



الجمهورية الجزائرية الديمقراطية الشعبية
People's Democratic Republic of Algeria
وزارة التعليم العالي والبحث العلمي
Ministry of Higher Education and Scientific Research
جامعة عبد الحميد ابن باديس مستغانم
Abd El Hamid Ibn Badis University – Mostaganem
كلية العلوم والتكنولوجيا
Faculty of Sciences and Technology
قسم الهندسة الكهربائية
Electrical Engineering Department



MEMOIRE DE FIN D'ETUDES

En vue de l'obtention du diplôme de

Master Académique

Filière : Electrotechnique

Spécialité : Electrotechnique industrielle

Détection de défauts des photovoltaïque par Machine Learning

Présenté par

REZALI Seuf Eddine Cherif


BENAOUAD Abdelmadjid

Soutenu le 28/06/2026 devant le jury composé de :

Président :	BENSTALI Wissam	Professeur	Université de Mostaganem
Examineur :	Missoum Ibrahim	MCA	Université de Mostaganem
Rapporteur :	DAOUD Mohamed	MCA	Université de Mostaganem
Co-Rapporteur :	BENTOUMI Mohamed	MCA	Université de Mostaganem

Année Universitaire

2025/2026



Dédicaces

Je souhaite dédier ce travail à :

A ma chère mère et à mon cher père.

A mes frères, et toute ma famille.

Tous mes amis

A tous mes camarades de classe, promotion 2026.

Je ne peux pas terminer ma dédicace sans rendre hommage au « Dr. Daoud Mohamed » simplement parce qu'il m'a donné une si grande partie de l'énergie nécessaire pour terminer ce travail.

REZALI Seuf Eddine Cherif

Je souhaite dédier ce travail à :

Mes très chers parents.

Mes frères, Mohamed Brahim, Abdelrahmen et Djamel Eddine.

Ma sœur Ahlam.

Ma sœur Nour El Imene, ainsi que ses enfants Mohamed Taha et Naila.

Toutes mes amies.

Tous ceux qui me connaissent de loin ou de près.

Tous ceux qui m'ont aidé.

J'apprécie énormément leur soutien sincère, et leurs encouragements ont été une source précieuse de motivation pour moi tout au long de mon parcours.

BENAOUAD Abdelmadjid

Remerciements

Avant tout, nous remercions ALLAH de nous avoir accordé la volonté, la patience et la santé tout au long de notre parcours académique, ce qui nous a permis de mener à bien ce travail.

Tout d'abord, nous souhaitons adresser nos remerciements à notre directeur de mémoire, Monsieur DAOUD Mohamed, maître de conférences à la faculté des sciences et de la technologie de l'Université Abdelhamid Ibn-Badis de Mostaganem. Nous tenons à profiter de cette occasion pour lui exprimer nos profondes gratitude et nos sincères remerciements pour sa guidance et son soutien. Ses conseils et son expertise ont été d'une valeur inestimable pour nous.

Nous aimerions également remercier Monsieur BENTOUMI Mohamed, maître de conférences à la faculté des sciences et de la technologie de l'Université Abdelhamid Ibn-Badis de Mostaganem, d'avoir accepté de Co-encadreur notre mémoire.

Nous remercions Monsieur BENSTALI Wissam, professeur à l'Université Abdelhamid Ibn-Badis de Mostaganem, pour l'honneur qu'il nous a fait en acceptant de présider le jury. Nous tenons également à exprimer notre gratitude envers l'ensemble des membres du jury, Missoum Ibrahim, pour avoir accepté de faire partie du jury de notre soutenance et pour avoir consacré leur temps ainsi que leur précieuse expertise à l'évaluation de notre mémoire.

Enfin, nous sommes reconnaissants envers nos collègues du laboratoire qui ont joué un rôle essentiel dans cette expérience. Leurs idées, discussions, suggestions et collaborations ont considérablement enrichi notre expérience de recherche.

Abstract

The performance and durability of photovoltaic (PV) systems depend heavily on the efficiency of Maximum Power Point Tracking (MPPT) algorithms, which allow panels to operate at their optimal power despite variations in weather conditions. Among the most widely used methods, the Perturbation and Observation (P&O) algorithm stands out for its simplicity of implementation. However, its performance degrades in the presence of partial shading or rapid variations in irradiance, leading to oscillations around the maximum power point and a slower response time. To address these limitations, this work proposes an approach based on artificial intelligence for diagnosing the condition of photovoltaic panels. The method exploits the electrical quantities of the panels, which are processed and classified using machine learning and deep learning techniques, notably Support Vector Machines (SVM), Artificial Neural Networks (ANN), and Convolutional Neural Networks (CNN). The results show that this approach enables reliable detection of critical faults, such as partial shading and short circuits, thereby contributing to improving the performance of photovoltaic systems and strengthening predictive maintenance strategies.

Keywords: PV systems; MPPT ; P&O ;IA ; ML ; DL ; ANN; CNN; SVM.

الملخص

تعتمد كفاءة الأنظمة الكهروضوئية (PV) وديمومتها بشكل كبير على فعالية خوارزميات تتبع نقطة الطاقة القصوى (MPPT)، والتي تتيح تشغيل الألواح عند قدرتها المثالية على الرغم من تقلبات الظروف الجوية. ومن بين الطرق الأكثر استخداماً، تمتاز خوارزمية "الاضطراب والملاحظة" (P&O) ببساطة تطبيقها. ومع ذلك، تتراجع كفاءتها في وجود ظلال جزئية أو تغيرات سريعة في شدة الإشعاع الشمسي، مما يؤدي إلى حدوث تذبذبات حول نقطة الطاقة القصوى وتباطؤ في سرعة الاستجابة ولمعالجة هذه القيود، يقترح هذا العمل أسلوباً يعتمد على الذكاء الاصطناعي لتشخيص حالة الألواح الكهروضوئية. وتعتمد هذه الطريقة على استغلال الكميات الكهربائية للألواح، ومعالجتها وتصنيفها باستخدام تقنيات التعلم الآلي والتعلم العميق، ولا سيما آلات ناقلات الدعم (SVM)، والشبكات العصبية الاصطناعية (ANN)، والشبكات العصبية الالتفافية (CNN). وتظهر النتائج أن هذا الأسلوب يتيح كشفاً موثقاً للعيوب الحرجة، مثل التظليل الجزئي والدوائر القصيرة (الماس الكهربائي)، مما يساهم في تحسين أداء الأنظمة الكهروضوئية وتعزيز استراتيجيات الصيانة التنبؤية.

الكلمات المفتاحية: الأنظمة PV؛ تتبع نقطة الطاقة القصوى (MPPT)؛ الاضطراب والملاحظة (P&O)؛ الذكاء الاصطناعي؛ التعلم الآلي؛ التعلم العميق؛ الشبكات العصبية الاصطناعية (ANN)؛ الشبكات العصبية الالتفافية (CNN)؛ آلات ناقلات الدعم (SVM)

Résumé

La performance et la durabilité des systèmes photovoltaïques (PV) dépendent fortement de l'efficacité des algorithmes de suivi du point de puissance maximale (MPPT), qui permettent d'exploiter les panneaux à leur puissance optimale malgré les variations des conditions météorologiques. Parmi les méthodes les plus utilisées, l'algorithme Perturbation et Observation (P&O) se distingue par sa simplicité de mise en œuvre. Toutefois, ses performances se dégradent en présence d'ombrage partiel ou de variations rapides de l'irradiance, entraînant des oscillations autour du point de puissance maximale et une réponse plus lente. Pour remédier à ces limitations, ce travail propose une approche basée sur l'intelligence artificielle (IA) pour le diagnostic de l'état des panneaux photovoltaïques. La méthode exploite les grandeurs électriques des panneaux, traitées et classifiées à l'aide de techniques d'apprentissage profond (Deep Learning : DL) d'apprentissage automatique (Machine Learning ; ML) notamment les machines à vecteurs de support (SVM), les réseaux de neurones artificiels (ANN) et les réseaux de neurones convolutifs (CNN). Les résultats montrent que cette approche permet une détection fiable des défauts critiques, tels que l'ombrage partiel et les courts-circuits, contribuant ainsi à améliorer les performances des systèmes photovoltaïques et à renforcer les stratégies de maintenance prédictive.

Mots-clés : Systèmes PV ; MPPT ; P&O ;IA ; ML ; DL ; ANN; CNN; SVM.

Table des matières

Introduction générale	1
Chapitre 1 Généralités sur les systèmes photovoltaïques	3
1.1 Introduction	3
1.2 L'énergie solaire photovoltaïque :	3
1.3 L'effet photovoltaïque	3
1.4 Notions fondamentales des systèmes photovoltaïques	4
1.4.1 Cellule photovoltaïque	4
1.4.2 Système photovoltaïque	5
1.5 La technologie photovoltaïque	6
1.5.1 Architecture et composants des systèmes photovoltaïques	6
1.5.2 Types de systèmes photovoltaïques	10
1.5.3 Performance des systèmes photovoltaïques	12
1.6 Conclusion	16
Chapitre 2 Les défauts des systèmes photovoltaïques et les techniques de diagnostic conventionnelles	17
2.1 Introduction	17
2.2 Classification des défauts dans les systèmes photovoltaïques	17
2.3 Principaux défauts des systèmes photovoltaïques	18
2.3.1 Défauts du générateur photovoltaïque	18
2.3.2 Défaut d'ombrage	19
2.3.3 Défaut de court-circuit	19
2.3.4 Défauts des diodes de by-pass et de la diode anti-retour	19
2.3.5 Défaut de la boîte de jonction	20
2.3.6 Effet de la température sur les performances photovoltaïques	20
2.4 Impact des défauts sur les systèmes photovoltaïques	20
2.5 Méthodes conventionnelles de diagnostic de défauts	21

2.5.1	Méthodes non-électriques	21
2.5.2	Méthodes électriques	24
2.6	Les limites des méthodes conventionnelles	25
2.7	Conclusion	26
Chapitre 3 Techniques de diagnostic des défauts à l'aide d'intelligence artificielle		27
3.1	Introduction	27
3.2	L'intelligence artificielle	27
3.3	Méthodes basées sur des techniques d'intelligence artificielle	27
3.4	Apprentissage automatique (Machine Learning)	28
3.4.1	Définition	28
3.4.2	L'apprentissage supervisé	29
3.4.3	L'apprentissage non supervisé	29
3.4.4	Algorithmes d'apprentissage automatique	30
3.4.4.1	Réseaux de neurones	30
3.4.4.1.1	Principe de fonctionnement du réseau	31
3.4.4.1.2	Architecture des réseaux de neurones artificiels	31
3.4.4.2	Machine à Vecteurs de Support (Support Vector Machine)	32
3.4.4.2.1	Définition	32
3.4.4.2.2	Principe de fonctionnement de l'algorithme SVM	33
3.5	Apprentissage profond (Deep Learning)	34
3.5.1	Définition	34
3.5.2	Réseaux Neuronaux Convolutifs	34
3.5.3	Réseaux Neuronaux Récurrents	34
3.6	Conclusion	35
Chapitre 4 Simulation et résultats		36
4.1	Introduction	36
4.2	L'environnement	36
4.3	Description du système PV utilisé	37

4.4	Simulation	37
4.4.1	Caractéristiques électriques du système PV utilisé	37
4.4.2	Influence d'irradiation	39
4.4.3	Influence de la température	40
4.4.4	Etude des défauts	42
4.4.5	Classification des défauts	47
4.4.6	Les Résultats	48
4.5	Conclusion	60
Conclusion Générale		61
Références bibliographiques		62

Liste des figures

Figure N°	Titre de la figure	Page
Figure 1.1	L'effet photovoltaïque dans un cellule PV cristalline [9]	04
Figure 1.2	Structure et principe de fonctionnement d'une cellule photovoltaïque.	05
Figure 1.3	Schéma général d'un système photovoltaïque.	06
Figure 1.4	Schéma d'installation du système photovoltaïque.	07
Figure 1.5	Composantes d'un champ photovoltaïques.	09
Figure 1.6	Système photovoltaïque autonome [4].	11
Figure 1.7	Système photovoltaïque connectés au réseau [4].	12
Figure 1.8	Système photovoltaïque hybrides [4].	13
Figure 1.9	Modèle équivalent d'une cellule solaire.	14
Figure 1.10	Caractéristiques électrique I-V et P-V d'un panneau photovoltaïque.	16
Figure 2.1	Schéma bloc de cellule et de champ PV avec la diode de by-pass et anti-retour, respectivement [18].	21
Figure 2.2	Classification des méthodes conventionnelles de détection des défauts [18].	22
Figure 2.3	Détecteur de défauts ultrasonores.	23
Figure 2.4	Techniques de thermographie infrarouge.	24
Figure 2.5	Techniques de l'inspection visuelle [9].	24
Figure 2.6	Techniques de la réflectométrie	26
Figure 3.1	Méthodes basées sur des techniques d'intelligence artificielle.	29
Figure 3.2	Types d'apprentissage de la méthode d'apprentissage automatique.	30
Figure 3.3	Schéma d'apprentissage supervisé.	30
Figure 3.4	Schéma d'apprentissage non supervisé.	31
Figure 3.5	Principe de fonctionnement du réseau de Neurones. [12]	32
Figure 3.6	Architecture des réseaux de neurones artificiels.	33
Figure 3.7	Machine à Vecteurs de Support (SVM).	34
Figure 3.8	Principe de fonctionnement de l'algorithme SVM.	35
Figure 4.1	Système PV utilisé.	38
Figure 4.2	Caractéristique $I=f(V)$ et $P=f(V)$ du système PV utilisé.	39
Figure 4.3	Caractéristique $P(V)$ pour différents niveaux de L'irradiation ($T=25^{\circ}C$).	40
Figure 4.4	Caractéristique $I=f(V)$ pour différents niveaux de L'irradiation ($T=25^{\circ}C$).	40
Figure 4.5	Caractéristique $P(V)$ pour différentes température ($G=1000W/m^2$).	41
Figure 4.6	Caractéristique $I(V)$ pour différentes température ($G=1000W/m^2$).	41
Figure 4.7	Caractéristiques ($I=F(V)$) ($P=F(V)$) pour Défaut de l'ombrage 1 panneau	42
Figure 4.8	Caractéristiques $I=f(V)$ et $P=f(V)$ pour Défaut de l'ombrage 2 panneaux	43
Figure 4.9	Caractéristiques ($P=F(V)$) de Défaut de court-circuit.	43

Figure 4.10	Caractéristiques ($I=F(V)$) de Défaut de court-circuit.	44
Figure 4.11	La matrice de confusion pour $C=5$	46
Figure 4.12	La matrice de confusion pour $C=10,20,30$ et 40	47
Figure 4.13	La matrice de confusion pour $N=5$.	49
Figure 4.14	La matrice de confusion pour $N=10,20,30$ et 40	50
Figure 4.15	Les matrices de confusion de SVM et RN	51
Figure 4.16	Les matrices de confusion de SVM et RN pour $M=1504$	52
Figure 4.17	Les matrices de confusion de SVM et RN	53
Figure 4.18	La matrice de confusion de CNN pour $M=257$.	54
Figure 4.19	la matrice de confusion de CNN pour $M=514$.	55
Figure 4.20	La matrice de confusion de CNN pour $M=771$.	55
Figure 4.21	La matrice de confusion de CNN pour $N=44$.	57
Figure 4.22	La matrice de confusion de CNN $N=54$.	58
Figure 4.23	La matrice de confusion de CNN $N=64$.	59

Liste des tableaux

Tableau N°	Titre du tableau	Page
Tableau 4.1	Les caractéristiques du module photovoltaïque utilisé.	39
Tableau 4.2	Les cas opérationnels avec leurs codes.	45
Tableau 4.3	Synthèse de résultats (SVM).	48
Tableau 4.4	Synthèse de résultats (RN).	50
Tableau 4.5	L'accuracy global de chaque classe M=752.	52
Tableau 4.6	Synthèse Global de résultats SVM et RN.	53
Tableau 4.7	Synthèse Global de résultats CNN de (M).	56
Tableau 4.8	Synthèse Global de résultats	58

Introduction générale

La croissance démographique, l'industrialisation et l'augmentation continue de la demande énergétique imposent le développement de sources d'énergie durables. Face aux limites des combustibles fossiles et à leurs impacts environnementaux, les énergies renouvelables occupent une place centrale dans la transition énergétique. Parmi elles, l'énergie solaire photovoltaïque se distingue par son abondance, son caractère propre et sa capacité à produire de l'électricité sans émissions directes de gaz à effet de serre [1].

Grâce aux avancées technologiques, les systèmes photovoltaïques connaissent un développement rapide et une intégration croissante dans les réseaux électriques. Toutefois, leur performance peut être affectée par différents défauts liés aux conditions environnementales, au vieillissement des composants, aux défauts de fabrication ou aux contraintes d'exploitation. Ces défaillances entraînent une baisse de la production, une dégradation des équipements et peuvent compromettre la sécurité des installations. Il est donc essentiel de mettre en œuvre des méthodes de détection et de diagnostic fiables afin d'assurer une maintenance efficace et d'améliorer la disponibilité des systèmes photovoltaïques [2,4].

Dans ce contexte, l'intelligence artificielle constitue une solution prometteuse pour la surveillance des installations photovoltaïques. Les techniques d'apprentissage automatique et d'apprentissage profond permettent d'analyser les données électriques, de reconnaître des schémas complexes et de détecter automatiquement les anomalies avec une grande précision [5].

Ce mémoire est consacré à la détection et à la classification des défauts photovoltaïques à l'aide de techniques d'intelligence artificielle. L'objectif est d'évaluer les performances de différentes approches d'apprentissage, notamment les machines à vecteurs de support (SVM), les réseaux de neurones artificiels (ANN) et les réseaux de neurones convolutifs (CNN), afin d'identifier la méthode la plus performante pour améliorer la fiabilité des systèmes photovoltaïques.

Le mémoire est organisé en quatre chapitres. Le premier présente les principes des systèmes photovoltaïques, le deuxième décrit les principaux défauts et les méthodes classiques de diagnostic, le troisième introduit les techniques d'intelligence artificielle appliquées au diagnostic, tandis que le quatrième expose la méthodologie adoptée, les résultats expérimentaux et leur analyse comparative. Enfin, une conclusion générale synthétise les principaux résultats et les perspectives de ce travail.

Chapitre 1

Généralités sur les systèmes photovoltaïques

1.1 Introduction

L'énergie solaire photovoltaïque représente une alternative durable aux sources d'énergie conventionnelles grâce à sa capacité à produire de l'électricité de manière propre et renouvelable. Ce chapitre présente les notions fondamentales relatives aux systèmes photovoltaïques, en mettant l'accent sur leur évolution historique, leurs principaux composants ainsi que les différents paramètres influençant leurs performances et leur rendement.

1.2 L'énergie solaire photovoltaïque :

L'énergie solaire photovoltaïque est une forme d'énergie renouvelable obtenue par la conversion directe du rayonnement solaire en électricité. Cette conversion repose sur l'effet photovoltaïque, phénomène découvert au XIX^e siècle, qui permet à une cellule photovoltaïque constituée de matériaux semi-conducteurs de produire une tension électrique sous l'action de la lumière [6]. En raison de son abondance, de sa disponibilité et de son faible impact environnemental, l'énergie solaire photovoltaïque est aujourd'hui considérée comme l'une des solutions les plus prometteuses pour répondre aux défis énergétiques et environnementaux actuels.

1.3 L'effet photovoltaïque

L'effet photovoltaïque correspond au processus de conversion directe de l'énergie lumineuse (photons) en énergie électrique. Ce phénomène a été observé pour la première fois par *Edmond Becquerel* en 1839, qui a mis en évidence l'apparition d'une tension électrique aux bornes d'un système électrochimique exposé à la lumière [6].

Le principe de l'effet photovoltaïque repose sur l'interaction entre les photons incidents et les électrons d'un matériau semi-conducteur. Lorsque l'énergie d'un photon est supérieure ou égale à l'énergie de bande interdite (gap énergétique E_g) du matériau, il peut exciter un électron de la bande de valence vers la bande de conduction, laissant derrière lui un trou. Cette interaction génère ainsi des paires électron-trou responsables de la conduction électrique. Les photons dont l'énergie est supérieure à E_g contribuent à la génération de porteurs de charge, tandis que l'excès d'énergie au-delà du gap est dissipé sous forme de vibrations du réseau cristallin (phonons), ce qui se traduit par des pertes thermiques. À l'inverse, les photons dont l'énergie est inférieure à E_g ne sont pas absorbés et ne participent pas au processus de conversion photovoltaïque [7,8].




Figure 1.1 – L'effet photovoltaïque dans une cellule PV cristalline [9].

1.4 Notions fondamentales des systèmes photovoltaïques

Un système photovoltaïque repose sur la conversion de l'énergie solaire en énergie électrique à travers plusieurs niveaux d'organisation : cellule, module et système complet. Chaque niveau joue un rôle spécifique dans la production et l'adaptation de l'énergie électrique aux besoins des applications [10].

1.4.1 Cellule photovoltaïque

La cellule photovoltaïque constitue l'unité élémentaire de conversion de l'énergie solaire. Elle est basée sur une jonction PN réalisée dans un matériau semi-conducteur, généralement le silicium. Sous l'effet du rayonnement solaire, l'absorption des photons génère des paires

électron-trou. Ces charges sont séparées par le champ électrique interne de la jonction, produisant ainsi une tension électrique et un courant continu lorsqu'un circuit externe est connecté. La cellule est basée sur une jonction PN, composée de deux couches dopées différemment : une couche de type P et une couche de type N. Grâce à cette structure, elle agit comme un convertisseur direct de l'énergie lumineuse en énergie électrique lorsqu'elle est exposée au rayonnement solaire, se comportant ainsi comme une source de courant continu [7].




Figure 1.2 – Structure et principe de fonctionnement d'une cellule photovoltaïque.

1.4.2 Système photovoltaïque

Un module photovoltaïque seul ne peut pas répondre directement aux besoins énergétiques des applications courantes. L'énergie produite est de type courant continu (DC) et varie en fonction de l'ensoleillement. Elle doit donc être adaptée, stockée ou convertie selon les exigences de la charge. Un système photovoltaïque regroupe l'ensemble des composants nécessaires à la production, la conversion, la gestion et éventuellement le stockage de l'énergie électrique issue du rayonnement solaire. Il comprend les modules photovoltaïques, les dispositifs de régulation, les onduleurs, ainsi que les systèmes de stockage d'énergie. Les configurations des

systèmes photovoltaïques varient en fonction des besoins énergétiques, des conditions d'installation et des contraintes économiques [7].




Figure 1.3 – Schéma général d'un système photovoltaïque.

1.5 La technologie photovoltaïque

La technologie photovoltaïque permet la conversion directe de l'énergie solaire en énergie électrique grâce à des matériaux semi-conducteurs. Lorsqu'un semi-conducteur est exposé au rayonnement solaire, l'absorption des photons génère des porteurs de charge (électrons et trous) qui sont séparés par un champ électrique interne, produisant ainsi un courant électrique continu exploitable [1].

1.5.1 Architecture et composants des systèmes photovoltaïques

Un système photovoltaïque comprend l'ensemble des équipements nécessaires à la production, la conversion et la gestion de l'énergie électrique. Il inclut les modules photovoltaïques, les convertisseurs de puissance, les systèmes de stockage et les dispositifs de protection, comme illustré dans la figure ci-dessous [12].




Figure 1.4 – Schéma d'installation du système photovoltaïque.

L'énergie produite par un système photovoltaïque est de nature continue et dépend fortement des conditions d'ensoleillement. Cela nécessite l'utilisation de dispositifs spécifiques pour adapter cette énergie et permettre l'alimentation efficace des charges électriques [13]. Les composants d'un système photovoltaïque varient en fonction de l'application, qu'il s'agisse d'une habitation isolée ou connectée à un réseau, avec ou sans batteries ou convertisseurs de puissance. Cependant, un système photovoltaïque comprend généralement les éléments suivants :

1.5.1.1 Module photovoltaïque

Un module photovoltaïque, également appelé photo-générateur ou panneau solaire, est un circuit électrique constitué d'un assemblage de plusieurs cellules photovoltaïques. Ces cellules peuvent être connectées en série, en parallèle ou en série-parallèle afin d'adapter la tension et le courant de sortie aux applications pratiques. L'association en série est la plus couramment utilisée, car elle permet d'augmenter la tension de sortie du module, tandis que la connexion en parallèle augmente le courant. Les cellules sont encapsulées dans une structure protectrice assurant leur durabilité face aux conditions environnementales [13].

$$\begin{cases} I_M = I_c \\ V_M = N_{CS} \times V_c \end{cases} \quad (1.1)$$

Où : I_c, I_M Sont les courants fournis par la cellule PV et le module PV. V_c, V_M Sont les tensions aux bornes de la cellule PV et du module PV. N_{CS} Est le nombre de cellule en série dans un module PV.

1.5.1.2 String photovoltaïque

Un string photovoltaïque est une association de modules photovoltaïques en série. Cette configuration permet de générer une tension suffisante et adaptée aux exigences de l'onduleur, facilitant ainsi la conversion de l'énergie solaire en électricité utilisable [13].

$$\begin{cases} I_{St} = I_M \\ V_{St} = N_{MS} \times V_M \end{cases} \quad (1.2)$$

Où : I_{St}, I_M Sont les courants du string et du module PV. V_{St}, V_M Sont les tensions aux bornes du string et du module PV. N_{MS} Est le nombre de cellule en série dans un string.

1.5.1.3 Champ photovoltaïque

De la même manière que l'association en série des modules permet d'augmenter la tension, l'association en parallèle des strings permet d'augmenter le courant. Cette configuration permet d'adapter la valeur du courant à la plage d'entrée de l'onduleur. L'ensemble des strings connectés en parallèle constitue ce que l'on appelle un champ photovoltaïque [7,13].

$$\begin{cases} I_G = N_{SP} \times I_{St} \\ V_G = V_{St} \end{cases} \quad (1.3)$$

En totale on aura :

$$\begin{cases} I_G = N_{SP} \times I_c \\ V_G = N_{MS} \times N_{CS} \times V_c \end{cases} \quad (1.4)$$

Où : I_{St}, I_G Sont les courants du string et du générateur PV. V_{St}, V_G Sont les tensions aux bornes du string et du générateur PV. N_{SP} Est le nombre de string en parallèle dans un générateur PV.




Figure 1.5 – Composantes d'un champ photovoltaïques.

1.5.1.4 Convertisseur

Les systèmes photovoltaïques utilisent généralement deux types de convertisseurs pour optimiser et exploiter l'énergie produite par les panneaux solaires. Ces deux convertisseurs fonctionnent de manière complémentaire [14].

- Le convertisseur continu-continu (DC/DC) : Ce dispositif est conçu pour rechercher et suivre le point de puissance maximale PPM (Maximum Power Point) du champ photovoltaïque. Il est équipé d'un système de commande appelé MPPT (Maximum Power Point Tracker), qui ajuste en permanence la tension et le courant pour maximiser la puissance extraite des panneaux solaires.
- Le convertisseur continu-alternatif (DC/AC) (ou onduleur) : Ce convertisseur a pour rôle de transformer l'énergie en courant continu (DC), extraite par le convertisseur DC/DC, en courant alternatif (AC). Ce courant alternatif est adapté en tension, en phase et en fréquence pour être injecté dans le réseau électrique ou utilisé par des appareils domestiques. L'onduleur est donc un élément clé pour rendre l'énergie photovoltaïque compatible avec les besoins du réseau ou des équipements électriques.

1.5.1.5 Régulateurs de charge

Les contrôleurs, également appelés régulateurs de charge, sont des dispositifs électroniques qui contrôlent la tension et le courant fournis par les panneaux photovoltaïques aux

batteries. Ils assurent une gestion optimale des cycles de charge et de décharge afin de maintenir les accumulateurs dans des conditions de fonctionnement appropriées. Ils limitent le courant entrant et sortant des batteries, préviennent les surcharges et les décharges excessives, et protègent le système contre les surtensions. Leur utilisation contribue à améliorer les performances et à prolonger la durée de vie des batteries [15].

1.5.1.6 Batteries et stockage

Dans les systèmes photovoltaïques autonomes, le stockage de l'énergie électrique est indispensable pour garantir l'alimentation des charges en l'absence ou en cas d'insuffisance d'ensoleillement. Différentes technologies de batteries sont utilisées selon les exigences de l'application. Parmi elles, les batteries au plomb demeurent les plus répandues grâce à leur coût relativement faible, leur fiabilité et leur robustesse dans les installations photovoltaïques autonomes [8].

1.5.1.7 Dispositifs de Protection

Les dispositifs de protection jouent un rôle essentiel dans la sécurité et la fiabilité des systèmes photovoltaïques. Ils permettent de protéger l'installation contre les défauts électriques, les surintensités et les courants inverses. Parmi les principaux équipements utilisés figurent les diodes de bypass, qui limitent les effets de l'ombrage sur les cellules, les diodes anti-retour, qui empêchent les courants inverses entre chaînes photovoltaïques, ainsi que les fusibles et les disjoncteurs DC, qui assurent la protection contre les courts-circuits et les surintensités tout en renforçant la sécurité de l'installation.

1.5.2 Types de systèmes photovoltaïques

Les systèmes photovoltaïques se divisent en trois catégories principales : systèmes autonomes, systèmes connectés au réseau et systèmes hybrides. Le choix dépend des besoins énergétiques, du site d'installation et du budget.

1.5.2.1 Système autonome

Un système photovoltaïque autonome fonctionne indépendamment du réseau électrique. Il est conçu pour assurer l'alimentation des charges dans les zones isolées ou non raccordées au

réseau. L'énergie produite par les panneaux photovoltaïques peut être utilisée directement pour alimenter les équipements électriques (éclairage, pompage, etc.) ou être stockée dans des batteries afin d'être disponible lorsque l'ensoleillement est insuffisant.




Figure 1.6 – Système photovoltaïque autonome [4].

1.5.2.2 Systèmes connectés au réseau

Les systèmes photovoltaïques connectés au réseau, ou interactifs, fonctionnent en parallèle avec le réseau électrique public. Leur élément principal est l'onduleur, qui transforme le courant continu produit par les panneaux photovoltaïques en courant alternatif compatible avec les exigences de tension et de qualité du réseau. Ces systèmes injectent l'énergie produite directement dans le réseau et s'arrêtent automatiquement en cas de coupure, afin d'assurer la sécurité des installations et du personnel.




Figure 1.7 – Système photovoltaïque connectés au réseau [4].

1.5.2.3 Systèmes hybrides

Les systèmes d'énergie solaire hybride associent l'énergie photovoltaïque à une autre source de production, comme l'éolien, afin d'améliorer la continuité de l'alimentation. Dans les systèmes éolien-solaire, les deux technologies se complètent, car leurs périodes de production maximale n'interviennent pas aux mêmes moments de la journée ni de l'année. Cette complémentarité permet d'obtenir une production électrique plus stable et moins intermittente que celle de chaque source prise séparément.




Figure 1.8 – Système photovoltaïque hybrides [4].

1.5.3 Performance des systèmes photovoltaïques

Les performances d'un système photovoltaïque dépendent principalement de l'irradiation solaire, de la température et des pertes électriques. Le rendement est fortement influencé par les conditions environnementales et les caractéristiques des composants.

1.5.3.1 Modèle d'une cellule solaire

La modélisation d'une cellule solaire permet d'analyser et d'évaluer les performances d'un module photovoltaïque de manière proche de la réalité. Elle repose sur un modèle

mathématique basé sur le circuit équivalent de la cellule. Le modèle à une diode est le plus couramment utilisé, car il offre une représentation simple et efficace du comportement réel de la cellule. Ce circuit équivalent est constitué d'une source de courant dépendant de l'irradiation solaire, en parallèle avec une diode. Il intègre également une résistance shunt R_{sh} représentant les courants de fuite, ainsi qu'une résistance série R_s qui modélise les pertes internes liées au transport du courant et aux connexions entre cellules.




Figure 1.9 – Modèle équivalent d'une cellule solaire.

Le courant de sortie d'une cellule PV est obtenu en appliquant la loi des nœuds de Kirchhoff au circuit équivalent représentée sur la figure précédente :

$$I_{ph} = I_d + I_{sh} + I \quad (1.5)$$

Le courant traversant la diode s'exprime par :

$$I_d = I_0 \left[\exp \left(\frac{V + R_s I}{a V_t} \right) - 1 \right] \quad (1.6)$$

Le courant circulant dans la résistance shunt R_{sh} est donné par :

$$I_{sh} = \left(\frac{V + R_s I}{R_{sh}} \right) \quad (1.7)$$

En combinant les équations (1), (2) et (3), on obtient l'expression du courant de sortie I :

$$I = I_{ph} - I_d - I_{sh} \quad (1.8)$$

soit :

$$I = I_{ph} - I_0 \left[\exp \left(\frac{V + R_s I}{a V_t} \right) - 1 \right] - \left(\frac{V + R_s I}{R_{sh}} \right) \quad (1.9)$$

avec la tension thermique définie par :

$$V_t = \left(\frac{N_s K_B T}{q} \right) \quad (1.10)$$

Enfin, la puissance délivrée par la cellule photovoltaïque est donnée par :

$$P = I.V = \left[I_{ph} - I_0 \left[\exp \left(\frac{V + R_s I}{a V_t} \right) - 1 \right] - \left(\frac{V + R_s I}{R_{sh}} \right) \right] V \quad (1.11)$$

avec :

I	Courant de sortie du cellule PV en ampère (A).	I_{ph}	Photo-courant généré.
V	Tension aux bornes de la cellule PV en volt (V).	I_0	Courant de saturation.
R_{sh}	Résistances parallèle (shunt) en ohm (Ω).	a	Facteur d'idéalité de la diode.
V_t	Tension thermique de la cellule PV.	N_s	Nombre de cellule par module.
K_B	Constante de Boltzmann $1.380 * 10^{-23} (J.K^{-1})$.	T	Température en Kelvin (K).
q	Charge de l'électron $1.602 * 10^{-19} (C)$.	R_s	Résistances série en ohm (Ω).

1.5.3.2 Caractéristique électrique d'un panneau photovoltaïque

Les propriétés électriques d'une cellule photovoltaïque sont généralement décrites à travers la relation courant-tension (I-V), ainsi que la courbe puissance-tension (P-V), obtenues dans des conditions constantes d'irradiation et de température. Ces courbes, illustrées par la figure 1-14, permettent de mettre en évidence le comportement électrique du panneau solaire. La caractéristique I-V se divise en deux zones principales : une région à droite assimilée à une source de tension, dont l'extrémité correspond à la tension de circuit ouvert, et une région à gauche assimilée à une source de courant, dont l'extrémité correspond au courant de court-circuit. Le point de fonctionnement optimal, appelé point de puissance maximale (PPM), se situe au niveau du coude de la courbe.

Le courant de court-circuit I_{cc} correspond au courant maximal délivré par la cellule lorsque la tension est nulle ($V = 0$). Il est proportionnel à l'irradiation solaire reçue. La tension de circuit ouvert V_{co} est la tension mesurée aux bornes de la cellule lorsque le courant est nul

($I = 0$). Enfin, la puissance maximale est obtenue au point de puissance maximale (PPM), où le produit $P = I \times V$ est optimal.




Figure 1.10 – Caractéristiques électrique I-V et P-V d'un panneau photovoltaïque.

1.5.3.3 Facteur de forme

Le facteur de forme (FF) permet d'évaluer le caractère rectangulaire de la courbe I-V et constitue un indicateur de la qualité électrique d'une cellule photovoltaïque. Il est défini comme le rapport entre la puissance maximale délivrée par la cellule et le produit de la tension de circuit ouvert V_{co} et du courant de court-circuit I_{cc} , soit :

$$FF = \frac{P_{PPM}}{V_{co} \times I_{cc}} = \frac{V_{PPM} \times I_{PPM}}{V_{co} \times I_{cc}} \quad (1.12)$$

1.5.3.4 Le rendement

Le rendement énergétique (η) d'une cellule photovoltaïque correspond au rendement de conversion de la puissance. Il est défini comme le rapport entre la puissance électrique maximale produite par la cellule et la puissance du rayonnement solaire incident reçu par sa surface, selon l'expression suivante :

$$\eta = \frac{P_{PPM}}{P_{inc}} = \frac{V_{PPM} \times I_{PPM}}{S \times E} \quad (1.13)$$

Avec : S est surface de la cellule ou du module (m^2) et E est l'éclairement (W/m^2)

1.5.3.5 Approche du point de puissance maximal MPPT

La puissance fournie par un générateur photovoltaïque dépend fortement des conditions d'irradiation et de température, ce qui modifie en permanence son point de fonctionnement optimal. Pour exploiter au mieux l'énergie solaire, il est donc nécessaire d'utiliser une technique de suivi du point de puissance maximale (MPPT), dont l'objectif est de maintenir le système au voisinage du point de puissance maximale (PPM) malgré les variations climatiques.

Parmi les différentes méthodes MPPT, l'algorithme Perturb & Observe (P&O) est le plus répandu en raison de sa simplicité, de son faible coût et de sa facilité d'implémentation. Il utilise généralement la mesure de la tension du générateur pour ajuster le point de fonctionnement. Bien qu'il présente de légères oscillations autour du PPM à l'état stable, il permet d'augmenter l'énergie récupérée de 20 % à 40 % par rapport à un système fonctionnant sans suivi du point de puissance maximale, notamment sous des conditions d'ensoleillement variables.

1.6 Conclusion

Ce chapitre a présenté les principes fondamentaux des systèmes photovoltaïques, notamment leur fonctionnement, leurs principaux composants, leurs caractéristiques électriques et leurs performances. Ces notions constituent une base indispensable pour comprendre le comportement des installations photovoltaïques. Le chapitre suivant est consacré à l'étude des principaux défauts pouvant affecter ces systèmes ainsi qu'à leur impact sur les performances énergétiques.

Chapitre 2

Les défauts des systèmes photovoltaïques et les techniques de diagnostic conventionnelles

2.1 Introduction

Les systèmes photovoltaïques peuvent être affectés par différents défauts au cours de leur fonctionnement. Ces anomalies, causées par des facteurs environnementaux, des dégradations internes ou des erreurs d'installation, entraînent une diminution des performances énergétiques et peuvent compromettre la sécurité ainsi que la fiabilité de l'installation. La détection précoce de ces défauts constitue donc un enjeu majeur pour assurer un fonctionnement optimal et une maintenance efficace des systèmes photovoltaïques. Ce chapitre présente les principaux défauts rencontrés dans les installations photovoltaïques. Une classification des défauts est d'abord proposée, suivie d'une analyse de leurs impacts sur les performances du système. Enfin, les méthodes conventionnelles de détection et de diagnostic sont présentées.

2.2 Classification des défauts dans les systèmes photovoltaïques

Les systèmes photovoltaïques sont soumis à diverses contraintes environnementales et opérationnelles susceptibles de provoquer des défauts affectant leur rendement et leur fiabilité. Ces défauts peuvent être classés selon leur origine en défauts externes, tels que l'ombrage et l'encrassement, et en défauts internes, liés à la dégradation des composants ou à des anomalies électriques. Une autre classification repose sur le niveau de l'installation concerné. Les défauts peuvent ainsi apparaître au niveau de la cellule, du module, du string ou de l'ensemble du système photovoltaïque. Cette classification facilite l'identification des défauts et le choix des méthodes de diagnostic appropriées.

Le Tableau 2.1 présente les principaux défauts rencontrés dans les systèmes photovoltaïques ainsi que leur classification selon leur niveau d'apparition.

Tableau 2.1 – : Classification des défauts d'un GPV.[16,17].

Le niveau de défaut	Le composant	Le défaut
Cellule	Cellule	1. La résistance série R_s. 2. La résistance parallèle R_p 3. Courant I_{ph} 4. La température T
Groupe	Diode By-pass	1. Court-circuit. 2. Circuit ouvert. 3. Impédance Z quelconque. 4. Inversion de la polarité.
Module	Module	1. Module court-circuité. 2. Module connecté en parallèle avec une impédance Z. 3. Inversion de la polarité du module.
String	Les Connexions	1. Court-circuit. 2. Circuit-ouvert. 3. Mauvais câblage. 4. Détérioration des connexions.
Champ	Diode Anti-retour	1. Court-circuit. 2. Circuit ouvert. 3. Impédance Z quelconque. 4. Inversion de la polarité.

2.3 Principaux défauts des systèmes photovoltaïques

Parmi les nombreux défauts susceptibles d'affecter les systèmes photovoltaïques, cette étude se concentre sur les plus fréquents en raison de leur impact significatif sur les performances énergétiques, la fiabilité et la sécurité de l'installation.

2.3.1 Défauts du générateur photovoltaïque

Le générateur photovoltaïque est soumis à diverses contraintes environnementales et électriques pouvant entraîner une dégradation progressive de ses performances. Les principaux défauts observés sont les microfissures des cellules, les points chauds (hot-spots), la délamination,

la corrosion des interconnexions, les défauts d'encapsulation et les phénomènes de mismatch entre modules. Ces anomalies provoquent généralement une diminution du rendement et une accélération du vieillissement des modules.

2.3.2 Défaut d'ombrage

L'ombrage correspond à la réduction partielle ou totale du rayonnement solaire incident sur les modules photovoltaïques. Il peut être causé par des obstacles naturels, des structures avoisinantes ou l'accumulation de poussière et de saletés. L'ombrage partiel est particulièrement critique puisqu'il peut provoquer des déséquilibres de courant, l'apparition de points chauds et une réduction importante de la puissance produite [17].

2.3.3 Défaut de court-circuit

Le défaut de court-circuit se produit lorsque les conducteurs positif et négatif sont connectés directement sans résistance. Cette anomalie peut résulter d'un défaut d'isolation, d'une erreur de câblage, de la corrosion ou d'une dégradation des modules. Elle engendre des courants élevés susceptibles d'endommager les équipements et de compromettre la sécurité du système.

2.3.4 Défauts des diodes de by-pass et de la diode anti-retour

Les diodes de by-pass et anti-retour assurent respectivement la protection des modules contre les effets de l'ombrage et les courants inverses. Leurs principaux modes de défaillance sont le court-circuit, le circuit ouvert, l'inversion de polarité et la dégradation de leurs caractéristiques électriques. Ces défauts peuvent entraîner des pertes de puissance, une surchauffe des modules ou une perte de protection du générateur photovoltaïque.




Figure 2.1 – Schéma bloc de cellule et de champ PV avec la diode de by-pass et anti-retour, respectivement [18].

2.3.5 Défaut de la boîte de jonction

La boîte de jonction assure la connexion électrique et la protection des conducteurs des modules photovoltaïques. Les défauts les plus fréquents sont la corrosion des contacts, les défauts d'isolation, les infiltrations d'humidité et les mauvaises connexions. Ces anomalies augmentent les pertes électriques et peuvent provoquer des échauffements localisés.

2.3.6 Effet de la température sur les performances photovoltaïques

La température affecte directement les performances électriques des modules photovoltaïques. Une augmentation de la température entraîne une diminution de la tension de circuit ouvert et de la puissance maximale délivrée par le module. Par conséquent, le rendement global du système diminue lorsque la température de fonctionnement devient élevée.

2.4 Impact des défauts sur les systèmes photovoltaïques

Les défauts dans les systèmes photovoltaïques provoquent une dégradation des performances énergétiques, se traduisant par une réduction de la puissance produite et du rendement global. Certains défauts critiques, tels que les points chauds, les défauts d'isolement et

les arcs électriques, peuvent également compromettre la sécurité de l'installation. De plus, ces anomalies accélèrent le vieillissement des composants et augmentent les coûts de maintenance en raison des pertes de production et des interventions correctives. Ces impacts soulignent la nécessité d'une détection précoce et fiable des défauts afin de garantir la performance et la sécurité des systèmes photovoltaïques.

2.5 Méthodes conventionnelles de diagnostic de défauts

Le diagnostic des systèmes photovoltaïques repose sur la surveillance des paramètres de fonctionnement afin d'identifier précocement les défauts et de limiter les pertes énergétiques. Ces méthodes permettent d'évaluer l'état de santé du générateur PV et de localiser les anomalies. Elles sont généralement classées en deux catégories principales : les méthodes non électriques et les méthodes électriques. La Figure 2.2 montre une classification simple de ces méthodes.




Figure 2.2 – Classification des méthodes conventionnelles de détection des défauts [18].

2.5.1 Méthodes non-électriques

Les méthodes non électriques regroupent les techniques de contrôle non destructif permettant la détection des défauts physiques et structurels des modules photovoltaïques.

2.5.1.1 Techniques des vibrations ultrasonores

La technique des vibrations ultrasoniques résonantes (RUV) est une méthode de contrôle non destructif qui utilise des ondes ultrasonores pour évaluer l'intégrité des modules photovoltaïques. En analysant les fréquences de résonance et le temps de propagation des ondes, elle permet de détecter et de localiser des défauts internes tels que les microfissures, les défauts de soudure, les inclusions et les vides, contribuant ainsi à la maintenance prédictive et au contrôle qualité des systèmes photovoltaïque



Figure 2.3 – Détecteur de défauts ultrasonores.

2.5.1.2 Thermographie infrarouge

La thermographie infrarouge (TIR) est une méthode de contrôle non destructif qui détecte les défauts des systèmes photovoltaïques en analysant la répartition de température des modules à l'aide de caméras thermiques. Rapide et sans contact, elle permet d'identifier efficacement les points chauds, les défauts de soudure, la délamination, les microfissures et les cellules endommagées, facilitant ainsi la surveillance et la maintenance prédictive des installations.



Figure 2.4 – Techniques de thermographie infrarouge.

2.5.1.3 Technique d'inspection visuelle

L'inspection visuelle constitue la méthode la plus simple de diagnostic. Elle permet de détecter les défauts externes visibles tels que les fissures, le brunissement des cellules et la dégradation du verre ou de l'encapsulant. Bien qu'elle soit limitée, elle reste une étape préliminaire essentielle [9].




Figure 2.5 – Techniques de l'inspection visuelle [9].

2.5.2 Méthodes électriques

Les méthodes électriques reposent sur l'analyse des grandeurs électriques (courant, tension et puissance) afin de surveiller les performances des systèmes photovoltaïques et de détecter les anomalies de fonctionnement [19].

2.5.2.1 Analyse de la puissance

Cette méthode compare la puissance réelle produite à la puissance théorique estimée à partir de l'irradiance et de la température. Les écarts observés permettent de détecter des défauts tels que la dégradation des modules, l'ombrage, les pertes dans les câbles ou les dysfonctionnements des convertisseurs et des algorithmes MPPT. Sa simplicité en fait une solution adaptée à la surveillance continue des installations [19].

2.5.2.2 Analyse des caractéristiques courant–tension

L'analyse de la courbe I–V, signature électrique du générateur photovoltaïque, permet d'évaluer son état de santé. Les déformations de cette courbe révèlent des défauts tels que l'augmentation de la résistance série, les microfissures, les points chauds, le vieillissement, l'ombrage partiel ou les défauts de désadaptation (mismatch). Cette méthode fournit un diagnostic précis des performances électriques [19].

2.5.2.3 Analyse du point de fonctionnement

Cette méthode consiste à suivre le point de puissance maximale (MPPT) et à comparer le point de fonctionnement réel au point attendu. Les écarts de tension, de courant ou de puissance permettent d'identifier des modules défectueux, des phénomènes d'ombrage, une dégradation des performances ou des anomalies du système MPPT. Elle est particulièrement adaptée au suivi en temps réel des installations [19].

2.5.2.4 Réflectométrie

La réflectométrie consiste à injecter un signal électrique dans les câbles et à analyser les signaux réfléchis afin de localiser les discontinuités. Elle permet de détecter avec précision les circuits ouverts, les courts-circuits, les défauts d'isolation, les connexions dégradées et les

variations d'impédance, facilitant ainsi la maintenance des réseaux de câblage photovoltaïques [19].



Figure 2.6 – Techniques de la réflectométrie.

2.6 Les limites des méthodes conventionnelles

Les méthodes conventionnelles de détection des défauts dans les systèmes photovoltaïques, bien qu'efficaces pour plusieurs cas, présentent des limites importantes. L'inspection visuelle reste subjective et fortement dépendante de l'expertise de l'opérateur. Les techniques telles que la thermographie infrarouge, l'électroluminescence et l'analyse des courbes I-V nécessitent des équipements spécialisés, coûteux, ainsi que des conditions d'acquisition spécifiques. De plus, ces approches sont généralement adaptées à des défauts bien définis et montrent des performances limitées face aux dégradations progressives ou aux défauts complexes. Elles ne permettent pas non plus une surveillance continue et en temps réel à grande échelle, ce qui constitue une contrainte majeure pour les installations photovoltaïques de grande taille. Ainsi, face à ces limitations, l'automatisation du diagnostic devient nécessaire. Les approches basées sur l'intelligence artificielle offrent des solutions plus robustes pour la détection précoce et la surveillance intelligente des systèmes photovoltaïques, et seront présentées dans le chapitre suivant.

2.7 Conclusion

Afin d'améliorer la performance et la disponibilité des installations photovoltaïques, le développement d'outils de détection de défauts est devenu essentiel. Ces outils visent à identifier et diagnostiquer rapidement les anomalies afin de limiter leur impact sur la performance et la fiabilité du système. Ce chapitre a présenté un état de l'art des principaux défauts des systèmes photovoltaïques ainsi que des méthodes conventionnelles de diagnostic. Les défauts sont généralement classés en défauts de fabrication et en défauts liés aux conditions environnementales et d'exploitation. Les méthodes traditionnelles de diagnostic permettent le suivi du fonctionnement des installations afin de détecter et localiser les défaillances, mais restent limitées en termes de précision et d'automatisation. Le chapitre suivant sera consacré à l'application de l'intelligence artificielle pour le diagnostic des systèmes photovoltaïques.

Chapitre 3

Techniques de diagnostic des défauts à l'aide d'intelligence artificielle

3.1 Introduction

Les méthodes conventionnelles de diagnostic des défauts photovoltaïques présentent certaines limites en termes de précision et d'automatisation. Pour y remédier, les techniques d'intelligence artificielle ont été développées afin d'améliorer la détection et l'identification des défauts à partir des données de fonctionnement. Grâce à leurs capacités d'apprentissage et d'analyse, ces approches sont devenues des outils performants pour le diagnostic des systèmes photovoltaïques. Ce chapitre présente les principales techniques d'intelligence artificielle utilisées dans ce domaine.

3.2 L'intelligence artificielle

L'intelligence artificielle (IA) est une branche de l'informatique visant à développer des systèmes capables de réaliser des tâches nécessitant habituellement l'intelligence humaine, telles que la reconnaissance de motifs, la compréhension du langage et la prise de décision.

3.3 Méthodes basées sur des techniques d'intelligence artificielle

Le diagnostic des systèmes photovoltaïques (PV), caractérisés par leur complexité et la diversité des défaillances, nécessite des approches capables de traiter des données hétérogènes, non linéaires et parfois incomplètes. Les méthodes conventionnelles, fondées principalement sur des modèles mathématiques déterministes, montrent rapidement leurs limites face à cette

complexité. Dans ce contexte, les techniques d'intelligence artificielle (IA) ont été introduites afin d'améliorer les performances de diagnostic. Elles permettent de reproduire des mécanismes d'apprentissage et de décision similaires au raisonnement humain, offrant ainsi une meilleure précision, une rapidité accrue et une plus grande robustesse dans la détection des défauts.




Figure 3.1 – Méthodes basées sur des techniques d'intelligence artificielle.

3.4 Apprentissage automatique (Machine Learning)

3.4.1 Définition

L'apprentissage automatique (Machine Learning, ML) est une branche de l'intelligence artificielle qui permet à un système d'apprendre à partir des données afin de réaliser des prédictions, des classifications ou de détecter des anomalies sans être explicitement programmé. Grâce à sa capacité à extraire automatiquement des connaissances à partir de grandes quantités de données, il est largement utilisé dans de nombreux domaines, notamment le diagnostic des systèmes photovoltaïques. Les principales approches du Machine Learning sont l'apprentissage supervisé, non supervisé, semi-supervisé et par renforcement, l'apprentissage supervisé étant le plus répandu pour les tâches de classification.




Figure 3.2 – Types d'apprentissage de la méthode d'apprentissage automatique.

3.4.2. L'apprentissage supervisé

L'apprentissage supervisé est une méthode de Machine Learning dans laquelle le modèle est entraîné à partir de données étiquetées afin d'apprendre la relation entre les entrées et les sorties. Après l'apprentissage, il est capable de réaliser des tâches de classification ou de régression sur de nouvelles données. Cette approche est particulièrement adaptée à la détection et à la classification des défauts dans les systèmes photovoltaïques lorsque des données historiques annotées sont disponibles.




Figure 3.3 – Schéma d'apprentissage supervisé.

3.4.3. L'apprentissage non supervisé

L'apprentissage non supervisé (Unsupervised Learning) est une approche dans laquelle les données d'entraînement ne possèdent pas d'étiquettes ou de classes prédéfinies.

Contrairement à l'apprentissage supervisé, l'algorithme doit découvrir de manière autonome les structures, les regroupements ou les relations existant au sein des données. L'objectif principal est d'identifier des caractéristiques communes permettant de former des groupes d'observations similaires, appelés clusters. Cette méthode est particulièrement utile lorsque les informations sur les classes sont indisponibles ou difficiles à obtenir. Les techniques d'apprentissage non supervisé sont largement utilisées pour la segmentation de données, la réduction de dimensionnalité, la détection d'anomalies et l'exploration de bases de données complexes. Elles peuvent également constituer une étape préliminaire à un apprentissage supervisé en facilitant la construction d'ensembles de données étiquetés [17].




Figure 3.4 – Schéma d'apprentissage non supervisé.

3.4.4. Algorithmes d'apprentissage automatique

De nombreux algorithmes ont été développés pour répondre aux différentes problématiques de classification, de régression et d'analyse de données. Parmi les plus utilisés figurent, les machines à vecteurs de support (Support Vector Machines, SVM), les forêts aléatoires (Random Forest), les arbres de décision (Decision Trees), les réseaux de neurones artificiels (Artificial Neural Networks, ANN). Le choix de l'algorithme dépend principalement de la nature des données, de la complexité du problème étudié et des performances recherchées.

3.4.4.1. Réseaux de neurones

Les réseaux de neurones artificiels constituent une branche majeure de l'intelligence artificielle inspirée du fonctionnement du cerveau humain. Ils sont composés d'unités de calcul simples, appelées neurones, organisées en couches et interconnectées par des poids synaptiques.

Le principe général repose sur l'apprentissage à partir de données historiques : le réseau ajuste progressivement ses paramètres afin de modéliser des relations complexes entre les entrées et les sorties. Cette capacité d'adaptation en fait un outil particulièrement efficace pour la classification, la prédiction et le diagnostic des systèmes complexes tels que les installations photovoltaïques [17].

3.4.4.1.1. Principe de fonctionnement du réseau

Le fonctionnement d'un réseau de neurones repose sur l'élaboration d'un raisonnement statistique. En s'appuyant sur une phase d'apprentissage préalable via une base de données dédiée, le modèle devient capable de prendre des décisions éclairées face à de nouvelles entrées. Concrètement, le processus de classification s'effectue en calculant la probabilité de ressemblance entre les données actuelles et les classes apprises par expérience. Le réseau agit ainsi comme un outil d'aide à la décision basé sur l'analyse statistique des corrélations [12].




Figure 3.5– Principe de fonctionnement du réseau de Neurones. [12]

3.4.4.1.2. Architecture des réseaux de neurones artificiels

Comme illustré par la Figure 3.3, un réseau de neurones artificiels, tel que le Perceptron Multicouche (MLP), est principalement défini par sa structure en couches et les poids de connexion qui les lient. Le comportement global du système repose sur l'interaction dynamique entre ses composants, organisés selon trois types de couches distinctes :

- La couche d'entrée : Elle constitue l'interface de réception du réseau. Son rôle est de collecter et de transmettre les données brutes (variables d'entrée) sans effectuer de traitement complexe.
- Les couches cachées : Situées entre l'entrée et la sortie, ces couches assurent le traitement de l'information. La performance du réseau dépend de l'ajustement des poids synaptiques reliant les neurones d'entrée aux neurones cachés. Ce sont ces poids qui déterminent le seuil d'activation des neurones, permettant ainsi l'extraction de caractéristiques pertinentes.
- La couche de sortie : Elle produit le résultat final du modèle. L'état d'activation des unités de sortie est directement conditionné par les signaux provenant des couches cachées et par la valeur des poids de connexion associés.




Figure 3.6 – Architecture des réseaux de neurones artificiels.

3.4.4.2. Machine à Vecteurs de Support (Support Vector Machine)

3.4.4.2.1. Définition

La machine à vecteurs de support (Support Vector Machine, SVM) est un algorithme d'apprentissage supervisé développé par Vapnik et ses collaborateurs dans les années 1990. Elle est principalement utilisée pour les tâches de classification, mais peut également être appliquée à la régression. Le principe fondamental des SVM consiste à déterminer un hyperplan optimal permettant de séparer les différentes classes de données tout en maximisant la marge de séparation entre elles. Cette marge est définie comme la distance entre l'hyperplan de décision et

les observations les plus proches de chaque classe, appelées vecteurs de support. Les SVM sont reconnues pour leur capacité de généralisation et leur efficacité dans les problèmes de classification à forte dimensionnalité.




Figure 3.7 – Machine à Vecteurs de Support (SVM).

3.4.4.2.2. Principe de fonctionnement de l'algorithme SVM

Dans un problème de classification binaire, les SVM cherchent à construire un hyperplan séparant les données en deux classes distinctes avec la marge maximale possible. Cette approche permet d'améliorer la robustesse du modèle et de réduire les erreurs de classification sur de nouvelles données. Lorsque les données ne sont pas linéairement séparables, les SVM utilisent des fonctions noyau (Kernel Functions) afin de projeter les données dans un espace de dimension supérieure où une séparation linéaire devient possible. Cette technique est connue sous le nom d'astuce du noyau (Kernel Trick). Les fonctions noyau les plus utilisées sont : le noyau linéaire (Linear Kernel), le noyau polynomial (Polynomial Kernel), le noyau à fonction de base radiale (Radial Basis Function – RBF), le noyau sigmoïde (Sigmoid Kernel). Grâce à cette flexibilité, les SVM peuvent traiter efficacement aussi bien les problèmes linéaires que non linéaires.




Figure 3.8 – Principe de fonctionnement de l'algorithme SVM.

3.5 Apprentissage profond (Deep Learning)

3.5.1 Définition

L'apprentissage profond (Deep Learning, DL) est une sous-discipline de l'apprentissage automatique basée sur des réseaux de neurones artificiels à plusieurs couches. Il permet d'extraire automatiquement des caractéristiques complexes à partir de grandes quantités de données et d'effectuer des tâches telles que la classification, la reconnaissance et la prédiction. Comme le Machine Learning, il comprend l'apprentissage supervisé, non supervisé et par renforcement [17].

3.5.2 Réseaux Neuronaux Convolutifs

Les réseaux neuronaux convolutifs (Convolutional Neural Networks, CNN) sont des architectures de Deep Learning spécialement conçues pour le traitement des images. Ils utilisent des opérations de convolution afin d'extraire automatiquement les caractéristiques visuelles telles que les contours, les formes et les textures. Les CNN sont largement utilisés dans la reconnaissance d'images, la détection d'objets, la reconnaissance faciale et l'imagerie médicale.

3.5.3 Réseaux Neuronaux Récurrents

Les réseaux neuronaux récurrents (Recurrent Neural Networks, RNN) sont adaptés au traitement des données séquentielles et temporelles. Grâce à leur mémoire interne, ils peuvent

exploiter les informations passées pour analyser des séquences de données. Afin de surmonter les limitations des RNN classiques dans la gestion des dépendances à long terme, des variantes plus performantes telles que les réseaux Long Short-Term Memory (LSTM) ont été développées.

3.6 Conclusion

Ce chapitre a présenté les concepts fondamentaux de l'intelligence artificielle appliqués au diagnostic des systèmes photovoltaïques. Après une introduction aux réseaux de neurones artificiels et à leur fonctionnement, les principales architectures utilisées dans les tâches de classification et de détection de défauts ont été décrites. Les notions essentielles du Machine Learning, du Deep Learning et des Machines à Vecteurs de Support (SVM) ont également été abordées, en mettant en évidence leurs principes de fonctionnement et leurs domaines d'application. Ces approches constituent aujourd'hui des outils performants pour le développement de systèmes intelligents de détection et de diagnostic des défauts dans les installations photovoltaïques.

Chapitre 4

Simulation et résultats

4.1 Introduction

La simulation est un outil puissant pour évaluer les performances théoriques d'un système. En fait, ce dernier peut être testé dans des conditions facilement contrôlées et ses performances peuvent être facilement contrôlées. Dans ce chapitre, nous allons utiliser les réseaux de neurones et SVM et Deep Learning (les réseaux de neurones profonds CNN pour étudier quelques scénarios de simulation de pannes qui se produisent au niveau du système photovoltaïque, On commence par l'obtention des caractéristiques $I=F(V)$ et $P=F(V)$, puis l'effet des conditions d'irradiation et de température sur ces mêmes caractéristiques, ainsi que les défauts d'ombrage et de court-circuit.

Notre objectif est d'étudier ces différents défauts en utilisant Machine Learning et Deep Learning dans des conditions de fonctionnement standard de fonctionnement et celles obtenues en présence d'un des défauts recensés permettra au moins de connaître la nature de ce défaut.

4.2 L'environnement

Les simulations ont été réalisées sous MATLAB (versions 2017a et 2023a) afin de bénéficier à la fois de la stabilité du développement initial et des optimisations de performance des versions récentes. Les principales boîtes à outils utilisées sont Signal Processing Toolbox, Statistics and Machine Learning Toolbox et Data base Toolbox. Afin d'assurer la compatibilité entre les deux versions, le code a été conçu de manière portable, avec des tests de validation et des adaptations des formats de données lorsque cela était nécessaire.

4.3 Description du système PV utilisé

Notre système photovoltaïque est composé de trois panneaux solaires connectés en série, alimentant ensuite un hacheur (convertisseur DC-DC) dont le fonctionnement est régulé par un algorithme de suivi du point de puissance maximale (MPPT). Le hacheur assure l'adaptation de la tension et du courant fournis par la chaîne PV afin d'optimiser l'extraction d'énergie selon les conditions d'ensoleillement et de température. La sortie du convertisseur alimente une charge purement résistive, ce qui a permis de caractériser les performances on nœuds du système en termes d'efficacité de conversion et de réponse dynamique sous différentes conditions de charge et d'irradiation. Des mesures de tension, courant et puissance ont été effectuées en différents points du montage pour valider le comportement du MPPT et évaluer les pertes du hacheur ainsi que la stabilité de la chaîne PV.




Figure 4.1: Système PV utilisé.

4.4 Simulation

4.4.1 Caractéristiques électriques du système PV utilisé

La figure 4-2 présente les caractéristiques électriques fondamentales du générateur photovoltaïque à travers les courbes $I=F(V)$ (courant-tension) et $P=F(V)$ (puissance-tension), constituant une étape préliminaire indispensable à la simulation. La courbe $I=F(V)$ illustre la

dépendance du courant vis-à-vis de la tension, marquée par un palier de courant quasi constant avant une décroissance abrupte à l'approche de la tension de circuit ouvert (V_{co} 150 V). Par ailleurs, la courbe $P=F(V)$ met en évidence le Point de Puissance Maximale (PPM), point de fonctionnement optimal que l'algorithme MPPT devra poursuivre. Ces profils caractéristiques servent de référence pour paramétrer et valider le modèle de simulation présenté ci-après.




Figure 4.2 : Caractéristique $I=f(V)$ et $P=F(V)$ du système PV utilisé

Tableau 4.1 – Les caractéristiques du module photovoltaïque utilisé.

Caractéristiques	Spécification
$I_{CC} = \max(I)$	6.2116 (A)
$V_{CO} = \max(V)$	210.0000 (V)
$[P_{max}, idx] = \max(P)$	749.4053 (W)
$V_{MMP} = V(idx)$	128.4386 (V)
$I_{MMP} = I(idx)$	5.8347 (A)
$FF = P_{max} / (I_{CC} * V_{CO})$	0.5745

4.4.2 Influence d'irradiation

Les résultats de la simulation du système photovoltaïque, obtenus sous différentes conditions d'irradiation et à une température constante ($T = 25^\circ\text{C}$), sont illustrés par les caractéristiques $I=f(V)$ et $P=f(V)$. Ces courbes représentent respectivement l'évolution du courant et de la puissance du générateur PV en fonction de la tension.

Lorsque l'irradiation augmente, la puissance P_{mpp} augmente par contre V_{co} reste presque constant




Figure 4.3: Caractéristique P(V) pour différents niveaux de L'irradiation (T=25°C).




Figure 4.4: Caractéristique $I=f(V)$ pour différents niveaux de L'irradiation ($T=25^{\circ}\text{C}$).

Interprétation :

Les résultats de la simulation du système photovoltaïque dans les conditions de changement de l'irradiation ($T=25^{\circ}\text{C}$) sont représentés par les caractéristique $I=f(V)$ et $P=f(V)$.

. Ces grandeurs représentent le courant et la puissance du générateur PV en fonction de tension.

Lorsque l'irradiation augmente , le courant I_{cc} augmente par contre V_{co} reste presque constant

4.4.3 Influence de la température

Afin d'évaluer l'influence de la température sur les performances du générateur PV, des simulations ont été effectuées à un éclairage fixe de 1000 W/m^2 . Les résultats de cette étude sont traduits par les courbes caractéristiques $I=f(V)$ (courant-tension) et $P=f(V)$ (puissance-tension) présentées ci-après, décrivant le comportement électrique du système.

Lorsque la température augmente , la puissance P_{mpp} diminue et V_{co} diminue.




Figure. 4.5: Caractéristique P(V) pour différentes température ($G=1000\text{W/m}^2$).




Figure. 4.6 : Caractéristique I(V) pour différentes température ($G=1000\text{W/m}^2$).

Interprétation :

Les courbes révèlent que l'élévation de la température provoque une chute significative de la tension en circuit ouvert (V_{co}), impactant directement à la baisse de la puissance maximale délivrée. En résumé, ces résultats illustrent la forte sensibilité des performances électriques du générateur PV face aux aléas climatiques : la puissance disponible est doublement pénalisée par la baisse de l'éclairement et par l'augmentation thermique des cellules.

4.4.4 Etude des défauts

4.4.4.1 Défaut de l'ombrage

Les effets de l'ombre sur les cellules photovoltaïques se divisent en deux catégories. D'une part, l'ombrage total intercepte la totalité du flux lumineux, privant le système de rayonnement. D'autre part, l'ombrage partiel ne masque qu'une portion de la surface, une situation fréquemment provoquée par la présence d'arbres, de cheminées, ou encore par l'accumulation de poussière. On considère deux cas d'ombrage, l'ombrage par un panneau et par deux panneaux. Les résultats sont présentés ci-après.




Figure 4.7: Caractéristique $I=f(V)$ et $P=f(V)$ pour défaut de l'ombrage par 1 panneau.




Figure 4.8: Caractéristique $I=f(V)$ et $P=f(V)$ pour défaut de l'ombrage par 2 panneaux.

Interprétation :

L'analyse des caractéristiques électriques montre que l'ombrage partiel modifie significativement le comportement du système. Dans le cas d'un seul panneau ombragé, l'activation de sa diode de bypass entraîne l'apparition d'un seul point d'inflexion sur la courbe $I=f(V)$ (chute du courant de 6 à 4 A), ce qui se traduit par deux pics de puissance sur la courbe $P=f(V)$. En revanche, lorsque deux panneaux sont ombragés, le phénomène s'accroît avec l'apparition de deux points d'inflexion successifs sur la courbe $I=f(V)$ et de trois pics de puissance distincts sur la courbe $P=f(V)$. En conclusion, l'augmentation du nombre de panneaux ombragés multiplie les pics locaux (LMPP), ce qui rend difficile la recherche du point de puissance maximale globale (GMPP).

4.4.4.2 Défaut court-circuit




Figure 4.9: Caractéristiques ($P=F(V)$) de Défaut de court-circuit.




Figure 4.10: Caractéristiques ($I=F(V)$) de Défaut de court-circuit.

Interprétation :

En condition de défaut de court-circuit, les courbes conservent une allure homogène sans distorsion ni pics multiples. Sur la courbe $I=F(V)$, le courant reste stable (I_{cc} approx 6.2 (A), mais on observe une chute nette de la tension en circuit ouvert (V_{oc}), qui se limite à environ 100(V). Cette réduction de tension se traduit sur la courbe $P=F(V)$ par un unique pic de puissance maximale (MPP) situé autour de 85 (V) (approx 500 (W)). Ainsi, ce défaut n'engendre pas de points d'inflexion (contrairement à l'ombrage) mais diminue directement la tension globale et, par conséquent, la productivité du système.

4.4.5 Classification des défauts

4.4.5.1 Prétraitement de données

Avant de procéder à la classification automatique des défauts, une étape de prétraitement est indispensable pour normaliser les données extraites des courbes $I=F(V)$ et $P=F(V)$. Ce processus consiste d'abord à nettoyer les signaux en éliminant les bruits de mesure, puis à extraire les caractéristiques clés (features) représentatives de chaque état, telles que les valeurs de la tension en circuit ouvert (V_{co}), du courant de court-circuit (I_{cc}), ainsi que le nombre de points d'inflexion et de pics de puissance (LMPP/GMPP). Enfin, les données sont recentrées et mises à l'échelle (normalisation) afin d'optimiser la précision et la rapidité des algorithmes de classification lors de la distinction entre l'ombrage et les défauts électriques.

4.4.5.2 Phase d'apprentissage

Le réseau de détection et de diagnostic est formé en utilisant l'apprentissage d'un ensemble de données obtenu et ne pas être traité dans la phase d'apprentissage. Il convient de noter ici que : D'une part, les données d'entrée (I_{MMP} et V_{MMP} , I_{CC} , V_{CO} , FF), sont de type continu et directement injecté dans le réseau de neurone (RN). Et d'un autre côté, les sorties (état sain, défaut # 1, défaut # 2, défaut # 3 et défaut # 4) sont variables nominales qui ne sont pas supportées par ce type de réseaux. Pour cette raison, des codes particuliers, choisis arbitrairement, ont été assignés à les sorties de RN comme mentionné ci-dessous :

- Système sain : classe "1", et qui sera utilisé pour décrire le cas d'exploitation de bon état.
- Défaut n ° 1 : classe "2", l'ombrage d'un panneau.
- Défaut n ° 2 : classe "3", l'ombrage de 2 panneaux.
- Défaut n ° 3 : classe "4", 1 panneau court-circuité.
- Défaut n ° 4 : classe "5", 2 panneaux court-circuités

Le tableau ci-dessous montre les cas opérationnels étudié ainsi que leurs codes.

Tableau 4.2 – Les cas opérationnels avec leurs codes [16].

Défaut	Codage
--------	--------

Sain	1	0	0	0	0
Ombrage d'un panneau	0	1	0	0	0
Ombrage de 2 panneaux	0	0	1	0	0
1 court-circuitée d'un panneau	0	0	0	1	0
2 court-circuitées de 2 panneaux	0	0	0	0	1

4.4.6 Les Résultats

Afin de classifier les différents défauts, trois méthodes de classification basées sur l'intelligence artificielle ont été mises en œuvre : La machine à vecteurs de support (SVM). Le réseau de neurone (RN). Le réseau neuronal convolutif (CNN).

4.4.6.1 La machine à vecteurs de support (SVM)

4.4.6.1.1 L'influence du paramètre de régulation C




Figure 4.11: la matrice de confusion pour C=5.

Calcul de l'accouracy globale :

$$TP = 64 + 94 + 49 + 53 + 58 = 318$$

$$TN = 64 + 1 + 94 + 9 + 1 + 7 + 49 + 20 + 12 + 53 + 7 + 58 = 375.$$

$$\text{Accouracy globale} = 318/375 = 0.848.$$

C=10

C=20




Figure 4.12: la matrice de confusion pour C=10,20,30 et 40

Synthèse de résultats (SVM) :**Tableau 4.3– Synthèse de résultats (SVM).**

C=5	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurecy	84.80	98.4615	90.3810	64.0000	81.5385	89.2308
C=10	Global	Sain	Défaut(d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurecy	85.60 %	98.4615	87.4762	76.0000	81.5385	84.6154
C=20	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurecy	83.776%	95.3846	80.6190	86.6667	75.3846	81.5385
C=30	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurecy	85.37%	98.4615	87.4762	76.0000	81.5385	84.6154
C=40	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurecy	83.373 %	100.0000	84.6667	70.7500	80.0000	84.6154

Interprétation :

L'analyse de ce tableau montre que le paramètre C influence significativement les performances du SVM. Une valeur trop faible peut conduire à un modèle insuffisamment contraint, tandis qu'une valeur trop élevée peut provoquer un surapprentissage et une baisse de la capacité de généralisation. Parmi les valeurs étudiées, C=10 offre le meilleur compromis avec une accuracy globale de 85,60 %, tout en maintenant de bonnes performances sur la majorité des classes. En revanche, si l'objectif est d'optimiser spécifiquement la détection du défaut d2, C=20 constitue un meilleur choix, puisqu'il atteint une accuracy de 86,67 % pour cette classe. Ainsi, C=10 est le paramètre recommandé pour une classification globale équilibrée, tandis que le choix de C peut être adapté selon la classe d'intérêt.

4.4.6.2 Le Réseau de neurones (RN)

4.4.6.2.1 L'influence du nombre des noyaux (N)






Figure 4.13 : la matrice de confusion pour N=5.



N=30

N=40




Figure 4.14 : la matrice de confusion pour N=10,20,30 et 40.

Synthèse de résultats (RN) :

Tableau 4.4 – Synthèse de résultats (RN).

N=5	Global	Sain	défaut(d1)	défaut(d2)	défaut(d3)	défaut(d4)
Accurecy	81.648%	92.3077	86.4762	63.9167	80.0000	86.1538
N=10	Global	Sain	défaut(d1)	défaut(d2)	défaut(d3)	défaut(d4)
Accurecy	84.75%	93.8462	84.5238	78.4167	80.0000	86.1538
N=20	Global	Sain	défaut(d1)	défaut(d2)	défaut(d3)	défaut(d4)
Accurecy	83.24%	93.8462	86.3810	74.1667	80.0000	81.5385
N=30	Global	Sain	défaut(d1)	défaut(d2)	défaut(d3)	défaut(d4)
Accurecy	84.57%	93.8462	88.4286	78.3333	80.0000	81.5385
N=40	Global	Sain	défaut(d1)	défaut(d2)	défaut(d3)	défaut(d4)
Accurecy	84.308%	93.7179	85.5238	82.0000	80.0000	80.0000

Interprétation :

Les résultats montrent que le nombre de neurones N influence les performances globales du classifieur. Une valeur trop faible ($N = 5$) limite la capacité d'apprentissage et conduit à une baisse de l'accuracy. L'augmentation de N améliore les performances jusqu'à $N = 10$, qui fournit la meilleure accuracy globale (84,75 %). Au-delà de cette valeur, les performances restent stables ou diminuent légèrement, ce qui suggère qu'un réseau plus complexe n'apporte pas de gain significatif. Ainsi, $N = 10$ constitue le meilleur compromis entre précision, complexité du modèle et capacité de généralisation. Toutefois, si l'objectif est de maximiser la détection du défaut d2, un choix de $N = 40$ est préférable (82,00 %), tandis que $N = 30$ est plus adapté pour le défaut d1 (88,43 %). Pour une utilisation générale, $N = 10$ demeure le paramètre recommandé.

4.4.6.2.2 Influence du nombre d'échantillons (M)




Figure 4.15 : les matrices de confusion de SVM et RN.

Tableau 4.5 – L’accuracy global de chaque classe M=752.

Classes N=10 C=10 M=752	Accuracy SVM (%)	Accuracy NN (%)	Erreur SVM (%)	Erreur NN (%)
Classe 1	99.2308	93.8462	0.7692	6.1538
Classe 2	88.8269	85.9698	11.1731	14.0302
Classe 3	91.0484	82.1169	8.9516	17.8831
Classe 4	79.2308	80.0000	20.7692	20.0000
Classe 5	80.7692	83.0769	19.2308	16.9231
Globale	88.03	84.98	11.97	15.02

M=1504


Figure 4.16: les matrices de confusion de SVM et RN pour M=1504



Figure 4.17: les matrices de confusion de SVM et RN

Synthèse Global de résultats :

Tableau 4.6 – Synthèse Global de résultats SVM et RN.

M (nombre d'échantillons)	148	752	1504	2256
Accuracy SVM	85.6	88.03	90.09	90.74
Accuracy NN	84.75	84.98	85.18	85.19

Interprétation :

L'analyse montre que l'augmentation du nombre d'échantillons améliore les performances de classification, mais cet effet dépend fortement du classifieur utilisé. Le SVM tire un bénéfice important de l'ajout de données d'apprentissage, son accuracy passant de 85,60 % à 90,74 %, soit un gain de 5,14 points. En revanche, le réseau de neurones reste pratiquement stable autour de 85 %, avec une amélioration de seulement 0,44 point.

Ces résultats indiquent que, pour cette base de données et les paramètres retenus, le SVM est plus robuste et présente une meilleure capacité de généralisation lorsque le nombre d'échantillons

augmente. Ainsi, le meilleur compromis est obtenu avec 2256 échantillons, où le SVM atteint une accuracy de 90,74 %, confirmant l'intérêt d'utiliser une base d'apprentissage plus importante pour améliorer les performances du système de diagnostic.

4.4.6.3 Le réseau neuronal convolutif (CNN)

4.4.6.3.1 Influence du nombre de données (M)

M=257

0	2 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
1	6 11.8%	9 17.6%	0 0.0%	0 0.0%	0 0.0%	60.0% 40.0%
2	0 0.0%	0 0.0%	11 21.6%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	0 0.0%	7 13.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	16 31.4%	100% 0.0%
	25.0% 75.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	88.2% 11.8%
	0	1	2	3	4	

Figure 4.18: la matrice de confusion de CNN pour M=257.

M=514

0	16 15.5%	8 7.8%	0 0.0%	0 0.0%	0 0.0%	66.7% 33.3%
1	0 0.0%	11 10.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	1 1.0%	21 20.4%	0 0.0%	0 0.0%	95.5% 4.5%
3	0 0.0%	0 0.0%	0 0.0%	12 11.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	34 33.0%	100% 0.0%
	100% 0.0%	55.0% 45.0%	100% 0.0%	100% 0.0%	100% 0.0%	91.3% 8.7%
	0	1	2	3	4	

Figure 4.19: la matrice de confusion de CNN pour M=514.

M=771

0	16 15.5%	8 7.8%	0 0.0%	0 0.0%	0 0.0%	66.7% 33.3%
1	0 0.0%	11 10.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	1 1.0%	21 20.4%	0 0.0%	0 0.0%	95.5% 4.5%
3	0 0.0%	0 0.0%	0 0.0%	12 11.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	34 33.0%	100% 0.0%
	100% 0.0%	55.0% 45.0%	100% 0.0%	100% 0.0%	100% 0.0%	91.3% 8.7%
	0	1	2	3	4	

Figure 4.20: la matrice de confusion de CNN pour M=771.

Tableau 4.7 – Synthèse Global de résultats CNN de (M)

M= 257	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurcy	88.24%	100.0000%	8660.0000%	63.9167	100.0000%	100%
M=514	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurcy	91.30%	66.6667%	100.0000%	95.4545%	100.0000	86100.0000%
M=771	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accurcy	98.10%	90.3226%	100.0000%	100.0000%	100.0000	100.0000%

Interprétation :

À travers les trois cas étudiés, on observe de manière flagrante une corrélation positive étroite entre la taille de l'échantillon et la performance du modèle. En effet, la précision globale augmente de façon proportionnelle et régulière à mesure que le nombre d'exemples d'apprentissage s'accroît. Cette progression constante démontre que l'apport de données supplémentaires permet à l'algorithme de mieux généraliser et d'affiner ses prédictions

4.4.6.3.2 L'influence du nombre des noyaux (N)

N=44

0	1 1.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
1	15 14.6%	20 19.4%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
2	0 0.0%	0 0.0%	21 20.4%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	0 0.0%	12 11.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	34 33.0%	100% 0.0%
	6.2% 93.8%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	85.4% 14.6%
	0	1	2	3	4	

Figure 4.21: la matrice de confusion de CNN pour N=44.

N=54

0	16 15.5%	13 12.6%	0 0.0%	0 0.0%	0 0.0%	55.2% 44.8%
1	0 0.0%	7 6.8%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	0 0.0%	21 20.4%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	0 0.0%	12 11.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	34 33.0%	100% 0.0%
	100% 0.0%	35.0% 65.0%	100% 0.0%	100% 0.0%	100% 0.0%	87.4% 12.6%
	0	1	2	3	4	

Figure 4.22: la matrice de confusion de CNN N=54.

N=64

0	16 15.5%	8 7.8%	0 0.0%	0 0.0%	0 0.0%	66.7% 33.3%
1	0 0.0%	11 10.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	1 1.0%	21 20.4%	0 0.0%	0 0.0%	95.5% 4.5%
3	0 0.0%	0 0.0%	0 0.0%	12 11.7%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	34 33.0%	100% 0.0%
	100% 0.0%	55.0% 45.0%	100% 0.0%	100% 0.0%	100% 0.0%	91.3% 8.7%
	0	1	2	3	4	

Figure 4.23: la matrice de confusion de CNN N=64.

Tableau 4.8 – Synthèse Global de résultats

N=44	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accuracy	85.40%	100.0000%	57.1429%	100.0000%	100.0000%	100.0000%
N=54	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accuracy	87.40%	55.1724%	100.0000%	100.0000%	100.0000	100.0000%
N=64	Global	Sain	Défaut (d1)	Défaut (d2)	Défaut (d3)	Défaut (d4)
Accuracy	88.20%	100.0000%	60.0000%	100.0000%	100.0000	100.0000%

Interprétation :

Les résultats obtenus dans les trois cas mettent en évidence un gain de performance notable : la précision globale augmente de façon strictement proportionnelle au nombre de noyaux alloués. Ce comportement souligne l'excellente stabilité du modèle, où l'augmentation des ressources matérielles se traduit par une amélioration directe et mesurable de l'exactitude des résultats.

4.5 Conclusion

Dans ce chapitre, On a fait l'objet d'une étude des défauts d'un système PV par trois méthodes avec le Matlab, cette étude permet de modéliser la détection des défauts, Une étude comparative dans le but d'un choix décisif de la méthode la mieux adaptée à l'application a été effectuée .

Dans cette étude, la précision la plus élevée a été obtenue avec le modèle CNN, atteignant 98,10 % pour une taille de jeu de données de $M = 771$, surpassant ainsi les performances des modèles RN et SVM. Par conséquent, le CNN constitue le choix optimal pour la détection de défauts..

Conclusion Générale

L'énergie solaire constitue un élément clé de la transition énergétique grâce à son caractère propre et renouvelable. Toutefois, les performances des systèmes photovoltaïques dépendent de l'efficacité des dispositifs de surveillance capables de détecter rapidement les défauts affectant le rendement et la durée de vie des panneaux. Ce travail présente une analyse des principaux défauts des modules photovoltaïques et de leurs causes, ainsi qu'un aperçu de l'évolution des méthodes de diagnostic, des approches conventionnelles aux techniques basées sur l'intelligence artificielle. Face aux limites des méthodes classiques, l'apprentissage profond apparaît comme une solution performante, offrant un diagnostic automatique, rapide et fiable des défauts des systèmes photovoltaïques.

Dans ce mémoire, nous avons proposé une approche hybride et comparative basée sur les modèles SVM, ANN et CNN pour la détection et la classification des défauts photovoltaïques à partir de grandeurs électriques. Les résultats obtenus démontrent la supériorité du modèle CNN, qui atteint une précision de 98 %, contre 85 % pour le SVM et 84 % pour l'ANN. Cette performance s'explique par la capacité des réseaux CNN à extraire automatiquement des caractéristiques complexes sans intervention manuelle. De plus, l'utilisation d'une base de données multisource a renforcé leur capacité de généralisation. Cette étude confirme ainsi le potentiel des réseaux CNN pour un diagnostic intelligent, rapide et non destructif, favorisant leur intégration dans les systèmes de maintenance prédictive des installations photovoltaïques.

Références bibliographiques

- [1] Renewable Energy Systems - Edition 3 - By Henrik Lund Elsevier Educate, (n.d.). <https://www.educate.elsevier.com/book/details/9780443141379>.
- [2] Acsolue Energie : spécialiste en installations photovoltaïques -Landes et alentours, (n.d.). <https://acsolue-energie.fr/>.
- [3] N.A. Ludin, N.I. Mustafa, M.M. Hanafiah, M.A. Ibrahim, M. Asri Mat Teridi, S. Sepeai, A. Zaharim, K. Sopian, Prospects of life cycle assessment of renewable energy from solar photovoltaic technologies: A review, Renewable and Sustainable Energy Reviews 96 (2018) 11–28. <https://doi.org/10.1016/j.rser.2018.07.048>.
- [4] A.A. Bekakra, A. Abbas, Détection des défauts dans les systèmes photovoltaïques basée sur des approches d'intelligence artificielle, Université de Guelma ,2025.. <https://archives.univ-eloued.dz/handle/123456789/38517>
- [5] C. Touzet, LES RESEAUX DE NEURONES ARTIFICIELS, INTRODUCTION AU CONNEXIONNISME, COURS, EXERCICES ET TRAVAUX PRATIQUES, EC2, 1992. <https://amu.hal.science/hal-01338010>.
- [6] E. Becquerel, La lumière: ses causes et ses effets, Didot, 1867.
- [7] A. Luque, S. Hegedus, Handbook of photovoltaic science and engineering, John Wiley & Sons, 2011.
- [8] A. Harkat, Diagnostic des défauts des panneaux photovoltaïque par les techniques d'optimisation méta-heuristiques (PSO) appliquées au modèle SANDIA, à l'Ecole Nationale Polytechnique en 2024. <http://repository.enp.edu.dz/jspui/handle/123456789/11019>
- [9] A. Belaout, Étude et diagnostic des défauts fréquents aux systèmes photovoltaïques (PV) par emploi de la caractéristique courant-tension, 2014.
- [10] S.M. Sze, The floating-gate non-volatile semiconductor memory—from invention to the digital age, Journal of Nanoscience and Nanotechnology 12 (2012) 7587–7596.
- [11] A. Marshall, Solaire thermique et photovoltaïque : une brève histoire, Encyclopédie de l'énergie (2019). <https://www.encyclopedie-energie.org/solaire-thermique-et-photovoltaïque-une-breve-histoire/>
- [12] A. Kial, O.F. Lahmar, ECHNIQUES DE DETECTION DES DEFAUTS DANS UN PANNEAU PHOTOVOLTAÏQUE, Université de Mostaganem ,2019. <http://e-biblio.univ-mosta.dz/handle/123456789/13140>
- [13] R.A. Messenger, Photovoltaic systems engineering, CRC press, 2018.
- [14] R. Benkercha, S. Moulahoum, Contribution au Développement d'un Algorithme de Détection et Diagnostic des Défauts Dans le Système Photovoltaïque fonctionnant en mode connecté au Réseau et Autonome, Université de Medea (2021). <https://dspace.univ-medea.dz/handle/123456789/6373>
- [15] X. Jiang, Étude comparative des convertisseurs pour systèmes photovoltaïques connectés à un réseau électrique moyenne tension, Studocu, Université du Québec, 2019. <https://www.studocu.com/row/document/universite-cadi-ayyad/energies-renouvelables/032314463/47309323>

- [16] B. Amel, A. Hanane, Détection de défauts de panneau solaire par réseau de neurones, Université de Mostaganem , 2022.. <http://e-biblio.univ-mosta.dz/handle/123456789/21497>
- [17] A. Bekhedda, S. Belmekki, Détection de défauts dans un système photovoltaïque par l'intelligence artificielle, Université de Mostaganem 2024. <http://e-biblio.univ-mosta.dz/handle/123456789/26711>
- [18] Z. Djallel, Etude et détection de défauts dans un système photovoltaïque, Faculté des Sciences et Technologies, Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj 2020. <http://10.10.1.6:4000/handle/123456789/518>
- [19] Y. Nour El Imane, G. Wissam Fatima Zohra, Contribution à l'étude d'influence des conditions météorologiques sur le rendement des systèmes photovoltaïques, université Ibn Khaldoun, 2024. <http://dspace.univ-tiaret.dz:80/handle/123456789/15511>