

**République Algérienne Démocratique & Populaire**  
**Ministère de l'Enseignement Supérieur & de la Recherche Scientifique**  
**Université Echahid Hamma Lakhdar – El Oued**

**Faculté des technologie**  
**Département des technologie**



**Mémoire**

**Présenté pour l'obtention de diplôme de Master Academie**

**Filière : Département de Génie Électrique**

**II Option : Réseaux électrique**

**Intitulé**

**Détection des défauts dans les systèmes photovoltaïques  
basée sur des approches d'intelligence artificielle**

**Réalisé par :**

**Bekakra Abderrahmane**

**Abbas Abderraouf**

**Supervisé par:**

**Dr. Kaid Imad Eddine**

**Présenté et soutenu publiquement**

**Devant le jury composé de**

**Président**

**Dr. Barka Nouredine**

**Encadreur**

**Dr. Kaid Imad Eddine**

**Examineur**

**Dr. Mammeri Oussama**

**Année Universitaire : 2024-2025**

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

# Remerciements

*Avant tout, nous tenons à adresser nos remerciements à Dieu Tout-Puissant, le Fort et le Puissant, de nous avoir accordé la force et le courage nécessaires pour atteindre notre objectif et accomplir notre travail.*

*Nous exprimons notre profonde reconnaissance à « **Dr. kaid Imad Eddine** » notre encadrant de mémoire, qui n'a jamais manqué de réactivité, de savoir-faire et de soutien. Nous le remercions pour ses conseils, son orientation et son aide tout au long de ce travail, ainsi que pour sa compréhension, sa bienveillance et son encadrement tout au long de l'élaboration de notre mémoire.*

*Nous remercions également chaleureusement les membres du jury pour avoir accepté d'évaluer ce travail.*

*Enfin, nous tenons à remercier toutes les personnes, qu'elles fassent ou non partie de la faculté, qui ont contribué directement ou indirectement à la réalisation de ce travail. Nous leur adressons ici notre profonde gratitude*

# إِهْدَاء

أهدي ثمرة جهدي المتواضع إلى من وهبوني الحياة والأمل، والنشأة على شغف الاطلاع والمعرفة،  
ومن علموني أن أرتقي سلم الحياة بحكمة وصبر؛ برّاً وإحساناً؛ ووفاءً لهم: والدي العزيز، ووالدتي العزيزة،  
إلى من وهبني الله نعمة وجودهم في حياتي.

إلى العقد المتين، من كانوا عوناً لي في رحلتي: إخوتي وأخواتي.

إلى كل من تعلّمت على يده حرفاً، فكان نوراً يبّد الظلام فأضاء سبيلي.

إلى كل من ساعدني، وكان له دور من قريب أو بعيد في إتمام هذه الدراسة،  
سائلاً المولى أن يجزي الجميع خير الجزاء في الدنيا والآخرة.

إلى أولئك الذين يحملون نور العلم في صدورهم، ويبدرونه حيثما حلّوا، ليزهر به طريق الآخرين.

إلى الأصدقاء والأحباب وإلى كل من تسعهم ذاكرتي ولا تسعهم مذكري.

عبدالرحمان

# إِهْدَاء

إلى من زرع الأمل في قلبي، وسقاه بحنانه حتى أثمر حلمًا تحقق

إلى أمي، يا نورًا لا ينطفئ، ويا دعاءً لا يخيب، إليك كل نبض في قلبي، وكل نجاح أبلغه...  
إلى أبي، سندي الأول، وصوت الحكمة في طريقي، إلى الذي علّمني أن الطموح لا سقف له، وأن الرجولة  
موقف ومسؤولية...

إلى من علّمني الحرف والنقطة، والذين كانوا مشاعل علم ونور في دربي... أساتذتي الأفاضل، شكرًا من  
القلب

وإلى جدّاتي الغاليات، نبع الحنان والدعاء الصادق، لهن في قلبي محبة لا توصف، وبدعواتهن الصادقة كنت  
أمضي بثبات في طريقي نحو هذا الإنجاز.

إلى إخوتي الأعزاء، الذين كانوا لي السند والرفقة الصادقة، منحتني أخوتهم القوة والثقة، وكانوا حاضرين في  
كل لحظة مهمة من حياتي.

إلى أصدقائي الأوفياء، الذين شاركوني الحلم، وساندوني في لحظات التعب، وضحكوا معي في لحظات  
الفرح. لوجودكم طعم خاص، وذكراكم لا تُنسى.

إلى أخوالي وأعمامي الأعزاء، الذين كانوا دومًا سندًا ودعامة، أفتخر بانتمائي إليهم، وأستلهم من محبتهم  
الصادقة ودعمهم الكثير من القوة.

إلى كل من أحبني بصدق، وآمن بي ولو بكلمة.

أهدي إليكم هذا العمل... لا لأنه نهاية الطريق، بل لأنه البداية التي حلمتم بها لي.

**عباس عبد الرؤوف**

---

---

## Résumé

Ce mémoire présente une étude pratique et comparative de techniques d'intelligence artificielle appliquées à la détection des défauts dans les systèmes photovoltaïques, en s'appuyant sur des données réelles collectées à partir d'une centrale solaire située dans le désert algérien.

En l'absence de données de panne étiquetées, trois approches non supervisées ont été explorées : Autoencoder (apprentissage profond), K-Means (clustering), et SVM à une seule classe (modélisation de frontière d'anomalie).

Chaque méthode a été appliquée au même jeu de données, et leur performance a été évaluée selon leur capacité à identifier des comportements anormaux, en s'appuyant respectivement sur les erreurs de reconstruction, les distances aux centroïdes, et les scores de décision.

Les résultats ont montré que l'Autoencoder offre la meilleure précision, que le SVM présente une bonne robustesse, tandis que K-Means se distingue par sa simplicité et sa rapidité. Les analyses graphiques, notamment les courbes Tension-Puissance, ont confirmé la pertinence physique des anomalies détectées.

Cette étude met en évidence le potentiel de l'intelligence artificielle pour la maintenance prédictive des installations solaires, en particulier dans les environnements isolés ou contraignants, où les moyens de surveillance classiques sont limités.

### Mots-clés :

Intelligence artificielle, Systèmes photovoltaïques, Détection d'anomalies, Apprentissage non supervisé

### Abstract

This work presents a practical and comparative study of artificial intelligence techniques applied to fault detection in photovoltaic (PV) systems, using real operational data collected from a solar power plant in the Algerian desert.

In the absence of labeled fault data, three unsupervised methods were explored: Autoencoder (deep learning), K-Means (clustering), and One-Class SVM (anomaly boundary modeling).

Each method was applied to the same dataset, and their ability to detect operational anomalies was evaluated through reconstruction errors, cluster distances, and decision scores, respectively.

The results demonstrate the Autoencoder's superior precision, the SVM's robustness, and the simplicity and speed of K-Means. Graphical analyses such as voltage-power plots confirmed the physical relevance of the detected anomalies.

---

This study highlights the potential of AI for predictive maintenance in solar plants, especially in isolated or harsh environments where traditional monitoring is limited.

**Keywords:**

Artificial Intelligence, Photovoltaic Systems, Anomaly Detection, Unsupervised Learning

**ملخص**

تقدّم هذه المذكرة دراسة تطبيقية ومقارنة لتقنيات الذكاء الاصطناعي في تشخيص الأعطال في الأنظمة الكهروضوئية، بالاعتماد على بيانات تشغيل حقيقية مأخوذة من محطة طاقة شمسية في الصحراء الجزائرية. ونظرًا لغياب بيانات أعطال موسومة، تم اختيار ثلاث طرق غير مراقبة: Autoencoder تعلم عميق، K-Means (تجميع)، و SVM ذو الصنف الواحد (نمذجة حدود الشذوذ).

تم تقييم أداء كل نموذج من حيث قدرته على كشف السلوكيات غير الطبيعية، باستخدام أخطاء الإعادة، المسافات إلى مراكز التجمعات، ودرجات القرار .

أظهرت النتائج أن Autoencoder قدّم أعلى دقة، بينما تميز SVM بالمرونة، و K-Means بالسرعة والبساطة. كما أثبتت التحليلات البيانية (مثل الجهد مقابل القدرة) التناسق الفيزيائي للعينات الشاذة المكتشفة. تؤكد هذه الدراسة أهمية الذكاء الاصطناعي كأداة ذكية للصيانة التنبؤية في محطات الطاقة الشمسية، خاصة في البيئات المعزولة أو القاسية.

**الكلمات المفتاحية**

الذكاء الاصطناعي، الأنظمة الكهروضوئية، اكتشاف الشذوذ، التعلم غير المراقب

## Liste des Figures

### Liste des Figures

Figure I-1: Schéma synoptique de l'effet photovoltaïque .	4
Figure I-2: Types des cellules photovoltaïques	5
Figure I-3: Modèle simplifié d'une cellule PV	6
Figure I-4: Modèle à une diode d'une cellule PV	7
Figure I-5: Modèle à deux diodes d'une cellule PV	8
Figure I-6: Caractéristiques électrique I-V et P-V d'un panneau photovoltaïque	9
Figure I-7: Caractéristique courant tension de $N_s$ cellule en série	11
Figure I-8: Caractéristique courant tension de $N_p$ cellule en parallèle	11
Figure I-9: Schéma d'un champ photovoltaïque avec diodes by-pass et diode anti-retour	13
Figure I-10: influence de la température sur la tension de circuit ouvert ( $V_{co}$ )	13
Figure I-11: influence de l'ensoleillement sur le point de puissance maximal (PPM)	14
Figure I-12: Organigramme de l'algorithme MPPT basé sur P&O	15
Figure I-13: Organigramme de l'algorithme MPPT basé sur IncCond	16
Figure I-14: Installation photovoltaïque autonome	18
Figure I-15: Installation photovoltaïque couplée au réseau	19
Figure I-16: Système hybride	19
Figure II-1 : Décoloration sur la surface de la cellule	24
Figure II-2: Délemination auteur jeu de barre	25
Figure II-3: Corrosion dans les interconnexions de cellules de jeu de barre	25
Figure II-4 : Traces d'escargot	26
Figure II-5: Bris de verre	26
Figure II-6: Fissure sur un Panneau photovoltaïque	27
Figure II-7: Défaut de circuit ouvert	29
Figure II-8: Défaut ligne à ligne	29
Figure II-9: Court-circuit entre le module PV et la terre	30
Figure II-10: Défaut d'arc	30
Figure II-11: Défaut d'ombrage	31
Figure II-12: Défaut Points Chauds	32
Figure II-13: Paramètres de la courbe IV	33
Figure II-14: EL Failure	35
Figure II-15: défaillance UVFL	36
Figure II-16: Contrôle et inspection par thermographie infrarouge	36
Figure III-1: Le fonctionnement général d'apprentissage automatique	40

## Liste des Figures

---

Figure III-2: Type Machine Learning. ....	40
Figure III-3: Apprentissage supervisé. ....	41
Figure III-4: Apprentissage non supervisé (Clustering).....	42
Figure III-5: Classification de la machine à vecteur de support. ....	43
Figure III-6:Architecture de réseau de neurones. ....	46
Figure III-5: Architecture d'un Auto-encodeur.....	47
Figure IV-1: Erreur de reconstruction par Autoencoder et seuil d'anomalie.....	52
Figure IV-2: Distribution des erreurs de reconstruction. ....	53
Figure IV-3: Détection des anomalies –Tension vs Puissance. ....	54
Figure IV-4: Distance des échantillons aux centres (K-Means). ....	56
Figure IV-5: Distribution des distance aux centres.....	57
Figure IV-6: Détection des anomalies –Méthode k-means.....	58
Figure IV-7: SVM à une seule classe – Score et seuil. ....	59
Figure IV-8: Distribution des score – SVM à une seule classe.....	60
Figure IV-9: Détection des anomalies – SVM à une seule classe. ....	61
Figure IV-10: Taux de détection des anomalies par méthodes. ....	62
Figure IV-11 : Temps d'exécution par méthodes. ....	63
Figure IV-12: Comparaison multidimensionnelle des méthodes.....	64

## Liste des Tableaux

---

### Liste des tableaux

Tableau I -1: Caractéristiques majeures des commandes MPPT .....	17
Tableau IV-1: Comparatif récapitulatif. ....	64

### Nomenclature et abréviations

*SVM : Support Vector Machines*

*ML : Machine Learning*

*CNN : Convolutional Neural Networks*

*RNN : Recurrent Neural Networks*

*LSTM : Long Short – Term Memory*

*PV : Photovoltaïque*

*$I_{cc}$  : Courant de court – circuit de la cellule*

*$I_s$  : Courant de saturation de la diode*

*$V_{th}$  : Tension thermique*

*$a$  : Coefficient d'idéalité de la diode*

*$q$  : Charge d'un électron ( $1.6 \times 10^{-19} C$ )*

*$K$  : Constante de Boltzmann ( $1.38 \times 10^{-23} J/K$ )*

*$V_m$  : Tension au point de puissance maximale*

*$I_m$  : Courant au point de puissance maximale*

*$FF$  : Facteur de forme*

*$E$  : Ensoleillement ( $W/m^2$ )*

*$S$  : Surface effective des cellules*

*$NOCT$  : Température nominale de fonctionnement des cellules*

*$\eta$  : Rendement de conversion d'énergie*

*$P_{in}$  : Puissance du flux lumineux incident*

*$P_{max}$  : Point de puissance maximale*

*$V_{oc}$  : Tension en circuit ouvert*

*$I$  : Courant disponible*

*$I_{ph}$  : Courant produit par la photopile*

*$V$  : Tension aux bornes de la cellule*

*$I_{pv}$  : Courant délivré par le module*

*$I_d$  : Courant de diode*

*$I_{sh}$  : Courant de shunt*

*$R_s$  : Résistance série*

*$R_{sh}$  : Résistance shunt*

*$N_s$  : Nombre de cellule en série.*

*$N_p$  : Nombre de cellule en parallèle.*

*MPPT : maximum power point tracking*

## Sommaire

---

---

### Sommaire

Liste des Figures.....	
Liste des Tableaux .....	
Nomenclature est abrégations.....	
Sommaire.....	
<b>Introduction générale .....</b>	<b>1</b>
<b>Chapitre I : Généralités sur les systèmes photovoltaïques .....</b>	<b>2</b>
Introduction : .....	3
I-1 Historique : .....	3
I-3 L'Effet photovoltaïque .....	3
I-4 Différents types des cellules solaires .....	5
I-5 Modélisation électrique d'une cellule photovoltaïque .....	5
I-5-1 Modèle simplifié.....	6
I-5-2 Modèle à une diode.....	6
I-5-3 Modèle à deux diodes .....	8
I-6 Caractéristique électrique d'un panneau photovoltaïque .....	8
I-6-1 Les paramètres d'un panneau photovoltaïque .....	9
I-7 Regroupement des cellules.....	10
I-7-1 Regroupement en série.....	10
I-7-2 Regroupement en parallèle .....	11
I-7-3 Module photovoltaïque.....	11
I-8 Générateur photovoltaïque.....	12
I-8-1 Protections classiques d'un GPV .....	12
I-9 La poursuite du point de puissance maximal MPPT (Maximum Power Point Tracker) ....	12
I-9-1 influence de la variation de la température et de l'ensoleillement sur le point.....	13
I-9 Approche MPPT .....	14
I-10 L'onduleur.....	17
I-11 Les différents types de systèmes photovoltaïques .....	17
I-11-1 Système PV autonome.....	18
I-11-2 Systèmes couplés au réseau .....	18
I-11-3 Systèmes hybrides .....	19
I-12 Les avantages et les inconvénients de l'énergie photovoltaïque .....	20
I-12-1 Les avantages de l'énergie photovoltaïque.....	20
I-12-2 Les inconvénients de l'énergie photovoltaïque .....	20

## Sommaire

---

Conclusion :	21
<b>Chapitr II: défauts liés aux systèmes photovoltaïques et méthodes détection</b>	<b>22</b>
Introduction :	23
II-2 Défauts photovoltaïques :	23
II-3 Types de défauts dans les systèmes PV :	24
II-3 -1 Défauts Physiques :	24
II-3 -2 Défauts électriques:	27
II-3 -2 Défauts environnementaux :	31
II-4 Méthodes de détection des défauts dans les systèmes PV :	32
II-4-1Méthodes électriques :	33
II-4-2 Méthodes visuelle est thermiques(VTM):	34
II-4-3 Méthodes d'intelligence artificielle	36
Conclusion :	37
<b>Chapitr III: Technologies d'intelligence artificielle</b>	<b>38</b>
Introduction :	39
III-2 L'apprentissage automatique	39
III-3 Les différents types de L'apprentissage automatique	40
III-3-1Apprentissage supervisé:	40
III-3-2 Apprentissage non supervisé:	41
III-3-3 L'apprentissage semi-supervisé	42
III-3-4 Apprentissage par renforcement	42
III-4 Type algorithmes L'apprentissage automatique	43
III-4-1 Support Vector Machine –SVM:	43
III-4-2 k- means:	44
III-5 L'apprentissage profond	44
III-6 Généralités sur les réseaux de neurones artificiels	45
III-6-1Types réseaux de neurones	46
III-6-1-1 Réseaux neuronaux convolutifs (CNN)	46
III-6-1-2 Réseaux neuronaux récurrents (RNN)	46
III-6-1-3 Réseaux de mémoire à long et court terme (LSTM)	46
III-7 Autoencoder:	47
Conclusion:	48
<b>Chapitr IV: Étude expérimentale de détection des défauts dans un système photovoltaïque</b>	<b>49</b>

## Sommaire

---

Introduction .....	50
IV-2 Présentation des méthodes d'intelligence artificielle utilisées.....	50
IV-3Description des données et du prétraitement .....	51
IV-4 Implémentation expérimentale et résultats .....	51
IV-4-1 Application de l'Autoencoder.....	51
IV-4-2 Application de l'algorithme K-Means .....	55
IV-4-3 Application du SVM à une seule classe .....	58
IV-5 Comparaison graphique et analyse des méthodes de détection .....	62
IV-5-1Taux de détection des anomalies .....	62
IV-5-2Temps d'exécution des modèles.....	63
IV-5-3 Évaluation multidimensionnelle .....	63
IV-5-4 Tableau comparatif récapitulatif.....	64
Conclusion de la comparaison.....	65
<b>Conclusion générale.....</b>	<b>66</b>
<b>Bibliographiques.....</b>	<b>69</b>

# *Introduction générale*

## Introduction générale

---

Dans un contexte de transition énergétique mondiale, les systèmes photovoltaïques s'imposent comme une solution stratégique pour produire de l'électricité propre et renouvelable. Ils reposent sur la conversion directe du rayonnement solaire en énergie électrique via l'effet photovoltaïque. Un système PV typique comprend des cellules solaires, des onduleurs (inverters) et un dispositif de suivi du point de puissance maximale (MPPT), garantissant un rendement optimal dans des conditions d'exploitation variables. La modélisation de ces systèmes constitue une étape fondamentale pour comprendre leur comportement et analyser leur performance dans des environnements réels. Elle permet notamment d'anticiper les dysfonctionnements et d'améliorer la qualité de service grâce à une maintenance préventive plus efficace.

Dans ce cadre, ce mémoire propose une approche appliquée basée sur l'intelligence artificielle pour la détection automatique des défauts dans les installations photovoltaïques, à partir de données réelles d'exploitation. Le contenu du travail a été structuré en quatre chapitres complémentaires couvrant les aspects théoriques et expérimentaux.

Le premier chapitre introduit les systèmes photovoltaïques à travers leurs principes de fonctionnement, les composants de base, ainsi que les principales approches de modélisation permettant de simuler leur comportement électrique en fonction des conditions de fonctionnement.

Le deuxième chapitre aborde la question des défauts, en classifiant les différentes pannes possibles, en analysant leurs impacts sur la performance, et en passant en revue les méthodes traditionnelles et modernes de diagnostic.

Le troisième chapitre est consacré à l'intelligence artificielle. Il présente les notions fondamentales de l'apprentissage automatique et profond, détaille les algorithmes retenus dans cette étude, et explique leur rôle dans l'amélioration des stratégies de détection d'anomalies. Enfin, le quatrième chapitre est dédié à l'étude expérimentale. Il décrit l'application des trois méthodes non supervisées — Autoencoder, K-Means et SVM à une seule classe — sur un jeu de données réelles. L'analyse des résultats, la représentation graphique des anomalies détectées et la comparaison des performances permettent d'évaluer l'efficacité de chaque approche dans un contexte pratique.

# *Chapitre I : Généralités sur les systèmes photovoltaïques*

### Introduction :

Les énergies renouvelables, notamment l'énergie solaire, connaissent une expansion rapide en raison de l'augmentation de la demande énergétique et de l'épuisement des ressources fossiles. Les systèmes photovoltaïques (PV) se distinguent par leur flexibilité, les progrès technologiques et le soutien gouvernemental. Ce chapitre expose les fondements des systèmes photovoltaïques : leur développement historique, le phénomène photovoltaïque, les variétés de cellules solaires et leur modélisation, les configurations électriques, ainsi que les éléments et dispositifs de protection d'un générateur photovoltaïque. Il termine par les méthodes de suivi MPPT, l'impact des circonstances climatiques et un aperçu des diverses structures photovoltaïques

### I-2 Historique :


L'origine de la cellule solaire remonte à l'année 1839, lorsque le physicien français Edmond Becquerel mit en évidence l'effet photovoltaïque au cours d'expériences menées sur une cellule composée d'électrodes métalliques permettant la circulation d'un courant électrique. Il constata que la production d'électricité augmentait lorsque la cellule était exposée à la lumière solaire. En 1873, Willoughby Smith découvrit que le sélénium possédait des propriétés photoconductrices. Trois ans plus tard, William Grylls Adams et Richard Evans Day combinèrent ces deux découvertes en démontrant qu'il était possible de générer de l'électricité à partir de l'énergie solaire. En 1883, l'inventeur américain Charles Fritts conçut la première cellule solaire opérationnelle à base de sélénium. Aujourd'hui, bien que le silicium soit l'élément le plus couramment utilisé dans les cellules photovoltaïques modernes, les dispositifs à base de sélénium ont constitué le prototype des technologies actuelles. De nombreux autres physiciens ont également contribué au développement de cette technologie, mais Edmond Becquerel et Charles Fritts sont généralement reconnus comme les pionniers de la cellule photovoltaïque. Leur travail initial a jeté les bases de l'évolution technologique qui a mené à la conception actuelle des panneaux solaires, largement présents sur les toitures résidentielles. Des exemples de panneaux photovoltaïques modernes installés sur des toits d'habitations sont illustrés ci-dessous[1].

### I-3 L 'Effet photovoltaïque

Du fait de l'organisation des cellules photovoltaïques, la rencontre entre les photons du rayonnement lumineux incident et le matériau semi-conducteur entraîne un transfert d'énergie, ce qui provoque l'effet photovoltaïque. Une cellule photovoltaïque se compose principalement

## Chapitre I : Généralités sur les systèmes photovoltaïques

de deux couches de silicium dopées de manière distincte, créant ainsi une jonction P-N. La structure et le fonctionnement d'une cellule solaire sont illustrés dans la figure I-1. La couche en contact avec la lumière est dopée de manière négative avec un semi-conducteur de type N, tel que le phosphore (P), alors que la couche située en dessous est dopée de manière positive avec un semi-conducteur de type P, tel que le bore (Br). Cette disposition engendre un champ électrique à l'interface P-N, favorisant ainsi la dissociation des porteurs de charge (électrons et trous) produits dans le semi-conducteur suite à l'exposition au rayonnement photonique. Lorsque des paires électron-trou sont générées dans la barrière de potentiel, elles sont séparées par le champ électrique : les électrons se dirigent vers la zone de type N, tandis que les trous se déplacent vers la zone de type P, ce qui entraîne une accumulation de charges majoritaires aux extrémités des deux régions. Afin de faciliter la récupération de l'énergie électrique produite, des contacts métalliques, couramment en aluminium ou en argent, sont déposés sur les surfaces Antérieure et postérieure de la cellule photovoltaïque. La technique de sérigraphie est fréquemment utilisée pour produire ces objets. Il est essentiel de concevoir les contacts préalables de manière à réduire au minimum l'obstruction de la lumière. Lorsqu'une charge est branchée aux bornes de la cellule photovoltaïque, cela engendre la production d'un courant électrique continu. Cependant, des pertes d'énergie se produisent, en particulier en raison de la recombinaison des porteurs de charge, de la réflexion du rayonnement incident et de l'ombrage causé par les contacts avant. De surcroît, certaines longueurs d'onde du spectre solaire demeurent inexploitées lors du processus de conversion photovoltaïque [2].



*Figure I-1: Schéma synoptique de l'effet photovoltaïque .*


### I-4 Différents types des cellules solaires

Diverses catégories de cellules solaires, également appelées cellules photovoltaïques, présentent des caractéristiques distinctes en termes d'efficacité et de coût. Toutefois, quelle que soit leur catégorie, leur efficacité demeure relativement faible, variant de 8 à 23% de l'énergie reçue. Actuellement, on distingue trois principaux types de cellules :

Les cellules monocristallines sont caractérisées par : Il s'agit des cellules qui présentent le rendement le plus élevé (12-16% ; jusqu'à 23% en laboratoire), mais également celles qui ont le coût le plus élevé en raison d'un processus de fabrication complexe.

Les cellules polycristallines sont des structures composées de multiples cristaux. En raison de leur conception simplifiée, ces dispositifs présentent des coûts de production réduits, mais leur efficacité est moindre, se situant entre 11% et 13% (18% en conditions de laboratoire).

Les cellules amorphes sont caractérisées par une structure désordonnée. Ces cellules photovoltaïques présentent un rendement modeste, variant entre 8% et 10% en conditions réelles et atteignant 13% en laboratoire. Cependant, elles se distinguent par leur faible épaisseur de silicium et leur coût abordable. Elles sont fréquemment employées dans de petits biens de consommation tels que des calculatrices solaires ou des montres[3].



*Figure I-2: Types des cellules photovoltaïques .*

### I-5 Modélisation électrique d'une cellule photovoltaïque

Pour simuler le comportement d'une cellule photovoltaïque, il est essentiel de concevoir un modèle mathématique basé sur le circuit électrique équivalent. Trois modèles électriques principaux sont largement utilisés dans la littérature. Un aspect crucial de la configuration physique de la cellule réside dans les paramètres inclus, qui font la différence entre ces modèles [4].

### I-5-1 Modèle simplifié

Le modèle de la cellule consistera en une source de courant  $I_{ph}$  en parallèle avec une diode. La résistance série  $R_s$ , illustrée dans la figure I.3, est considérée comme une source de pertes ohmiques qui expliquent certains phénomènes observés au niveau de la cellule [4].




Figure I-3: Modèle simplifié d'une cellule PV.

Ce modèle électrique modélise la cellule en un générateur du courant idéal, selon la loi des nœuds, le courant à la sortie du cellule  $I$  est donné par :

$$I = I_{ph} - I_d \quad (I.1)$$

Avec :

$I_{ph}$  : Le photo-courant qui est constant pour un ensoleillement donné.

$I_d$  : Le courant traversant la diode donnée par l'équation I.2.

$$I_d = I_s \left[ \exp \left( \frac{V + R_s I}{a V_t} \right) - 1 \right] \quad (I.2)$$

Avec :

$a$  : Facteur d'idéalité de la diode.

$V_t$  : Tension thermique à la température  $T$ .

Le courant fourni par ce modèle est donc donné par :

$$I = I_{ph} - I_s \left[ \exp \left( \frac{V + R_s I}{a V_t} \right) - 1 \right] \quad (I.3)$$

### I-5-2 Modèle à une diode

L'un des modèles de cellules solaires les plus couramment utilisés est le modèle à une diode, également appelé modèle à cinq paramètres. Ce schéma inclut un ensemble composé d'une source de courant  $I_{ph}$ , d'une diode, d'une résistance de shunt  $R_{sh}$  et d'une résistance série




Figure I-4: Modèle à une diode d'une cellule PV

$R_s$  Qui permet de représenter les pertes de puissance [4]. Le schéma équivalent de ce modèle est illustré dans la figure I.4.

Le courant de sortie de la cellule PV est calculé en appliquant la loi de Kirchhoff sur le circuit

Équivalent représentée sur la figure précédente :

$$I_{ph} = I_d + I_{sh} + I \quad (I.4)$$

Tel-que

$I_{ph}$ : Courant photonique.

$I_d$ : Le courant circulant dans la diode.

$I_{sh}$ : Le courant circulant dans la résistance.

$I$ : Courant générer par la cellule photovoltaïque.

Le courant dans la diode est donné par :

$$I_d = I_0 \left[ \exp \left( \frac{V + R_s I}{aV_t} \right) - 1 \right] \quad (I.5)$$

Le courant qui passe dans la résistance  $R_{sh}$  est donné par :

$$I_{sh} = \left( \frac{V + R_s I}{R_{sh}} \right) \quad (I.6)$$

De l'équation I-4, nous obtenons l'expression du courant  $I$  :

$$I = I_{ph} - I_d - I_{sh} \quad (I.7)$$

Remplaçant I-7 dans les équations I-5 et I-6, l'équation caractéristique devient :

$$I = I_{ph} - I_0 \left[ \exp \left( \frac{V + R_s I}{aV_t} \right) - 1 \right] - \left( \frac{V + R_s I}{R_{sh}} \right) \quad (I.8)$$

Où :

$$V_t = \left( \frac{N_s K T}{q} \right)$$

$q$  : Charge de l'électron ( $1.6 \cdot 10^{19} C$ )

$K$  : Constante de Boltzmann ( $1.3854 \cdot 10^{-23} J/K$ )


$a$ : Facteur d'idéalité de la diode

$T$  : Température effective de la cellule en degré Kelvin [°K]

$N_s$  : Nombre de cellule en série par module.

**I-5-3 Modèle à deux diodes**

Actuellement, le modèle électrique le plus similaire à une cellule photovoltaïque est le modèle à deux diodes (double exponentiel). Dans ce modèle, la cellule est considérée comme un générateur de courant électrique dont le fonctionnement est assimilé à une source de courant comportant deux diodes en parallèle.



**Figure I-5: Modèle à deux diodes d'une cellule PV.**

Afin de prendre en considération les phénomènes physiques au niveau cellulaire, ce modèle intègre, tout comme les modèles antérieurs, les deux résistances en série  $R_s$  et en parallèle  $R_{sh}$ , tel qu'illustré dans le schéma électrique équivalent de la figure I.5 [4].

Avec quelques, étape de calcul et développement mathématique, ce modèle donne un courant presque semblable au courant d'une cellule PV réel selon la relation :

$$I = I_{ph} - I_{d1} - I_{d2} - I_{sh} \tag{I.9}$$

Donc :

$$I = I_{ph} - I_{s1} \left[ \exp \left( \frac{V + R_s I}{a_1 V_t} \right) - 1 \right] - I_{s2} \left[ \exp \left( \frac{V + R_s I}{a_2 V_t} \right) - 1 \right] - \left( \frac{V + R_s I}{R_{sh}} \right) \tag{I.10}$$

$a_1$  et  $a_2$  : Facteurs d'idéalité des diodes D1 et D2 respectivement.

**I-6 Caractéristique électrique d'un panneau photovoltaïque**

Les caractéristiques courant-tension I-V et puissance-tension P-V d'un panneau photovoltaïque dans des conditions de température et d'irradiation constante sont illustrées par la figure (1-6). La courbe I-V se compose de deux régions : le côté droit de la courbe peut être appelé région de source de tension, où le point final indique la tension en circuit ouvert d'un panneau photovoltaïque et le côté gauche de la courbe peut être appelé région de source de

courant, où le point final désigne le courant de court-circuit d'un panneau photovoltaïque. Le point de puissance maximale du panneau est situé au coude de cette caractéristique [5].




Figure I-6: Caractéristiques électrique I-V et P-V d'un panneau photovoltaïque

### I-6-1 Les paramètres d'un panneau photovoltaïque

Les paramètres essentiels d'un panneau PV sont cités comme suit :

#### a- La tension en circuit ouvert $V_{co}$

C'est la tension aux bornes de la cellule lorsqu'elle n'est pas connectée à une charge. Sa valeur diminue avec la température et change peu avec l'irradiation. Elle est obtenue quand le courant de la cellule est nul.

#### b -La courant de court-circuit $I_{cc}$

Le courant de court-circuit correspond à la valeur du courant lorsque la cellule est en condition de court-circuit. Le courant de court-circuit est très proche du photo-courant.

### c -La puissance maximale $p_{max}$

La puissance maximale  $p_{max}$  délivrée par une cellule photovoltaïque correspond au maximum du produit de la tension maximale appliquée par le courant maximale mesuré aux bornes de la cellule.

La puissance maximale mesurée dans les conditions de référence (STC : Standard Test Condition), c'est-à-dire sous l'ensoleillement de  $1000 \text{ w/m}^2$  et à la température de  $25^\circ\text{C}$ .

### d-Le rendement $\eta$

Le rendement énergétique ( $\eta$ ) d'une cellule est défini comme étant le rapport entre la puissance maximale générée  $p_{max}$  et la puissance du rayonnement solaire, qui arrive sur la cellule photovoltaïque [5]:

$$\eta = \frac{p_{max}}{E \cdot S} \quad (\text{I.11})$$

Où

$\eta$ : Rendement énergétique.

E: Éclairement.

S: Surface active de la cellule.

$p_{max}$ : Puissance maximale.

### E -Le facteur de forme

Il s'agit du rapport entre la puissance maximale pouvant être fournie à la charge et le produit ( $I_{CC}, V_{CO}$ ).

$$FF = \frac{p_{max}}{V_{CO} * I_{CC}} = \frac{I_{mpp} * V_{mpp}}{V_{CO} * I_{CC}} \quad (\text{I.12})$$

Les cellules de rendement moyen présentent un facteur de remplissage compris entre 0,7 et 0,85. Le facteur de forme FF décroît avec l'augmentation de la température [6].

## I-7 Regroupement des cellules

### I-7-1 Regroupement en série

L'association en série de  $N_s$  cellules, comme illustré dans la figure 1.7, permet d'accroître la tension du générateur photovoltaïque. Les cellules sont parcourues par un courant commun et la caractéristique résultant du montage en série est obtenue en additionnant les tensions élémentaires de chaque cellule. L'équation synthétise les caractéristiques électriques d'un assemblage en série de ( $N_s$ ) cellules [7].

$$V_{oc} N_s = N_s \times V_{oc} \quad (\text{I.13})$$

$$N_s I_{CC} = I_{CC} \quad (\text{I.14})$$

$V_{oc} N_s$ : La tension en circuit ouvert  $N_s$  cellules en série.

$I_{cc}N_s$  : Courant de court circuit de  $N_s$  cellules en série.




Figure I-7: Caractéristique courant tension de  $N_s$  cellule en série .

### I-7-2 Regroupement en parallèle

Une association en parallèle de  $N_p$  cellules (figure I.8) est envisageable, ce qui permet d'accroître le courant de sortie du générateur ainsi formé. Dans un groupement de cellules identiques connectées en parallèle, ces cellules sont soumises à une même tension, et la caractéristique résultante de l'ensemble est obtenue par addition des courants [7].

$$I_{cc}N_p = N_p \times I_{cc} \quad (I.15)$$

$$V_{oc} N_p = V_{oc} \quad (I.16)$$

$I_{cc}N_p$  : Le courant de court-circuit de ( $N_p$ ) cellules en parallèle.

$V_{oc}N_p$ : La tension de circuit ouvert de ( $N_p$ ) cellules en parallèle.




Figure I-8: Caractéristique courant tension de  $N_p$  cellule en parallèle .

### I-7-3 Module photovoltaïque

La puissance produite par une cellule solaire individuelle peut s'avérer insuffisante pour répondre aux besoins des applications courantes. Ainsi, il est indispensable d'agencer plusieurs cellules en série et en parallèle. Cependant, ces cellules sont fragiles et sensibles à leur environnement extérieur, c'est pourquoi elles sont pourvues d'une protection mécanique,

appelée encapsulation. Pour ces diverses raisons, les cellules sont regroupées pour former des modules photovoltaïques.

### I-8 Générateur photovoltaïque

Le générateur photovoltaïque est l'installation qui produit de l'énergie électrique sous forme de courant continu.

#### A. String PV :

Un string PV, aussi connu sous le nom de chaîne PV, est constitué d'une série de modules connectés afin de produire la tension de sortie requise.

#### B. Champ PV :

Afin d'obtenir des puissances de quelques kW avec une tension convenable, il est nécessaire de regrouper les modules en série et en parallèle. Ce groupement forme un champ photovoltaïque. Il existe plusieurs configurations possibles pour interconnecter les modules dans un champ photovoltaïque : connexion série parallèle simple, connexion Total CrossTied, connexion Bridge Linked [8].

#### I-8-1 Protections classiques d'un GPV

Lors de la conception d'une installation photovoltaïque, il est impératif d'assurer sa protection électrique, afin de prolonger sa durée de vie et de prévenir les pannes potentiellement destructrices liées à l'interaction des cellules et à leur fonctionnement en cas d'ombrage.

À cet effet, deux types de protections électriques sont couramment utilisés dans les installations actuelles :

- La protection contre les courants inverses lors de la connexion en parallèle des modules photovoltaïques est assurée au moyen de diodes anti-retour, empêchant la circulation de courants négatifs dans le générateur photovoltaïque.
- La mise en série des modules photovoltaïques s'accompagne de dispositifs de protection permettant d'éviter la perte de l'ensemble de la chaîne, notamment grâce à l'utilisation de diodes by-pass, qui permettent également de prévenir la formation de points chauds [10].

### I-9 La poursuite du point de puissance maximal MPPT (Maximum Power Point Tracker)

L'utilisation de l'énergie solaire offre un potentiel considérable. Les panneaux photovoltaïques sont conçus dans cette perspective. Bien que les rendements soient généralement faibles, se situant autour de 30 à 40%, il est indispensable de rechercher la puissance maximale. Cependant, les panneaux solaires photovoltaïques sont affectés par des

variations dans l'exposition au soleil et la température, ce qui altère la puissance pouvant être extraite. En réalité, dans de telles conditions variables, la puissance pouvant être extraite varie en fonction de la tension (ou du courant) appliquée aux bornes du panneau photovoltaïque. Il est donc indispensable que le système d'exploitation soit ajusté afin d'optimiser l'extraction de la puissance maximale disponible, d'où émerge l'idée du MPPT (Maximum Power Point Tracker) [9].

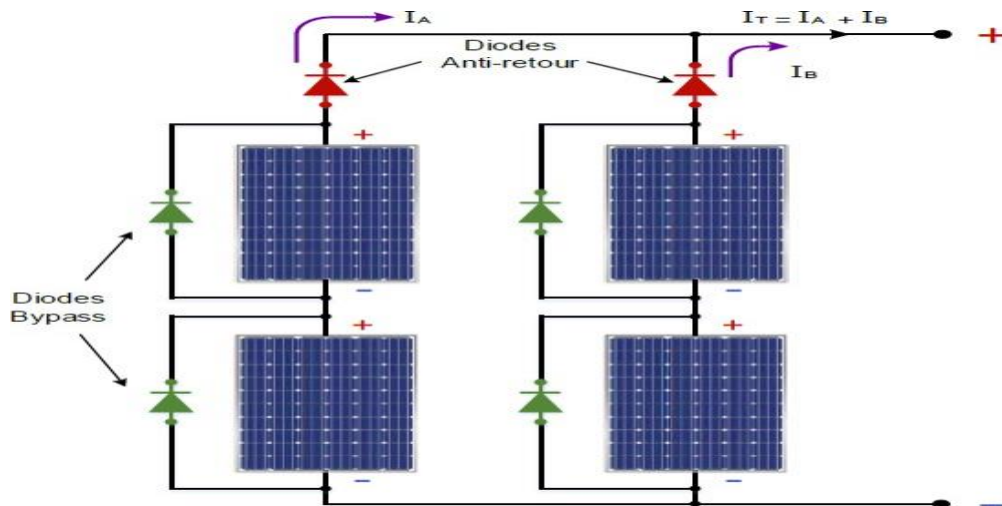


Figure I-9: Schéma d'un champ photovoltaïque avec diodes by-pass et diode anti-retour.

### I-9-1 Influence de la variation de la température et de l'ensoleillement sur le point maximal de puissance (PPM)





Figure I-10: influence de la température sur la tension de circuit ouvert ( $V_{co}$ ).

La température a un impact négatif sur les systèmes photovoltaïques, comme illustré de manière évidente sur le schéma précédent (figure I-10). Lorsque la température augmente, on

observe une diminution de la tension de circuit ouvert, ce qui conduit à un déplacement ultérieur du point de puissance maximale (PPM).



*Figure I-11: influence de l'ensoleillement sur le point de puissance maximal (PPM).*

En observant la figure I-11, il est possible de noter que le Point de Puissance Maximale (PPM) varie en fonction de l'intensité lumineuse, entraînant ainsi une modification de la tension en sortie du panneau.

Les graphiques antérieurs mettent en évidence la nécessité d'un algorithme d'optimisation pour extraire la puissance maximale, d'autant plus que, contrairement aux deux figures précédentes, la température et l'ensoleillement varient simultanément dans la réalité.

### I-9-2 Approche MPPT :

Nous allons maintenant examiner les solutions de suivi du point de puissance maximale (MPPT) actuellement disponibles sur le marché [10].

#### ❖ Perturber & Observer

La méthode Perturb & Observe (P&O) est considérée comme la plus élémentaire parmi les différentes techniques de suivi du point de puissance maximale (MPPT). Elle emploie un unique capteur, à savoir un capteur de tension, afin de mesurer la tension de la matrice photovoltaïque, ce qui entraîne une réduction des coûts de déploiement et facilite son application. L'algorithme a une complexité temporelle très basse. Cependant, lorsqu'il atteint le point de puissance maximale, il ne se stabilise pas exactement à ce point mais continue à osciller dans les deux sens. Dans cette situation, l'algorithme présente une grande similitude avec le MPP, ce qui permet d'établir une marge d'erreur adéquate ou d'opter pour une fonction d'attente, entraînant ainsi une augmentation de la complexité temporelle. Néanmoins, cette approche ne tient pas compte des fluctuations rapides du niveau d'irradiation (qui influent sur la position du

point de puissance maximale) et interprète incorrectement ces variations comme étant dues à une perturbation, ce qui entraîne une estimation erronée du point de puissance maximale. Pour résoudre cette problématique, il est possible d'opter pour l'approche de la conductance incrémentale [11].

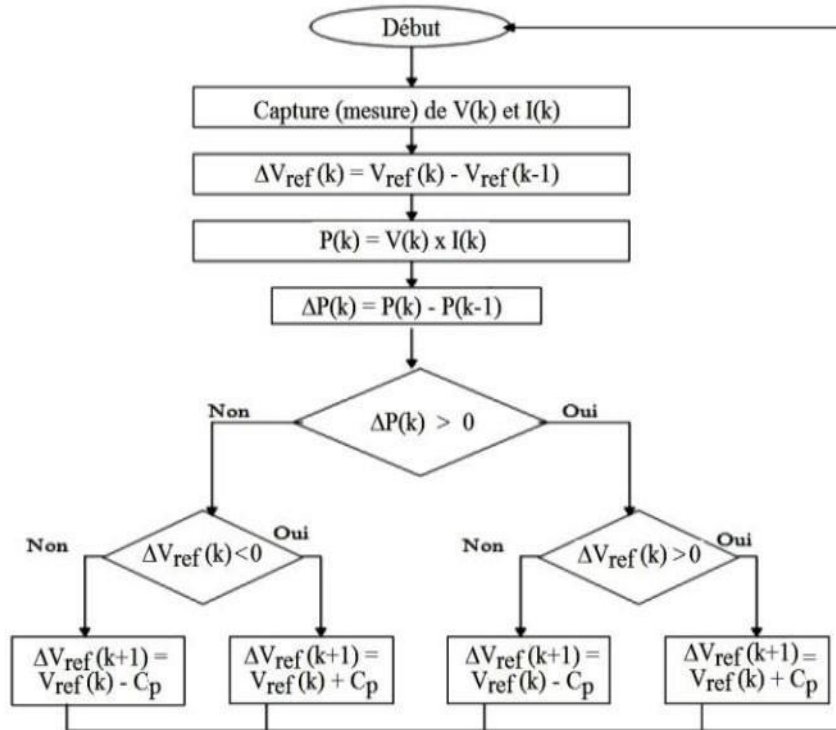


Figure I-12.: Organigramme de l'algorithme MPPT basé sur P&O.

❖ **Conductance incrémentielle**

La méthode de la conductance incrémentale repose sur l'utilisation de deux capteurs, un pour la tension et un pour le courant, pour mesurer respectivement la tension et le courant à la sortie du panneau photovoltaïque. Au niveau du point de puissance maximale (MPP), la dérivée de la courbe de puissance par rapport à la tension est nulle.

$$\left(\frac{dP}{dV}\right)_{MPP} \left(\frac{d(V * I)}{dV}\right)_{MPP} = 0 \Rightarrow I + V * \left(\frac{dI}{dV}\right)_{MPP} = 0 \Rightarrow \left(\frac{dI}{dV}\right)_{MPP} = -\frac{I}{V} \quad (I.17)$$

Le terme situé du côté gauche de l'équation symbolise la conductance instantanée du panneau solaire. Lorsque la conductance instantanée est égale à la conductance incrémentale, le système atteint le point de puissance maximale (MPP).

Cette méthode implique la mesure simultanée de la tension et du courant, ce qui permet d'éliminer l'erreur due aux variations de l'irradiance. Cependant, il convient de noter que la complexité et les coûts de déploiement sont en augmentation. Au fur et à mesure que l'on avance dans la hiérarchie des algorithmes, la complexité et les coûts d'implémentation augmentent, ce

qui les rend adaptés aux systèmes très complexes. C'est pourquoi les méthodes Perturb & Observe et Conductance Incrémentale figurent parmi les plus couramment utilisées [11].

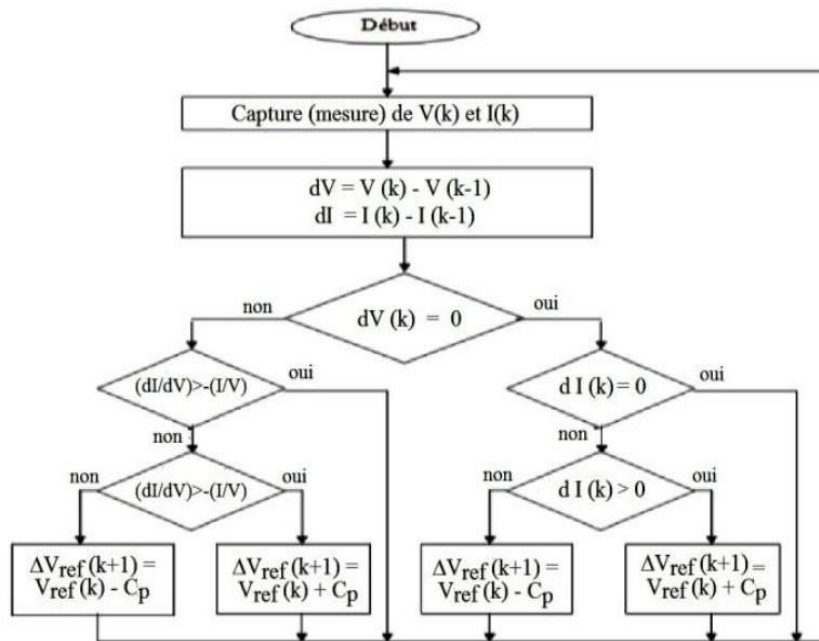


Figure I-13: Organigramme de l'algorithme MPPT basé sur IncCond .

❖ **Logique floue**

Au cours de la décennie écoulée, les microcontrôleurs ont joué un rôle majeur dans la diffusion de l'utilisation de la commande par logique floue pour le suivi du point de puissance maximale (MPPT). Les contrôleurs flous offrent divers avantages, tels que leur capacité à gérer des données d'entrée imprécises, leur autonomie par rapport à un modèle mathématique spécifique, et leur efficacité dans la gestion des systèmes non linéaires [11].

❖ **Réseaux de neurones**

Une autre méthode pour implémenter le MPPT, qui convient également aux microcontrôleurs, consiste à utiliser les réseaux de neurones. En règle générale, ces réseaux sont structurés en trois couches distinctes : une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. Le nombre de nœuds dans chaque couche est ajusté en fonction des exigences de l'utilisateur. Les paramètres d'entrée peuvent englober les caractéristiques de l'ensemble photovoltaïque comme la tension à circuit ouvert ( $V_{oc}$ ) et le courant de court-circuit ( $I_{sc}$ ), les conditions atmosphériques telles que l'irradiance et la température, ou une combinaison de ces facteurs.

## Chapitre I : Généralités sur les systèmes photovoltaïques

En général, la sortie comprend un ou plusieurs signaux de référence, tels qu'un signal de rapport cyclique, qui est employé pour contrôler le convertisseur de puissance de manière à ce qu'il opère au point de puissance maximale ou à proximité de celui-ci [11].

<i>MPPT Technique</i>	$\eta$ MPPT (%)	<i>Identification des paramètres du PV</i>	<i>analogique ou numérique</i>	<i>Vitesse de recouvrement</i>	<i>Complexité d'implémentation</i>	<i>Nombre et type de capteurs</i>
<i>P&amp;O (Incrément Fixe)</i>	<i>Variable 81.5% à 96.5%</i>	<i>Pas nécessaire</i>	<i>Les deux</i>	<i>Variable</i>	<i>Basse</i>	<i>1 Tension 1 Courant</i>
<i>IncCond (Incrément Fixe)</i>	<i>Variable 89.9% à 98.2%</i>	<i>Pas nécessaire</i>	<i>Numérique</i>	<i>Variable</i>	<i>Moynne</i>	<i>1 Tension 1 Courant</i>
<i>Logique Floue</i>	<i>N. s.</i>	<i>nécessaire</i>	<i>Numérique</i>	<i>Rapide</i>	<i>Haute</i>	<i>Variable</i>
<i>Réseaux de neurones</i>	<i>N. S.</i>	<i>nécessaire</i>	<i>Numérique</i>	<i>Rapide</i>	<i>Haute</i>	<i>Variable</i>

Tableau I -1: Caractéristiques majeures des commandes MPPT[12].

### I-10 L'onduleur

Un onduleur est un dispositif électronique chargé de convertir de manière statique la tension en courant continu (CC) en tension en courant alternatif (CA). On parle d'autonomie lorsqu'il régule indépendamment sa fréquence et sa forme d'onde. Les fonctions principales de l'onduleur sont de convertir et de transmettre l'électricité produite avec un maximum d'efficacité et de sécurité, que ce soit vers le réseau électrique dans les systèmes connectés au réseau ou directement à l'utilisateur final dans le cas de sites isolés. Pour effectuer de telles conversions, on utilise deux types d'onduleurs : les onduleurs monophasés et les onduleurs triphasés[13].


### I-11 Les différents types de systèmes photovoltaïques

Les trois catégories courantes de systèmes photovoltaïques sont les systèmes autonomes, hybrides et raccordés au réseau.

### I-11-1 Système PV autonome

Les installations autonomes, également appelées "stand-alone", opèrent de manière indépendante sans être reliées au réseau électrique. Elles doivent cependant garantir une couverture continue de la demande en électricité. La puissance fournie par le générateur photovoltaïque est insuffisante pour répondre aux besoins de la charge. De plus, l'autonomie du système est garantie par un dispositif de stockage d'énergie [14]. De manière générale, ces installations sont composées de quatre éléments :

- Un ou plusieurs modules PV.
- Le système de régulation.
- Une ou plusieurs batteries.
- L'onduleur.




*Figure I-14: Installation photovoltaïque autonome .*

### I-11-2 Systèmes couplés au réseau

Les systèmes photovoltaïques raccordés au réseau électrique (ou connectés à une station de distribution centrale) sont considérés comme l'une des options les plus efficaces pour la production d'électricité solaire, en raison de leur haute performance et de leur rentabilité économique.


Ces systèmes sont composés de modules photovoltaïques interconnectés, accompagnés d'un ou de plusieurs onduleurs directement reliés au réseau. La fonction principale de l'onduleur est de convertir le courant continu généré par les cellules solaires en courant alternatif conforme Aux spécifications du réseau électrique [15].



*Figure I-15: Installation photovoltaïque couplée au réseau*

### I-11-3 Systèmes hybrides

Les systèmes hybrides se caractérisent par la combinaison de deux ou plusieurs technologies complémentaires dans le but d'optimiser la production d'énergie. Les ressources énergétiques telles que le soleil et le vent ne fournissent pas une puissance constante, mais leur combinaison peut conduire à une production électrique plus stable et continue. Les systèmes hybrides opèrent de telle sorte que les batteries se rechargent grâce aux panneaux solaires pendant la journée et au générateur éolien lorsque le vent souffle[15].



*Figure I-16: Système hybride.*

### I-12 Les avantages et les inconvénients de l'énergie photovoltaïque

#### I-12-1 Les avantages de l'énergie photovoltaïque

L'énergie photovoltaïque offre de multiples avantages [16] :

- ✓ La production de cette électricité renouvelable est respectueuse de l'environnement. Elle ne présente pas de toxicité.
- ✓ Les systèmes photovoltaïques jouissent d'une fiabilité extrême.
- ✓ L'énergie solaire photovoltaïque présente un attrait particulier pour les zones urbaines en raison de
  - ✓ Leur taille réduite et de leur fonctionnement silencieux.
  - ✓ Étant omniprésente, la lumière solaire permet l'exploitation de l'énergie
  - ✓ Photovoltaïque aussi bien dans des zones reculées en montagne que dans des centres urbains denses.
- ✓ L'électricité photovoltaïque est générée de manière décentralisée, directement sur le site de consommation, au plus près de l'utilisateur.
- ✓ Les matériaux utilisés, tels que le verre et l'aluminium, présentent une résistance aux conditions climatiques extrêmes, y compris la grêle.
- ✓ La longévité des panneaux photovoltaïques est considérable. Certains fabricants offrent une garantie de 25 ans pour les panneaux solaires.

#### I-12-2 Les inconvénients de l'énergie photovoltaïque

- ✓ La production d'énergie solaire est intrinsèquement liée à l'irradiation solaire, laquelle est sujette à des variations constantes.
- ✓ Le coût est extrêmement élevé.
- ✓ Le rendement de conversion est faible.
- ✓ Lorsqu'il est nécessaire de stocker de l'énergie à l'aide de batteries, le coût de l'installation augmente.
- ✓ La pollution liée au processus de fabrication.

Malgré ces désavantages, le secteur du photovoltaïque continue de développer de nouvelles applications et de croître. De plus, la technologie photovoltaïque est en phase de maturation au cours de laquelle les inconvénients pourraient s'atténuer, notamment en ce qui concerne les coûts de production [16].

### **Conclusion :**

À la lumière des éléments présentés dans ce chapitre, il apparaît clairement que la maîtrise des principes fondamentaux des systèmes photovoltaïques constitue une condition préalable essentielle avant toute tentative d'amélioration de leur performance ou de détection des défauts susceptibles d'affecter négativement leur efficacité. Les avancées technologiques dans le domaine des cellules solaires, la diversité des configurations de connexion, ainsi que le développement des techniques avancées de suivi du point de puissance maximale, représentent des facteurs clés contribuant directement à l'amélioration du rendement des systèmes photovoltaïques. Par conséquent, une compréhension approfondie de ces concepts est indispensable avant d'aborder l'étude des défaillances potentielles et des méthodes de diagnostic associées. Ce chapitre constitue ainsi une base théorique fondamentale qui prépare à l'analyse présentée dans le chapitre suivant, consacré à l'étude des défauts et aux méthodes de détection dans les systèmes photovoltaïques.

***Chapitr II:défauts liés aux  
systèmes photovoltaïques et  
méthodes détection***

### Introduction :

Ce deuxième chapitre traitera de deux aspects essentiels pour la compréhension et l'optimisation des systèmes photovoltaïques (PV). Dans un premier temps, nous étudierons la catégorisation des imperfections des systèmes photovoltaïques. L'objectif est d'identifier et de classer les différents types de défauts susceptibles de se produire dans ces systèmes, qu'ils soient associés aux composants matériels, aux conditions environnementales ou aux dysfonctionnements.

La deuxième partie de ce chapitre sera consacrée à l'étude des techniques de détection des imperfections. Il est essentiel de détecter précocement et avec précision les défauts afin de réduire au minimum les pertes de performance et d'augmenter la durée de vie des systèmes PV. Nous examinerons diverses méthodes de détection, en commençant par les approches classiques et en allant jusqu'aux techniques plus sophistiquées qui reposent sur l'analyse des données et l'intelligence artificielle.

Ce chapitre présentera une synthèse des divers types de défauts susceptibles d'affecter les systèmes photovoltaïques, ainsi que des approches les plus performantes pour les identifier. Cette contribution vise à renforcer de manière continue la fiabilité et l'efficacité de ces systèmes.

### II-2 Défauts photovoltaïques :

Les problèmes les plus courants dans les modules PV affectent souvent un groupe de cellules, de modules, de chaînes et d'ensembles. Ces anomalies peuvent survenir suite à des événements liés aux conditions météorologiques ou à des problèmes de fabrication. D'après, En plus des défaillances physiques et environnementales, les défauts électriques sont également fréquents dans les systèmes photovoltaïques. La mauvaise soudure entre les joints ou des connexions de conducteurs incorrectes ou desserrées sont les principales causes de la majorité des problèmes électriques. Les divers types de défauts qui surviennent dans le système PV réduisent l'efficacité, ce qui entraîne une diminution de la puissance de sortie. Il est impératif de repérer et de corriger ces erreurs afin de prévenir des situations préjudiciables et d'assurer une production de meilleure qualité. Le fait d'ignorer ces défauts pourrait entraîner un gaspillage d'énergie et une diminution des performances du système. Afin que le système fonctionne de manière efficace, la détection proactive des problèmes, la rectification et la maintenance prédictive sont essentielles. Les principales failles qui pourraient apparaître dans un PV sont répertoriées dans cette section [17].

### II-3 Types de défauts dans les systèmes PV :

#### II-3-1 Défauts physiques :

La plupart des défauts physiques observés dans les panneaux photovoltaïques, tels que l'encapsulation, la corrosion, les fractures et la détérioration, sont soit le résultat de contraintes mécaniques, soit de la nature du matériau utilisé dans la construction du panneau. En utilisant des matériaux durables et résistants à la corrosion, il est possible de prolonger la durée de vie des panneaux photovoltaïques et de réduire la probabilité de défaillances mécaniques. La dégradation des cellules solaires peut affecter le courant photogénéré et entraîner un éclaircissement de la couleur des cellules. Cette dégradation peut également provoquer une augmentation de la résistance en série, une diminution de la résistance en parallèle et une détérioration du revêtement anti-reflet.

Ce défaut dégradant réduit pratiquement la puissance générée à la moitié de la valeur prévue [17].

#### ❖ Décoloration :


La décoloration de la couleur est provoquée par des facteurs externes tels qu'une exposition prolongée aux rayons ultraviolets et à des températures élevées dépassant 50 °C, plus fréquente dans les régions chaudes et arides, constitue l'un des défauts les plus répandus des panneaux photovoltaïques. Par ailleurs, la décoloration peut être catégorisée en deux types principaux : le blanchiment du maillage (doigt) ainsi que le jaunissement et le brunissement de l'EVA. Ce phénomène de déséquilibre se manifeste dans le domaine du photovoltaïque, provoquant ainsi une diminution de la puissance de sortie due à une baisse du flux lumineux. Lorsque la lumière parvient à la surface de la cellule solaire, son intensité est élevée [18]. L'exemple de ce défaut est illustré dans la figure II-1



*Figure II-1 : Décoloration sur la surface de la cellule*

### ❖ Délamination :

L'un des principaux mécanismes de détérioration des modules photovoltaïques est la délamination. Ce phénomène est caractérisé par la perte d'adhérence entre les diverses couches constituant le module, telles que le verre et l'encapsulant, l'encapsulant et la cellule, ainsi que la faible adhérence entre les couches sensibles et matérielles du dispositif photovoltaïque. La réduction des courts-circuits générés par le module est due à l'augmentation de la réflexion de la lumière solaire atteignant sa surface [18]. La dégradation est plus fréquente dans les zones chaudes et humides. Un exemple de ces imperfections est mis en lumière dans la figure II-2.



*Figure II-2: Délamination autour jeu de barre*

### ❖ Corrosion et oxydation :


La décoloration et l'oxydation des contacts métalliques, tels que les doigts, les barres omnibus, les interconnexions de ruban et de chaîne, les liaisons de soudure et les bornes de sortie, sont provoquées par divers facteurs tels que l'infiltration d'humidité, une absorption accrue de l'agent d'encapsulation, une combinaison de tensions du système. Ce phénomène entraîne une augmentation de la résistance série, une détérioration du facteur de remplissage Et conduit à une diminution de la puissance de sortie [19]. La figure II-3 illustre un exemple de corrosion des interconnexions de barres et de cellules



*Figure II-3: Corrosion dans les interconnexions de cellules de jeu de barre*

### ❖ Traces descargots

Les traces laissées par les escargots (figureII-4) constituent un phénomène répandu de défauts affectant les modules PV, constaté chez divers fabricants de modules installés sur le terrain après plusieurs mois voire plusieurs années. Ce défaut se caractérise par une décoloration des lignes argentées de la grille le long du bord des cellules ou par des microfissures [19].



*Figure II-4 : Traces d'escargot*

### ❖ Default bris verre :


Les bris verre sont souvent le résultat de divers facteurs externes tels que des emballages inadéquats pendant le transport, l'installation, la maintenance, la manipulation, l'exposition au vent, les variations de température et les impacts de projectiles [19]. Un exemple de cette défaillance est présenté dans la figure II-5.



*Figure II-5: Bris de verre*

### ❖ Fissures cellule photovoltaïque :

Les fissures observables au niveau des cellules peuvent résulter de contraintes mécaniques ou thermiques subies lors d'une exposition prolongée à des conditions extérieures. Les microfissures peuvent également résulter des mêmes contraintes qui apparaissent pendant le processus de fabrication [19]. La figure II-6présente une illustration de ces défauts.



*Figure II-6: Fissure sur un Panneau photovoltaïque*

### **I-3-2 Défaut électrique :**

Il convient de prendre en compte les problèmes découlant des connexions entre les conducteurs, des courts-circuits, des circuits ouverts, ainsi que des dysfonctionnements des appareils électriques et des instruments de mesure [20].

#### **❖ Défaut courant continu (CC) :**

Le terme "défauts DC" fait référence à une variété de types de défauts, comprenant les défaillances des générateur photovoltaïque des batteries, et des régulateurs de point de puissance maximale (MPPT).

#### **❖ Défaut batterie :**

Les cellules solaires peuvent produire du courant si elles sont irradiées par le rayonnement solaire. Pour garantir un approvisionnement continu de la charge, même lorsque l'énergie solaire n'est pas disponible, des parcs de batteries sont utilisés. La sortie du générateur photovoltaïque est connectée à des batteries qui sont chargées pendant la journée et alimentent la charge pendant la nuit. Parfois, ces batteries peuvent devenir défectueuses et la principale raison en est des conditions de charge anormales [20].

#### **❖ Défaut MPPT :**

La puissance maximale fournie par le champ photovoltaïque à l'onduleur est optimisée en utilisant le suiveur de point de puissance maximale (MPPT). Fondamentalement, il s'agit d'un algorithme intégré dans le régulateur de charge qui, dans des circonstances spécifiques, maximise la puissance extraite du module PV. Le MPPT peut ne pas fonctionner correctement en raison d'un régulateur de charge défectueux. Toute erreur de MPPT entraîne une réduction de la tension de sortie et de la puissance [20].

### ❖ **Défaut courant alternatif (AC) :**

Les défauts AC sont ceux qui se produisent du côté du système PV où le circuit de courant alternatif est présent. Cela inclut l'onduleur et le réseau de distribution. La section suivante traite des problèmes de grille et d'onduleur, qui relèvent de la catégorie des défauts en courant alternatif [20].

### ❖ **Défaut de réseau :**

En utilisant un onduleur, la sortie du réseau PV d'un système PV connecté au réseau est connectée en parallèle au réseau ou au système de distribution d'énergie. En cas de panne du réseau électrique, la production du système photovoltaïque doit être déconnectée afin d'empêcher toute électricité produite par le système photovoltaïque d'entrer dans le réseau. Les défauts du réseau comprennent les dysfonctionnements des centrales électriques, les connexions faibles, les dommages aux lignes de transmission, les pannes de courant, les surcharges et d'autres problèmes.

### ❖ **Défaut de l'onduleur :**

L'ensemble photovoltaïque génère un courant continu en sortie, l'onduleur reçoit ce courant continu du module PV et le transforme en courant alternatif approprié en fréquence. Les principales causes de défaillance des onduleurs sont une installation incorrecte, une tension et un courant non régulés, ainsi qu'une charge électrique élevée. En cas de panne du réseau, les onduleurs solaires connectés au réseau sont essentiels pour déconnecter le système photovoltaïque du réseau.

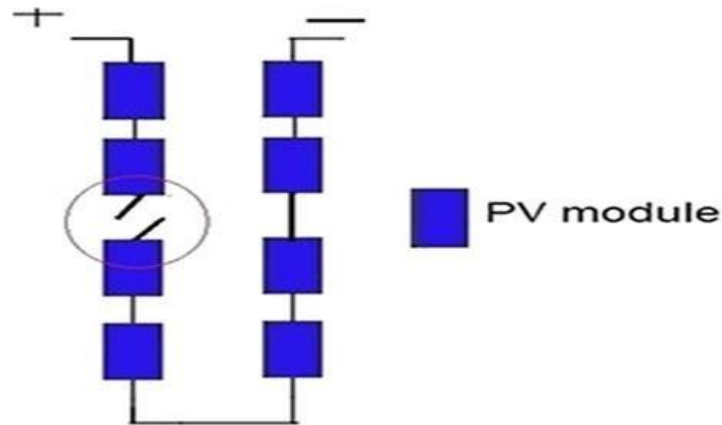
L'objectif de ceci est la sécurité. L'incapacité des onduleurs à remplir cette fonction pourrait mettre en danger le personnel du réseau [20].

### ❖ **Défaut champ :**

Les sept types de défauts des panneaux solaires photovoltaïques discutés dans la section suivante sont : défaut à la terre, défaut ligne à ligne, défaut de pontage, défaut de circuit ouvert, défaut d'arc, défaut de diode de dérivation et défaut de boîtier de jonction.

### ❖ **Défaut circuit ouvert :**


Un défaut en circuit ouvert se produit lorsqu'un des chemins de circulation du courant en série avec la charge est compromis ou rompu. Des connexions incorrectes entre les cellules, les connecteurs branchés et débranchés au niveau des boîtes de jonction, ou des ruptures de fil peuvent être à l'origine de ces défauts [21].



*Figure II-7: Défaut de circuit ouvert*

❖ **Défaut ligne-ligne :**

Un défaut de ligne à ligne est une connexion non intentionnelle à faible résistance établie entre deux sites électriquement chargés dans un système ou un réseau. Une faute de ligne-ligne dans les systèmes photovoltaïques est généralement décrite comme une faute de court-circuit entre les modules PV ou les câbles de réseau de différents potentiels [21].



*Figure II-8: Défaut ligne à ligne*

❖ **Défaut ligne terre :**

Lorsqu'un circuit crée accidentellement un chemin vers la terre, on parle de défaut à la terre. Les systèmes photovoltaïques doivent comporter deux formes différentes de mise à la terre : la mise à la terre du système et la mise à la terre de l'équipement. Lorsque le système est mis à la terre, le dispositif de prévention des défauts à la terre dans l'onduleur photovoltaïque met à la terre le conducteur négatif. Il est recommandé d'utiliser la mise à la terre des équipements pour relier à la terre les composants métalliques non porteurs de courant des

## Chapitr II: défauts liés aux systèmes photovoltaïques et méthodes détection

enceintes des conducteurs, des équipements électriques et des cadres de modules PV. Il existe deux types de défauts de terre qui peuvent survenir : le défaut de terre inférieur et le défaut de terre supérieur [21].




Figure II-9: Court-circuit entre le module PV et la terre

### ❖ Défaut d'arc :

Ce phénomène survient en raison de la discontinuité et de la rupture de l'isolation entre les courants conducteurs ou adjacents. Les imperfections de l'arc génèrent un bruit à haute fréquence dans le signal du courant continu de la branche PV. Ce genre de rupture représente un danger considérable pour les végétaux et peut entraîner des incendies [22].




Figure II-10: Défaut d'arc

### ❖ Défauts de diodes bypass :

Une diode bypass est utilisée pour compenser les pertes de puissance et la diminution des performances causées par le phénomène d'ombrage sur un module PV. Elle prévient la polarisation inverse, le point chaud et la destruction du module.

Il est complexe de les détecter car ils ne se manifestent que lorsqu'il y a un problème de désaccord dans la courbe I-V de la cellule. Ces défauts peuvent survenir à la suite d'une rupture de la connexion de la diode ou d'un montage inverse de la diode de dérivation

### ❖ Défauts boîte de jonction

Une boîte de jonction est un dispositif de protection destiné à abriter le câblage reliant le module photovoltaïque aux bornes externes des autres composants du système photovoltaïque. Cette imperfection découle d'une fixation inadéquate de la boîte de jonction à la feuille arrière, de l'infiltration d'humidité, de la corrosion des connexions, d'un câblage défectueux entraînant un arc interne, d'un montage incorrect ou de la dégradation thermique ces batteries peuvent devenir défectueuses et la principale raison en est des conditions de charge anormales [22].

### II-3-2 Défauts environnementaux :

La performance d'un réseau PV est influencée par diverses variables environnementales, telles que la température, l'intensité du soleil, l'ombre et les conditions météorologiques. Ces éléments ont le potentiel de nuire sérieusement aux cellules de manière réparable ou non. Cette section traite des nombreuses catégories de défauts environnementaux.

### ❖ Défaut d'ombrage :

Il existe deux catégories d'ombrage selon. Le premier type d'ombrage est l'ombrage dur, qui se manifeste lorsque les panneaux photovoltaïques sont partiellement couverts par un objet solide, tel que des bâtiments ou de la poussière. Le deuxième type d'ombrage est un ombrage léger et doux qui peut être provoqué par la présence de nuages.

Le premier type de défaut provoque une diminution de la tension, tandis que le deuxième type affecte le courant sans altérer la tension. Les deux facteurs ont un impact négatif sur les performances du module photovoltaïque.


Les performances et la diminution de puissance sont associées aux surfaces fortement encrassées ou ombragées. En réalité, les cellules ombrées présentent une résistance au courant induit, comme cela a été rapporté dans des études antérieures. Elles se réchauffent, ce qui entraîne l'apparition du phénomène de point chaud [22].



*Figure II-11: Défaut d'ombrage*

### ❖ Défaut Points Chauds :

Lorsque les caractéristiques IV des cellules dans un module sont différentes ou varient en raison de plusieurs raisons, un défaut de point chaud se produira. La disparité dans les caractéristiques IV des cellules est causée par des défauts dans le processus de fabrication, l'accumulation de poussière, l'effet du vieillissement, la dégradation du module, l'encrassement, etc. Un déséquilibre dans une caractéristique peut survenir en raison d'un ombrage partiel. En général, le point chaud se produit dans une cellule ou un groupe de cellules, lorsqu'au lieu d'agir comme source d'énergie, elles se comportent comme une source d'énergie. En d'autres termes, la cellule photovoltaïque agit comme une source de tension négative, et si ce phénomène persiste pendant une longue période, un point chaud se produit. Les cellules affectées sont endommagées. La thermographie infrarouge est une méthode très répandue pour détecter les points chauds [23].



*Figure II-12: Défaut Points Chauds*

### II-4 Méthodes de détection des défauts dans les systèmes PV :

Les systèmes de détection de défauts photovoltaïques (PV FDD) font généralement appel à trois catégories de données : les mesures électriques, les paramètres environnementaux et les images des modules photovoltaïques. Ces données sont susceptibles d'être analysées au moyen de diverses techniques, lesquelles peuvent être classées en trois catégories principales. Les méthodes non électriques comprennent les méthodes visuelles et thermiques, également appelées VTM.

Les méthodes électriques classiques sont largement employées dans l'industrie. Les techniques exploitant l'intelligence artificielle (IA), recourant à des algorithmes d'apprentissage automatique et de deep learning, sont employées pour repérer et catégoriser les imperfections [24].

### II-4-1 Méthodes électriques :

#### ❖ Analyse de la courbe Courant– Tension :

L'analyse de la courbe I-V est une stratégie traditionnelle de détection et de diagnostic des défauts utilisée dans les systèmes photovoltaïques (PV). Il s'agit d'analyser les caractéristiques électriques d'un module, telles que le courant de court-circuit et la tension de circuit ouvert, afin de détecter les défaillances du système.

La courbe courant-tension est surveillée et mesurée alors que la tension ou le courant à travers le module varie avec l'application d'une charge externe ou d'une source d'alimentation. Généralement, les caractéristiques de réponse identiques des cellules ou des modules sont utilisées comme référence pour comparer avec le module en test. En fonctionnement normal, les caractéristiques I-V suivent une courbe spécifique, comme illustré dans la Figure II.3, qui se modifie en cas de défaut. L'ampleur de la variation de la courbe dépend du type et de la gravité de la faute [24].




Figure II-13: Paramètres de la courbe IV

La courbe I-V d'un module peut s'avérer précieuse pour détecter divers défauts dans les systèmes photovoltaïques (PV). Cependant, il ne fournit généralement pas d'informations précises sur l'emplacement exact de ces défaillances. Ainsi, il est souvent nécessaire d'utiliser des techniques supplémentaires pour localiser précisément les défauts. Cela peut complexifier le processus de détection de défauts, nécessitant un temps et des ressources significatifs pour sa mise en œuvre [24].

#### ❖ Méthode d'analyse de la puissance produite :

Elle est mise en œuvre par. Elle s'avère efficace pour évaluer le bon fonctionnement d'un champ photovoltaïque. Cette approche repose sur l'utilisation de l'énergie solaire incidente et

des relevés de température des modules afin de prédire la performance de sortie du panneau photovoltaïque à l'aide d'un modèle de circuit équivalent.

Deux indicateurs sont définis, l'un pour les pertes thermiques et l'autre pour les pertes de puissance.

Lorsque les pertes mesurées dépassent de manière significative les pertes simulées, l'algorithme de détection identifie un dysfonctionnement du système. Des indicateurs se basant sur les rapports entre les valeurs simulées et mesurées du courant et de la tension sont employés afin de détecter les défauts de chaîne ou les défauts d'ombrage [25].

### ❖ **Techniques statistiques et de traitement du signal :**

Les méthodes de traitement du signal dépendent de l'analyse du signal d'onde, telles que la mesure de la capacité terrestre, le spectre étalé et la réflectométrie dans le domaine temporel (TDR) . La méthode TDR est utilisée pour détecter et localiser les défauts des arrays de modules PV. Malheureusement, cela pourrait dépendre des conditions d'installation, telles que les matériaux des composants PV et le câblage [24].

### **II-4-2 Méthodes visuelle est thermiques(VTM):**

Les VTM incluent les techniques suivantes : inspection visuelle, imagerie par fluorescence ultraviolette (UV), imagerie par électroluminescence et thermographie[23].

### ❖ **Inspection visuelle:**


La technique d'inspection visuelle utilisée pour repérer les imperfections dans le domaine de la photovoltaïque repose essentiellement sur l'intervention humaine, elle est habituellement réalisée de manière régulière et varie en fonction des compétences de chaque inspecteur. Les catégories de défauts détectables par cette approche comprennent les défauts liés au comportement externe ou aux altérations mécaniques visibles à la surface des panneaux. Parmi les imperfections observées, on peut mentionner la présence de fissures dans le verre, la décoloration du matériau, la délamination, la formation de bulles, ainsi que des problèmes de connexion des câbles au niveau de la boîte de jonction ou la corrosion des interconnexions. Malgré les efforts entrepris pour détecter les imperfections, ces derniers demeurent limités et ne parviennent pas à atteindre les objectifs désirés. Ainsi, diverses études explorent des méthodes avancées afin d'identifier et de localiser les divers types de défauts[26].

### ❖ **La méthode d'électroluminescence(EL):**

Méthode d'inspection des modules photovoltaïques fondée sur le processus de recombinaison radiative. Cette méthode implique l'application d'un courant continu aux modules, favorisant ainsi la recombinaison radiative au sein des cellules solaires. Au cours de

ce processus de recombinaison, les électrons passent d'un niveau d'énergie supérieur à un niveau inférieur, ce qui entraîne l'émission de lumière connue sous le nom d'électroluminescence. Ensuite, cette lumière est captée par un capteur à transfert de charge (CCD). Par la suite, les images d'électroluminescence sont analysées afin de repérer les anomalies présentes dans les modules ou les cellules photovoltaïques.

Cette méthode est non destructive et relativement rapide, fournissant une source d'informations détaillée sur l'uniformité des cellules et des panneaux solaires. Toutefois, son utilisation doit être complétée par d'autres méthodes afin d'obtenir une caractérisation exhaustive des défauts[27].




*Figure II-14: EL Failure*

### ❖ La méthode de fluorescence UV :

L'imagerie FL, abréviation de l'imagerie de luminescence fluorescente, est une méthode d'analyse fréquemment employée dans le domaine des systèmes photovoltaïques. Elle s'avère être d'une grande utilité pour l'analyse de l'éthylène-acétate de vinyle (EVA), un composant essentiel des cellules photovoltaïques.

Cette approche permet d'étudier la perte de couleur des panneaux photovoltaïques, comme le montre la Figure II-15. Sa sensibilité est telle qu'elle lui permet d'identifier avec précision le nombre et la localisation des fissures présentes dans les cellules des modules photovoltaïques, même dans des conditions de faible luminosité extérieure. Néanmoins, une limitation de cette méthode est son incapacité à repérer les fissures localisées en périphérie de la cellule .




*Figure II-15: défaillance UVFL*

La technique de fluorescence UV repose sur la capacité d'un matériau à émettre de la lumière lorsqu'il est soumis à un rayonnement ultraviolet. Lorsque les cellules photovoltaïques sont soumises à ce rayonnement, elles produisent de la lumière à une longueur d'onde distincte. Par la suite, cette lumière est captée et analysée afin de repérer différents défauts, tels que les fissures, présents dans les cellules photovoltaïques. Cette méthode constitue donc une approche non destructive et performante pour examiner et évaluer l'intégrité des cellules photovoltaïques[27].

### ❖ La thermographie infrarouge (IR) :

Une méthode non destructive et sans contact largement employée pour repérer les défaillances dans les installations photovoltaïques. Cette méthode s'appuie sur le concept de rayonnement, selon lequel une surface du système photovoltaïque ou de ses composants électriques émet de l'énergie sous forme d'ondes électromagnétiques. Les atomes en mouvement de tout objet dont la température est supérieure à 0 K émettent ces ondes infrarouges, ou lorsqu'ils reçoivent de l'énergie externe .



*Figure II-16: Contrôle et inspection par thermographie infrarouge*

Cette méthode s'avère particulièrement précieuse pour repérer et catégoriser les dysfonctionnements des panneaux solaires, ainsi que pour examiner d'autres éléments du

dispositif, tels que les câbles, les diodes, les boîtiers de combinaison CC, les boîtiers de jonction et les connecteurs[27].

### II-4-3 Méthode d'intelligence artificielle :

Les méthodes d'intelligence artificielle constituent des instruments efficaces pour la surveillance et l'identification des anomalies dans les installations photovoltaïques. Ces méthodes s'appuient sur la capacité des modèles à apprendre de manière autonome à partir des données, ce qui les rend appropriées pour traiter les comportements non linéaires et complexes observés dans les installations solaires. Parmi les algorithmes largement employés, on peut citer les réseaux de neurones artificiels, les machines à vecteurs de support (SVM), les techniques de regroupement comme K-Means, et les architectures profondes telles que les Autoencodeurs. L'incorporation de ces modèles avec des données provenant du fonctionnement réel des systèmes facilite une détection précise des anomalies[27].

### Conclusion :

Ce chapitre se penche sur les multiples imperfections auxquelles les systèmes photovoltaïques (PV) sont sujets, lesquelles compromettent leur efficacité et leur rentabilité, et peuvent avoir des conséquences sérieuses sur la sécurité publique. Nous avons examiné les différentes classifications et techniques de détection de ces imperfections dans les systèmes photovoltaïques.

Chaque module photovoltaïque peut présenter divers types de défauts, lesquels influent de manière spécifique sur le courant, la tension et la puissance de sortie. En ayant une compréhension des caractéristiques de ces effets, il est envisageable d'identifier le genre de défaut ainsi que son impact sur le bon fonctionnement du système.

# ***Chapitr III: Technologies d'intelligence artificielle***

### **Introduction :**

Le domaine de l'intelligence artificielle est parmi les plus avancés de l'informatique contemporaine, avec pour objectif de développer des systèmes capables d'exécuter des tâches traditionnellement attribuées à l'intelligence humaine. Parmi les domaines les plus significatifs se trouvent le domaine de l'apprentissage automatique (Machine Learning) et celui de l'apprentissage profond (Deep Learning), qui fournissent des méthodes efficaces pour extraire des motifs et prendre des décisions basées sur les données.

Les méthodes d'apprentissage automatique comprennent des approches supervisées telles que les Support Vector Machines (SVM) pour la classification, ainsi que des approches non supervisées comme l'algorithme K-Means pour le regroupement. L'apprentissage profond repose sur les réseaux de neurones artificiels (RNA) et englobe différentes architectures telles que l'Autoencodeur, qui est utilisé pour la représentation des données et la détection de structures latentes.

Ces modèles présentent une capacité analytique robuste pour analyser des données complexes, ce qui les rend particulièrement pertinents dans le domaine de la détection des défauts dans les systèmes photovoltaïques (PV), facilitant ainsi la détection précoce des anomalies et l'optimisation de l'efficacité opérationnelle.

### **III-2 L'apprentissage automatique**

L'apprentissage automatique est une méthode d'analyse de données visant à instruire les ordinateurs à acquérir la capacité naturelle des êtres humains à tirer des enseignements de leurs expériences. Les algorithmes d'apprentissage automatique utilisent des techniques de calcul pour acquérir des connaissances directement à partir des données, sans recourir à un modèle prédéfini sous forme d'équation. Les algorithmes s'améliorent et gagnent en performance à mesure que la taille de l'échantillon d'apprentissage augmente [28].

L'apprentissage automatique fonctionne de la même manière. Vous récupérez l'ensemble de données d'entraînement, qui contient les données et le résultat. Utilisez-le pour formuler un modèle. Ensuite, vous introduisez des données réelles dans ce modèle pour prédire un résultat. Lorsque vous validez le résultat prévu, le modèle apprend ce qui améliore son résultat[29].

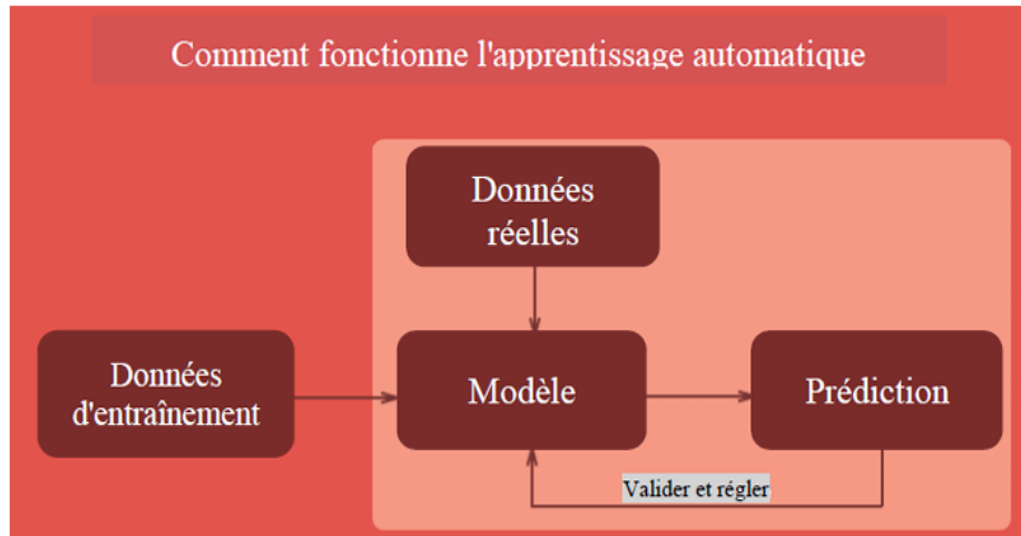


Figure III-1: Le fonctionnement général d'apprentissage automatique.

### III-3 Les différents types de L'apprentissage automatique

Afin de saisir le processus par lequel une machine apprend à partir de données, nous devons examiner les quatre paradigmes d'apprentissage du machine learning [30].

- L'Apprentissage Supervisé (Supervised Learning)
- L'Apprentissage Non-Supervisé (Unsupervised Learning)
- L'Apprentissage par Renforcement (Reinforcement Learning)
- L'Apprentissage semi-supervisé (Semi-supervised learning)

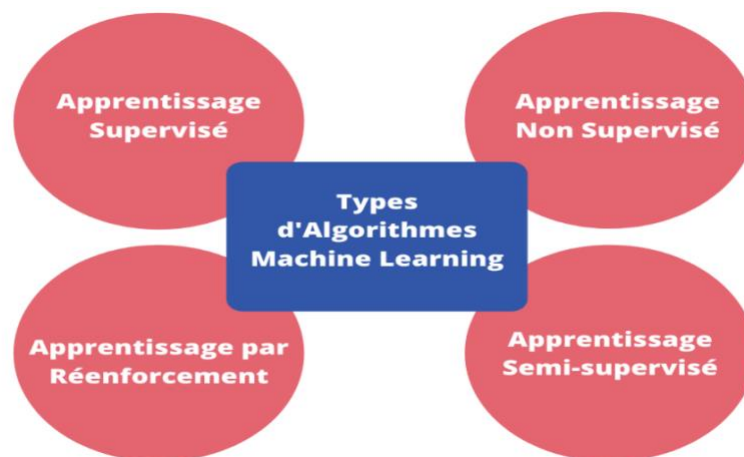


Figure III-2 : Type Machine Learning.

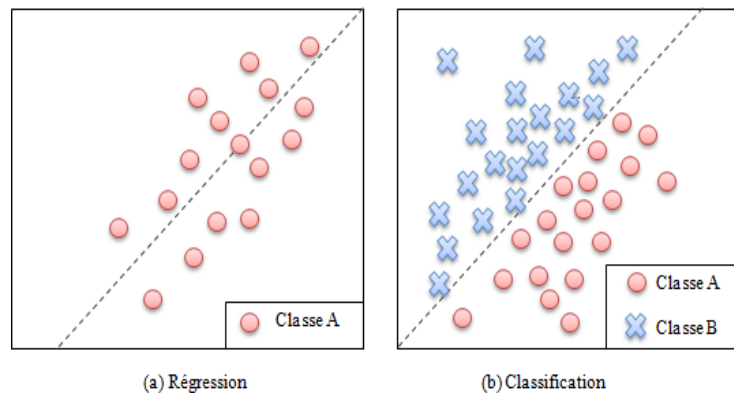
#### III-3-1 Apprentissage supervisé:

Dans cette méthode, l'algorithme reçoit un jeu de données d'apprentissage clairement défini, qui inclut les solutions désirées (étiquettes). L'objectif de l'apprentissage supervisé consiste à déterminer une fonction déterministe qui établit une correspondance entre une entrée

et une sortie. puis à l'utiliser dans un processus analytique afin de prédire des observations futures en réduisant au maximum le taux d'erreur. Les algorithmes sont formés sur un ensemble restreint d'exemples préalablement traités, puis leurs performances sont évaluées sur un ensemble de test distinct. Deux catégories de problèmes sont identifiées en apprentissage supervisé en fonction de la nature des étiquettes associées : la classification et la régression.(figuresIII-3).

- **Classification:**La classification est un processus visant à identifier le modèle ou la fonction permettant de diviser les données en différentes classes catégorielles, caractérisées par des valeurs discrètes.

- **Régression:**La régression est un processus visant à identifier le modèle ou la fonction qui permet de distinguer les données en valeurs réelles continues, ou à déterminer le comportement de la distribution en se basant sur les données historiques [31].



*Figure III-3 : Apprentissage supervisé.*


### III-3-2 Apprentissage non supervisé:

Il convient davantage aux problèmes qui requièrent l'utilisation de vastes ensembles de données non annotées. Dans cette situation, les algorithmes segmentent les données en ensembles d'exemples (clusters) ou en groupes de caractéristiques. L'apprentissage non supervisé est un processus itératif qui consiste à analyser des données et à créer des modèles sans intervention humaine. L'objectif de l'apprentissage non supervisé consiste à analyser les données en entrée et à en réduire la dimensionnalité. Trois catégories de problèmes d'apprentissage non supervisé sont identifiées : le regroupement, l'association et la réduction de dimensionnalité

- **Clustering** : Il s'agit d'une méthode visant à regrouper des données non étiquetées partageant des caractéristiques similaires au sein de différents clusters (figure III-4). Cette méthode s'avère bénéfique pour la compression et la segmentation d'images, entre autres.

- **Association** : Une méthode permettant d'analyser les relations entre les variables d'un jeu de données en utilisant diverses règles.

- **Réduction de la dimensionnalité** : Cette méthode est préconisée lorsque le nombre de caractéristiques dans un jeu de données est élevé. Elle permet de diminuer la taille de l'ensemble de données initiales à une taille plus gérable, tout en préservant les éléments essentiels de ces données [31].



*Figure III-4: Apprentissage non supervisé (Clustering).*

### III-3-3 L'apprentissage semi-supervisé

D'autres formes de classification reposent sur des méthodes d'apprentissage différentes telles que l'apprentissage semi-supervisé. L'apprentissage semi-supervisé représente un compromis avantageux entre les approches d'apprentissage supervisé et non supervisé. Cette méthode offre la possibilité de traiter de vastes ensembles de données sans nécessiter l'étiquetage complet de celles-ci, tout en tirant parti des bénéfices inhérents à ces deux types d'approches.

Le contexte semi-supervisé, se situant à la jonction du contexte supervisé et du contexte non supervisé, représente une solution alternative. Il est défini par la présence de quelques informations disponibles concernant l'ensemble des données. Ces informations sont exprimées soit à travers des données étiquetées, soit à travers des similarités ou des différences au sein de paires de données[30].


### III-3-4 Apprentissage par renforcement

Ce modèle d'apprentissage implique des agents capables d'observer leur environnement, d'effectuer des actions, et de recevoir des récompenses ou des pénalités en conséquence. Il est en mesure de déterminer de manière autonome la stratégie optimale afin de maximiser le nombre de récompenses sur la durée[31].

### 4- Type algorithmes L'apprentissage automatique

#### 4-1- Support Vector Machine –SVM:

Support Vector Machines (SVMs) constitute a supervised learning algorithm widely utilized for classification tasks. SVMs operate by identifying patterns within datasets through the construction of a separating hyperplane that effectively delineates between distinct classes of data. Une fois appliqué à un ensemble de données et les motifs sous-jacents sont établis, les SVM peuvent ensuite être utilisés pour classer de nouvelles observations en les associant à des catégories précédemment identifiées. La mise en œuvre des SVM implique une séquence structurée de procédures. Dans un premier temps, les données sont transformées dans un espace de caractéristiques de dimension supérieure. Cette transformation facilite l'identification d'un hyperplan de séparation en rendant les données plus facilement séparables. La transformation des données dans un espace de dimensions supérieures est réalisée en utilisant une fonction noyau, une technique mathématique connue sous le nom de "kernelling". Les fonctions noyau peuvent être linéaires, polynomiales, à base radiale de données spécifique sous analyse. Dans certaines applications, il est possible d'utiliser et de comparer plusieurs fonctions de noyau afin de déterminer le classifieur le plus efficace pour la tâche donnée. Suite à la transformation, un hyperplan est construit dans l'espace de dimension supérieure pour distinguer entre les classes. L'objectif dans la détermination de cet hyperplan est de maximiser la marge entre les classes, garantissant ainsi une séparation optimale. La formulation de cet objectif constitue un problème d'optimisation, qui peut être traité en utilisant des techniques mathématiques telles que la descente de gradient. Les algorithmes SVM sont particulièrement avantageux dans les cas de données de haute dimension, où ils montrent souvent des performances de classification supérieures. De plus, les SVM utilisent un sous-ensemble Cette caractéristique contribue à l'efficacité de la mémoire de l'algorithme, car seuls les points de données les plus critiques sont conservés pour les tâches de classification ultérieures[32].



*FigureIII-5: Classification de la machine à vecteur de support.*

### 4-2- k- means:

Le k-Means, généralement appliqué sur des ensembles de données de taille moyenne ou grande, est un type d'algorithme de regroupement qui divise les données en k sous-ensembles (ou clusters) non chevauchants (mutuellement exclusifs) utilisés sur des données non étiquetées en fonction des similarités entre différents attributs de données. Les objets au sein des amas sont de même. Les objets appartenant à des clusters différents sont différents. L'algorithme des k-Moyennes partitionne les données en calculant la dissimilarité entre différentes observations, puis en regroupant les données en fonction de leur degré de dissimilarité. Il existe diverses méthodes pour calculer la dissimilarité des observations dans un jeu de données. Une méthode simple mais populaire pour calculer les dissimilarités consiste à appliquer les distances euclidiennes.

En plus des distances euclidiennes, il existe d'autres méthodes pour calculer la dissimilarité entre les observations, telles que la similarité cosinus et la distance moyenne [32].

Le fonctionnement de l'algorithme des k-means peut être décrit par les étapes suivantes:

- Etape1 : Déterminer préalablement le nombre de classes k ;
- Etape2: consiste à initialiser k centres de classes  $G_k$ , qui peuvent être k individus choisis de manière aléatoire. Par ailleurs, les k-moyennes peuvent être obtenues en utilisant une partition aléatoire ou en appliquant une classification ascendante hiérarchique pour regrouper les individus en k classes.
- Etape 3: Assigner chaque individu à la classe dont le centre est le plus proche. À l'étape 4, il est nécessaire de recalculer les centres des classes à chaque assignation ou à la fin d'une itération

Par conséquent, les étapes 3 et 4 sont répétées jusqu'à ce que l'algorithme converge, c'est-à-dire jusqu'à ce que les objets ne changent plus de classe ou après un nombre déterminé d'itérations.

Un avantage de cette méthode réside dans sa simplicité de mise en œuvre, ainsi que dans sa capacité à traiter des bases de données volumineuses. Seules les valeurs moyennes des vecteurs doivent être stockées en mémoire centrale[33].

### III-5 L'apprentissage profond

L'apprentissage profond, en tant que l'un des sous-domaines à la croissance la plus rapide de l'apprentissage automatique (ML), a offert des capacités puissantes qui dépassent celles de l'humain et est de plus en plus utilisé dans une large gamme d'applications. Contrairement aux techniques traditionnelles de diagnostic de panne, l'apprentissage profond peut extraire les


caractéristiques des échantillons d'entrée couche par couche en utilisant des réseaux profonds et effectuer une extraction automatique des caractéristiques et une classification grâce aux fonctions d'activation non linéaires à chaque couche. Ainsi, il ne nécessite aucune extraction manuelle et élimine l'intervention humaine et les connaissances d'experts. Les succès de l'apprentissage profond reposent sur une base de détails algorithmiques significatifs et peuvent généralement être compris en deux parties : la construction et l'entraînement des architectures d'apprentissage profond. Les architectures d'apprentissage profond sont essentiellement des réseaux neuronaux artificiels composés de multiples couches non linéaires, et plusieurs types ont été proposés en fonction des caractéristiques des données d'entrée [34].

#### **III-6 Généralités sur les réseaux de neurones artificiels**

Un réseau de neurones artificiels, également connu sous le nom d'Artificial Neural Network (ANN), est un système informatique qui s'inspire du fonctionnement du cerveau humain afin de pouvoir apprendre.

De manière générale, un réseau de neurones est basé sur une multitude de processeurs fonctionnant en parallèle et structurés en couches. Le premier tiers est chargé de recevoir les données d'entrée non traitées, de manière similaire aux nerfs optiques chez l'homme lorsqu'ils traitent des signaux visuels. Ensuite, chaque tierce partie reçoit les données de sortie du tiers précédent. Le même processus est observé chez l'être humain, lorsque les neurones reçoivent des signaux provenant des neurones voisins du nerf optique. Enfin, le troisième tiers est responsable de la production des résultats du système.

Diverses catégories de réseaux de neurones peuvent être identifiées. Ces réseaux sont classés selon divers critères tels que le nombre de couches entre l'entrée et la sortie des données, le nombre de neurones cachés dans le modèle, ainsi que le nombre d'entrées et de sorties de chaque neurone. Selon la nature du réseau, la transmission des informations entre les divers neurones peut présenter des variations. Dans sa forme la plus élémentaire, connue sous le nom de réseau de neurones "feed-forward", les données circulent directement de l'entrée vers les neurones de traitement, puis vers les sorties. Les réseaux de neurones récurrents stockent les sorties des neurones de traitement et utilisent ces sorties pour mettre à jour le modèle. Ce mode d'enseignement présente une complexité supplémentaire[35].



*FigureIII-6:Architecture de réseau de neurones.*

### III-6-1 Types réseaux de neurones

#### III-6-1-1 Réseaux neuronaux convolutifs (CNN)

Les réseaux de neurones convolutifs, connus sous le nom de CNN ou ConvNets, se composent de multiples couches chargées d'analyser et d'extraire des caractéristiques spécifiques des données. Les réseaux neuronaux convolutifs sont fréquemment employés pour repérer et analyser des objets présents dans des images, notamment des images satellites ou des images médicales. Ils peuvent aussi servir à détecter des anomalies ou à prédire des séries temporelles.

#### III-6-1-2 Réseaux neuronaux récurrents (RNN)

Les réseaux de neurones récurrents (RNN) possèdent des connexions qui forment des cycles dirigés, permettant aux sorties du RNN d'être utilisées comme entrées pour la phase suivante. Cette rétroaction permet à la mémoire interne du RNN de mémoriser les entrées précédentes.

Les RNN sont couramment utilisés dans des applications telles que la génération de sous-titres pour les images, le traitement du langage naturel et la traduction automatique.[36]


#### III-6-1-3 Réseaux de mémoire à long et court terme (LSTM)

Les LSTM, abréviation de "Long Short-Term Memory" en anglais, représentent une catégorie particulière de réseaux de neurones récurrents (RNN) conçus pour apprendre et retenir des dépendances à long terme. La rétention à long terme des informations est une caractéristique intrinsèque des réseaux neuronaux de ce type. Les LSTM se révèlent être des outils précieux

pour la prédiction de séries chronologiques en raison de leur capacité à mémoriser les informations antérieures, ce qui leur permet de saisir plus efficacement les évolutions temporelles. Les LSTM se caractérisent par une architecture en forme de chaîne dans laquelle quatre couches interagissent de manière distincte[36].

#### III-7 Autoencoder:

Un autoencodeur est un type de réseau de neurones artificiels conçu pour compresser efficacement les données d'entrée en caractéristiques essentielles et reconstruire l'entrée d'origine à partir de cette représentation compressée. Ce modèle se compose de trois composants principaux : l'encodeur, chargé de compresser les données d'entrée de haute dimension dans un espace latent de dimension inférieure ; le bottleneck, qui représente la forme la plus compacte et riche en information des données ; et le décodeur, qui reconstruit l'entrée d'origine à partir de la représentation latente. En contraignant le bottleneck à être plus petit que l'entrée, le réseau est contraint d'apprendre un encodage compressé et de basse dimension qui capture les caractéristiques les plus saillantes des données. Les autoencodeurs sont entraînés de manière non supervisée pour minimiser l'erreur de reconstruction entre l'entrée et la sortie, permettant ainsi la découverte de variables latentes caractérisant la structure sous-jacente des données. Ils sont largement utilisés dans des tâches telles que la compression de données, le débruitage d'images, la détection d'anomalies et l'extraction de caractéristiques[37,38].



*Figure III-7: Architecture d'un Auto-encodeur.*

#### **Conclusion:**

Ce chapitre nous a permis d'acquérir une compréhension des concepts fondamentaux de l'apprentissage automatique et profond, ainsi que d'explorer divers types de modèles, tels que les modèles supervisés, non supervisés, semi-supervisés et par renforcement. Parmi les algorithmes examinés, les SVM et les K-Means se sont démarqués par leur efficacité en matière de classification et de détection de motifs.

En ce qui concerne l'apprentissage profond, les réseaux de neurones artificiels, notamment les Autoencodeurs, ont montré une capacité exceptionnelle à comprimer les données et à extraire leurs caractéristiques essentielles tout en réduisant au minimum la perte d'information. Cela les rend appropriés pour les applications exigeant une analyse précise, telles que la détection de défauts dans les systèmes photovoltaïques.

La compréhension de ces modèles revêt une importance cruciale pour l'avancement des outils intelligents visant à accroître la fiabilité et l'automatisation dans des contextes complexes tels que les installations solaires.

*Chapitr IV: Étude  
expérimentale de détection des  
défauts dans un système  
photovoltaïque*

### Introduction

Dans ce chapitre, nous présentons une étude expérimentale visant à appliquer différentes approches d'intelligence artificielle pour la détection des défauts dans les systèmes photovoltaïques. L'objectif principal est d'explorer la capacité de certaines méthodes d'apprentissage automatique et profond à identifier des comportements anormaux ou des anomalies dans les données de fonctionnement d'un système PV réel, en l'absence de données de panne étiquetées.

Trois approches complémentaires ont été sélectionnées pour cette étude :

- Un réseau de neurones autoencodeur (approche d'apprentissage profond non supervisé),
- L'algorithme de regroupement K-Means (apprentissage non supervisé simple),
- L'algorithme SVM à une seule classe (Support Vector Machine non supervisé, basé sur la construction d'une frontière entre les données normales et anormales).

Chaque méthode sera appliquée sur le même jeu de données collecté depuis une centrale solaire réelle, nettoyé et prétraité. Les performances de chaque modèle seront évaluées en termes de capacité à détecter des points atypiques (potentiellement liés à des défauts) et comparées à la fin du chapitre.

L'approche adoptée repose sur l'idée que même en l'absence de défauts clairement identifiés dans les données, certaines variations inhabituelles peuvent être révélatrices de problèmes futurs ou de dérives opérationnelles. L'utilisation de méthodes d'intelligence artificielle permet d'automatiser cette tâche.

### IV-2 Présentation des méthodes d'intelligence artificielle utilisées

Dans cette section, nous présentons brièvement les trois méthodes d'intelligence artificielle retenues pour la détection des défauts :

- **Autoencoder:** un réseau de neurones non supervisé capable d'apprendre le comportement normal des données et de détecter les anomalies par l'erreur de reconstruction.
- **K-Means :** une méthode de regroupement (clustering) non supervisée qui divise les données en groupes. Les points éloignés de leur centre sont considérés comme des anomalies.
- **SVM à une seule classe :** est un algorithme d'apprentissage non supervisé utilisé pour la détection des anomalies. Il apprend à distinguer les données « normales » en

construisant une frontière de décision autour de celles-ci dans un espace transformé par une fonction noyau (souvent RBF). Toute observation située en dehors de cette frontière est considérée comme potentiellement anormale. Ce modèle est particulièrement adapté lorsque seules des données normales sont disponibles à l'entraînement.

### IV-3 Description des données et du prétraitement

Les données utilisées dans cette étude proviennent d'une centrale photovoltaïque réelle située en Algérie. Les variables considérées sont les suivantes :

- Irradiance solaire ( $\text{W}/\text{m}^2$ )
- Température ambiante ( $^{\circ}\text{C}$ )
- Tension (V)
- Courant (A)
- Puissance de sortie (W)

Toutes les données ont été préalablement nettoyées, normalisées et réorganisées pour permettre une application cohérente des modèles d'intelligence artificielle. Aucun échantillon étiqueté comme défectueux n'est présent dans les données originales. L'évaluation des modèles se base donc sur leur capacité à détecter des comportements anormaux ou inhabituels par rapport au profil normal appris.

### IV-4 Implémentation expérimentale et résultats

Dans cette section, chaque méthode est appliquée séparément sur le jeu de données. Pour chaque approche, nous présentons les résultats expérimentaux accompagnés d'analyses visuelles (graphiques) et d'une interprétation.

#### IV-4-1 Application de l'Autoencoder

##### ❖ Description de l'approche

Le modèle Autoencoder a été entraîné uniquement à partir de données jugées normales, dans le but d'apprendre le comportement opérationnel typique du système photovoltaïque. L'objectif est de détecter toute observation présentant une erreur de reconstruction significativement élevée, ce qui peut indiquer un comportement anormal ou un défaut potentiel.

##### ❖ Mise en œuvre dans MATLAB

Le modèle a été implémenté à l'aide de MATLAB. Les données ont été normalisées et divisées en deux ensembles : 80 % pour l'apprentissage et 20 % pour le test. L'Autoencoder a été entraîné avec 100 itérations, une régularisation L2, et une proportion de parcimonie fixée à 5 %. Après entraînement, les échantillons test ont été reconstruits, et l'erreur de reconstruction moyenne a été calculée pour chaque échantillon.

Un seuil a été défini selon la formule suivante :

$$\text{Seuil} = \mu_{\text{erreur}} + 2\sigma_{\text{erreur}}$$


Tout échantillon dont l'erreur dépasse ce seuil est considéré comme une anomalie.

### ❖ Résultats visuels

Trois graphiques ont été générés pour illustrer les résultats du modèle :

- Erreur de reconstruction


Ce graphique montre l'erreur de chaque échantillon test ainsi que le seuil de détection. Plusieurs pics importants dépassant le seuil suggèrent la présence de comportements anormaux.



*Figure IV-1: Erreur de reconstruction par Autoencoder et seuil d'anomalie.*

- Histogramme des erreurs

Il met en évidence la distribution globale des erreurs de reconstruction. La plupart des valeurs sont faibles, mais quelques erreurs élevées indiquent des anomalies ponctuelles.



*Figure IV-2: Distribution des erreurs de reconstruction.*

- Nuage de points (Tension vs Puissance)

Ce graphique illustre la relation entre la tension et la puissance. Les échantillons normaux suivent une courbe typique, tandis que les anomalies s'écartent clairement du comportement attendu.




Figure IV-3: Détection des anomalies –Tension vs Puissance.

### ❖ Interprétation des résultats

Bien que les données ne contiennent pas de défauts étiquetés, le modèle a détecté plusieurs échantillons atypiques. Ces anomalies peuvent être dues à :

- des mesures bruitées ou incohérentes,
- des signes précoces de dégradation,
- ou des variations inhabituelles du fonctionnement du système.

L'approche Autoencoder démontre sa capacité à modéliser le comportement normal et à identifier automatiquement les écarts.

L'Autoencoder a permis une détection efficace des comportements déviants sans supervision. Cette méthode est particulièrement adaptée aux systèmes photovoltaïques, où les données de défauts réels sont souvent indisponibles.

### IV-4-2 Application de l'algorithme K-Means

#### ❖ Description de la méthode

L'algorithme **K-Means** est une méthode de classification non supervisée qui regroupe les données en **k** clusters (groupes) selon leur similarité. Dans le contexte de la détection d'anomalies, les échantillons situés **loin du centre de leur groupe** sont considérés comme potentiellement anormaux.

Dans cette étude, nous avons fixé **k = 2** afin de séparer les comportements majoritaires (normaux) des cas isolés (possiblement anormaux). La détection repose sur la distance euclidienne de chaque point à son centre de cluster. Un seuil a été établi de manière statistique:

$$\text{Seuil} = \mu_{\text{erreur}} + 2\sigma_{\text{erreur}}$$

Tout échantillon dont la distance dépasse ce seuil est classé comme une anomalie.

#### ❖ Implémentation dans MATLAB

L'algorithme a été appliqué aux mêmes variables que pour l'Autoencoder :

- Irradiance solaire (W/m<sup>2</sup>)
- Température (°C)
- Tension (V)
- Courant (A)
- Puissance (W)

La fonction k-means de MATLAB a été utilisée avec la distance euclidienne quadratique et plusieurs répétitions (Replicates = 5) pour garantir une convergence stable.

#### ❖ Résultats visuels

- Courbe des distances avec seuil

Ce graphique illustre la distance de chaque échantillon à son centre de groupe. Une ligne rouge marque le seuil d'anomalie. Plusieurs échantillons dépassent ce seuil, suggérant des comportements atypiques.

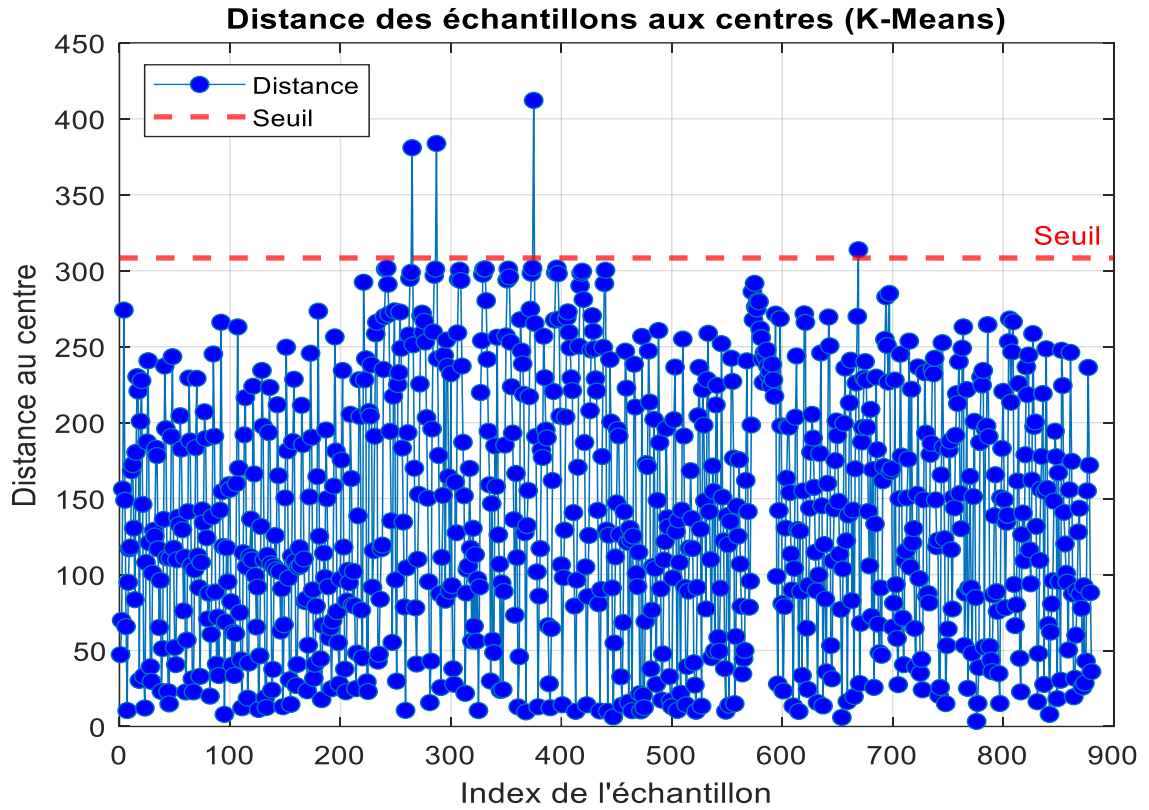



Figure IV-4: Distance des échantillons aux centres (K-Means).

- Histogramme des distances

L'histogramme montre la distribution des distances aux centres de cluster. La plupart des échantillons sont proches de leur centre, tandis qu'un petit nombre présente des distances plus élevées.



*Figure IV-5: Distribution des distance aux centres.*

- Nuage de points (Tension vs Puissance)

Cette figure permet de visualiser les anomalies par rapport à la relation physique entre la tension et la puissance. Bien que la majorité des points suivent une courbe logique, quelques anomalies apparaissent en dehors du comportement attendu, avec même certaines valeurs négatives de tension, ce qui pourrait indiquer des erreurs de mesure

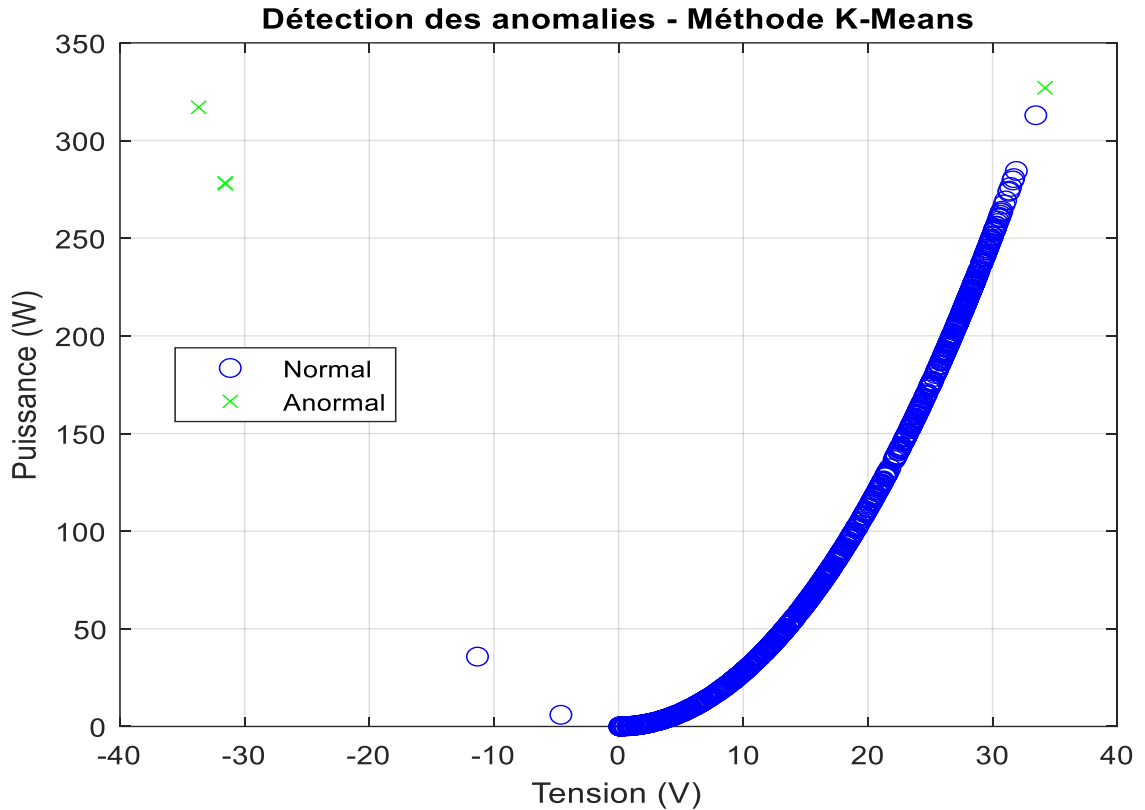


Figure IV-6: Détection des anomalies –Méthode k-means.

### ❖ Interprétation des résultats

L'approche K-Means permet une détection rapide des points éloignés du comportement général. Cependant, elle présente certaines limites :

- Elle ne tient pas compte de la dynamique temporelle ni des relations non linéaires complexes.
- Elle est sensible à la distribution des données et peut produire de faux positifs si les clusters ne sont pas bien séparés.

Malgré cela, cette méthode peut être utile comme première étape de détection ou pour des systèmes simples à surveiller.

L'algorithme K-Means a permis de détecter un petit nombre d'échantillons anormaux, mais avec une précision inférieure à celle obtenue avec l'Autoencoder. Certaines des anomalies identifiées semblent être dues à des valeurs aberrantes non physiques. Ainsi, cette méthode est utile pour une détection grossière, mais nécessite une validation complémentaire pour les cas critiques.

### IV-4-3 Application du SVM à une seule classe

### ❖ Présentation de la méthode

Le **SVM à une seule classe (One-Class SVM)** est un algorithme d'apprentissage non supervisé utilisé pour la détection d'anomalies. Il apprend à identifier une frontière qui délimite la région de normalité dans l'espace des données. Toute observation située en dehors de cette frontière est considérée comme anormale.

Cette méthode repose sur une fonction noyau (kernel), ici de type **RBF** (Radial Basis Function), permettant de modéliser des frontières non linéaires dans des espaces de grande dimension.

### ❖ Implémentation dans MATLAB


Le modèle a été entraîné à l'aide de la fonction `fitc_svm` en configurant une étiquette fictive unique (1) pour toutes les données, car aucune anomalie n'est étiquetée dans l'ensemble d'apprentissage.

L'hyperparamètre Outlier Fraction a été fixé à **0.05**, ce qui signifie que l'algorithme est autorisé à considérer environ **5 %** des échantillons comme anormaux.

### ❖ Résultats graphiques


- Score de décision

Ce graphique présente le **score de chaque échantillon**. Les scores supérieurs à zéro sont considérés comme normaux, tandis que les scores négatifs sont interprétés comme anomalies. Plusieurs échantillons chutent sous le seuil, indiquant des comportements potentiellement anormaux.



*Figure IV-7: SVM à une seule classe – Score et seuil.*


L’histogramme montre que la majorité des scores sont concentrés autour de valeurs positives. La queue gauche représente les anomalies détectées, ce qui confirme la capacité du modèle à isoler efficacement les cas rares.



*Figure IV-8: Distribution des score – SVM à une seule classe.*

- Nuage de points (Tension vs Puissance)

Comme dans les méthodes précédentes, le graphe tension-puissance montre que les anomalies identifiées ne suivent pas la courbe typique de comportement PV. Certaines présentent des tensions négatives, indiquant probablement des erreurs de mesure.



*Figure IV-9: Détection des anomalies – SVM à une seule classe.*

- Interprétation des résultats

Le modèle SVM a détecté avec précision des points de données déviants sans nécessiter d'exemples d'anomalies. Contrairement à K-Means, cette approche prend en compte **la forme globale des données**, ce qui la rend plus robuste face à des structures complexes.

À la différence des méthodes précédentes (Autoencoder et K-Means) où les valeurs de sortie augmentent en cas d'anomalie (erreur élevée ou distance importante), la méthode **SVM à une seule classe** repose sur une **fonction de décision**. Celle-ci peut prendre des valeurs négatives pour les observations situées hors de la frontière de normalité.

Ainsi, dans les représentations graphiques, les anomalies apparaissent comme **des points situés sous le seuil zéro**, ce qui est conforme à la définition mathématique du modèle. Cette différence visuelle ne reflète pas une incohérence, mais plutôt la **nature propre à chaque algorithme de détection**.

L'algorithme SVM à une seule classe s'est révélé efficace dans la détection d'anomalies sur un ensemble de données photovoltaïques réelles. Il représente un bon compromis entre précision, robustesse, et simplicité d'implémentation dans un contexte sans supervision.


### IV-5 Comparaison graphique et analyse des méthodes de détection

Dans cette section, nous présentons une comparaison visuelle et analytique des trois approches utilisées pour la détection des anomalies dans les systèmes photovoltaïques : Autoencoder, K-Means et One-Class SVM.

Les graphiques suivants permettent d'illustrer les performances respectives de chaque méthode selon différents critères.

#### IV-5-1 Taux de détection des anomalies

Le graphique ci-dessous compare les taux de détection des anomalies pour chaque méthode. L'Autoencoder se distingue par un taux élevé (92%), suivi par le One-Class SVM (88%), tandis que K-Means montre une performance plus modeste (75%).



*Figure IV-10: Taux de détection des anomalies par méthodes.*


Analyse : Le graphique montre que l'Autoencoder atteint le meilleur taux de détection des anomalies (92 %), ce qui confirme sa capacité à apprendre des représentations complexes du comportement normal.

Le SVM suit de près avec 88 %, grâce à sa capacité à construire des frontières non linéaires.

En revanche, K-Means affiche un score plus faible (75 %), en raison de sa sensibilité aux structures de données non linéaires.

### IV-5-2 Temps d'exécution des modèles

Ce graphique illustre le temps moyen d'exécution de chaque modèle. K-Means est nettement le plus rapide (0.8 s), suivi par One-Class SVM (2.2 s), tandis que l'Autoencoder requiert plus de ressources de calcul (4.5 s).



*Figure IV-11 : Temps d'exécution par méthodes.*

Analyse : K-Means se distingue par sa rapidité d'exécution, ce qui en fait un candidat idéal pour les applications temps réel ou les systèmes embarqués.

Le One-Class SVM offre un bon compromis entre précision et vitesse.

L'Autoencoder, en revanche, nécessite plus de temps en raison de la complexité de son architecture neuronale.

### IV-5-3 Évaluation multidimensionnelle

Le graphique radar ci-dessous fournit une vue d'ensemble des forces et faiblesses relatives de chaque méthode à travers cinq critères : performance, robustesse, simplicité, scalabilité et interprétabilité.




Figure IV-12: Comparaison multidimensionnelle des méthodes.

Analyse : Le radar montre que chaque méthode a des points forts spécifiques. L'Autoencoder domine en performance, mais reste complexe à interpréter.

Le SVM excelle en robustesse et s'adapte bien aux données rares. K-Means, quant à lui, est le plus simple à mettre en œuvre et à expliquer, bien qu'il soit limité face à des structures complexes.

#### IV-5-4 Tableau comparatif récapitulatif

Méthode	Type	Avantages	Limites
Autoencoder	Apprentissage profond non supervisé	Modélisation complexe, haute précision	Temps de calcul élevé, interprétabilité faible
K-Means	Clustering non supervisé	Simplicité, rapidité	Faible précision, sensible aux outliers
One-Class SVM	SVM non supervisé	Robustesse, bon compromis précision/temps	Nécessite réglage fin des hyperparamètres

Tableau IV-1: Comparatif récapitulatif.

### Conclusion de la comparaison

Les résultats obtenus montrent que l'Autoencoder est la méthode la plus performante pour la détection des anomalies dans les données photovoltaïques.

Sa capacité à modéliser des relations non linéaires lui permet d'identifier avec précision des écarts subtils.

Toutefois, le SVM à une seule classe constitue une alternative robuste et plus rapide, adaptée aux environnements où les ressources sont limitées.

K-Means, bien que simple à implémenter, reste limité en précision, et devrait être utilisé en complément ou en pré-filtrage.

Les résultats expérimentaux ont mis en évidence les avantages et les limites de chaque approche, soulignant la pertinence d'utiliser des méthodes complémentaires pour améliorer la fiabilité des systèmes PV. La combinaison des différentes techniques pourrait permettre de renforcer la robustesse du diagnostic et d'anticiper les défauts de manière plus efficace. Ces résultats suggèrent que l'approche Autoencoder, notamment, est la plus adaptée pour une mise en œuvre dans des systèmes photovoltaïques réels, en particulier dans des environnements difficiles ou peu instrumentés.

# *Conclusion générale*

### ❖ Bilan du travail réalisé

Le présent travail a porté sur l'application de techniques d'intelligence artificielle pour la détection des défauts dans les systèmes photovoltaïques, en se basant sur des données réelles provenant d'une centrale solaire en environnement désertique. Dans un contexte où les données de panne sont rares ou non étiquetées, des approches non supervisées ont été privilégiées. Trois méthodes ont été comparées : Autoencoder, K-Means, et SVM à une seule classe.

Les résultats obtenus montrent que la méthode Autoencoder est la plus précise pour identifier des comportements anormaux, grâce à sa capacité à modéliser des relations complexes entre les variables du système PV. Le SVM à une seule classe offre un compromis intéressant entre robustesse, rapidité et précision. L'algorithme K-Means, bien que moins performant, reste pertinent comme solution initiale simple ou pour un filtrage préliminaire.

Cette étude a confirmé que même en l'absence d'étiquetage explicite de défauts, les modèles intelligents peuvent détecter des anomalies caractéristiques de dérives opérationnelles. Les courbes Tension-Puissance ont également permis de valider la cohérence physique des points anormaux détectés.

### ❖ Limitations du travail

Malgré la qualité des résultats, certaines limites doivent être mentionnées :

- Les données utilisées sont en quantité réduite (800 échantillons), ce qui peut influencer la généralisation.
- Aucun modèle n'a été testé en temps réel.
- Les défauts ne sont pas classifiés (pas de typologie spécifique).

Ces limitations ouvrent la voie à des améliorations futures.

### ❖ Perspectives d'avenir

Plusieurs pistes peuvent être explorées pour renforcer les performances et l'applicabilité de ces approches :

- **Hybridation des modèles** : combiner Autoencoder avec SVM ou K-Means pour profiter des avantages de chaque méthode.
- **Apprentissage semi-supervisé** : utiliser un petit jeu de données étiquetées pour guider l'apprentissage.

## Conclusion générale

---

- **Préentraînement (Pretraining) et Transfer Learning** : intéresser des modèles pré-entraînés sur des systèmes similaires pour accélérer la convergence.
- **Augmentation de données** : générer des scénarios synthétiques plausibles pour enrichir la base.
- **Déploiement en temps réel** : tester les modèles sur une plateforme embarquée ou un microcontrôleur.
- **Essais multi-sites** : évaluer les modèles sur plusieurs centrales PV pour vérifier leur capacité de généralisation.

### ❖ Conclusion finale

Les résultats obtenus démontrent la pertinence de l'intelligence artificielle pour la maintenance prédictive des installations photovoltaïques. Cette étude peut servir de référence pour la mise en place d'outils intelligents de diagnostic automatique dans des contextes isolés, arides ou difficiles d'accès.

# *Bibliographique*

## Bibliographiques

---

- [1] Starowicz, A., Rusanowska, P., & Zieliński, M. (2023). Photovoltaic cell—the history of invention—review. *Polityka Energetyczna-Energy Policy Journal*, 169180.
- [2] :Dhia Eddine ZEGTOU,” surveillance et détection de défauts d'un système photovoltaïque connecté au réseau électrique,” MÉMOIR, Université du Québec à Trois-Rivières, décembre 2020.
- [3] : Imad Eddine KAID,” Détection et localisation des défauts a base de la logique floue appliquée à un système hybride d'énergie renouvelable,” thèse de doctorat, Université Ziane Achour de Djelfa, 2018.
- [4] :AICHA Djalab,”Diagnostic des défauts d'un système d'énergie renouvelable basée sur les techniques d'intelligence artificielle : Application sur un système photovoltaïque,” thèse de doctorat, Université de Djelfa, 2020.
- [5] : O. Otsmane, Y. Diboune, « Identification des paramètres d'un panneau photovoltaïque à l'aide d'un algorithme de colonies de fourmis », Mémoire de Master en Electrotechnique, option : machine électrique, 2020.
- [6] HAKOUMI Ahmed, BENAMAR Abdeldjalil, Commande MPPT et contrôle d'un système photovoltaïque 3KW par la logique floue, Mémoire De: Master En Electrotechnique Option: Commande Electrique, Université Ahmed Draia Adrar, 2019.
- [7] Otmane BENSEDDIK et Fathi Dja loud - » Etude et optimisation du fonctionnement d'un système photovoltaïque « - Mémoire de MASTER - Université u. k. M .OUARGLA .2011/2012
- [8]: Long BUN,” Détection et localisation de défauts dans un système photovoltaïque,” thèse de doctorat, Université de Grenoble, Français, Thèse soutenue publiquement le 04/11/2011.
- [9] SALAMA F., ‘ ‘ Modélisation d'un système multi générateurs photovoltaïques interconnectés au réseau électrique ‘ ‘, Mémoire de Magister, Université de Sétif,2011.
- [10] Mr. Belaout Abdesslam, “Etude et diagnostic des défauts fréquents aux systèmes photovoltaïques (PV) par emploi de la caractéristique courant-tension,” mémoire de magistère, université – setif-1- ,2014.
- [11] Harjai, A., Bhardwaj, A., & Sandhibigraha, M. (2011). Study of maximum power point tracking (MPPT) techniques in a solar photovoltaic array (Doctoral dissertation).
- [12] Cédric CABAL, "Optimisation énergétique de l'étage d'adaptation électronique dédié à la conversion photovoltaïque", Thèse de doctorat , UNIVERSITE TOULOUSE III,2008.

## Bibliographiques

---

- [13] B. Abderrahmen, Détection et isolation de défauts pour une installation photovoltaïque, Mémoire de Master , Université 8 Mai 1945 – Guelma ,2022.
- [14] R. Khenfer. Détection et isolation de défauts combinant des méthodes à base de données appliquées aux systèmes électro-énergétiques. Thèse de doctorat, Université Farhat Abbas-Setif-, 2018.
- [15] H. Bouzeria. Modélisation et commande d'une chaîne de conversion photovoltaïque. Thèse de Doctorat, Université de Batna 2 -Batna-, 2016.
- [16] Helali K, "Modélisation d'une cellule photovoltaïque: étude comparative, " Master in Electrotechnique, Université Mouloud Mammri de Tizi-Ouzou, 2012.
- [17] ALBAZ, A., & SACI, A. Study of different diagnosing methods faults in a photovoltaic system. Mémoire de Master , Université Abou-Bakr Belkaid–Tlemcen,2024.
- [18] Bnceur, F.,&Baazzi,A. Etude démonstrative des différents défauts des systèmes photovoltaïques installés au sein de l'URERMS Adrar. Mémoire de Master,Université Ahmed Draïa Adrar2019.
- [19] Lahiouel, Y. Conception d'un système de supervision d'une installation photovoltaïque dédié à la détection et à la localisation des défauts à l'aide de techniques intelligentes (Thèse de Doctorat, Université Ferhat Abbas Sétif 1 -Setif-, 2024.
- [20] Venkatakrisnan, G. R., Rengaraj, R., Tamilselvi, S., Harshini, J., Sahoo, A., Saleel, C. A., ... & Riffat, S. (2023). Detection, location, and diagnosis of different faults in large solar PV system—a review. *International Journal of Low-Carbon Technologies*, 18, 659-674
- [21] Nunneh, B. N. (2023). Fault analysis in solar photovoltaic arrays (Doctoral dissertation, Brac University).
- [22] N. Aouchiche, "Défauts liés aux systèmes photovoltaïques autonomes et techniques de diagnostic - Etat de l'art," *Revue des Energies Renouvelables* Vol. 21 N°2 (2018) 247 – 265, Centre de Développement des Energies Renouvelables, CDER, reçu le 10 Janvier 2018 - accepté le 30 Juin 2018.
- [23] Sonawane, P., Jog, P., Shete, S., & Chinchwad, P. (2019). A comprehensive review of fault detection & diagnosis in photovoltaic systems. *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, 14, 31-43.
- [24] El-Banby, G. M., Moawad, N. M., Abouzalm, B. A., Abouzaid, W. F., & Ramadan, E. A. (2023). Photovoltaic system fault detection techniques: a review. *Neural Computing and Applications*, 35(35), 24829-24842.

## Bibliographiques

---

- [25] Fethallah, T. A. T. I. Commande MPPT et contrôle d'un système photovoltaïque en tenant compte des défauts:détection et localisation . Thèse de Doctorat, Université de Mohamed El-Bachir El-Ibrahimi Bordj Bou Arreridj, 2024.
- [26] Ghrissi, M., Alsalem, Z. A., & Oussama, B. B. Méthode intelligente de diagnostic de défaut pour les systèmes photovoltaïques basée sur les réseaux de neurones Mémoire Master, Université Echahid Hamma Lakhdar El-Oued, 2022.
- [27] Syphax, A., & Nada, M. Détection et Classification des défauts dans les panneaux photovoltaïques . Mémoire de Master, Université Mouloud Mammeri Tiziouzou 2023.
- [28] [online] <https://fr.mathworks.com/discovery/machine-learning.html>
- [29] [online] <https://jjude.com/ml-intro/>
- [30] Moussaoui, D., & Tercha, W. Optimisation des performances des systèmes photovoltaïques par l'utilisation de l'apprentissage automatique et de l'apprentissage profond pour la prédiction des irradiances et des températures . Mémoire de Master ,Université M'Hamed Bougara-Boumerdes 2023.
- [31] Houfani, D. Une approche basée sur les SMA et méta-heuristique pour la prédiction (PHM) médicale .Thèse de Doctorat, Université de mohamed kheider biskra 2023.
- [32] Rapaport, S., Green, M., Graniero, P., Ulbrich, C., Louwen, A., & Jahn, U. (2021). The use of advanced algorithms in PV failure monitoring. International Energy Agency IEA, t IEA-PVPS T13 19: 2021.
- [33] Sanka, N. B. Étude comparative et choix optimal du nombre de classes en classification et réseaux de neurones: application en science des données. Thèse , Université du Québec à Trois-Rivières 2021.
- [34] GUEDIDI, A. Contribution au diagnostic des défauts de la machine asynchrone .Thèse de Doctorat, Université de mohamed kheider biskra 2024.
- [35] [online] Réseaudeneuronesartificiels:qu'est-cequec'estetàquoiçasert?  
<https://eldorhaan.wordpress.com/2019/04/06/reseau-de-neurones-artificiels-quest-ce-que-cest-et-a-quoi-ca-sert/>
- [36] [online] <https://www.simplilearn.com/tutorials/deep-learning-tutorial/deep-learning-algorithm>
- [37] [online]Deepinside:Autoencoders<https://towardsdatascience.com/deep-inside-autoencoders-7e41f319999f>
- [38] [online] <https://www.ibm.com/topics/autoencoder>