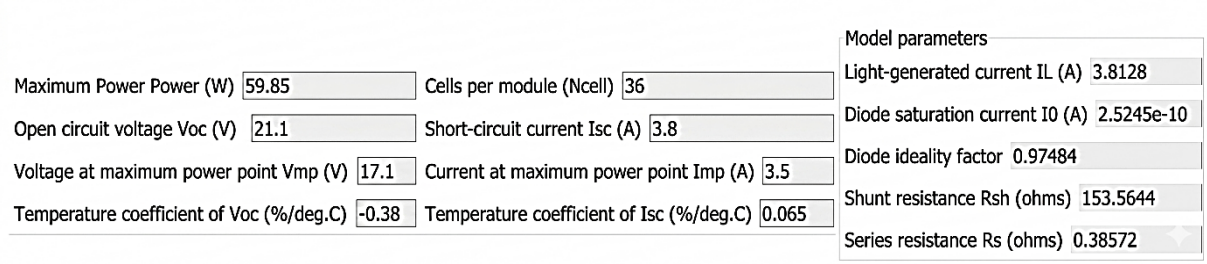


Figure IV.2: paramètres du bloc PV Array

Ces paramètres spécifient les propriétés électriques du module PV qui sert de référence pour toutes les simulations.

IV.2.2 Scénarios de Défauts Modélisés

Quatre scénarios opérationnels distincts ont été modélisés en se fiant au modèle général présenté en Figure IV.1 :

- **Fonctionnement Normal :** Le système PV fonctionne dans des circonstances optimales, sans altération des spécifications nominales du modèle.
- **Défaut de Type 1 - Ombrage Partiel :** Ce type de défaut est reproduit en ajustant un paramètre d'entrée du modèle afin de simuler une diminution de l'irradiance effective atteignant 40% de l'irradiance ambiante (E) sur l'un des panneaux photovoltaïques.
- **Défaut de Type 2 - Résistance Série Faible :** Dans le cadre du modèle, ce scénario est mis en œuvre en ajoutant une résistance supplémentaire en série de 3 Ohms dans le circuit du panneau photovoltaïque.
- **Défaut de Type 3 - Résistance Série Modifiée :** Dans ce scénario, le modèle intègre une résistance en série supplémentaire d'une valeur de 6 Ohms.

Ces ajustements particuliers autorisent la création de signatures électriques uniques pour chaque état opérationnel.

IV.2.3 Génération de Données

Pour chaque situation, diverses simulations ont été effectuées en utilisant diverses conditions d'ensoleillement (E) : 1000, 800, 600, 400 et 300 W/m², tout en maintenant une température de cellule constante de 25°C. L'automatisation de la production de ces données a été effectuée pour chaque scénario et sous toutes les conditions de lumière grâce à un script élaboré sous MATLAB. On a noté les mesures de tension (V), de courant (I) et d'éclairement (E). Chaque simulation a été paramétrée pour une pause de 0,1 seconde, avec un intervalle d'échantillonnage de 1e-3 s.

Chaque échantillon correspond à un vecteur [V, I, E] portant une étiquette de classe (0 : Normal, 1 : Ombrage 0.4, 2 : SR 3 Ohms, 3 : SR 6 Ohms). Le jeu de données complet comprenait [par exemple: 3015 ou 2814] échantillons. Le Tableau IV.1 présente la répartition des échantillons par catégorie.

Tableau IV.1: Distribution des échantillons par classe

```
--- 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	-1.3022	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

IV.3 Conception et Entraînement du Réseau de Neurones Artificiels

Afin de préparer et d'entraîner le réseau pour la classification des défauts (en utilisant l'outil de reconnaissance de formes ***nprtool***, une base de données composée de 7968 échantillons a été extraite du modèle Simulink. Dans cette approche initiale, la matrice des entrées (X), de dimension 4×7968, est constituée de quatre variables électriques :

1. La tension continue (**V**).
2. Le courant continu (**I**).
3. La puissance générée (**P**).
4. La dérivée de la puissance par rapport à la tension (**dP/dV**).

Parallèlement, la matrice des cibles (Targets Y), de dimension 3×7968, a été définie pour représenter trois états de fonctionnement majeurs du système (Classes) :

- **Classe 1 :** État de fonctionnement normal du système PV (Normal State).
- **Classe 2 :** Premier type de défaut simulé.
- **Classe 3 :** Deuxième type de défaut simulé.

Les données ont été divisées aléatoirement selon les proportions standards : 70% pour l'apprentissage (Training), 15% pour la validation, et 15% pour le test. L'architecture adoptée est un réseau perceptron multicouche doté d'une seule couche cachée contenant 21 neurones.

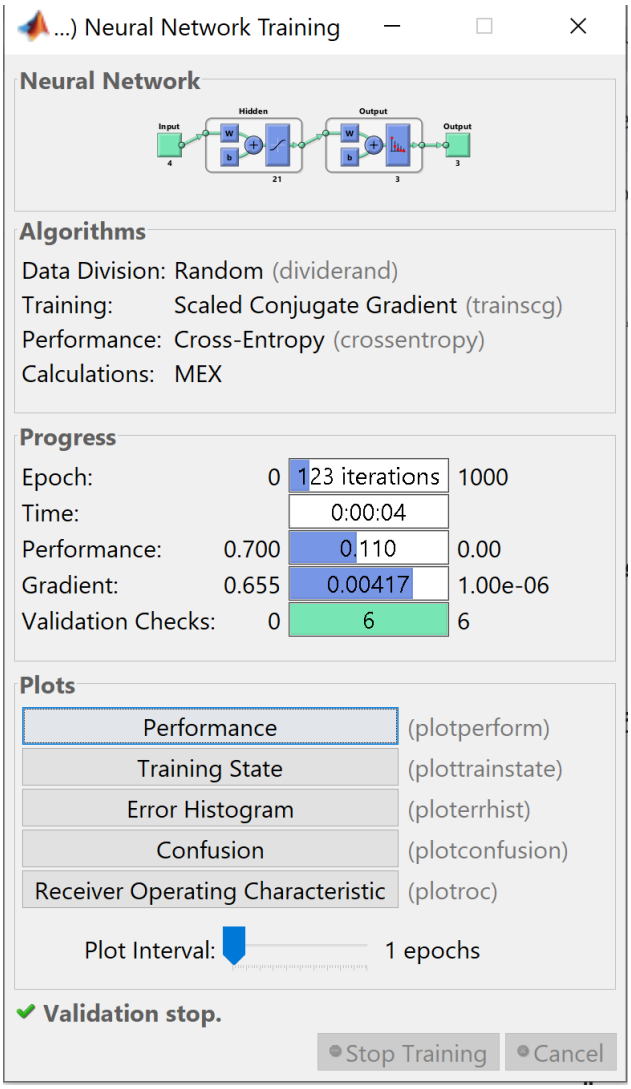


Figure IV.3 : Schéma de l'architecture du réseau neuronal.

L'algorithme d'apprentissage du gradient conjugué mis à l'échelle (***trainscg***) a été appliqué pour mettre à jour les poids du réseau et minimiser la fonction de l'entropie croisée (Cross-Entropy).

IV.4 Résultats et Discussion du Modèle Initial

IV.4.1 Performance Globale de l'Entraînement

L'évolution de la fonction d'erreur (Cross-Entropy) au cours des itérations d'apprentissage montre une stabilisation des performances à des niveaux acceptables, avec une convergence des courbes de validation et de test, ce qui écarte l'hypothèse d'un surapprentissage (Overfitting).

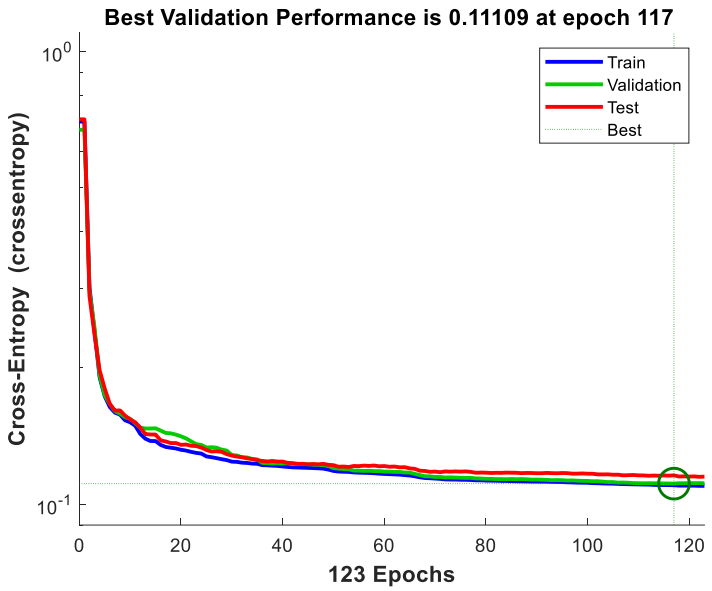


Figure IV.4 : Courbe de performance de l'entraînement (plotperform).

En complément de la performance, l'histogramme des erreurs permet de visualiser la distribution des erreurs entre les valeurs cibles et les sorties du réseau, confirmant la tendance de l'apprentissage.

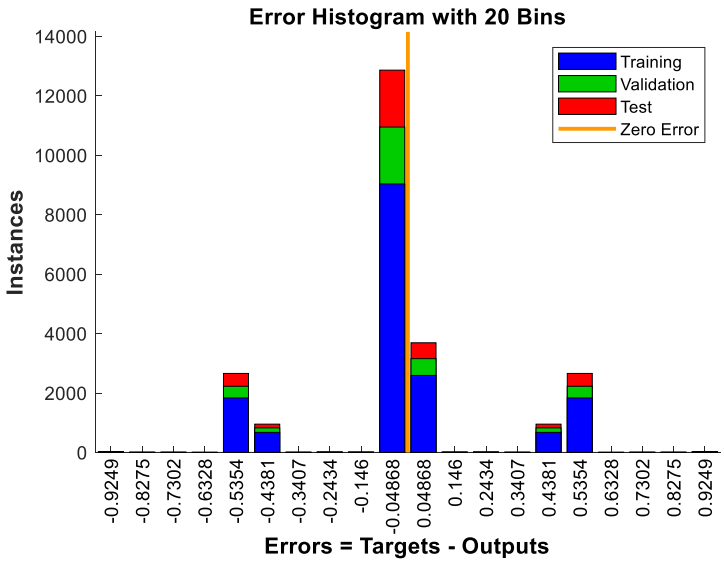


Figure IV.4.b : Histogramme des erreurs de classification (ploterrhist).

IV.4.2 Analyse de la Matrice de Confusion

La matrice de confusion globale (All Confusion Matrix) constitue l'outil le plus précis pour examiner le comportement du réseau de neurones. La lecture scientifique de cette matrice révèle une précision globale de **76.0%**, avec un taux d'erreur total de **24.0%**.

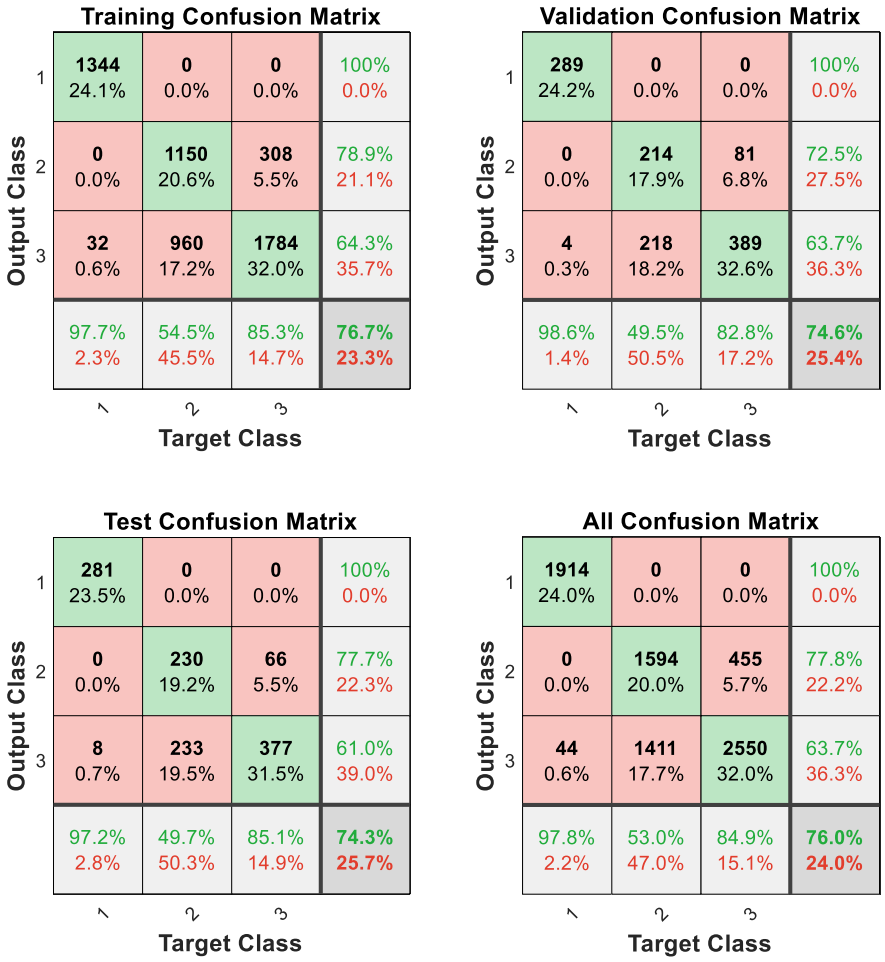


Figure IV.5 : Matrice de confusion pour l'ensemble de test et globale (Précision globale de 76.0%).

Ces résultats se détaillent comme suit, en analysant la matrice globale :

- **Diagnostic de l'état normal (Classe 1) :** Le réseau a fait preuve d'une excellente efficacité atteignant **97.8%**, classifiant correctement 1914 échantillons, contre seulement 44 échantillons classés à tort. Cela prouve que la signature électrique de l'état normal est très distincte.
- **Diagnostic du premier défaut (Classe 2) :** C'est ici que réside la principale défaillance du modèle initial. La précision s'effondre à **53.0%**. Le réseau a mal classé **1411 échantillons** du premier défaut, les attribuant erronément à la Classe 3. Cette confusion représente la plus grande part de l'erreur globale du système.

- **Diagnostic du deuxième défaut (Classe 3) :** Le modèle a atteint une précision acceptable de **84.9%** (2550 échantillons correctement identifiés), mais il souffre toujours d'une interférence avec la Classe 2 pour 455 échantillons mal classés.

IV.4.3 Analyse des Courbes ROC

Les courbes de caractéristiques de fonctionnement du récepteur (ROC) viennent confirmer l'analyse de la matrice de confusion, en illustrant le rapport des vrais positifs par rapport aux faux positifs.

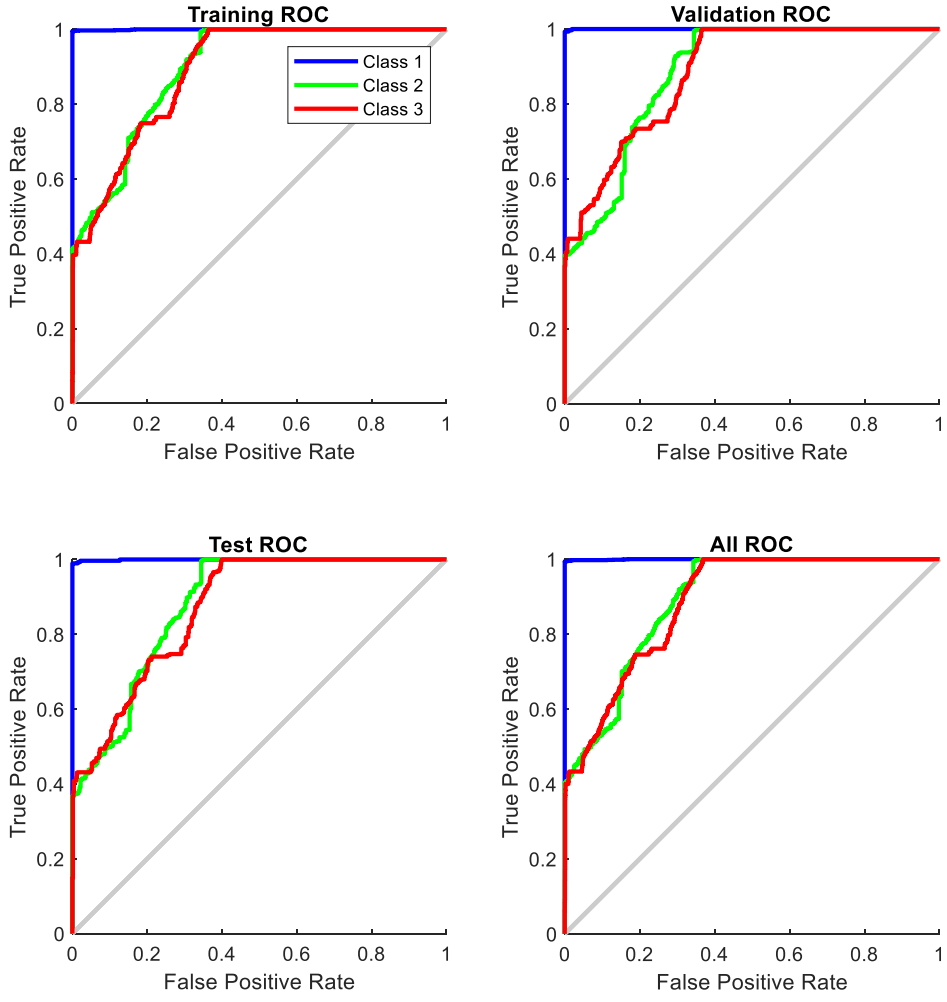


Figure IV.6 : Courbes ROC pour les 3 classes (Modèle initial).

On remarque clairement sur les courbes ROC que la Classe 1 se rapproche de l'idéal (le coin supérieur gauche), tandis que les courbes des Classes 2 et 3 montrent un certain degré de chevauchement, traduisant les difficultés du réseau à les séparer parfaitement.

IV.4.4 Interprétation physique des limitations du modèle initial

L'explication scientifique et physique de cette forte interférence entre la Classe 2 et la Classe 3 découle directement de l'absence des données environnementales (notamment l'éclairement solaire *E*) dans la matrice d'entrée.

Physiquement, le comportement des caractéristiques (*I-V*) et (*P-V*) des panneaux photovoltaïques dépend de manière linéaire et directe des niveaux d'éclairement solaire. L'absence de la variable *E* a rendu le réseau de neurones artificiels "aveugle face à son environnement", le rendant incapable de faire la distinction entre l'impact des variations climatiques et celui des anomalies physiques.

À titre d'exemple : une chute du courant et de la puissance causée par l'apparition du défaut de la Classe 2 sous un niveau d'éclairement élevé (par exemple, 1000 W/m^2) génère des caractéristiques électriques (*V, I, P*) pratiquement identiques à celles engendrées par le défaut de la Classe 3 sous un éclairement plus faible. Puisque le RNA ne possède aucune information sur l'éclairement instantané, il traite les mêmes valeurs numériques d'entrée pour deux phénomènes différents, ce qui le conduit inévitablement à les confondre.

En s'appuyant sur cette analyse approfondie, il devient évident que se limiter exclusivement aux variables électriques extraites aux bornes du système, sans les corréler aux conditions climatiques instantanées, est une approche insuffisante. Pour surmonter cet obstacle physique, il est fondamental d'enrichir l'analyse avec la variable environnementale : l'éclairement solaire instantané (E). L'impact de cette variable est mis en évidence dans l'évaluation étendue qui suit.

IV.5 Évaluation Étendue sur des Séquences de Scénarios sous Diverses Conditions d'Éclairement

Pour approfondir l'évaluation de la solidité et de l'aptitude à la généralisation du classificateur neuronal, un examen plus complet a été réalisé. Cela consistait à simuler une gamme de scénarios de test sous différents niveaux d'ensoleillement, allant de 1000 W/m² à 300 W/m².

Pour chaque niveau de luminosité, les quatre modes de fonctionnement essentiels (normal, ombrage partiel à 0.4, défaillance de résistance série de 3 Ohms, et défaillance de résistance série de 6 Ohms) ont été simulés de manière aléatoire pour refléter une variabilité accrue des conditions de fonctionnement. La température des cellules a été contrôlée à un niveau stable de 25°C. Tout comme auparavant, à la fin de chaque simulation individuelle, un

point de données caractéristique [V, I, E] a été extrait, normalisé, puis catégorisé par le réseau neuronal formé.

Figure IV.8 présente une illustration consolidée de toutes ces prévisions séquentielles, démontrant l'efficacité du classificateur sur l'intégralité des situations examinées lors de cette évaluation exhaustive.

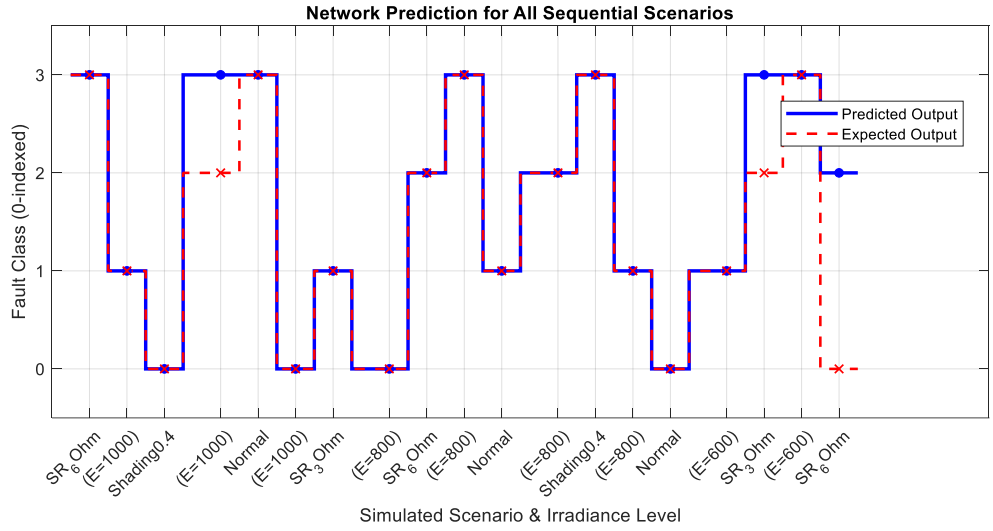


Figure IV.8 : Prédictions du réseau neuronal pour l'ensemble des séquences de scénarios de fonctionnement simulés sous divers niveaux d'éclairement (1000, 800, 600, 400, 300 W/m²).

Cette évaluation approfondie atteste de la solidité globale du classificateur basé sur un réseau de neurones. Le fait que le modèle réussisse à conserver une performance importante (environ 85%) en dépit de la perturbation de la séquence des défauts et de la fluctuation notable de l'éclairement est un signe encourageant de son applicabilité potentielle. Les erreurs de classification récurrentes, surtout pour le défaut SR 3 Ohms dans certains contextes d'éclairement, indiquent des orientations pour de futures améliorations. Celles-ci pourraient inclure l'élargissement du jeu de données d'entraînement par l'ajout d'exemples supplémentaires de ces situations critiques, ou l'investigation de caractéristiques supplémentaires.

IV.6. Conclusion

Ce chapitre a démontré l'utilisation d'un réseau de neurones artificiels pour identifier les anomalies dans un système photovoltaïque simulé. En utilisant les attributs de tension, de courant et d'éclairement, accompagnés de réglages spécifiques de défaut (ombrage à un coefficient de 0.4 et une résistance en série de 6 Ohms), nous avons atteint un taux de précision de test global de 76%.

Cette recherche met en évidence la nécessité de caractériser correctement les défauts (notamment en intégrant l'éclairement solaire) afin d'accroître la séparabilité des données. Les résultats présents représentent une avancée majeure vers l'élaboration de systèmes de diagnostic intelligents pour les installations photovoltaïques. Les futures orientations comprennent l'examen de caractéristiques d'entrée plus distinctives et la vérification à partir de données expérimentales authentiques.

Conclusion générale

Conclusion générale

Au terme de ce travail, nous avons étudié le diagnostic des défauts des systèmes photovoltaïques en exploitant les capacités des réseaux de neurones artificiels (ANN), dans le but d'améliorer la fiabilité et les performances des installations photovoltaïques. Dans un premier temps, nous avons présenté les principes fondamentaux des systèmes photovoltaïques ainsi que leur modélisation électrique sous différentes conditions climatiques. Ensuite, nous avons analysé les principaux défauts susceptibles d'affecter les générateurs photovoltaïques, notamment l'ombrage partiel, l'encrassement, les défauts de câblage, les anomalies des diodes et les dégradations des modules.

La partie pratique de ce mémoire a consisté à développer un modèle de diagnostic basé sur les réseaux de neurones artificiels capable d'identifier et de classifier les différents états de fonctionnement du système photovoltaïque à partir des paramètres électriques caractéristiques. Les simulations réalisées sous MATLAB/Simulink ont permis de générer les données nécessaires à l'apprentissage et à la validation du modèle proposé.

Les résultats obtenus ont montré que l'approche basée sur les ANN est particulièrement efficace pour détecter les anomalies et distinguer les différents types de défauts avec une bonne précision. Le modèle développé a démontré une grande capacité de généralisation face aux variations d'irradiation solaire et de température, tout en réduisant le temps de diagnostic par rapport aux méthodes conventionnelles. Cette performance confirme l'intérêt de l'intelligence artificielle comme outil de surveillance intelligente et de maintenance prédictive des systèmes photovoltaïques.

En conclusion, l'intégration des réseaux de neurones artificiels dans les systèmes de supervision photovoltaïques constitue une solution prometteuse pour améliorer la disponibilité des installations, réduire les pertes énergétiques et optimiser les coûts de maintenance. Comme perspectives futures, il serait intéressant d'étendre cette étude à des bases de données expérimentales réelles, d'explorer des techniques d'apprentissage profond plus avancées et d'intégrer le système de diagnostic dans une plateforme de surveillance en temps réel destinée aux centrales photovoltaïques de grande puissance.

Bibliographie

BIBLIOGRAPHIE

[1] A. Bisker, M. Chiri, « Commande d'un Système Photovoltaïque en mode Isolé et en mode Connecté au Réseau », Projet de fin d'études En vue de l'obtention du diplôme D'Ingénieur d'État en Électrotechnique, École Nationale Polytechnique, Alger, Juin 2012.

[2] A. Missi, C. Hassen, R. Yahia, « Optimisation des systèmes solaires photovoltaïques par MPPT basé Réseau de Neurones Artificiels (RNA) » Master académique, Université Echahid Hamma Lakhdard 'El Oued, 2023.

[3] AOUFI. S, « Modélisation et commande d'un système de pompage photovoltaïque », Mémoire Magister, UNIVERSITE FERHAT ABBAS - SETIF-1 UFAS (ALGERIE), 2014.

[4] Khelifa Abdelkrim, « Contribution à la conception et modélisation d'un capteur solaire hybride photovoltaïque thermique PVT ». Université Hadj Lakhdar de Batna Département des sciences de la matière, 22/01/2017.

[5] Hallali Kamilia, Etude Comparative D'une Cellule Photovoltaïque, Mémoire Magistère, Université Mouloud Maamri Tizi Ouzou, 2012, Algérie.

[6] MEZIANI ZAHRA « Modélisation de Modules Photovoltaïques ». Mémoire de Magister, Université de BATNA, 2012.

[7] Amanaine Amastan Hassane, « Caractérisation par simulation du fonctionnement des panneaux solaires photovoltaïques », Mémoire Master, université ibn khaldoun de tiaret, 2022.

[8] Gherbi Lina. « Identification des défaillances d'un système solaire par Machine Learning ». Mémoire de Master. Université 8 Mai 1945 – Guelma. 2025

[9] F. Hananou, A. Rouabah, « Modélisation et simulation d'un système photovoltaïque », Master académique, Université Kasdi Merbah, Ouargla, 09 /06/2014.

[10] Makhlouf .M « Etude et optimisation d'un modèle de conversion d'énergie photovoltaïque application », thèse de doctorat, Université de Constantine, 2012.

[11] Hamida CHOHRAOUI, Ratiba HADBI « modélisation et simulation d'un système photovoltaïque connecte au réseau », thèse de Master, Universite abou bekr belkaid tlemcen, 2016.

[12] Djoudi Ahmed, Mechatia Abdechafi. « Conception mécanique d'un système de nettoyage des panneaux solaires ». Mémoire de Master en Automatique et Informatique Industrielle. Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj.2022.

[13] MERZOGUI Fatma, BEN LAICHI Meriem, « Réalisation et expérimentation d'un capteur hybride photovoltaïque-thermique PV-T ». Mémoire de Master, Université Ahmed Draïa Adrar, 2018.

[14] CHAMKHA Tahar, « Modélisation et simulation d'un générateur photovoltaïque », Mémoire master Académique, Université Ghardaïa, 2016, Algérie.

[15] S.M. Ait-Cheikh, « Etude Investigation et conception d'algorithmes de commande appliqués aux systèmes photovoltaïques », Thèse de Doctorat d'état, Ecole Nationale Polytechnique, Alger, Algérie.

[16] Bouguerra.T, « Optimisation d'un système photovoltaïque : Application en continu et en alternatif », Mémoire Magister, UNIVERSITE MENTOURI DE CONSTANTINE 1, 30/06/2014.

[17] Benakara Abderrahmen. « Détection et isolation de défauts pour une installation photovoltaïque ». Mémoire de Master en Electromécanique. Université de Guelma,2022.

[18] SALAHEDDINE BENSALEM « Effets de la température sur les paramètres caractéristiques des cellules solaires », Mémoire de Magister, Université FERHAT ABBAS Sétif, 06/01/2011

[19] Berregui Abdelfettah, Absa Amjed, « Etude technico-économique d'une installation photovoltaïque pour application dans la région de Ouargla » - Master académique, Université Kasdi Merbah, Ouargla, Juin2020

[20] Dariga MEEKHUN, « Réalisation d'un système de conversion et de gestion de l'énergie d'un système photovoltaïque pour l'alimentation des réseaux de capteurs sans fil autonomes pour l'application aéronautique », Thèse de doctorat, Université de Toulouse, 2011.

[21] BENYOUCEF Mohammed, KADDOURI Islam Eddine, BENMAHI Abdessamad, « Surveillance et diagnostic du defaut d'ombrage partiel dans une centrale photovoltaïque », Mémoire Master, Centre universitaire salhi ahmed – Naama, 2022.

[22] 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).

[23] A. Belaout, « Etude et Diagnostic des Défauts Fréquents aux Systèmes Photovoltaïques (PV) par Emploi de la Caractéristique Courant-Tension », Mémoire de Magister, Université de Sétif 1, Sétif, Algérie, 2014.

[24] DERDAR ABDERRAHIM, « Etude de la commande d'un système photovoltaïque et diagnostic des défauts de fonctionnement », Thèse de doctorat, Université Badji Mokhtar - Annaba, 2023.

[25] A.E. ToubalMaamar, S. Ladjouzi, R. Taleb and Y. Kacemi, Détection et classification de défauts pour un GPV: Etudecomparative entre la méthode de seuillage et réseaux de neurones, Revue des Energies Renouvelables Vol. 21 N°1 (2018) 45 – 53

[26] BOUZANA Sanaa, BENZAKHROUFA Kamel, « Diagnostique de Pannes dans un Système Photovoltaïque », Master academique, Universite abdelhamid ibn badis - Mostaganem, 2022

[27] Sendid Merouan, Cheriet Sassi Mokthar, Ben Haoua Med Rida, « Détection des défauts dans les systèmes photovoltaique basée sur les techniques d'intelligence artifivielle », Master academique, Université Echahid Hamma Lakhdar d'El-Oued, 2021.

[28] Belamri Lotfi, « Modélisation et diagnostic des défauts dans les systèmes photovoltaic », Master academique, Universite Kasdi Merbah- Ouargla, 2025.

[29] B. Farida « diagnostic de pannes d'un système pompage photovoltaïque », mémoire de magister. Université Tizi-Ouzou 2012

[30] T. Maamar « Détection et classification de défauts pour un GPV », mémoire de magister. Université de Chleff 2018.

[31] N. Aouchiche « défauts liés aux systèmes photovoltaïques autonomes et techniques de diagnostic », centre développement d'énergie Alger bouzaréah 2018.

[32] B. Abdeslam « étude et diagnostic des défauts fréquents au système photovoltaïque PV par emploi de la caractéristique courant-tension », mémoire de magister. Université Stif 2014

[33] G. B. Alers, "Photovoltaic Failure Analysis: Techniques for Microelectronics and Solar," in PV Module Reliability Workshop, Colorado, USA, 2011.

[34] W. Dallas and et al., "Resonance ultrasonic vibrations for crack detection in photovoltaic silicon wafers," Measurement Science and Technology, vol. 18, p. 852, 2007

[35] 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 ;

[36] D. W. Peter. Fault Detection and Performance Visualisation for a Grid-Connected Photovoltaic Power Plant Using Sensor Data. Master of Engineering Thesis, Stellenbosch University, 2019.

[37] 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.

[38] 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 sustainable energy reviews. Vol 62, pp. 695-709, 2016.

[39] 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

[40] 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.

[41] T. Takashima, J. Yamaguchi, M. Ishida, Fault detection by signal response in PV module strings. in 2008 33rd IEEE Photovoltaic Specialists Conference. 2008. IEEE.

[42] K.-H. Chao, S.-H. Ho and M.-H. Wang, "Modeling and fault diagnosis of a pho-tovoltaic system," Electric Power Systems Research, vol. 78, pp. 97-105, 2008.

[43] A. Drews, A. C. de Keizer, H. G. Beyer, E. Lorenz, J. Betcke, et al., "Monitor-ing and remote failure detection of grid-connected PV systems based on satellite obser-vations," Solar Energy, vol. 81, pp. 548-564, 2007.

[44] S. Stettler, P. Toggweiler, E. Wiemken, W. Heydenreich, A. C. de Keizer, et al., "Failure detection routine for grid-connected PV systems as part of the PVSAT-2 project," in Proceedings of the 20th European Photovoltaic Solar Energy Conference & Exhibition, Barcelona, Spain, 2005, pp.
2490–2493.

[45] Y. Liu, B. Li,Z. Cheng, Research on PV module structure based on fault detection. In Chinese Control and Decision Conference. 2010. IEEE.

[46] 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.

[47] F. Wang, Z. Zhen, Z. Mi, H. Sun, S. Su,G. Yang. Solar irradiance feature extraction and support vector machines based weather status pattern recognition model for short-term photovoltaic power forecasting. Energy Buildings. Vol 86, pp. 427-438, 2015.

[48] M. Hildmann, A. Rohatgi, G. Andersson, Constrained support vector machines for photovoltaic infeed prediction. in 2013 1st IEEE Conference on Technologies for Sustainability (SusTech). 2013. IEEE.

[49] B. Grichting, J. Goette, M. Jacomet, cascaded fuzzy logic based arc fault detection in photovoltaic applications. in 2015 International Conference on Clean Electrical Power (ICCEP). 2015. IEEE.

[50] M. Dhimish, V. Holmes, B. Mehrdadi, M. Dales. Diagnostic method for photovoltaic systems based on six-layer detection algorithm. Electric Power Systems Research. Vol 151, pp. 26-39, 2017.

[51] M. Dhimish, V. Holmes, B. Mehrdadi, M. Dales,P. Mather. Photovoltaic fault detection algorithm based on theoretical curves modelling and fuzzy classification system. Energy. Vol 140, pp. 276- 290, 2017.

[52] K.-H. Chao, M.-S. Yang,C.-P. Hung, Applying a CMAC neural network to a photovoltaic system islanding detection. in 2013 International Conference on Machine Learning and Cybernetics. 2013. IEEE.

[53] F.-J. Lin, K.-C. Lu, T.-H. Ke, B.-H. Yang,Y.-R. Chang. Reactive power control of threephase gridconnected PV system during grid faults using Takagi–Sugeno–Kang probabilistic fuzzy neural network control. IEEE Transactions on Industrial Electronic. Vol 62, pp. 5516-5528, 2015.

[54] L. Bonsignore, M. Davarifar, A. Rabhi, G. M. Tina,A. Elhajjaji. Neural network controlled grid interfaced solar photovoltaic power generation. Energy Procedia. Vol 62, pp. 431-441, 2014

[55] Rezzag Habla Abd Nasser, Gasmi Haidar, Mennad abdelmalek, « Amélioration de l'efficacité du MPPT dans les systèmes PV par l'intégration des ANN », Master academique, Université Echahid Hamma Lakhdar d'El-Oued, 2024.

[56] F. Hassani Et M. I. Noura, « Détection Des Pannes Photovoltaïques Par Les Réseaux De Neurones Probabiliste », Master academique, Université Djilali Bounaama Khemis Miliana, 2017/2018.

[57] M. Khemliche, S. Djeriou, S. Latreche, « Diagnostic de Défauts dans le Système Photovoltaïque par les Réseaux de Neurones Artificiels», Unité de Recherche Appliquée en Energies Renouvelables, Ghardaïa – Algérie, 2012.

[58] CHEGGAGA Nawal, « Diagnostique d'un champ solaire photovoltaïque par réseaux de neurones artificiels », Master academique, Université SAAD DAHLAB de BLIDA, 2018.

[59] Rezzag Habla Abd Nasser, Gasmi Haidar, Mennad abdelmalek, « Amélioration de l'efficacité du MPPT dans les systèmes PV par l'intégration des ANN », Master academique, Université Echahid Hamma Lakhdar d'El-Oued, 2024.

[60] Nacef Ayoub, Mihoub youssouf, « Diagnostic des défauts dans les panneaux photovoltaïques par les Réseaux De Neurones », Master academique, Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj, 2022.

[61] A.E. Toubal et Y. Kacemi, R. Taleb et S. Ladjouzi, «Détection et classification de défauts pour un GPV: Etude comparative entre la méthode de seuillage et réseaux de neurones», Mar 31, 2018.

[62] 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)