République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Mouloud Mammeri de Tizi-Ouzou

Faculté de Génie de la Construction

Département d'électromécanique

MEMOIRE DE FIN D'ETUDE

En vue de l'obtention du diplôme académique Master

Filière : *Electromécanique*

***Option** : Maintenance industrielle*

Thème

Détection et Classification des défauts dans les panneaux photovoltaïques

Encadré par :

Mme. OUSSIDHOUM Samira

Présenté par :

M. ABDMEZIANE Syphax

Mlle. MAKHLOUFI Nada

Examiné par :

M. OUELMOKHTAR Hand

Mme. ARAR Ouiza

2023/2024

REMERCEMENT

Nous remercions Dieu le tout puissant pour ce qu'il nous a tant donné Comme volonté, santé et surtout patience, pour pouvoir, durant toutes ces Longues années d'études d'arriver là où nous sommes aujourd'hui et de Concrétiser tous nos efforts par ce modeste travail.

Nous tenons à remercier sincèrement notre directrice de mémoire, Mme.OUSSIDHOUM Samira, pour son encadrement, ses précieux conseils et son soutien tout au long de ce travail. Et notre Co-encadrante Mlle.AIT MOULOUD Louiza pour son soutien et ses précieux conseils.

Nous voudrions adresser nos remerciements particuliers à Mme.MOUHALBI, pour son aide précieuse et son appui constant. Et nous lui en sommes profondément reconnaissants.

Nous remerciements aussi tous les enseignants et les responsables du département d'électromécanique de l'université Mouloud Mammeri de Tizi-Ouzou

Nous remercions également les membres du jury qui ont accepté d'examiner notre modeste travail.

On veut également exprimer notre reconnaissance à nos familles, nos Camarades, ainsi que tous nos amis pour leur soutien moral

Dédicaces

Je dédie ce modeste travail à ceux qui, quels que soient les termes embrassés, je n'arriverais jamais à leur exprimer mon amour sincère

A la femme qui a souffert sans me laisser souffrir, qui n'a jamais dit non âmes exigences et qui n'a épargné aucun effort pour me rendre heureuse: mon adorable mère **HAKIMA**

À ma sœur **KENZA**, pour son amour inconditionnel et son soutien sans faille. Ta présence à mes côtés a été une source de motivation constante.

À son mari **MAYES**, pour son aide et son encouragement tout au long de ce projet.

À leur fils **RIYADH**, dont la joie de vivre et l'innocence ont apporté une lumière et une inspiration quotidiennes.

A toute ma famille pour leur soutien tout au long de mon parcours universitaire.

À mes proches et amis pour votre amitié sincère, votre soutien moral et vos encouragements constants. Vous avez été une source de motivation et de bonheur inestimable.

À mon cher binôme **SYPHAX** pour ta collaboration, ton soutien et ton dévouement tout au long de cette aventure. Travailler avec toi a été une expérience enrichissante et mémorable.

À mes collègues de travail de l'Imprimerie **Sebaou**, pour leur camaraderie et leur appui tout au long de ce parcours

A tous mes enseignants .et le corps de département

A tout qui de loin ou de prés nous ont aidés

N. MAKHLOUFI

Dédicaces

Je dédie ce mémoire à toutes les personnes qui ont contribué de manière significative à ma vie et à mon parcours académique.

À mes défunts grand-père et grand-mère vos souvenirs et vos valeurs continuent de m'inspirer chaque jour. Vous restez à jamais gravés dans mon cœur.

À mon père pour ton soutien indéfectible, tes conseils avisés et ta foi en mes capacités. Ta présence et tes encouragements ont été une force motrice dans ma vie.

À ma mère pour ton amour inconditionnel, ta patience infinie et ta présence constante. Tu as toujours été mon pilier et ma source d'inspiration.

À ma tante pour ton affection, ta générosité et ton soutien précieux tout au long de cette aventure. Ta présence a été une lumière dans les moments difficiles.

À mes sœurs pour votre complicité, votre compréhension et votre soutien sans faille. Vous êtes mon refuge et ma source de joie.

À ma famille pour l'amour, la chaleur et la solidarité qui me soutiennent chaque jour. Vous êtes le fondement de ma force et de ma détermination.

À mes proches et amis Pour votre amitié sincère, votre soutien moral et vos encouragements constants. Vous avez été une source de motivation et de bonheur inestimable.

À mon cher binôme Pour ta collaboration, ton soutien et ton dévouement tout au long de cette aventure. Travailler avec toi a été une expérience enrichissante et mémorable.

Avec beaucoup d'amour et de gratitude, je vous remercie tous du fond du cœur. Puisse ce mémoire être à la hauteur de vos espérances et refléter l'amour et le soutien que vous m'avez apportés.

S. ABDMEZIANE

Résumé :

Un panneau photovoltaïque n'est jamais à l'abri des défauts et anomalies qui peuvent l'affecter et Réduisant ainsi ses performances en termes de production d'énergie. Ces défauts pouvant être permanents, il est nécessaire de les détecter, de les classifier pour réparer et restaurer l'alimentation dès que possible.

Ce mémoire explore la détection et la classification des défauts dans les panneaux photovoltaïques. Nous avons étudié les types de défauts courants dans les panneaux PV. Ainsi que leur détection.

L'objectif de ce travail est l'utilisation de l'efficacité de la méthode Deep Learning pour la classification des problèmes

Dans ce travail, nous utilisons le réseau LSTM, une sous-classe de réseaux de neurones récurrents (RNN). Le processus commence par la collecte et la préparation des données, nécessaires pour former et tester le modèle. Ensuite, l'architecture du modèle LSTM est expliquée en détail. Le modèle est implémenté en Python, en utilisant des bibliothèques populaires comme Keras.

Les mots clé : photovoltaïque, Défauts, détection, classification, Deep Learning, LSTM

Abstract:

A photovoltaic panel is never safe from defects and anomalies which can affect it and thus reduce its performance in terms of energy production. These faults can be permanent; it is necessary to detect and classify them in order to repair and restore power as quickly as possible.

This thesis explores the detection and classification of defects in photovoltaic panels. We studied common types of defects in photovoltaic panels. As well as their detection.

The objective of this work is the use of the effectiveness of the Deep Learning method for the classification of problems

In this work, we use the LSTM network, a subclass of recurrent neural networks (RNN). The process begins by collecting and preparing the data needed to train and test the model. Next, the architecture of the LSTM model is explained in detail. The model is implemented in Python, using popular libraries like Keras.

Key words: photovoltaics, Defects, detection, classification, Deep Learning, LSTM

Sommaire :

Liste des figures

Liste des tableaux

Introduction générale ……..1

I. Chapitre 1 : Etat de l'art sur les systèmes photovoltaïques 3

I.1 Introduction : 4

I.2 Energie solaire : 4

I.2.1 L'énergie solaire photovoltaïque : 4

I.2.2 L'énergie solaire thermique : 5

I.2.3 L'énergie solaire thermodynamique : 5

I.3 Historique : 6

I.4 Les rayonnent solaire : 6

I.4.1 Le rayonnement direct : 7

I.4.2 Le rayonnement diffus : 7

I.4.3 Le rayonnement global : 7

I.5 Le gisement solaire en Algérie : 7

I.6 Cellule photovoltaïque : 8

I.6.1 Principe de fonctionnement : 8

I.6.2 Schéma équivalent d'une cellule photovoltaïque : 9

I.6.3 Les différents types de cellules solaires (cellules photovoltaïque) : 11

I.6.3.1 Cellules cristallines : 11

I.6.3.2 Cellule à couches minces "thin films" : 11

I.6.3.3 Cellule Perovskites : 12

I.6.4 Raccordement des cellules photovoltaïque : 12

I.6.4.1 Association en série 13

I.6.4.2 Association en parallèle : 13

I.6.5 La protection des cellules et des modules (Les diodes de by-pass) : 14

I.6.5.1 Les diodes parallèles (shunt) : 14

I.6.5.2 Les diodes séries : 14

I.7 Influence de l'ensoleillement et de la température : 15

I.8 Systèmes photovoltaïques : 17

I.8.1 Définition d'un système photovoltaïque : 17

I.8.2 Composants d'un système photovoltaïque : 17

I.8.2.1 Le générateur photovoltaïque : 17

I.8.2.2 Les régulateurs de charge : 18
➢ Le régulateur « PWM » : 18
➢ Le régulateur « MPPT » « Maximum Power Point Trac King » : 19
I.8.2.3 L'onduleur : 19
I.8.2.4 La batterie 19
I.8.2.5 Câblage et boîte de jonction : 20
I.8.3 Types de systèmes PV : 20
I.8.3.1 Systèmes PV autonomes : 20
I.8.3.2 Système hybride : 21
I.8.3.3 Système PV raccordée au réseau : 21
I.9 Les dispositifs de protection des systèmes photovoltaïques : 22
I.10 Les avantages et les inconvénients de l'énergie photovoltaïque : 22
I.10.1 Les avantages : 22
I.10.2 Les inconvénients : 23
I.11 Conclusion : 23
II. Chapitre 2 : les défauts des systèmes photovoltaïques et les méthodes de détection 24
II.1 Introduction : 25
II.2 Types de défauts dans les systèmes PV : 25
II.2.1 Défauts physiques : 25
II.2.1.1 Défaut d'encapsulation : 25
II.2.1.2 Décoloration : 25
II.2.1.3 Délamination : 26
II.2.1.4 Corrosion : 26
II.2.1.5 Traces descargots : 27
II.2.1.6 Default du materiel d'emballage : 27
II.2.1.7 Fissures cellulaires : 28
II.2.1.8 Défaut diode de By-Pass : 28
II.2.2 Défaut électrique : 29
II.2.2.1 Défaut champ : 29
II.2.2.1.1 Défaut circuit ouvert : 29
II.2.2.1.2 Défaut ligne-ligne : 30
II.2.2.1.3 Défaut ligne terre : 30
II.2.2.1.4 Défaut D'ARC : 31
II.2.2.2 Défaut CC : 31
II.2.2.2.1 Défaut batterie : 31

II.2.2.2.2 Défaut MPPT : 31
II.2.2.3 Défaut AC : 32
II.2.2.3.1 Défaut de réseau : 32
II.2.2.3.2 Défaut de l'onduleur : 32
II.2.3 Défauts environnementaux : 32
II.2.3.1 Défaut d'ombrage : 32
II.2.3.2 Défaut Points Chauds : 34
II.3 Méthodes de détection des défauts dans les systèmes PV : 34
II.3.1 Méthodes électriques : 34
II.3.1.1 Analyse de la courbe Courant – Tension : 34
II.3.1.2 Techniques statistiques et de traitement du signal : 35
II.3.2 Méthodes visuelles et thermiques (VTM) : 35
II.3.2.1 La méthode d'électroluminescence (EL) : 35
II.3.2.2 La méthode de fluorescence UV : 36
II.3.2.3 La thermographie infrarouge (IR) : 36
II.3.3 Méthode d'intelligence artificielle : 37
II.4 Conclusion : 37
III. Chapitre 3 : Réseaux de neurones et prétraitement des données des systèmes photovoltaïque 38
III.1 Introduction : 39
III.2 Notions de base de L'intelligence artificielle : 39
III.2.1 Définition de l'objet de IA : 39
III.3 Apprentissage automatique (Machine Learning) : 39
III.3.1 Méthodes d'apprentissage automatique : 40
III.3.1.1 L'apprentissage supervisé : 40
III.3.1.2 L'apprentissage non supervisé : 40
III.4 Apprentissage profond (Deep Learning) : 40
III.5 Machine learning vs Deep learning: 41
III.6 Réseau de neurones : 42
III.6.1 Fonctionnement de réseaux de neurones : 42
III.6.2 Types de réseaux de neurones : 42
III.6.2.1 Réseaux CNN (Convolution) : 42
III.6.2.2 Réseaux DNN (Déconvolution) : 42
III.6.2.3 Réseaux FeedForward : 43
III.6.2.4 Réseaux de Neurones Antagonistes Génératifs (GAN) : 43

III.6.2.5 Réseaux RNN (Récurrents) : 43
III.7 Model utilisé – LSTM (long short terme memory) : 43
III.7.1 Architecture général du model LSTM : 44
III.8 Contexte expérimental : 46
III.8.1 Google Colab : 46
III.8.2 Kaggel: 46
III.8.3 Python : 46
III.8.4 Bibliothèques utilisé : 47
III.9 Description du dataset : 47
III.9.1 Structuration des données : 48
III.10 Prétraitement des Données : 51
III.10.1 Création de fenêtres glissantes : 52
III.10.2 Filtrage des données : filtre passe-bas 54
III.10.3 Division l'ensemble de données en ensembles d'entrainement et de teste : ... 57
III.11 Conclusion : 58
IV. Chapitre 4 : Entrainement du modèle et Interprétation des résultats 59
IV.1 Introduction : 60
IV.2 Architecture du model utilisée : 60
IV.3 configuration du LSTM : 60
IV.4 Entrainement et interprétation des résultats : 61
IV.4.1 Entrainement : 61
IV.4.2 Interprétation des résultats d'entrainement : 62
IV.5 Evaluation des résultats du teste : 64
IV.5.1 Définition des Métriques : 64
IV.5.2 Matrice de confusion : 64
IV.5.2.1 Définition : 64
IV.5.2.2 Interprétation de la matrice donnée : 65
IV.5.2.2.1 Analyse et remarques : 65
IV.5.3 Évaluation des Performances du Modèle de Classification par Classe : 66
IV.6 Conclusion : 66
Conclusion générale : 67
Bibliographie : XI

Liste des figures :

Chapitre 1 :

Figure I-1 : Panneau photovoltaïque 4
Figure I-2 :Panneaux solaires thermiques 5
Figure I-3 Panneaux solaires thermodynamique 5
Figure I-4 : Analyse spectrale du rayonnement solaire 6
Figure I-5: Nouvel Atlas solaire du monde 8
Figure I-6 : Principe de fonctionnement 9
Figure I-7: schéma équivalent d'une cellule photovoltaïque..... 9
Figure I-8:schéma équivalent simplifié 10
Figure I-9 :cellule monocristalline 11
Figure I-10 : cellule polycristalline..... 11
Figure I-11 : Cellule à couche fine. 12
Figure I-12 : cellule pérovskites 12
Figure I-13 : Caractéristique courant-tension d'une cellule photovoltaïque individuelle et de plusieurs cellules en série 13
Figure I-14 :Caractéristique courant-tension d'une cellule photovoltaïque individuelle et de plusieurs cellules en parallèle 13
Figure I-15 : caractéristiques globales d'une installation 14
Figure I-16 : protection des cellules contre la tension inverse 15
Figure I-17 : protection des modules par des diodes 15
Figure I-18 : Influence de l'ensoleillement sur la courbe I-V 16
Figure I-19 : Influence de la température sur la courbe I-V 16
Figure I-20 : Systèmes photovoltaïques..... 17
Figure I-21 :Système photovoltaïque plus détaillé 17
Figure I-22 :Composantes d'un générateur de modules photovoltaïques 18
Figure I-23: Régulateur solaire PWM 18
Figure I-24: Régulateur solaire MPPT..... 19
Figure I-25 :Système photovoltaïque autonome. 20
Figure I-26:Système hybride..... 21
Figure I-27 : Système PV raccordée au réseau 22

Chapitre 2 :

Figure II-1 : Défaut d'encapsulation 25
Figure II-2: Décoloration sur la surface de la cellule..... 26
Figure II-3 : Délamination auteur jeu de barre 26
Figure II-4 : Corrosion dans les interconnexions de cellules de jeu de barre..... 27
Figure II-5 : Traces d'escargot 27
Figure II-6 : Bris de verre 28
Figure II-7 : Fissure sur un Panneau photovoltaïque..... 28
Figure II-8 : Défaut diode de By-Pass 29
Figure II-9 : Défaut de circuit ouvert 29
Figure II-10 : Défaut ligne à ligne 30

Figure II-11 : Court-circuit entre le module PV et la terre 30
Figure II-12: Défaut d'arc..... 31
Figure II-13: Défaut d'ombrage partiel 33
Figure II-14 :Panneau solaire photovoltaïque (a) entièrement couvert (b) partiellement couvert à cause de la neige 33
Figure II-15 : Ombrage entre les Rangées de Modules sur Toit Plat ou Terrasse 33
Figure II-16 :Défaut Points Chauds 34
Figure II-17 : Paramètres de la courbe I-V 35
Figure II-18 : EL Failure 36
Figure II-19 : défaillance UV FL 36
Figure II-20:Contrôle et inspection par thermographie infrarouge..... 37

Chapitre 3 :

Figure III-1 :Le fonctionnement général d'apprentissage automatique 39
Figure III-2 :Méthodes d'apprentissage automatique..... 40
Figure III-3 :L'interaction entre intelligence artificielle et machine learning et deep learning [45] 41
Figure III-4 :Comparaison entre la machine Learning et le Deep Learning 41
Figure III-5: Exemple de Fonctionnement de réseau neurones. 42
Figure III-6:Architecture LSTM 44
Figure III-7: porte de l'oublie 44
Figure III-8: porte d'entrée 45
Figure III-9 : porte de sortie 46
Figure III-10 : données de défauts en mode IPPT..... 51
Figure III-11 : données de défauts en mode MPPT..... 51
Figure III-12: signal filtré en rouge et signal non filtré……..……..…….56

Chapitre 4 :

Figure IV-1 :graphe de perte en entrainement et en validation..... 62
Figure IV-2 : graphe de précision en entrainement et validation..... 63
Figure IV-3 : Courbe du taux d'apprentissage. 63
Figure IV-4 : matrice de confusion. 65
Figure IV-5 : récapitulatif des performances du modèle de classification pour chaque classe 66

Liste des tableaux :

Chapitre 1 :

Tableau I-1: Ensoleillement reçu en Algérie par région climatique 7

Chapitre 3 :

Tableau III-1: Type des défauts et leurs caractéristique..... 48
Tableau III-2 : Exemple de défauts en mode IPPT et MPPT 50

Introduction générale :

Les besoins énergétiques des pays du monde continuent de croître, entraînant une augmentation de la consommation et la possibilité d'épuisement des ressources. Ainsi, les humains sont constamment à la recherche de nouvelles sources d'énergie, y compris des sources renouvelables.

L'énergie renouvelable représente l'ensemble des sources d'énergie qui se renouvellent naturellement, La lumière du soleil et le vent par exemple, Parmi les différentes sources ont trouvées l'énergie solaire qui provient du rayonnement solaire, En particulier, l'énergie solaire photovoltaïque est l'électricité générée par la transformation d'une partie du rayonnement solaire à l'aide de cellules photovoltaïques. Ces cellules, lorsqu'elles sont reliées entre elles, forment un panneau photovoltaïque. Ce processus repose sur l'effet photovoltaïque, découvert par Alexandre-Edmond Becquerel en 1839, qui permet de convertir directement la lumière solaire en électricité.

L'efficacité des panneaux photovoltaïques (PV) est cruciale pour maximiser la production d'énergie. Cependant, ces panneaux peuvent être sujets à divers défauts qui réduisent leur performance et leur durée de vie. Il est donc essentiel de détecter et de classifier ces défauts le plus tôt possible pour maintenir l'efficacité des systèmes PV et minimiser les pertes économiques.

Dans ce mémoire, nous nous intéressons particulièrement à la détection et à la classification des défauts des panneaux photovoltaïques. En utilisant les réseaux de neurones à mémoire à long terme (LSTM). Les réseaux LSTM sont particulièrement adaptés pour traiter des données séquentielles et temporelles, ce qui en fait un outil puissant pour identifier et prévoir les anomalies dans les performances des panneaux PV. Grâce à cette méthode, nous visons à améliorer la précision de la détection précoce des défauts, contribuant ainsi à l'optimisation de l'efficacité et à la réduction des pertes économiques des systèmes photovoltaïques.

Pour décrire cela, ce mémoire est présenté en quatre chapitres :

Dans le premier chapitre, nous avons présenté une introduction générale sur les systèmes photovoltaïques. Nous avons débuté par un bref rappel sur l'énergie solaire, en mettant en lumière des notions essentielles sur le rayonnement solaire. Ensuite, nous avons exposé le principe de l'effet photovoltaïque ainsi que le fonctionnement des cellules solaires, en détaillant les différents types disponibles sur le marché et en expliquant leur mode de raccordement. Par la suite, nous avons défini ce qu'est un système photovoltaïque et avons donné un aperçu des différents types de systèmes existants et les composants.

Le chapitre deux présente les types d'erreurs qui peuvent survenir Sur les systèmes photovoltaïques et les méthodes les plus efficaces pour leur détection.

Le troisième chapitre explore les applications de l'intelligence artificielle, notamment l'apprentissage automatique et l'apprentissage profond, dans le domaine des systèmes photovoltaïques. Nous commençons par présenter les concepts de base de ces techniques, et les types de réseaux de neurones, mettant un accent particulier sur le modèle de réseau de neurones LSTM (Long Short-Term Memory) développé spécifiquement pour notre étude. Nous

détaillons les types de données collectées et traitées afin d'entraîner efficacement notre modèle LSTM. Cette section met en lumière l'importance du prétraitement des données pour assurer la qualité et la précision des analyses réalisées.

Dans le chapitre 4, nous détaillons l'architecture de notre modèle de réseau neuronal, explorant ses choix de conception et ses couches spécifiques. Nous présentons ensuite le processus d'entraînement avec les algorithmes d'optimisation utilisés. Enfin, nous évaluons les performances du modèle et comparons les résultats aux attentes initiales.

Enfin, nous terminerons ce mémoire par une conclusion générale qui résumera notre travail.

Chapitre 1 : Etat de l’art sur les systèmes photovoltaïques.

I.1 Introduction :

Les énergies renouvelables sont des sources d'énergie caractérisées par des ressources naturelles illimitées, se renouvelant naturellement. Elles se divisent en plusieurs filières technologiques selon leur origine spécifique, permettant ainsi une diversification significative des sources d'énergie disponibles. Il existe plusieurs types d'énergie renouvelable énergie solaire, éolienne, hydraulique….

Ce travail explore l'énergie solaire et ses applications, en mettant l'accent sur les technologies photovoltaïques, est l'énergie la plus prometteuse des énergies renouvelables. Nous commencerons par un historique de l'énergie solaire, une explication des rayonnements solaires et une analyse du potentiel solaire en Algérie. Ensuite, nous détaillerons le fonctionnement des cellules photovoltaïques, leurs types, leur raccordement, et les dispositifs de protection.

Nous aborderons également l'impact de l'ensoleillement et de la température sur ces cellules. Puis, nous définirons les différents types de systèmes photovoltaïques, qu'ils soient autonomes, hybrides ou raccordés au réseau, ainsi que leurs dispositifs de protection. Enfin, nous discuterons des avantages et des inconvénients de l'énergie photovoltaïque avant de conclure en soulignant son importance pour le développement durable.

I.2 Energie solaire :

L'énergie solaire est une source d'énergie qui dépend du soleil. Cette énergie permet de fabriquer de l'électricité à partir de panneaux photovoltaïques ou des centrales solaires thermiques, grâce à la lumière du soleil captée par des panneaux solaires.

I.2.1 L'énergie solaire photovoltaïque :

L'énergie photovoltaïque est obtenue à partir des rayonnements du soleil. Le principe consiste à transformer l'énergie des photons contenus dans la lumière en électricité. C'est pourquoi les panneaux photovoltaïques, qui captent cette énergie, sont souvent installés sur les toits avec la meilleure orientation possible. La cellule photovoltaïque joue un rôle central dans ce processus, et c'est ce que nous aborderons dans ce chapitre [1] .

Figure I-1 : Panneau photovoltaïque *[2]*

I.2.2 L'énergie solaire thermique :

Les panneaux solaires thermiques contiennent des fluides caloporteurs. Lorsqu'ils sont chauffés par le soleil, ces fluides transfèrent leur chaleur au ballon d'eau chaude.

L'énergie solaire thermique sert aussi bien pour alimenter :

- Un chauffage solaire.
- Un chauffe-eau.
- Une cuisinière.

Elle ne produit pas d'électricité mais bien de la chaleur. Elle peut être utile dans certains usages industriels pour remplacer une partie des usages d'énergie fossile [1].

Figure I-2 :Panneaux solaires thermiques *[3]*

I.2.3 L'énergie solaire thermodynamique :

Produite via des centrales solaires à concentration. Il s'agit d'un assemblage de miroirs contenant des fluides caloporteurs, couplés à un générateur d'électricité solaire.

Tout comme les panneaux solaires thermiques, ce sont les miroirs qui transforment l'énergie collectée par les rayons du soleil en chaleur. Cette chaleur est ensuite convertie en électricité au moyen d'une turbine et d'un alternateur, de manière similaire à une centrale thermique [1].

Figure I-3 :Panneaux solaires thermodynamique *[4]*

I.3 Historique :

Découvert en 1839 par le physicien A. Becquerel, l'effet photovoltaïque a été peu utilisé jusqu'au début des années 60 où il a connu un développement important du fait de ses applications spatiales. L'électricité photovoltaïque, qui est aujourd'hui largement répandue notamment dans le domaine de l'électrification rurale, est obtenue par transformation directe de photons lumineux en électricité par les cellules PV [5].

I.4 Le rayonnent solaire :

Le rayonnement ou spectre solaire est comparable à celui d'un corps noir à une température de 5800 K, il est compris dans une bande de longueur d'onde variant de 0.22 à 10 μm et se décompose approximativement sur 3 bandes:

- 9% dans la bande des Ultraviolets (0.8μm).
- 47% dans la bande visible (0.4 à 0.8μm).
- 44% dans la bande des infrarouges (> 0.8μm).

L'énergie solaire reçue sur terre en dehors de l'atmosphère est estimée à 1370 W/m2 cependant elle s'atténue et perd son intensité en traversent l'atmosphère ne dépassant pas les 1000 W/m2 à la surface de la terre en raison de l'absorption dans ce dernier, ce chiffre variera par la suit en fonction de la localisation géographique du site (latitude), la saison, l'heure, les conditions météorologiques (nébulosité, poussière, humidité…), et latitude du lieu [6].

Le spectre solaire est la distribution spectrale en fonction de la longueur d'onde ou de la fréquence. L'énergie de chaque photon est reliée à la fréquence μ ou à la longueur d'onde λ par la suit:

$$E=h.\mu=h.C/\lambda$$

E : énergie h : est la constante de Planck. C : étant la vitesse de propagation. λ : la longueur d'onde μ : la fréquence

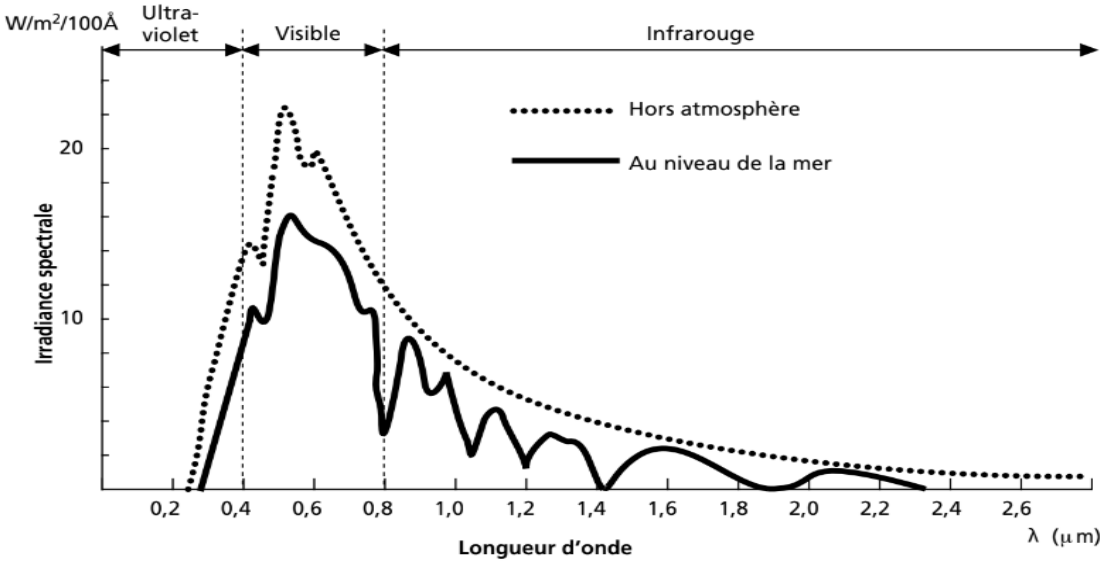

Figure I-4 : Analyse spectrale du rayonnement solaire *[7]*

Il y a trois types de rayonnement [7]:

I.4.1 Le rayonnement direct : est le rayonnement reçu directement du Soleil. Il peut être mesuré par un pyrhéliomètre.

I.4.2 Le rayonnement diffus : Est le rayonnement provenant de toute la voûte céleste. Ce rayonnement est dû à l'absorption et à la diffusion d'une partie du rayonnement solaire par l'atmosphère et à sa réflexion par les nuages. Sa mesure peut être effectuée à l'aide d'un pyranomètre équipé d'un écran occultant le soleil.

I.4.3 Le rayonnement global : Est la somme de tous les rayonnements reçus, y compris le rayonnement réfléchi par le sol et les objets qui se trouvent à sa surface. Il est mesuré par un pyranomètre ou un solarimètre sans écran.

I.5 Le gisement solaire en Algérie :

La situation géographique de l'Algérie dispose un gisement solaire énorme, L'Algérie représente le potentiel solaire le plus important de tout le bassin méditerranéen, soit 169.000 TWh/an pour le solaire thermique, 13,9 TWh/an pour le solaire photovoltaïque. Le potentiel solaire algérien est l'équivalent de 10 grands gisements de gaz naturel qui auraient été découverts à Hassi R'Mel [8].

La répartition du potentiel solaire par région climatique au niveau du territoire algérien est représentée dans le tableau I-1 selon l'ensoleillement reçu annuellement

Région	Régions côtières	Hauts plateaux	Sahara
Superficie (%)	4	10	86
Durée moyenne d'ensoleillement (h/an)	2650	3000	3500
Energie moyenne reçue (kWh/m²/an)	1700	1900	2650

Tableau I-2: Ensoleillement reçu en Algérie par région climatique *[8]*

En raison de sa situation géographique, l'Algérie est l'un des pays classée comme étant les mieux dotés en ressources solaires au monde et au bassin méditerranéen (Figure I -5) ; soit 169.000 TWh/an pour le solaire thermique, et 13,9 TWh/an pour le solaire photovoltaïque [9].

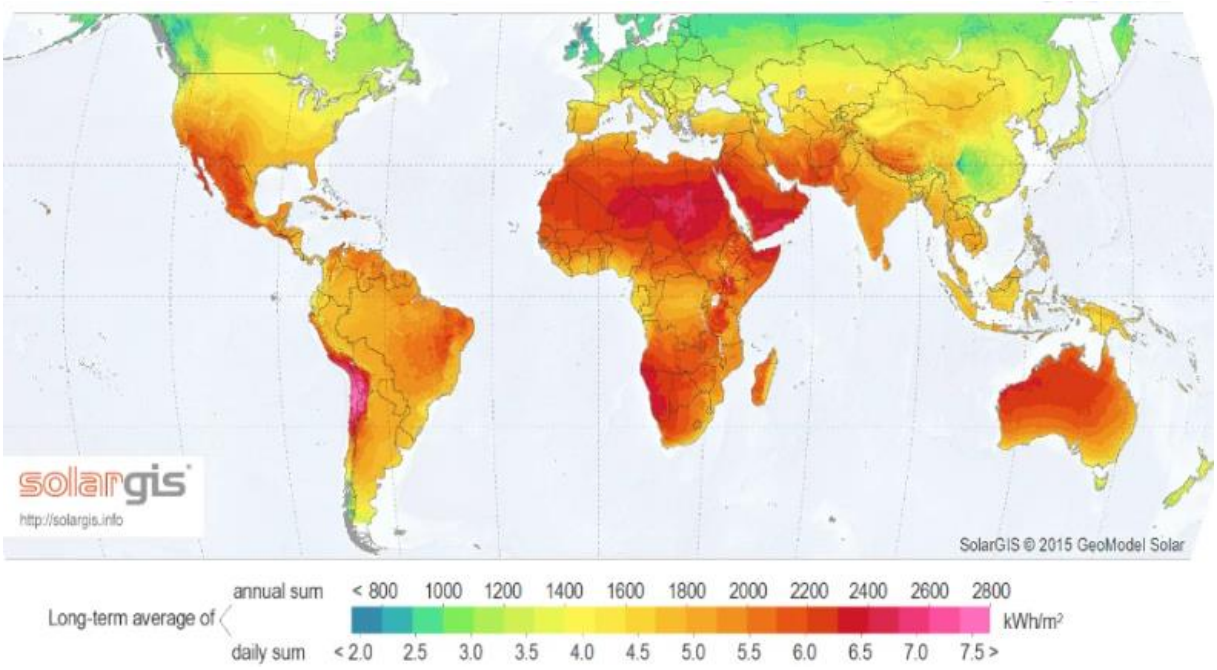

Figure I-5: Nouvel Atlas solaire du monde *[10]*

I.6 Cellule photovoltaïque :

Pour comprendre le fonctionnement d'une cellule photovoltaïque, il faut connaître l'effet photovoltaïque, qui est la capacité de certains matériaux à convertir la lumière en électricité.

Tous les semi-conducteurs présentent cet effet avec une efficacité variable. Lorsqu'un photon (particule de lumière) pénètre dans un matériau, il crée des paires électrons-trous qui génèrent une charge négative (électrons) et une charge positive (trous).

Les électrons séparés peuvent ensuite être collectés pour créer un courant, comme dans une pile. Les modules photovoltaïques utilisent cet effet et sont reliés à des onduleurs pour convertir le courant continu en courant alternatif.

I.6.1 Principe de fonctionnement :

La cellule photovoltaïque classique en silicium est constituée d'une jonction P/N (Figure I-6). Cette dernière est la juxtaposition de deux zones, l'une comportant un fort excès d'électrons libres : partie N, et l'autre comportant un fort défaut d'électrons libres (ou excès de trous), partie P. La jonction PN engendre un champ électrique dans la zone de charge d'espace, à l'interface des deux zones N et P. Les photons incidents créent des porteurs dans les zones N et P et dans la zone de charge d'espace. Ces porteurs ont un comportement différent suivant la région où ils sont générés :

- Dans la zone N ou P, les porteurs minoritaires qui atteignent la zone de charge d'espace sont "envoyés" par le champ électrique dans la zone P (pour les trous) ou dans la zone N (pour les électrons) où ils seront majoritaires. On aura un photo-courant de diffusion.

- Dans la zone de charge d'espace, les paires électron/trou créées par les photons incidents sont dissociées par le champ électrique : les électrons vont aller vers la région N, les trous vers la région P. On aura un photo-courant de génération.

Ces deux contributions s'ajoutent pour donner un photocourant résultant Iph. C'est un courant de porteurs minoritaires. Il est proportionnel à l'intensité lumineuse.

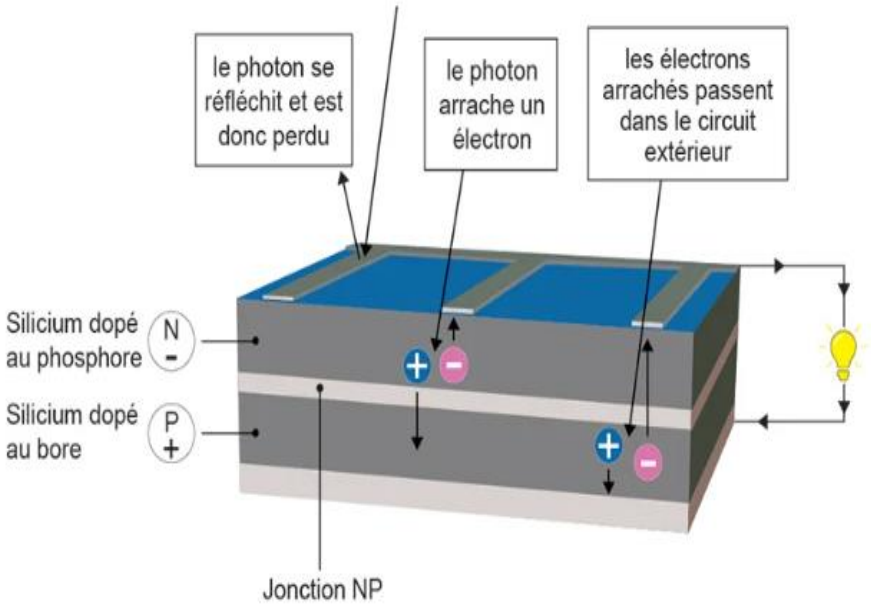

Figure I-6 : Principe de fonctionnement *[11]*

I.6.2 Schéma équivalent d'une cellule photovoltaïque :

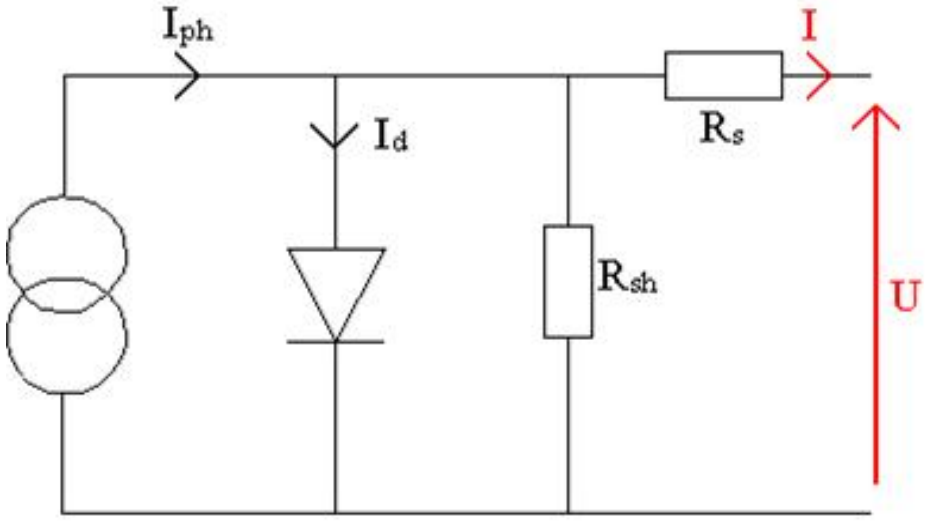

Figure I-7: schéma équivalent d'une cellule photovoltaïque *[12]*

Le modèle mathématique associé à une cellule se trouve à partir de celui d'une jonction PN. On y ajoute le courant I_{ph} , proportionnel à l'éclairement, ainsi qu'un terme modélisant les phénomènes internes. Le courant I issu de la cellule s'écrit alors [13] :

$$I = I_{ph} - I_{0d} \cdot \left(e^{\frac{q.(U.R_S.I)}{K.T}} - 1 \right) - \frac{U + R_s.I}{R_{sh}}$$

$$I_d = I_{0d} \cdot \left(e^{\frac{q.(U.R_S.I)}{K.T}} - 1 \right)$$

Avec :

- ✓ .I_{ph}: photocourant, ou courant généré par l'éclairement (A)
- ✓ .I_{0d} : courant de saturation de la diode (A)
- ✓ .R_s: résistance série (W)
- ✓ .R_{sh}: résistance shunt (W)
- ✓ . K : constante de Boltzmann (k = 1,38.10 -23)
- ✓ . q : charge de l'électron (q = 1,602.10 -19 C)
- ✓ . T : température de la cellule (°K)

On peut déduire de cette expression un schéma équivalent, comme le montre la figure I-7

La diode modélise le comportement de la cellule dans l'obscurité. Le générateur de courant modélise le courant I ph généré par un éclairement.

Enfin, les deux résistances modélisent les pertes internes :

- ✓ Résistance série R_S : modélise les pertes ohmiques du matériau.
- ✓ Résistance shunt R_{sh} : modélise les courants parasites qui traversent la cellule.

Idéalement, on peut négliger R_S et I devant U, puis travailler avec un modèle simplifié :

$$I = I_{ph} - I_{0d}\left(e^{\frac{q.U}{K.T}} - 1\right) - \frac{U}{R_{sh}}$$

Comme la résistance shunt est beaucoup plus élevée que la résistance série, on peut encore négliger le courant dévié dansR_{sh}. On obtient :

$$I = I_{ph} - I_{0d}\left(e^{\frac{q.U}{K.T}} - 1\right)$$

Le schéma équivalent de la figure I -8 correspondant est celui de la cellule idéale :

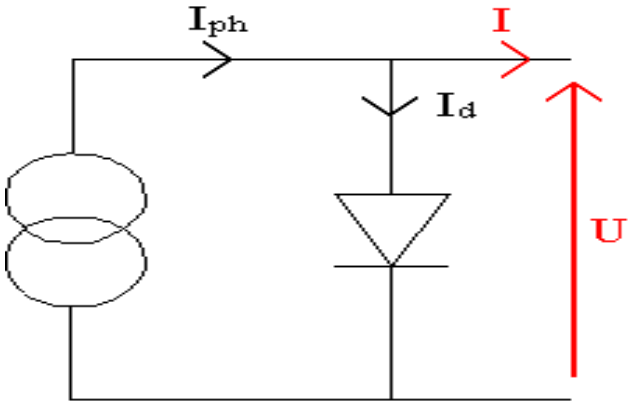

Figure I-8:schéma équivalent simplifié *[12]*

I.6.3 Les différents types de cellules solaires (cellules photovoltaïque) :

Il existe différentes sortes de cellules photovoltaïques. Même si elles fonctionnent globalement de la même manière, elles ont chacune leurs spécificités [14] .

I.6.3.1 Cellules cristallines :

- Les cellules en silicium monocristallin :

Figure I-9 :cellules monocristallines *[15]*

On reconnaît les cellules monocristallines grâce à leur couleur très foncée. Il s'agit d'un seul cristal de silicium**.** Au sein d'un même module solaire, tous les cristaux de silicium sont orientés dans le même sens. Le rendement de ce matériau est supérieur à celui du silicium polycristallin, mais il est également vendu plus cher, car sa fabrication est plus délicate [14].

- Les cellules polycristallines :

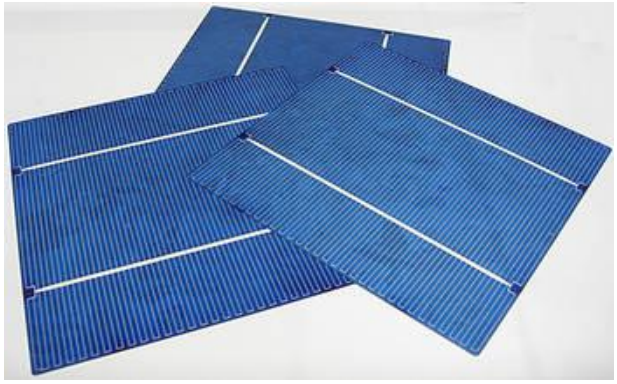

Figure I-10 : cellules polycristallines *[15]*

Le refroidissement du silicium en fusion est effectué dans des creusets parallélépipédiques à fond plat. Par cette technique, des cristaux orientés de manière irrégulière se forment. Cela donne l'aspect caractéristique de ces cellules bleutées présentant des motifs générés par les cristaux [14].

I.6.3.2 Cellules à couches minces "thin films" :

Dans le cas de "couches minces", le semi-conducteur est directement déposé par vaporisation sur un matériau support (du verre par exemple). Le silicium amorphe (a-Si)

(silicium non cristallisé de couleur gris foncé), le tellurure de cadmium (CdTe), le disélénium de cuivre indium (CIS) font notamment partie de cette génération. Ce sont des cellules de cette technologie que l'on retrouve dans les montres, calculatrices, … dites solaires [14] .

Figure I-11 : Cellules à couche fine. *[15]*

I.6.3.3 Cellules Perovskites :

Les pérovskites sont un nouveau type de cellules, fondées sur un matériau hybride : une partie est organique, l'autre est inorganique. Leur rendement en laboratoire est assez prometteur, mais leur instabilité est aujourd'hui un frein à leur industrialisation. Leurs avantages seraient un coût de production bas, des cellules légères, souples et maniables, permettant d'être intégrées à différents types de revêtement [14].

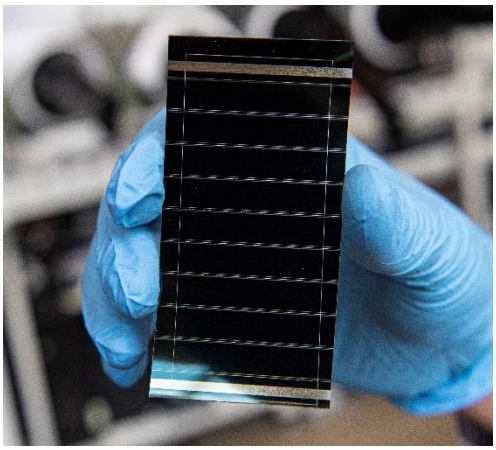

Figure I-12 : cellule pérovskites *[15]*

I.6.4 Raccordement des cellules photovoltaïque [15]:

Sous des conditions standardisées de test, une cellule en silicium (Si) de 100 cm^2 (10 cm x 10 cm) produit une puissance maximale d'environ 1,25 Watt. Cette puissance est trop faible pour les applications électriques courantes, ce qui fait des cellules individuelles des générateurs de très faible puissance. Pour pallier cette insuffisance, les cellules élémentaires sont associées en série et/ou en parallèle dans des modules.

Les modules, généralement sous forme de panneaux, sont constitués de cellules élémentaires placées en série pour obtenir une tension de sortie utilisable. Ces modules sont

ensuite interconnectés en réseaux série-parallèle pour atteindre les tensions et courants souhaités.

I.6.4.1 Association en série :

Par association en série (appelée "String"), les cellules sont traversées par le même courant et la tension résultante correspond à la somme des tensions générées par chacune des cellules [15].

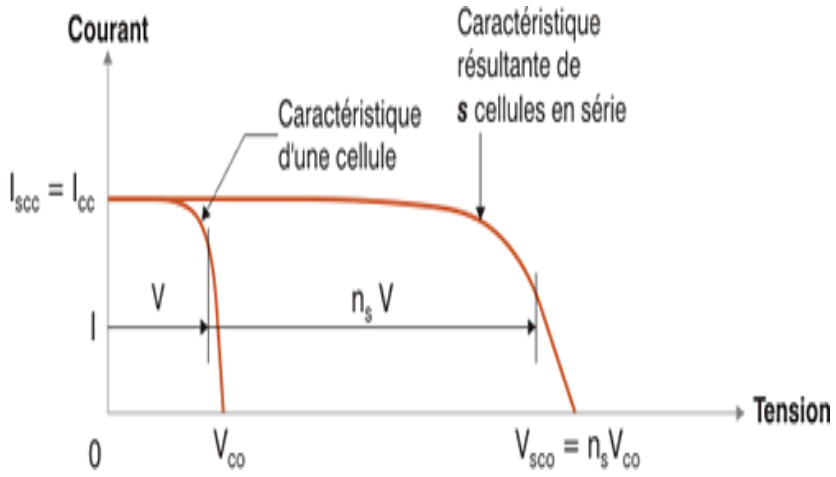

Figure I-13 : Caractéristique courant-tension d'une cellule photovoltaïque individuelle et de plusieurs cellules en série *[15]*

Iscc : Courant de court-circuit des cellules en séries.
Icc : Courant de court-circuit.
Vco : Tension en circuit ouvert.
ns : Nombre de cellules en séries.
Vsco : La tension en circuit ouvert des cellules connectées en série.
I : Courant de la cellule individuelle.
V : Tension de la cellule individuelle.

I.6.4.2 Association en parallèle :

Par association en parallèle, les cellules sont soumises à la même tension et le courant résultant correspond à la somme des courants générés par chacune des cellules [15].

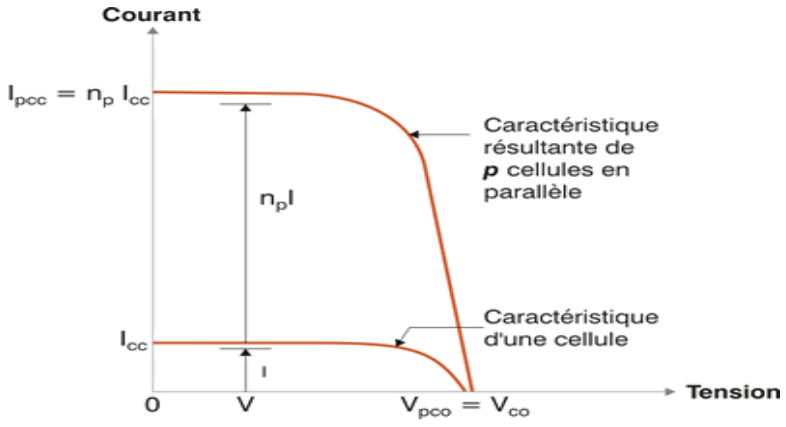

Figure I-14 :Caractéristique courant-tension d'une cellule photovoltaïque individuelle et de plusieurs cellules en parallèle *[15]*

Ipcc : Courant de court-circuit résultant des cellules connectées en parallèle.
Icc : Courant de court-circuit.
Vpco : Tension en circuit ouvert résultant des cellules connectées en parallèle.
Vco : Tension du circuit ouvert.
np : Nombre de cellules en parallèle.

Les caractéristiques globales d'une installation se déduisent donc d'une combinaison des caractéristiques des constituants des ns*np.

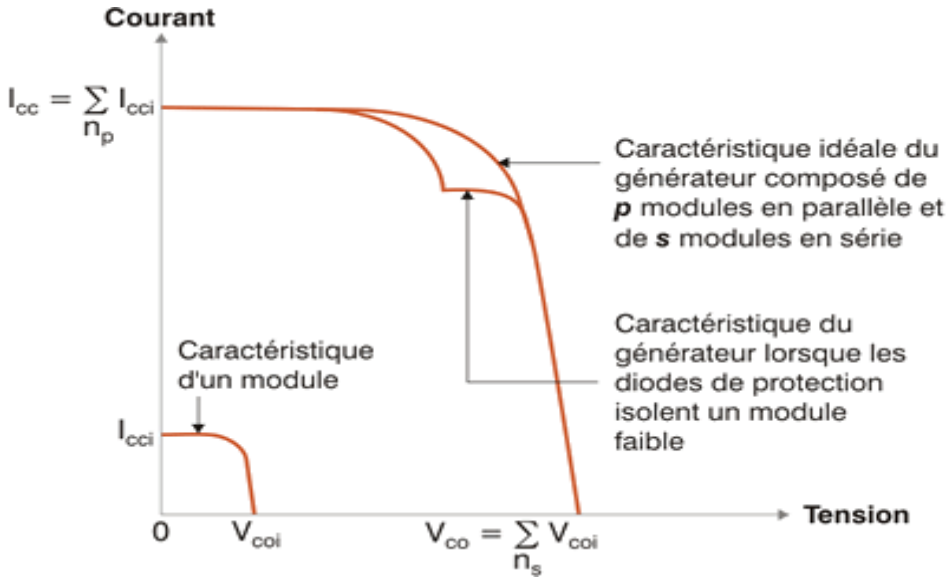

Figure I-15 : caractéristiques globales d'une installation *[15]*

Icc=∑np .Icci : Courant de court-circuit résultant des modules connectés en parallèle (somme des courants de chaque module).
Vco=∑ns.Vcoi: Tension en circuit ouvert résultant des modules connectés en série (somme des tensions de chaque module).
Icci: Courant de court-circuit d'un module.
Vcoi: Tension en circuit ouvert d'un module.

I.6.5 La protection des cellules et des modules (Les diodes de by-pass) [16]:

La cellule photovoltaïque est un élément très fragile, en cas d'occultation ou d'un court-circuit accidentel, la cellule peut subir une tension inverse très élevée ou être traversée par un courant assez important.

Afin de protéger les cellules et les modules photovoltaïques, on utilise des diodes de protections qui doivent être montées en série ou en parallèle.

I.6.5.1 Les diodes parallèles (shunt) :
Pour la protection des cellules contre les tensions inverses (voir Figure I -16).

I.6.5.2 Les diodes séries :
Pour la protection d'une branche de module ou de cellules contre le courant inverse (Voir Figure I -17).

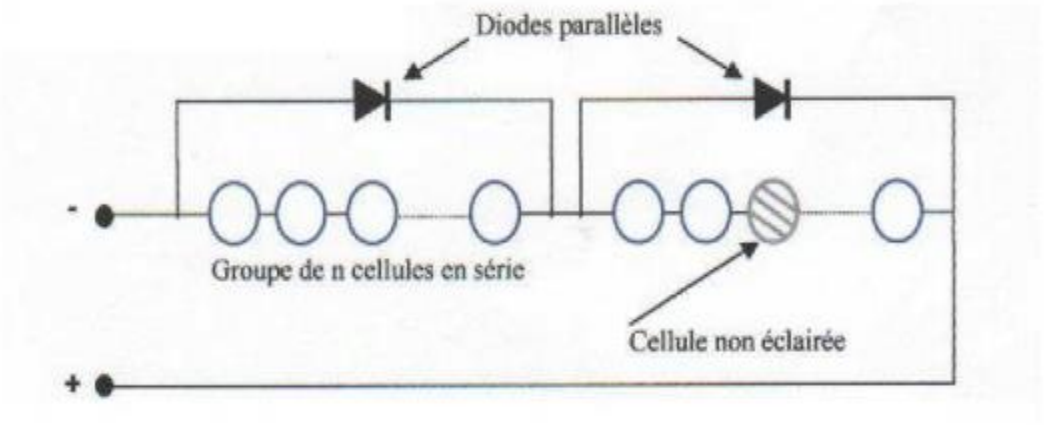

Figure I-16 : protection des cellules contre la tension inverse *[16]*

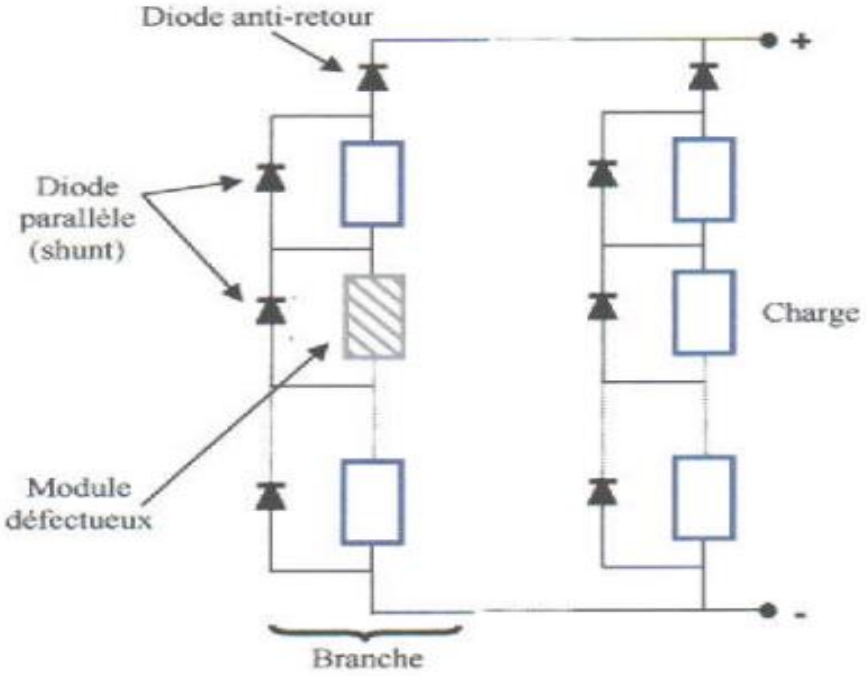

Figure I-17 : protection des modules par des diodes *[16]*

I.7 Influence de l'ensoleillement et de la température [7] :

Nous avons vu que le courant produit par la photopile (Iph) est pratiquement proportionnel au flux lumineux (ø). Par contre, la tension (V) aux bornes de la jonction varie peu car elle est fonction de la différence de potentiel à la jonction N-P du matériau lui-même (pour le silicium monocristallin, elle est de 590mV pour Tj = 25°C). La tension de circuit ouvert ne diminuera que légèrement avec le flux lumineux. Ceci implique :

- La puissance optimale de la cellule (Pm) est pratiquement proportionnelle à l'éclairement;
- Les points de puissance maximale se situent à peu près à la même tension

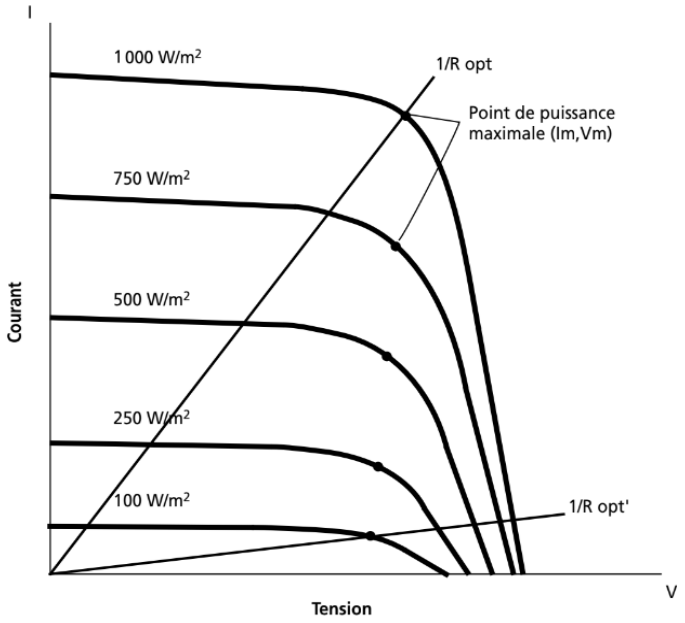

Figure I-18 : Influence de l'ensoleillement sur la courbe I-V *[7]*

L'influence de la température est non négligeable sur la caractéristique courant/tension d'un semi-conducteur (voir figure I-19). Pour le silicium, lorsque la température augmente, le courant augmente d'environ 0,025 mA/cm2/°C alors que la tension décroît de 2,2 mV/°C/cellule.

Cela se traduit par une baisse de puissance d'environ 0,4%/°C. Cette influence devra être prise en compte lors du dimensionnement du générateur photovoltaïque.

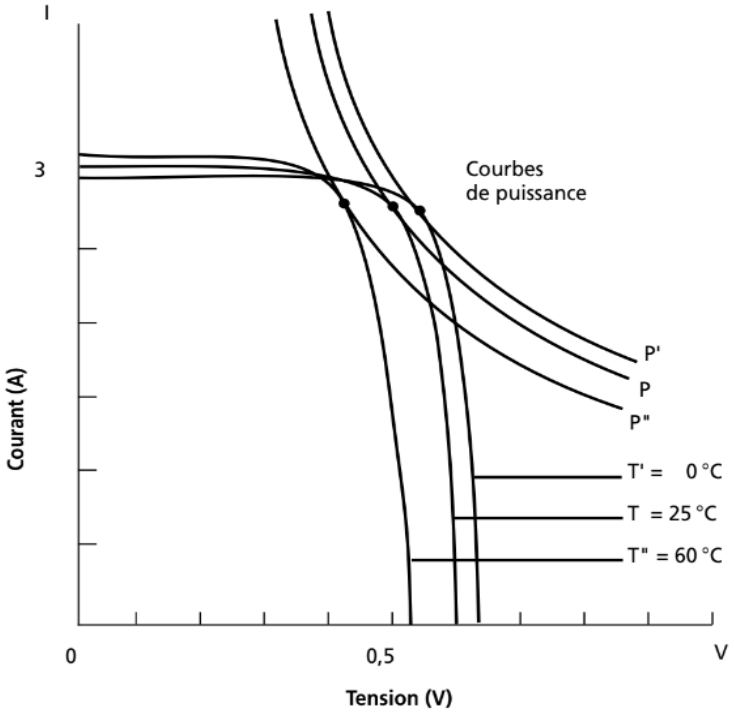

Figure I-19 : Influence de la température sur la courbe I-V *[7]*

I.8 Systèmes photovoltaïques :

I.8.1 Définition d'un système photovoltaïque :

Le générateur photovoltaïque est principalement constitué d'un champ de modules solaires, accompagné d'un ensemble de composants assurant la compatibilité entre l'électricité produite et les besoins des équipements. Cet ensemble, souvent appelé "Balance of System" (ou BOS), englobe tous les équipements nécessaires entre les modules et la charge finale. Cela comprend la structure de support des modules (fixe ou mobile), le câblage électrique, les batteries avec leur régulateur de charge pour le stockage de l'énergie, ainsi que l'onduleur permettant de convertir le courant continu des panneaux solaires en courant alternatif utilisable par les appareils électriques [17].

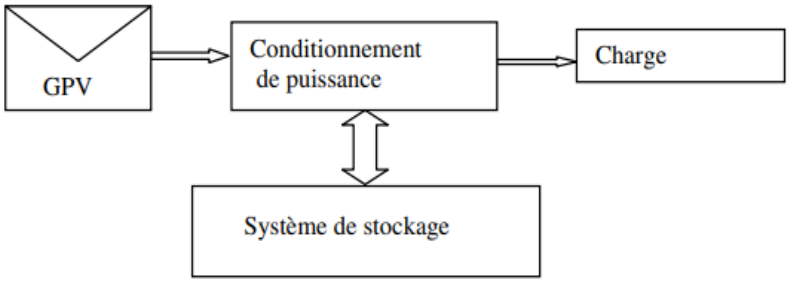

Figure I-20 : Systèmes photovoltaïques *[18]*

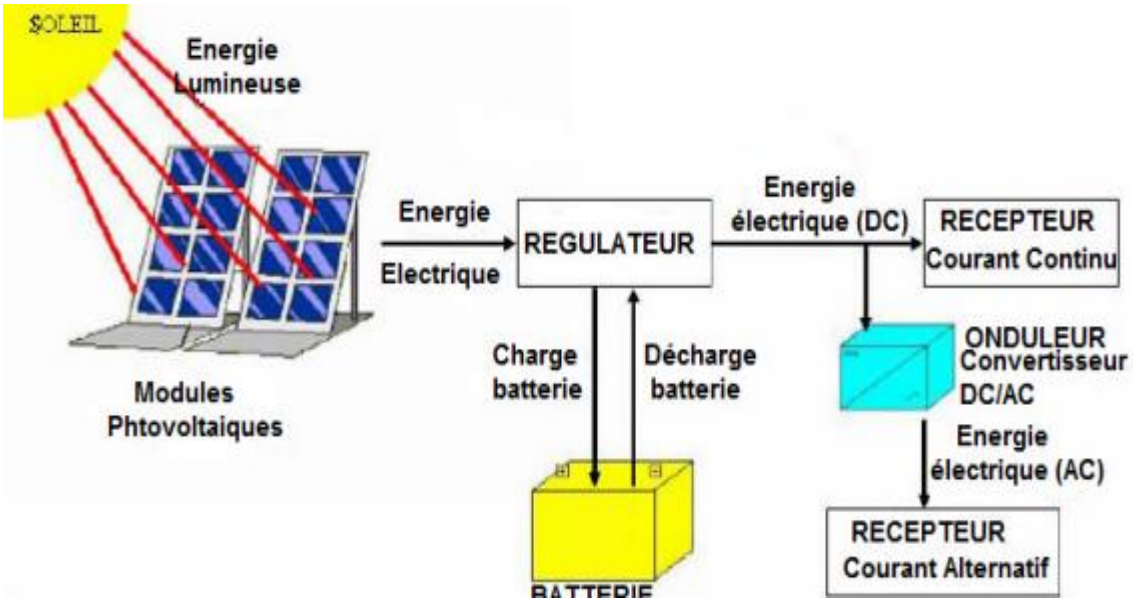

Figure I-21 :Système photovoltaïque plus détaillé *[18]*

I.8.2 Composants d'un système photovoltaïque :

I.8.2.1 Le générateur photovoltaïque :

Le générateur photovoltaïque est une installation convertissant l'énergie solaire en courant continu. Sa composante de base, la cellule photovoltaïque, transforme directement la lumière solaire en électricité. Ces cellules sont assemblées pour former des panneaux

photovoltaïques (ou modules). Lorsque plusieurs panneaux sont installés ensemble sur un même site, cela constitue un champ photovoltaïque.

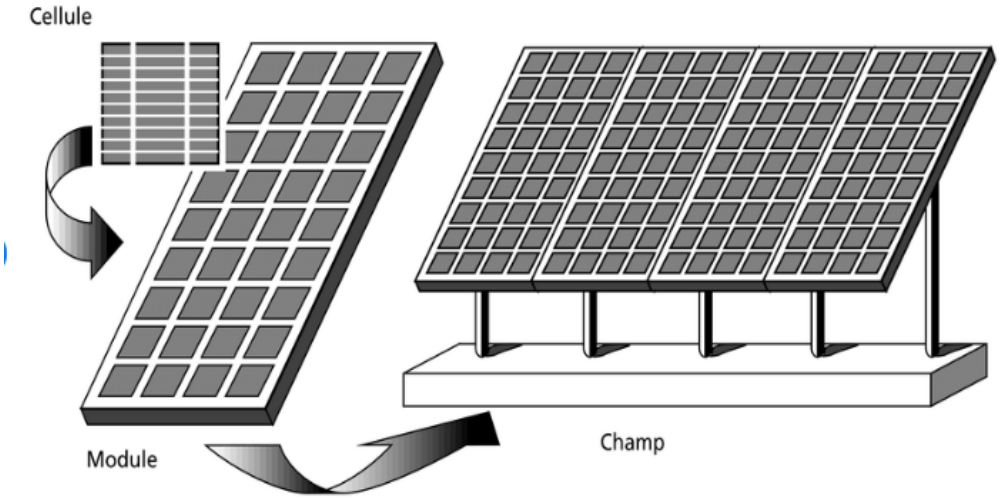

Figure I-22 :Composantes d'un générateur de modules photovoltaïques *[7]*

I.8.2.2 Les régulateurs de charge :

Le régulateur de charge a pour principale fonction de surveiller l'état de la batterie. Il est équipé de différentes limites de valeurs, chacune correspondant à un type de protection spécifique: surcharge, décharge profonde, température de fonctionnement, court-circuit, etc. Les nouvelles générations de régulateurs, quant à eux, sont de plus en plus perfectionnés et proposent des fonctionnalités plus nombreuses et de plus en plus évoluées [19].

Il existe deux type de régulateur de charge

- **Le régulateur « PWM » :**

Certains régulateurs fonctionnent en utilisant la modulation de largeur d'impulsion (PWM), ajustant le rapport cyclique en fonction de l'énergie à transmettre à la batterie pour réaliser une charge à tension constante. Cette méthode est plus complexe que le simple "tout ou rien". Les régulateurs solaires classiques qui intègrent la technologie PWM connectent les panneaux solaires au groupe de batteries. Dans ce mode d'utilisation directe, la tension de sortie des panneaux est abaissée à la tension nominale des batteries [19].

Figure I-23: Régulateur solaire PWM *[19]*

- **Le régulateur « MPPT » « Maximum Power Point Trac King »** :

Les régulateurs MPPT, ou "Maximum Power Point Tracking", représentent une avancée significative par rapport aux régulateurs PWM. Ils permettent au panneau solaire de fonctionner à son point de puissance maximale, c'est-à-dire à la tension optimale pour une puissance de sortie maximale. A mesure que la luminosité varie tout au long de la journée, la tension et le courant générés par les panneaux solaires changent également. Les régulateurs MPPT effectuent un balayage constant de la courbe de puissance des panneaux solaires pour déterminer le point où la puissance de sortie est maximale. Ils ajustent ensuite la tension et le courant de charge pour maintenir le système à ce point optimal. Grâce à cette technologie intelligente, les régulateurs de charge solaire MPPT peuvent être jusqu'à 30 % plus efficaces, en fonction de la tension de la batterie et de la tension de fonctionnement (Vmp) du panneau solaire [20].

Figure I-24: Régulateur solaire MPPT *[19]*

I.8.2.3 L'onduleur :

Un onduleur est un dispositif de conversion statique qui transforme l'énergie électrique de sa forme continue (CC) à sa forme alternative (CA). En fait, cette conversion d'énergie est satisfaite au moyen d'un dispositif de commande (semi-conducteurs). Il permet d'obtenir aux bornes du récepteur une tension alternative réglable en fréquence et en valeur efficace, en utilisant ainsi une séquence adéquate de commande [21].

I.8.2.4 La batterie

La batterie des panneaux solaires est une composante parfois présente dans les kits d'autoconsommation photovoltaïque. Sa fonction est d'assurer un stockage de l'énergie solaire pour pouvoir consommer l'électricité produite ultérieurement.

La batterie a aussi ces deux importantes fonctions :

• Fournir une puissance instantanée supérieure à celle fournie par l'ensemble des panneaux et nécessaire pour la mise en place de quelques éléments

• Déterminer la marge des tensions de travail de l'installation.

I.8.2.5 Câblage et boîte de jonction [22] :

Le câblage vise à relier électriquement les modules solaires. Habituellement, les modules sont d'abord câblés en série pour former des ensembles, chacun équipé d'une diode en série. Ensuite, la mise en parallèle de ces ensembles est effectuée à l'aide de boîtes de jonction fixées sur les châssis. Ces boîtes de jonction peuvent également intégrer des éléments de protection tels que des fusibles, des interrupteurs et des sectionneurs.

Il est essentiel de porter une attention particulière au serrage des cosses et au câblage d'une installation, car une chute de tension excessive dans les connexions et les câbles peut considérablement réduire le courant de charge de la batterie. Cette chute de tension est particulièrement significative lorsque des courants élevés sont fournis à de faibles tensions. Par conséquent, il est nécessaire d'utiliser des câbles résistant aux intempéries et de choisir leur section en fonction de la distance entre le panneau solaire et la batterie.

I.8.3 Types de systèmes PV :

On distingue trois types de systèmes PV :

- autonomes.
- hybrides.
- raccordées au réseau.

I.8.3.1 Systèmes PV autonomes :

Un système PV autonome est un système photovoltaïque qui opère de manière indépendante, sans être connecté au réseau électrique. Il alimente des charges passives telles que des lampes ou des moteurs, sans nécessiter d'autres sources d'énergie. Ce type de système est principalement utilisé dans des endroits isolés ou éloignés du réseau électrique, où les besoins en énergie sont relativement faibles, généralement moins de 10 kWc. Pour fonctionner pendant les périodes sans soleil, telles que la nuit ou les jours nuageux, les systèmes autonomes font généralement appel à des batteries ou à d'autres moyens de stockage d'énergie. Ils sont couramment employés pour alimenter des maisons isolées, des installations en milieu insulaire ou montagneux, ainsi que pour des applications telles que la surveillance à distance et le pompage de l'eau [18].

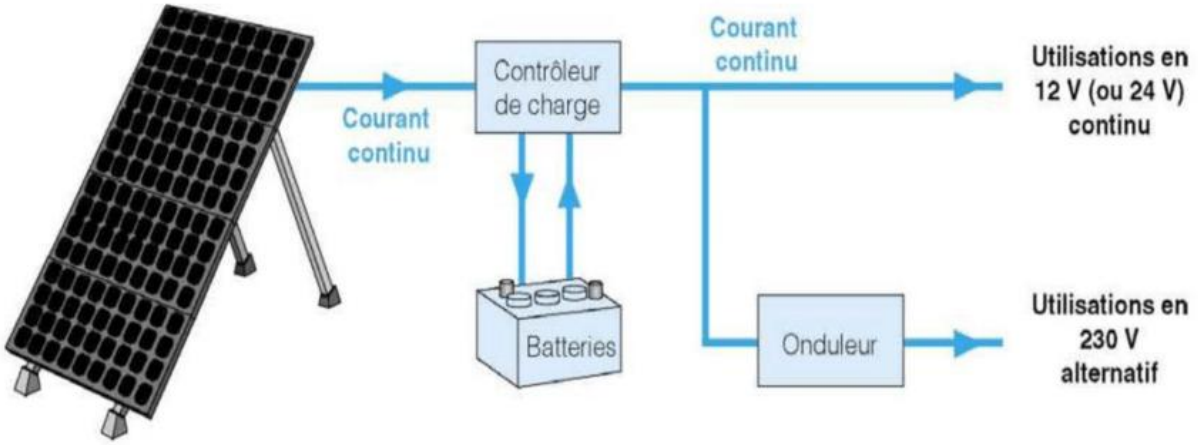

Figure I-25 :Système photovoltaïque autonome. *[18]*

On distingue deux types :

- Les systèmes au fil du soleil

Les systèmes au fil du soleil sont des systèmes sans stockage. Ils exploitent directement l'énergie solaire sans aucune source d'appoint. Ces systèmes sont classés, selon la nature de la charge à alimenter L'application la plus connue est le pompage photovoltaïque Ces systèmes sont simples mais leur inconvénient est la coupure de l'alimentation en absence du soleil [18].

- Les systèmes avec stockage

Les systèmes avec stockage sont des systèmes qui intègrent des moyens de stockage d'énergie. Ces systèmes permettent de fournir de l'énergie aux charges pendant les périodes de faible ensoleillement, telles que les passages nuageux, ou durant l'absence totale d'ensoleillement, comme pendant la nuit. Le système de stockage est conçu pour accumuler l'énergie excédentaire produite par les panneaux solaires et la restituer pendant les périodes où la production d'énergie est insuffisante. Par exemple, ces systèmes sont utilisés pour alimenter en électricité des maisons situées dans des endroits isolés [18].

I.8.3.2 Système hybride :

Les systèmes hybrides reçoivent une partie de leur énergie d'une ou plusieurs sources supplémentaires, qui sont également indépendants des réseaux de distribution d'électricité. En pratique le générateur photovoltaïque est combiné à une éolienne ou à un combustible, ou aux deux à la fois avec des accumulateurs de stockage de l'énergie. Un tel système s'avère un bon choix pour les applications qui nécessitent une alimentation continue d'une puissance assez élevée [23].

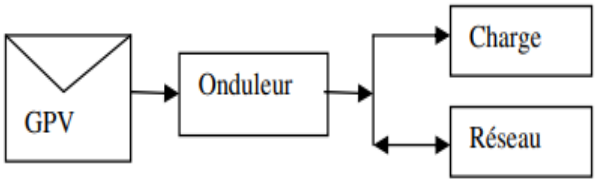

Figure I-26:Système hybride *[18]*

I.8.3.3 Système PV raccordée au réseau :

Une installation PV peut être connectée en parallèle avec le réseau électrique. Les panneaux solaires sont généralement connectés en série pour former des "strings", qui sont ensuite reliés à un onduleur. L'onduleur a pour fonction de convertir le courant continu provenant des panneaux en courant alternatif. Chaque onduleur est sélectionné en fonction de la puissance des panneaux et peut accueillir un ou plusieurs "strings" [24].Lorsque la consommation locale dépasse la production de l'installation PV, l'appoint est fourni par le réseau électrique. En revanche, si la production excède la consommation locale, l'énergie excédentaire est injectée dans le réseau public, contribuant ainsi à l'alimentation des consommateurs environnants.

.

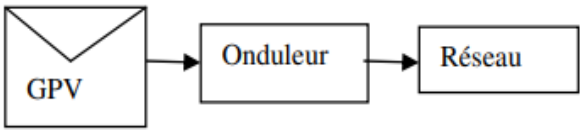

Figure I-27 : Système PV raccordée au réseau *[18]*

I.9 Les dispositifs de protection des systèmes photovoltaïques :

- Disjoncteurs DC (courant continu) : sont installés sur les circuits en courant continu des panneaux solaires pour protéger contre les surcharges et les court-circuit.

- Dispositifs de protection contre les surtensions (parafoudres) : Les parafoudres sont utilisés pour protéger les panneaux solaires et les onduleurs contre les surtensions induites par la foudre ou les fluctuations de tension dans le réseau électrique.

- Fusibles ou disjoncteurs AC (courant alternatif) : Ces dispositifs protègent les circuits en courant alternatif entre l'onduleur et le réseau électrique contre les surcharges et les court-circuit.

- Dispositifs de protection contre les surintensités : Ces dispositifs surveillent les courants dans les circuits et coupent l'alimentation en cas de surintensité pour éviter tout dommage aux équipements.

- Dispositifs de protection contre les arcs électriques : Ces dispositifs détectent et coupent l'alimentation en cas d'arcs électriques dangereux pouvant survenir dans les installations solaires.

- Dispositifs de mise à la terre : Une mise à la terre adéquate est essentielle pour éviter les risques d'électrocution et pour protéger les équipements en cas de surtensions.

I.10 Les avantages et les inconvénients de l'énergie photovoltaïque :

I.10.1 Les avantages :

Fiabilité élevée : Leur fiabilité les rend particulièrement adaptés aux régions isolées, raison pour laquelle ils sont largement utilisés dans l'espace.

Modularité : La nature modulaire des panneaux photovoltaïques permet un montage simple et adaptable à une variété de besoins énergétiques. Les systèmes peuvent être dimensionnés pour des applications allant de quelques milliwatts à plusieurs mégawatts.

Impact environnemental : Sur le plan écologique, la technologie photovoltaïque présente plusieurs avantages. Les produits finis sont non polluants et silencieux, et leur utilisation ne perturbe généralement pas l'environnement, à l'exception de l'occupation de l'espace pour les installations de grande taille [25].

I.10.2 Les inconvénients :

La fabrication des modules photovoltaïques est une entreprise hautement technologique qui nécessite des investissements considérables. Malgré cela, le rendement réel de conversion d'un module reste relativement faible, avec une limite théorique de conversion d'énergie pour une cellule au silicium cristallin de 28%.

Comparativement aux générateurs Diesel, les générateurs photovoltaïques ne sont compétitifs que pour des demandes d'énergie faibles dans les régions isolées. De plus, lorsque le stockage de l'énergie électrique sous forme chimique (batterie) est nécessaire, le coût global du générateur photovoltaïque est augmenté.

Cependant, la fiabilité et les performances du système restent équivalentes, pour autant que la batterie et les composants de régulation associés soient judicieusement choisis [25].

I.11 Conclusion :

Dans ce chapitre, nous avons exploré l'histoire de l'énergie photovoltaïque. Nous avons ensuite présenté les généralités sur les systèmes photovoltaïques, leur production d'énergie électrique, et comment cette énergie est générée à partir de cellules photovoltaïques. Nous avons également discuté des différents types de cellules photovoltaïques et de leurs caractéristiques spécifiques. Pour conclure, nous avons examiné les divers types de systèmes photovoltaïques existants, en mettant en lumière leurs avantages et inconvénients respectifs.

Dans le prochain chapitre (chapitre 02), nous aborderons les différents types de défauts qui peuvent survenir dans les systèmes photovoltaïques.

Chapitre 2 : les défauts des systèmes photovoltaïques et les méthodes de leurs détection.

II.1 Introduction :

Dans ce deuxième chapitre, nous aborderons deux aspects pour la compréhension et l'amélioration des systèmes photovoltaïques (PV). Tout d'abord, nous examinerons la classification des défauts des systèmes PV. Il s'agit d'identifier et de catégoriser les divers types de défauts qui peuvent survenir dans ces systèmes, qu'ils soient liés aux composants matériels, aux conditions environnementales ou aux erreurs de fonctionnement.

Dans la seconde partie de ce chapitre, nous nous concentrerons sur les méthodes de détection des défauts. La détection précoce et précise des défauts est fondamentale pour minimiser les pertes de performance et prolonger la durée de vie des systèmes PV. Nous explorerons différentes techniques de détection, allant des méthodes traditionnelles aux approches plus avancées basées sur l'analyse des données et l'intelligence artificielle.

Ainsi, ce chapitre fournira une vue d'ensemble des types de défauts que peuvent rencontrer les systèmes photovoltaïques et des méthodes les plus efficaces pour les détecter, contribuant ainsi à l'amélioration continue de la fiabilité et de l'efficacité de ces systèmes.

II.2 Types de défauts dans les systèmes PV :

II.2.1 Défauts physiques :

II.2.1.1 Défaut d'encapsulation :

L'échec de l'encapsulation est causé par un délaminage ou une décoloration du module PV. La principale raison de ce défaut est l'accumulation de sels, la pénétration de l'humidité et d'autres facteurs externes [26].

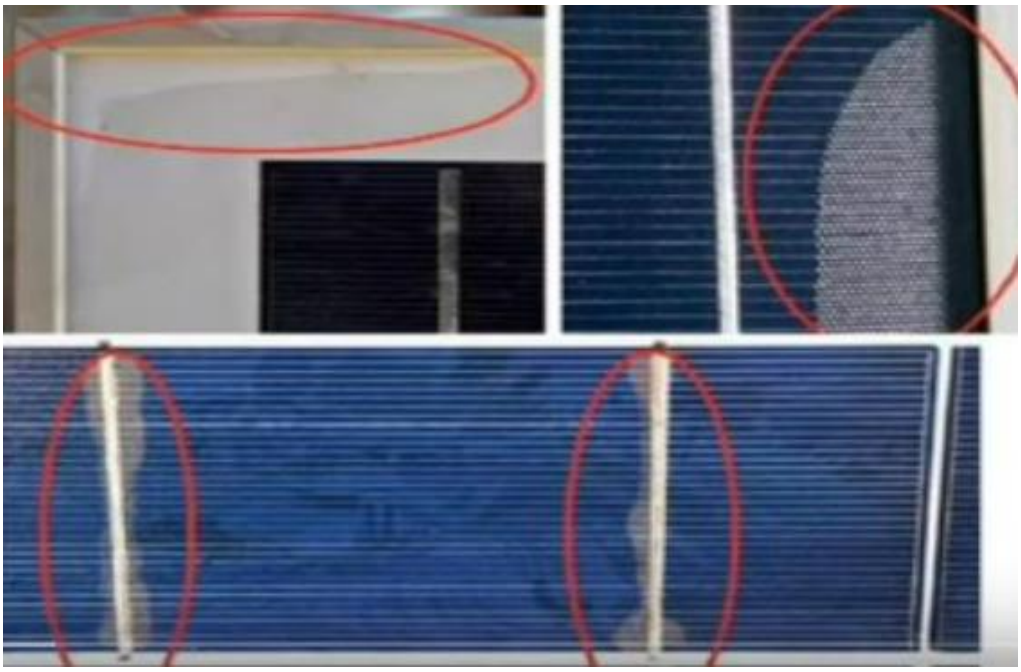

Figure II-1 : Défaut d'encapsulation *[27]*

II.2.1.2 Décoloration :

La décoloration des cellules photovoltaïques peut être facilement détectée à l'œil nu. Dans ce type de défaut, on peut observer que la couleur blanche du matériau PV passe au jaune ou au marron [28, 29] réduisant ainsi l'intensité de la lumière tombant sur les cellules solaires.

Cela peut entraîner une augmentation de la température, ce qui peut avoir des conséquences considérables sur les performances du système photovoltaïque. Les principales causes de décoloration comprennent le stress thermique, l'exposition aux rayons UV, l'accumulation de gaz ou d'acides entre les couches, ainsi que la corrosion des contacts métalliques.

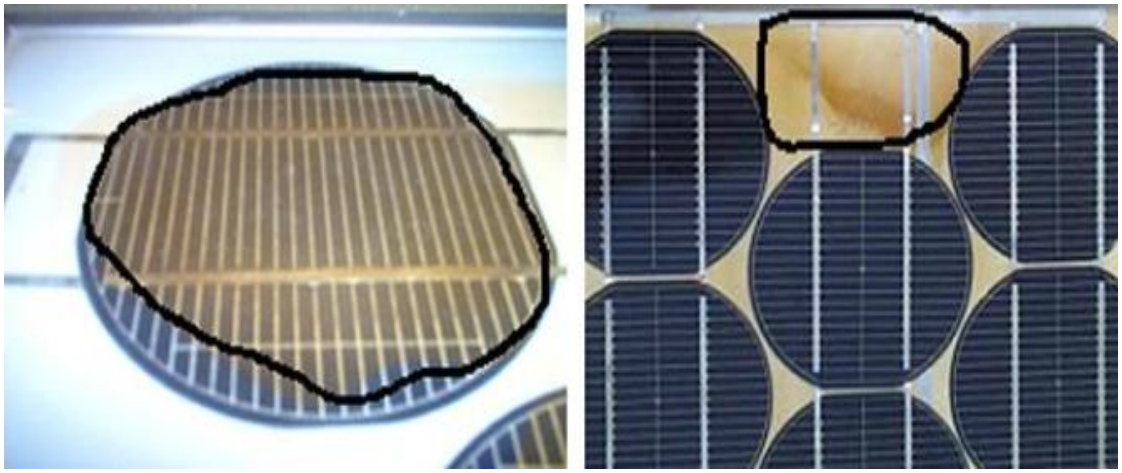

Figure II-2: Décoloration sur la surface de la cellule *[27]*

II.2.1.3 Délamination :

Le délaminage se produit lorsque des espaces ou des décollements se forment entre les couches successives du module photovoltaïque, comme entre le verre et l'encapsulant, l'encapsulant et la cellule, ou l'encapsulant et la feuille arrière. Ce problème est généralement dû à une mauvaise adhésion entre les couches.

Le délaminage du module photovoltaïque entraîne une réflexion accrue de la lumière, au lieu de son absorption prévue, ainsi qu'une possible infiltration d'humidité ou de gaz. Ces conséquences peuvent conduire à l'apparition d'une série d'autres défauts dans le module [28].

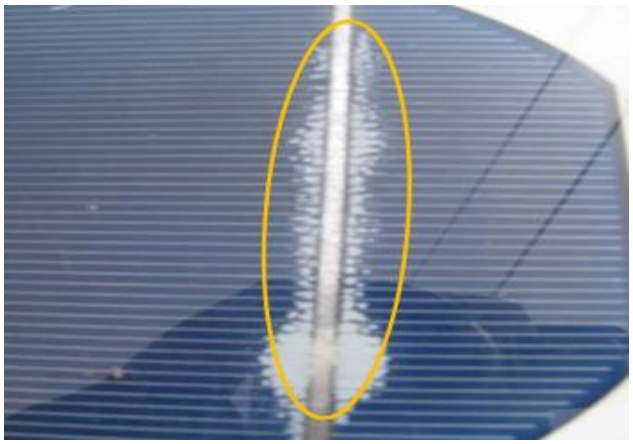

Figure II-3 : Délamination auteur jeu de barre *[27]*

II.2.1.4 Corrosion :

Le délaminage ou les fissures dans l'encapsulation peuvent provoquer la pénétration de l'humidité dans le module, ce qui peut entraîner la corrosion du matériau photovoltaïque. Contacts métalliques fixés à la base de la cellule, les doigts d'argent présents sur le dessus de la cellule peuvent se corroder facilement s'ils sont exposés à l'oxygène atmosphérique, au soufre, au dioxyde de carbone et à d'autres gaz corrosifs [30]. Les dommages causés au panneau

photovoltaïque en raison du défaut de corrosion ont été illustrés dans la figure II-4. La corrosion des contacts métalliques peut provoquer la circulation d'un courant de fuite dans le système [26], et la corrosion du fil conducteur peut augmenter sa résistance, ce qui peut éventuellement conduire à une perte de puissance extrêmement élevée. Un exemple de corrosion des interconnexions de barres et de cellules est présenté à la figure II-4

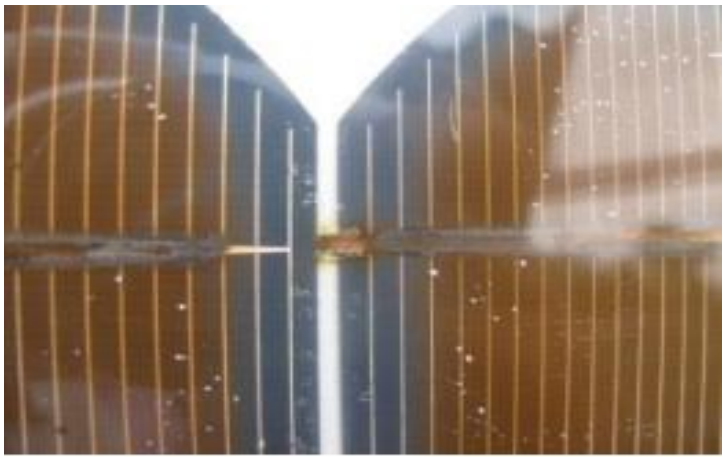

Figure II-4 : Corrosion dans les interconnexions de cellules de jeu de barre *[27]*

II.2.1.5 Traces descargots :

Les traînées d'escargots sont une décoloration des doigts d'argent due à la formation de nanoparticules de carbonate d'argent (Ag2CO3), Les traînées d'escargots se forment en raison de la réaction de l'argent avec le dioxyde de carbone et l'humidité. Ces gaz peuvent facilement pénétrer par les fissures, c'est pourquoi les traînées d'escargots se trouvent principalement près des fissures et des bords des cellules [31].

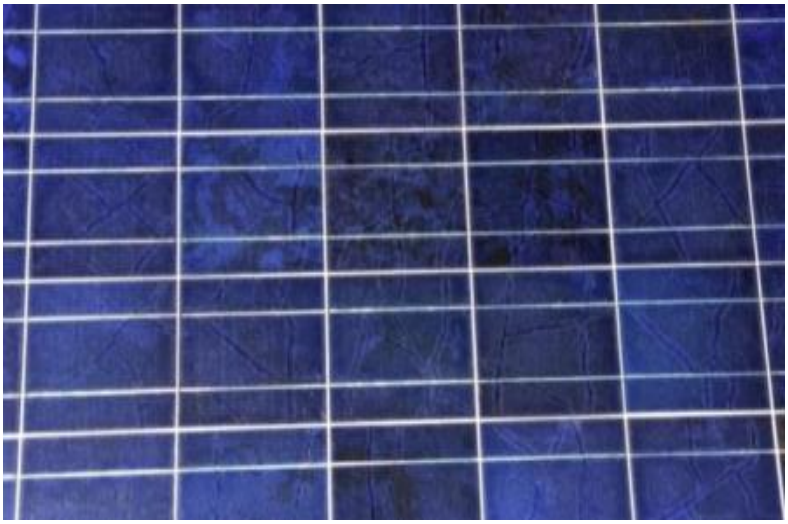

Figure II-5 : Traces d'escargot *[27]*

II.2.1.6 Default du materiel d'emballage :

Une pression inutile appliquée lors de l'emballage des cellules photovoltaïques peut entraîner des fissures sur la cellule. Tout défaut lors de la fabrication ou de l'emballage peut réduire la puissance de sortie des cellules photovoltaïques. Un exemple de ce défaut est illustré à la Figure II-6

Figure II-6 : Bris de verre *[27]*

II.2.1.7 Fissures cellulaires :

Les fissures développées dans le substrat de silicium du module PV sont appelées fissures de cellule, comme le montre Figure II-7. Outre le substrat en silicium, des fissures peuvent également se produire dans différentes couches de stratification de la cellule. Parfois, ces fissures sont très petites (également appelées micro-fissures) et ne sont pas visibles à l'œil nu. Leur détection peut donc être effectuée par imagerie par électroluminescence. Certaines des principales raisons d'apparition de fissures répertoriées dans [31 , 26] sont : les contraintes mécaniques lors de la fabrication, du transport ou de l'installation, les chocs pouvant survenir pendant le transport, les défauts de fabrication, la mauvaise manipulation lors de l'emballage, le vieillissement des cellules, les températures élevées et les tempêtes de grêle., couverture neigeuse, vent, pluie.

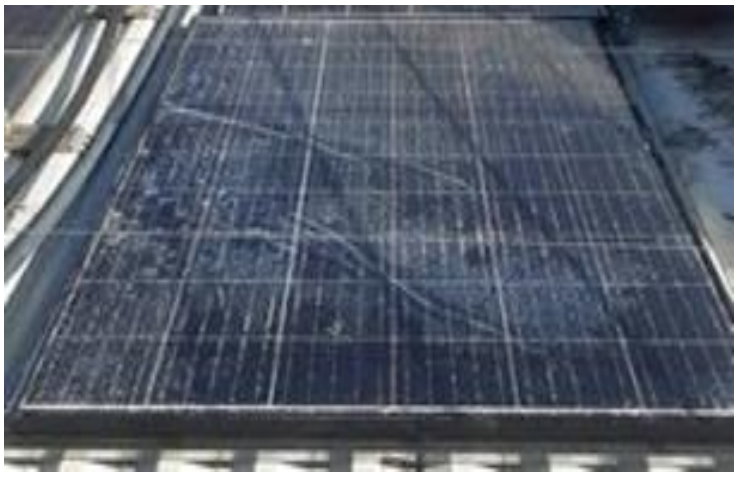

Figure II-7 : Fissure sur un Panneau photovoltaïque *[27]*

II.2.1.8 Défaut diode de By-Pass :

Les diodes by-pass, connues en électronique sous le nom de diodes de roue libre est un des solutions pour protéger les cellules à l'ombrage partiel. Cette diode Connecté en parallèle avec des cellules ou des panneaux solaires individuels pour la protection. [33] La figure II-8 montre un schéma des défauts électriques associés à cette diode.

-Court-circuit.

-Circuit ouvert.

-Impédance Z quelconque.

-Inversion de la polarité.

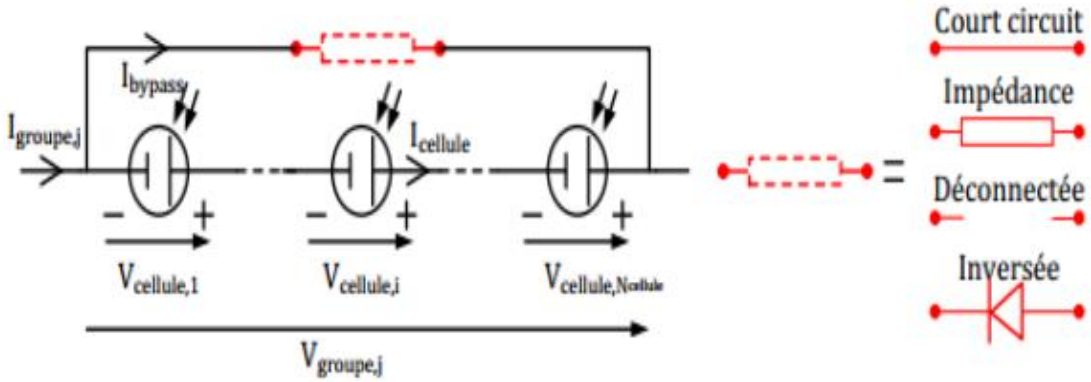

Figure II-8 : Défaut de diode de By-Pass *[33]*

II.2.2 Défaut électrique :

Les défauts survenant dans les connexions entre conducteurs, les courts-circuits, les défauts dus aux circuits ouverts et les défauts des appareils électriques et des appareils de mesure sont tous classés comme défauts électriques.

II.2.2.1 Défaut champ :

II.2.2.1.1 Défaut circuit ouvert :

Lorsque la ligne qui transporte le courant et qui est connectée en série avec la charge est retirée du circuit ou déconnectée, un défaut de circuit ouvert se produit. Le facteur prédominant à l'origine de ce défaut est le branchement ou les connexions incorrectes ou desserrées entre les différents composants du système. Le défaut de circuit ouvert se produisant dans le panneau photovoltaïque est illustré à la figure II-9. En raison du défaut de circuit ouvert, le courant de court-circuit et la puissance de sortie la plus élevée générée diminuent avec l'augmentation du nombre de chaînes déconnectées et la tension est maintenue presque proche de la valeur normale [28,34].

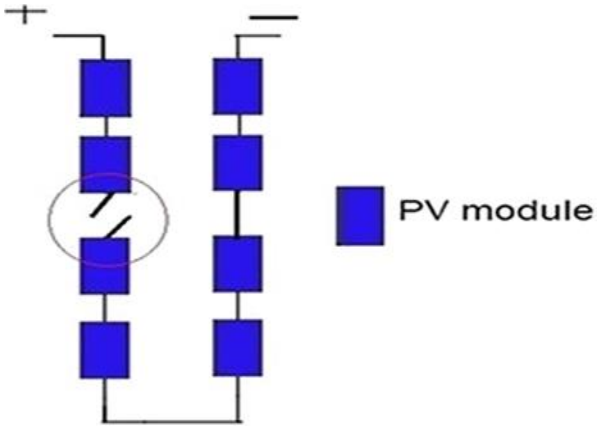

Figure II-9 : Défaut de circuit ouvert *[27]*

II.2.2.1.2 Défaut ligne-ligne :

Le défaut ligne à ligne dans un générateur photovoltaïque, comme le montre la Figure II-10, se produit en raison d'un court-circuit accidentel entre deux potentiels variables ou parfois entre les câbles du générateur. Cette faute se produit de deux manières par rapport à sa position, lorsqu'elle est dans la même chaîne, elle est appelée faute intra-chaîne et lorsqu'elle est dans des chaînes voisines, elle est appelée défaut entre chaînes. Il y a un changement dans le tracé V-I d'un système PV en raison de la réduction de tension [35].

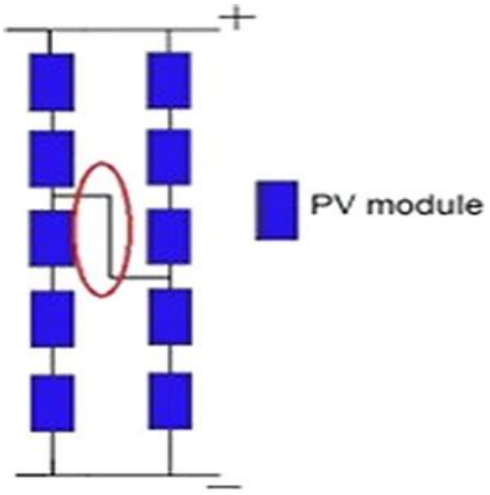

Figure II-10 : Défaut ligne à ligne *[27]*

II.2.2.1.3 Défaut ligne terre :

Le défaut de terre ou défaut à la terre est un type de défaut de court-circuit illustré à la Figure II 11. Cela se produit lorsqu'un circuit génère un chemin accidentel vers le sol [36]. Pour protéger le client ou l'utilisateur contre les chocs électriques potentiels et autres dangers, chaque métal non conducteur est connecté à la terre ou mis à la terre. Lorsque ces métaux non conducteurs rencontrent les conducteurs porteurs de courant, une quantité massive de courant les traverse puis dans le sol [37]. Dans le générateur photovoltaïque, le défaut de discordance est provoqué par l'énorme augmentation du courant circulant dans les conducteurs non porteurs de courant. Ce défaut est connu sous le nom de défaut à la terre. Ils sont de deux sortes, à savoir les défauts à la terre inférieurs et les défauts à la terre supérieurs.

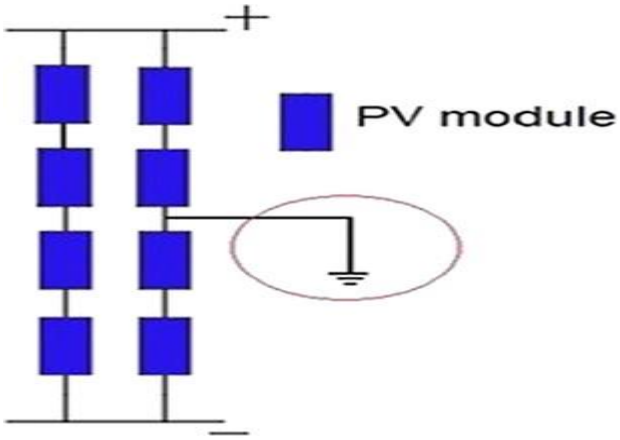

Figure II-11 : Court-circuit entre le module PV et la terre *[27]*

II.2.2.1.4 Défaut D'ARC :

Le passage involontaire d'un courant dans l'air ou dans un autre diélectrique est connu sous le nom de défaut d'arc. Les défauts d'arc produisent le bruit de haute fréquence dans le signal du courant continu de la branche PV. Ce type de rupture est très dangereux pour les plantes et peut produire des incendies [38,39].

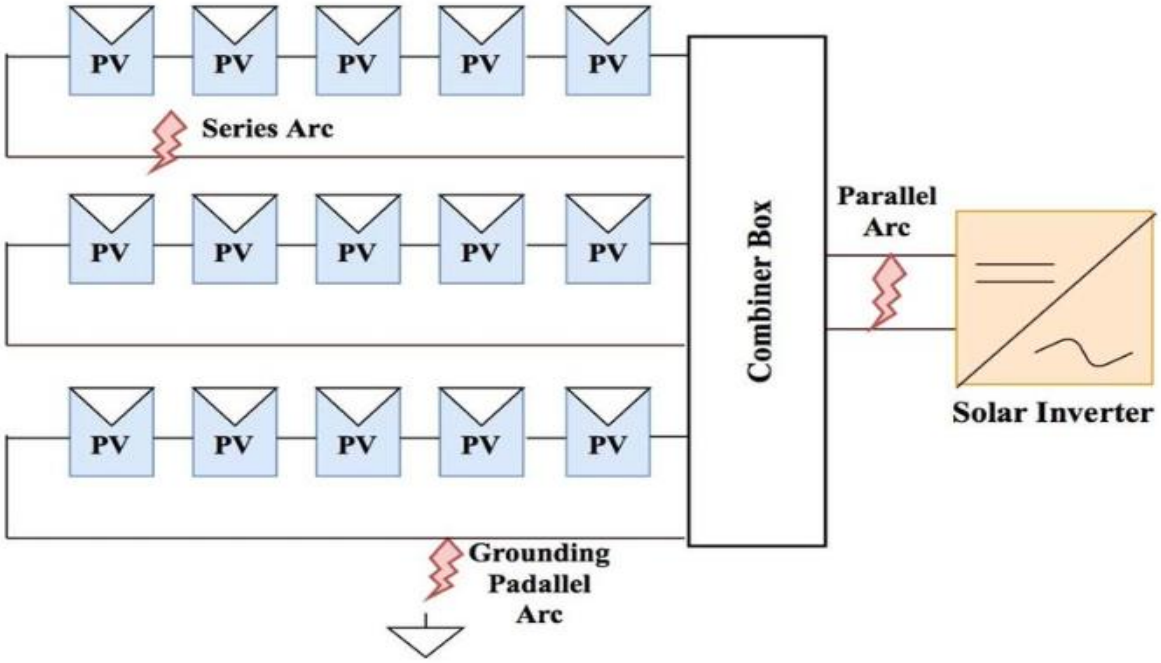

Figure II-12: Défaut d'arc *[40]*

II.2.2.2 Défaut courant continu (CC) :

Les différents types de défauts qui entrent dans la catégorie des défauts CC sont les suivants : défaut de suivi du point de puissance maximale (MPPT), défaut du banc de batteries et défaut du générateur photovoltaïque.

II.2.2.2.1 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.

II.2.2.2.2 Défaut MPPT :

Le tracker Maximum PowerPoint (MPPT) maximise la puissance fournie à l'onduleur à partir du générateur photovoltaïque. Il s'agit essentiellement d'un algorithme, inclus dans le régulateur de charge, qui extrait la puissance maximale du module PV dans certaines conditions. Un régulateur de charge défectueux peut affecter le fonctionnement du MPPT. Tout défaut dans MPPT réduit la puissance de sortie et la tension de sortie [36] .

II.2.2.3 Défaut courant alternatif (AC) :

Les défauts survenant du côté du système photovoltaïque où est présent le circuit à courant alternatif, qui comprend le réseau de distribution et l'onduleur, relèvent des défauts AC. Les défauts du réseau et de l'onduleur qui entrent dans la catégorie des défauts AC sont abordés ci-dessous.

II.2.2.3.1 Défaut de réseau :

Dans un système photovoltaïque connecté au réseau, la sortie du générateur photovoltaïque est connectée en parallèle au système de distribution d'énergie ou au réseau, via un onduleur. En cas de panne de courant dans le réseau électrique public, la production photovoltaïque doit être coupée du réseau, afin qu'il n'y ait aucun flux d'énergie du système photovoltaïque vers le réseau. Les défauts survenant dans la PowerStation, les connexions lâches ou les dommages dans la ligne de transmission, les pannes de courant, les surcharges, etc. relèvent de la faute du réseau [36].

II.2.2.3.2 Défaut de l'onduleur :

Le courant de sortie produit par le générateur photovoltaïque est de nature continue. Ce courant continu de sortie PV est envoyé à l'onduleur qui le convertit en courant alternatif de la fréquence requise. Les principales raisons d'un défaut de l'onduleur sont une mauvaise installation, un courant de tension incontrôlé et une énorme quantité de puissance de charge [41] . Les onduleurs solaires liés au réseau jouent un rôle majeur dans la déconnexion du système photovoltaïque du réseau en cas de panne du réseau. Ceci est fait pour des raisons de sécurité. L'incapacité des onduleurs à effectuer cette action peut constituer une menace pour les travailleurs du réseau.

II.2.3 Défauts environnementaux :

De nombreux facteurs environnementaux tels que la météo, le rayonnement solaire, les conditions d'ombrage, la température, etc. affectent le fonctionnement du générateur photovoltaïque. Ces facteurs peuvent causer de graves dommages aux cellules, qui peuvent ou non être inversés. Dans cette section, les différents types de défauts environnementaux sont décrits dans cette section.

II.2.3.1 Défaut d'ombrage :

Il existe plusieurs Type d'ombrage [42] :

a-Ombrage directe : appelé aussi ombre immédiat ce type d'ombragé provoque des pertes de production importantes du système photovoltaïque Plus l'obstacle d'ombrage est proche des modules ou des champs PV, plus l'ombre est important, moins la lumière atteint la surface des modules PV.

Exemple : cheminée, parabole d'antenne, câbles, poteau, arbre proche, bâtiment du voisin

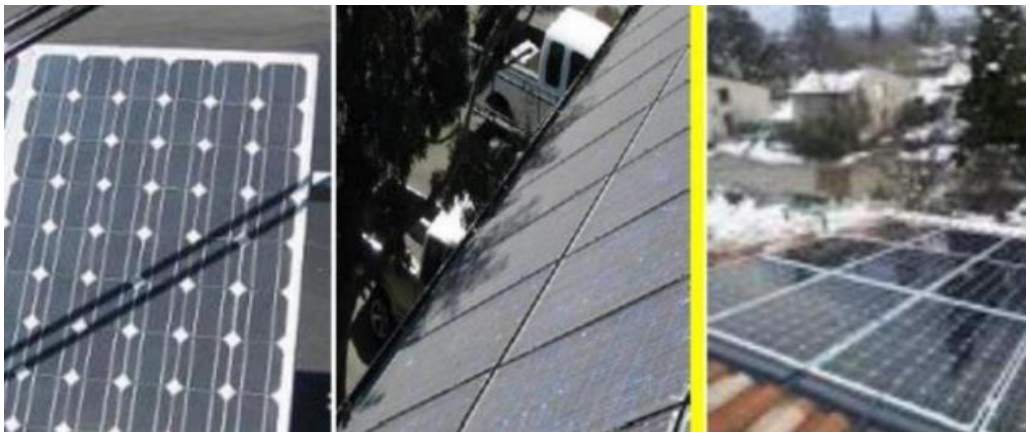

Figure II-13: Défaut d'ombrage partiel *[27]*

b. Ombrage temporaire : est cause par les conditions naturelles par exemple :la neige, feuilles d'arbre, poussière, et autres. Pour ces conditions il faut incliner les modules d'un angle plus de 10° afin de faciliter l'auto-nettoyage d'eau (par l'eau de pluie)

Figure II-14 :Panneau solaire photovoltaïque (a) entièrement couvert (b) partiellement couvert à cause de la neige *[27]*

c. Auto-ombrage : l'ombrage entre les régnées des modules sur toit plat ou sur terrasse

Figure II-15 : Ombrage entre les Rangées de Modules sur Toit Plat ou Terrasse *[42]*

II.2.3.2 Défaut Points Chauds :

L'effet de point chaude peut provoquer des dommages permanent tels qu'une dégradation, la fusion des joints de soudure et le vieillissement des matériaux d'encapsulation qui peuvent affecter la puissance de sortie et la durée de vie des module PV.

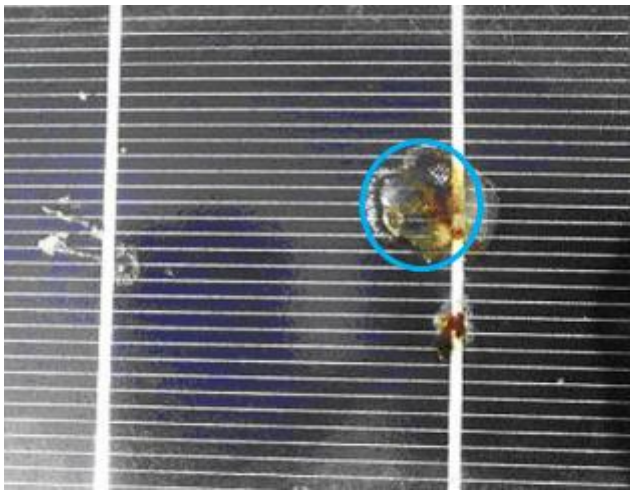

Figure II-16 :Défaut Points Chauds *[27]*

II.3 Méthodes de détection des défauts dans les systèmes PV :

Dans les systèmes de détection de défauts photovoltaïques (PV FDD), on utilise généralement trois types de données : les mesures électriques, les données environnementales et les images des panneaux photovoltaïques. Ces données peuvent être analysées à l'aide de différentes techniques, que l'on peut regrouper en trois catégories principales [43] :

1. Les méthodes non électriques, qui englobent les méthodes visuelles et thermiques (VTM).

2. Les méthodes électriques traditionnelles, couramment utilisées dans l'industrie.

3. Les méthodes basées sur l'intelligence artificielle (IA), qui utilisent des algorithmes d'apprentissage automatique et de deep learning pour détecter et classer les défauts.

II.3.1 Méthodes électriques :

II.3.1.1 Analyse de la courbe Courant – Tension :

L'analyse des courbes courant-tension (I-V) est une méthode classique pour détecter les défauts dans les systèmes photovoltaïques. Cette technique s'appuie sur l'observation des caractéristiques électriques d'un module, telles que le courant de court-circuit et la tension en circuit ouvert.

Les mesures sont effectuées lorsque la tension ou le courant varient sous l'effet d'une charge externe ou d'une source d'alimentation. Les modules ou cellules avec des réponses similaires servent souvent de référence. En conditions normales, les caractéristiques I-V suivent une courbe spécifique qui se modifie en présence d'un défaut. L'ampleur de cette modification dépend du type et de la gravité du défaut [44].

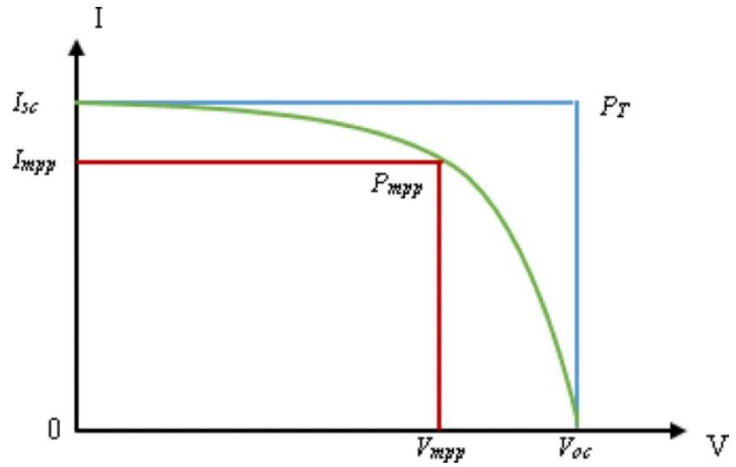

Figure II-17 : Paramètres de la courbe IV *[45]*

Courant de Court-circuit (Isc), Tension du circuit ouvert (Voc), point de puissance maximale (Pmpp) et pour point de puissance virtuel (PT).

La courbe I-V d'un module peut être utile pour détecter divers défauts. Malheureusement, l'emplacement précis de ces pannes n'est pas détecté, d'autres techniques sont donc souvent nécessaires pour trouver leur emplacement. Cela rend l'ensemble du processus difficile.

II.3.1.2 Techniques statistiques et de traitement du signal :

Les techniques de traitement du signal, telles que l'analyse de forme d'onde, la mesure de la capacité terrestre, le spectre lancé et la réflectométrie dans le domaine temporel (TDR), sont employées pour détecter et localiser les défauts dans les panneaux photovoltaïques. Toutefois, leur efficacité peut varier en fonction des conditions d'installation, notamment les matériaux utilisés et le câblage des composants photovoltaïques [46].

II.3.2 Méthodes visuelles et thermiques (VTM) :

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

II.3.2.1 La méthode d'électroluminescence (EL) :

Technique d'inspection des modules photovoltaïques basée sur la recombinaison radiative. Dans cette méthode, un courant continu est appliqué aux modules, ce qui stimule la recombinaison radiative dans les cellules solaires. Pendant cette recombinaison, les électrons descendent d'un niveau d'énergie élevé à un niveau inférieur, émettant une lumière appelée électroluminescence.

Cette lumière est ensuite capturée par une caméra à dispositif à transfert de charge (CCD). Les images d'électroluminescence obtenues sont ensuite analysées pour détecter les défauts dans les modules ou les cellules photovoltaïques [47].

Cette technique est non destructive et relativement rapide, offrant une riche source d'informations sur l'uniformité des cellules et des modules solaires. Cependant, elle doit être utilisée en combinaison avec d'autres méthodes pour une caractérisation complète des défauts.

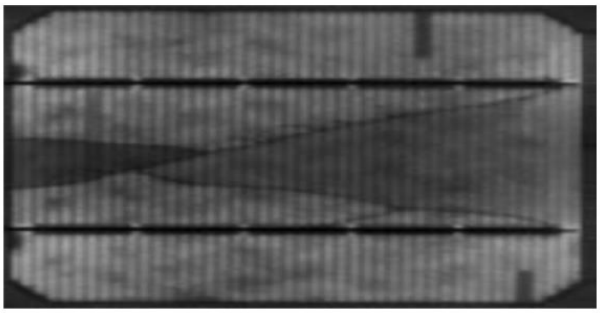

Figure II-18 : EL Failure *[45]*

II.3.2.2 La méthode de fluorescence UV :

Connue sous le nom d'imagerie FL, est une technique d'analyse utilisée dans le domaine des systèmes photovoltaïques. Elle est particulièrement utile pour l'analyse de l'éthylène-acétate de vinyle (EVA), un composant clé des cellules photovoltaïques.

Cette méthode permet d'analyser la décoloration des modules photovoltaïques, comme illustré à la Figure II- 19. Elle est si sensible qu'elle peut déterminer le nombre et l'emplacement des fissures dans les cellules des modules photovoltaïques, même dans un environnement extérieur sombre. Cependant, elle présente une limitation : elle ne peut pas détecter les fissures situées sur le bord de la cellule [44].

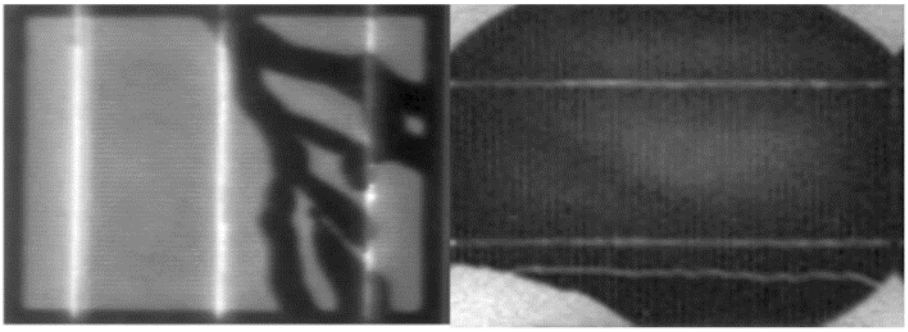

Figure II-19 : défaillance UV FL *[45]*

La méthode de fluorescence UV fonctionne en exploitant l'émission de lumière par un matériau exposé à un rayonnement ultraviolet. Lorsqu'on expose les cellules photovoltaïques à ce rayonnement, elles émettent une lumière à une longueur d'onde différente. Cette lumière est ensuite capturée et analysée pour détecter divers défauts, comme les fissures, dans les cellules photovoltaïques. Cette technique offre ainsi une méthode non destructive et efficace pour inspecter et évaluer l'intégrité des cellules photovoltaïques.

II.3.2.3 La thermographie infrarouge (IR) :

Technique non destructive et sans contact couramment utilisée pour détecter les pannes dans les systèmes photovoltaïques. Elle repose sur le principe du rayonnement, où une surface du système photovoltaïque ou de ses composants électriques libère de l'énergie sous forme d'ondes électromagnétiques. Ces ondes infrarouges sont émises par les atomes en mouvement de tout objet ayant une température supérieure à 0 K ou lorsqu'il reçoit de l'énergie externe [48].

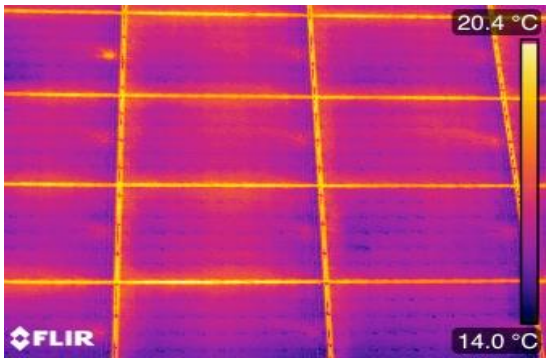

Figure II-20:Contrôle et inspection par thermographie infrarouge

Cette technique est particulièrement utile pour localiser et classer les pannes des modules photovoltaïques, ainsi que pour inspecter d'autres composants du système, tels que le câblage, les diodes, les combinateurs de boîtes CC, les boîtes de jonction et les connecteurs.

II.3.3 Méthode d'intelligence artificielle :

Les techniques d'intelligence artificielle (IA) sont largement utilisées dans le domaine des systèmes photovoltaïques, notamment pour la détection des défauts. Ces techniques, qui incluent des méthodes statistiques et l'apprentissage automatique (ML), sont capables de gérer des problèmes complexes et non linéaires. Parmi les systèmes d'IA utilisés figurent les réseaux de neurones artificiels, la logique floue, les machines à vecteurs de support et les arbres de décision. L'apprentissage automatique permet aux ordinateurs d'apprendre à partir des données sans programmation explicite [49].

II.4 Conclusion :

Ce chapitre examine les nombreux défauts auxquels sont sujets les systèmes photovoltaïques (PV), qui compromettent leur efficacité et leur rentabilité, avec des répercussions potentiellement graves sur la sécurité publique. Nous avons exploré les diverses classifications et méthodes de détection de ces défauts dans les systèmes PV.

Chaque panneau solaire peut être affecté par différents types de défauts, chacun ayant un impact spécifique sur le courant, la tension et sur la puissance générée. En comprenant les propriétés de ces effets, il devient possible de détecter le type de défaut et son incidence sur le fonctionnement du système.

Chapitre 3 : Réseaux de neurones et prétraitement des données des systèmes photovoltaïques

III.1 Introduction :

Dans ce chapitre, nous explorons l'application de l'intelligence artificielle (IA) dans le domaine des systèmes photovoltaïques, en mettant particulièrement l'accent sur le modèle de réseau de neurones LSTM (Long Short-Term Memory) développé pour notre étude. L'IA, avec ses diverses techniques.

Nous détaillerons les types de données collectées et traitées pour entraîner notre modèle LSTM, ainsi que les performances et les avantages de ce dernier dans l'analyse des systèmes photovoltaïques. De plus, nous expliquerons le prétraitement de ces données, étape cruciale pour garantir la précision et l'efficacité de notre modèle.

III.2 Notions de base de L'intelligence artificielle :

III.2.1 Définition de l'objet de IA :

L'intelligence artificielle (IA) est un processus d'imitation de l'intelligence humaine qui repose sur la mise en œuvre et l'application d'algorithmes exécutés dans un environnement informatique dynamique. Son but est de permettre à des ordinateurs de penser et d'agir comme des êtres humains [50]. Elle est utilisée dans divers domaines tels que la médecine, les transports, le traitement de signal, et bien d'autres.

III.3 Apprentissage automatique (Machine Learning) :

Le Machine Learning (ML) peut être défini comme étant une technologie d'intelligence artificielle. C'est également une science qui concerne le développement et l'implémentation de procédures automatisables qui permettent à une machine d'apprendre et d'évoluer. L'être humain a tendance à améliorer sa situation en utilisant l'expérience obtenue durant des années [51].

L'apprentissage automatique fonctionne de la même manière. Nous récupérons l'ensemble de données d'entraînement, qui contient les données et le résultat. Nous l'utilisons pour formuler un modèle. Ensuite, nous introduisons des données réelles dans ce modèle pour prédire un résultat. Lorsque nous validons le résultat prévu, le modèle apprend ce qui améliore son résultat (voir la Figure III 1) [52].

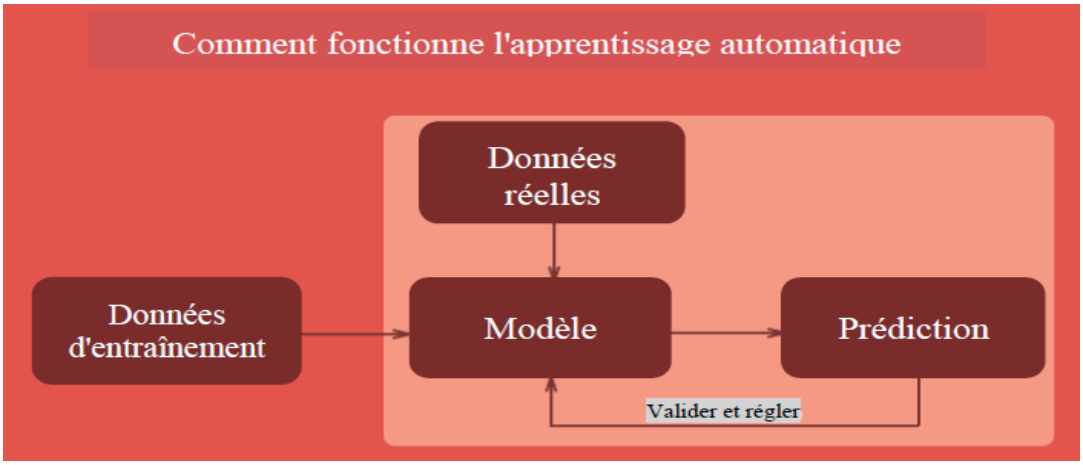

Figure III-1 :Le fonctionnement général d'apprentissage automatique. *[53]*

III.3.1 Méthodes d'apprentissage automatique :

Les méthodes d'apprentissage automatique sont utilisées pour que le système apprenne en utilisant des méthodes comme l'apprentissage supervisé et l'apprentissage non supervisé qui sont ensuite classées dans des méthodes comme la classification, la régression et le regroupement [12] (voir la Figure III 2).

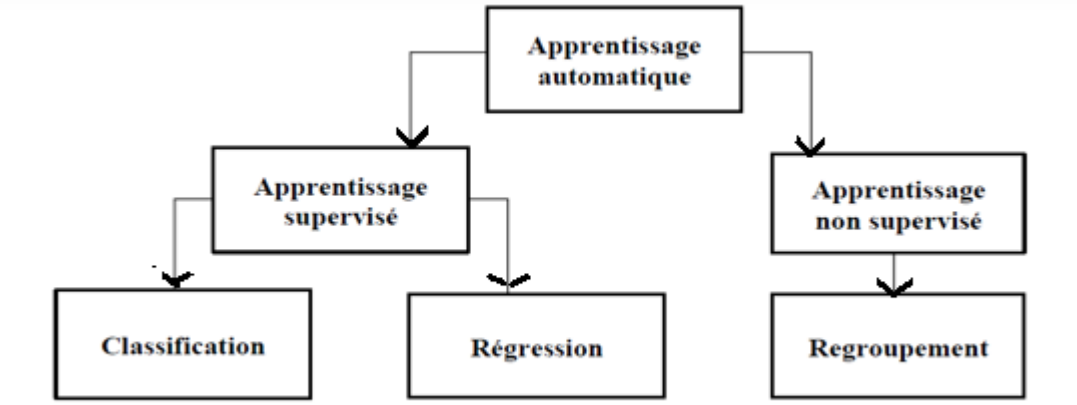

Figure III-2 :Méthodes d'apprentissage automatique

III.3.1.1 L'apprentissage supervisé :

Dans ce cas, la connaissance a priori de la sortie désirée est nécessaire. On présente au réseau le vecteur d'entrée puis on calcule sa sortie, cette dernière sera comparée avec la sortie désirée, ensuite les poids sont ajustés de façon à réduire l'écart entre elles. Cette procédure est répétée jusqu'à ce qu'un critère de performance soit satisfait.

L'apprentissage supervisé détermine les poids synaptiques à partir d'exemples étiquetés de formes auquel un professeur a associé des réponses ou des cibles désirées également étiquetées et grâce à une stratégie spécifique [54] .

III.3.1.2 L'apprentissage non supervisé :

Contrairement à l'apprentissage supervisé, on ne trouvera d'étiquetage dans ce modèle. L'objectif est que l'algorithme lui-même utilise un jeu de données brutes et obtient un résultat en se fondant sur la détection de similarités entre certaines de ces données [55].

III.4 Apprentissage profond (Deep Learning) :

Le Deep Learning ou apprentissage profond (DL) est un type d'intelligence artificielle dérivé du Machine Learning (apprentissage automatique) où la machine est capable d'apprendre par elle-même, contrairement à la programmation où elle se contente d'exécuter à la lettre des règles prédéterminées [56].

Le Deep Learning est utilisé dans de nombreux domaines, tels que la reconnaissance d'image, la traduction automatique, la reconnaissance vocale, la robotique, traitement de signal, etc

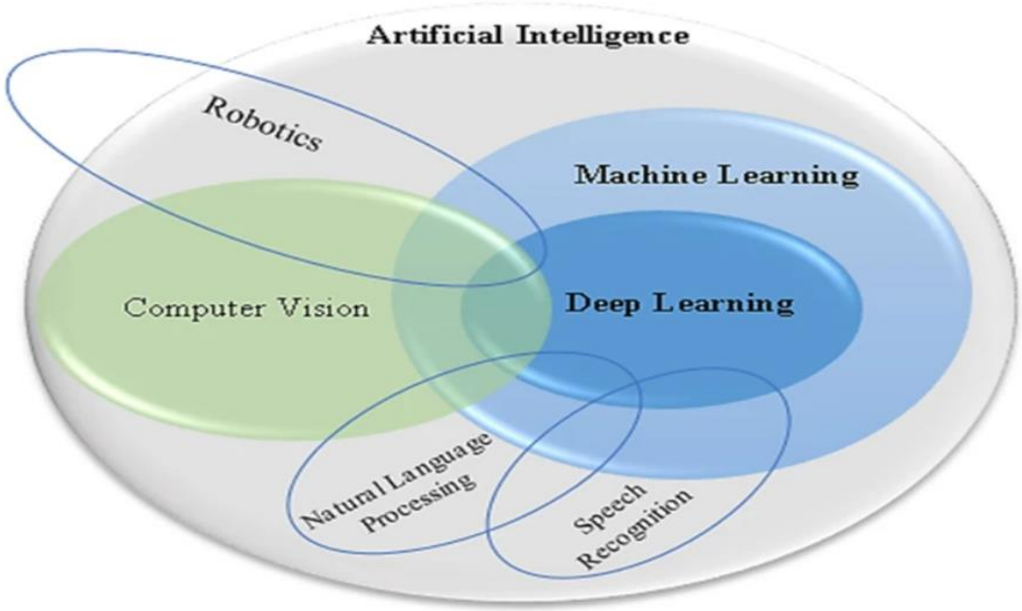

Figure III-3 :L'interaction entre intelligence artificielle et machine learning et deep learning *[45]*

III.5 Machine learning vs Deep learning:

En termes pratiques, l'apprentissage profond est une sous-catégorie de l'apprentissage automatique. Bien qu'ils fonctionnent de manière similaire, leurs capacités diffèrent. Alors que les modèles d'apprentissage automatique classiques s'améliorent progressivement avec l'expérience, ils nécessitent toujours une intervention humaine pour ajuster les prédictions inexactes.

En revanche, avec les modèles d'apprentissage profond, un algorithme peut évaluer la précision de ses propres prédictions à l'aide de son propre réseau neuronal, sans nécessiter d'intervention humaine. Cette capacité à auto-évaluer et à s'adapter rend les modèles d'apprentissage profond particulièrement puissants et efficaces dans de nombreuses tâches d'analyse de données et de prédiction [57].

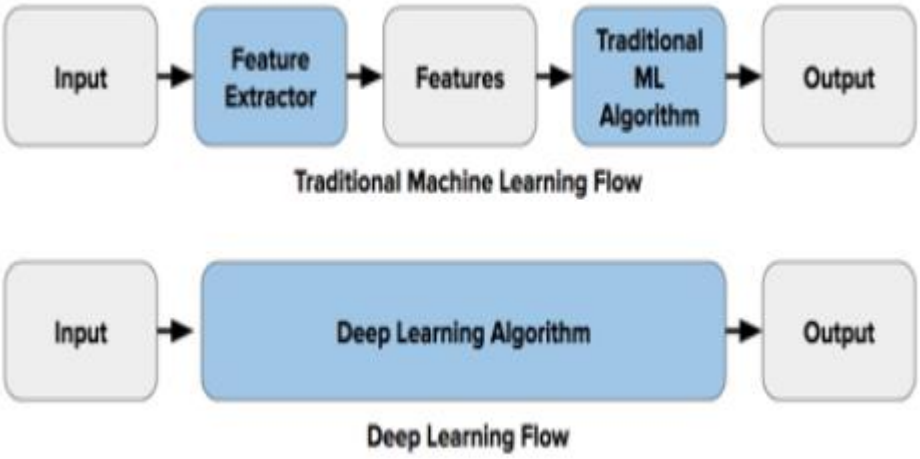

Figure III-4 :Comparaison entre la machine Learning et le Deep Learning *[57]*

III.6 Réseau de neurones :

Le concept de réseau de neurones est issu de l'étude des neurones biologiques à partir desquels un mécanisme d'apprentissage et de restitution d'informations a été déterminé. Les réseaux de neurones font partie du domaine des sciences cognitives qui cherche à développer des modèles de systèmes capables de présenter des capacités d'apprentissage et d'adaptation à leur environnement, ils permettent aux ordinateurs de résoudre des problèmes de manière autonome et d'améliorer leurs capacités de manière générale [58].

III.6.1 Fonctionnement de réseaux de neurones :

Un réseau de neurones repose sur un grand nombre de processeurs fonctionnant en parallèle et organisés par tiers. Le premier tiers reçoit les entrées d'informations brutes.

Par la suite, chaque tiers reçoit les sorties d'informations du tiers précédent. Le dernier tiers, en revanche, produit les résultats du système [59].

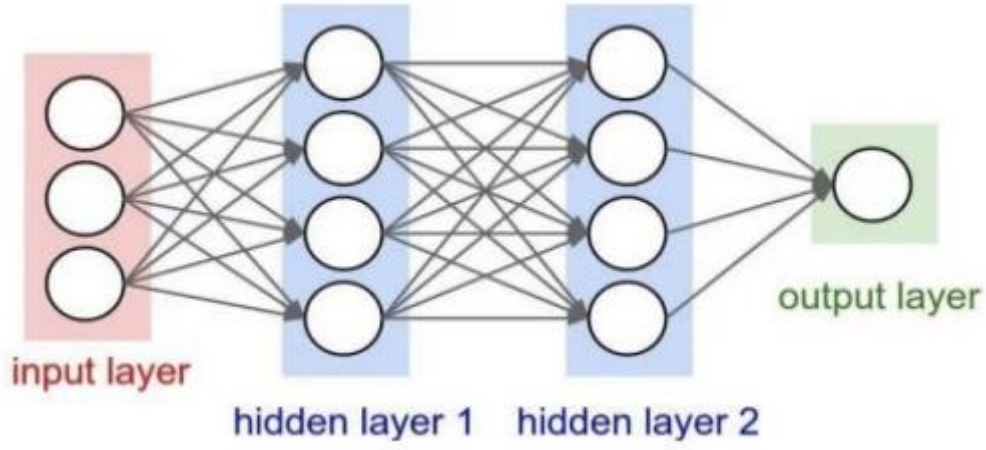

Figure III-5: Exemple de Fonctionnement de réseau neurones.

III.6.2 Types de réseaux de neurones :

III.6.2.1 Réseaux CNN (Convolution) :

Les réseaux de neurones convolutionnels (CNN) sont spécifiquement conçus pour le traitement des images. Leur force réside dans leur capacité à reconnaître et à classifier visuellement des éléments en identifiant des motifs et des caractéristiques dans les images.

Ces réseaux comprennent des couches de convolution qui filtrent et transforment l'entrée pour extraire des caractéristiques significatives telles que les formes et les textures. Cette capacité les rend particulièrement adaptés à des tâches telles que la reconnaissance faciale, la détection d'objets ou l'analyse d'imagerie médicale [60].

III.6.2.2 Réseaux DNN (Déconvolution) :

Les réseaux DNN, ou réseaux de déconvolution, sont souvent utilisés pour des tâches de reconstruction d'image, jouant un rôle crucial dans des applications comme l'amélioration d'image ou la vision par ordinateur.

Par exemple, un DNN est capable d'améliorer la résolution d'une vieille vidéo de surveillance pour aider à identifier un suspect [60].

III.6.2.3 Réseaux FeedForward :

Les réseaux FeedForward représentent la forme la plus basique de réseaux de neurones. Dans ces réseaux, l'information se propage dans une seule direction, de l'entrée vers la sortie, sans rétroaction. Ils sont souvent utilisés pour des tâches de classification simples.

Par exemple, un réseau FeedForward basique peut être utilisé pour catégoriser des emails en différentes classes telles que "urgent", "important", "secondaire" ou "spam" en se basant sur le contenu textuel. Dans ce cas, chaque mot du contenu de l'email serait représenté par une entrée du réseau, et le réseau apprendrait à associer ces entrées à des étiquettes de catégories spécifiques. Une fois entraîné, le réseau serait capable de classer de nouveaux emails en fonction des catégories apprises [60].

III.6.2.4 Réseaux de Neurones Antagonistes Génératifs (GAN) :

Les Réseaux de Neurones Antagonistes Génératifs (GAN) sont une classe de modèles de machine learning inventée par Ian Goodfellow et ses collègues en 2014. Les GAN sont utilisés principalement pour la génération de données synthétiques qui sont indiscernables des données réelles. Ils se composent de deux réseaux de neurones en compétition : un générateur et un discriminateur.

III.6.2.5 Réseaux RNN (Récurrents) :

Les réseaux de neurones récurrents (RNN) sont spécialement conçus pour traiter des séquences de données telles que du texte ou du son. Ils sont particulièrement adaptés à des tâches telles que la traduction automatique ou la reconnaissance vocale.

Ce qui distingue les RNN, c'est leur capacité à prendre en compte non seulement l'entrée actuelle, mais aussi les entrées précédentes, leur permettant ainsi de "se souvenir" d'informations d'une étape à l'autre. Par exemple, dans une application de messagerie, un RNN peut prédire le mot suivant que l'utilisateur est susceptible de taper en se basant sur les mots précédemment tapés. Cette capacité à contextualiser les données en fonction des entrées précédentes rend les RNN très efficaces pour les tâches où la séquent alité des données est importante [60].

III.7 Model utilisé – LSTM (long short terme memory) :

Un RNN traditionnel possède un seul état caché transmis dans le temps, ce qui complique l'apprentissage des dépendances à long terme. Les LSTM résolvent ce problème grâce à une cellule mémoire capable de retenir des informations sur une longue période. Cela permet aux LSTM d'apprendre les dépendances à long terme dans les données séquentielles, les rendant idéaux pour des tâches telles que la traduction linguistique, la reconnaissance vocale et la prévision de séries chronologiques. Les LSTM peuvent également être combinés avec d'autres architectures de réseaux neuronaux, comme les réseaux neuronaux convolutifs (CNN) pour l'analyse d'images et de vidéos.

La cellule mémoire des LSTM est régulée par trois portes : la porte d'entrée, la porte d'oubli et la porte de sortie [61].

III.7.1 Architecture général du model LSTM [61] :

L'architecture LSTM possède une structure en chaîne qui contient quatre réseaux de neurones et différents blocs de mémoire appelés cellules.

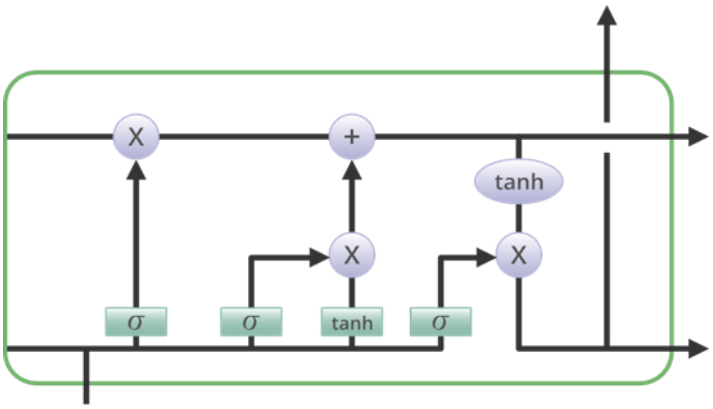

Figure III-6:Architecture LSTM *[61]*

Les informations sont conservées par les cellules et les manipulations de mémoire sont effectuées par 3 portes.

❖ **La porte d'oubli :**

Les informations qui ne sont plus utiles dans l'état de la cellule sont supprimées avec la porte d'oubli. Deux entrées X_t (entrée à un moment donné) et h_{t-1} (sortie de cellule précédente) sont transmises à la porte et multipliées par des matrices de poids suivies de l'ajout d'un biais.

Le résultat passe par une fonction d'activation qui donne une sortie binaire. Si pour un état de cellule particulier la sortie est 0, l'information est oubliée et pour la sortie 1, l'information est conservée pour une utilisation future.

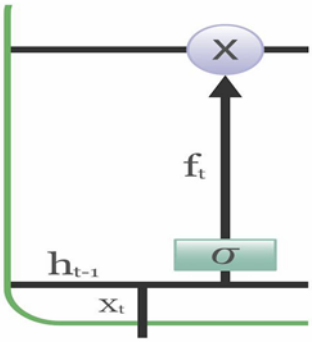

Figure III-7: porte de l'oublie *[61]*

L'équation de la porte oubliée est :

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad \text{où:}$$

- W_F Représente la matrice de poids associée à la porte d'oubli.
- $[h_{t-1}, X_t]$ désigne la concaténation de l'entrée actuelle et de l'état caché précédent.
- b_fEst le biais avec la porte oubliée.
- σ est la fonction d'activation sigmoïde.

❖ **Porte d'entrée :**

L'ajout d'informations utiles à l'état de la cellule est effectué par la porte d'entrée. Tout d'abord, les informations sont régulées à l'aide de la fonction sigmoïde et filtrent les valeurs à retenir de la même manière que la porte d'oubli en utilisant les entrées h_{t-1} et X_t

Ensuite, un vecteur est créé à l'aide de la fonction tanh qui donne une sortie de -1 à +1, qui contient toutes les valeurs possibles de h_{t-1} et X_t .

Enfin, les valeurs du vecteur et les valeurs régulées sont multipliées pour obtenir l'information utile.

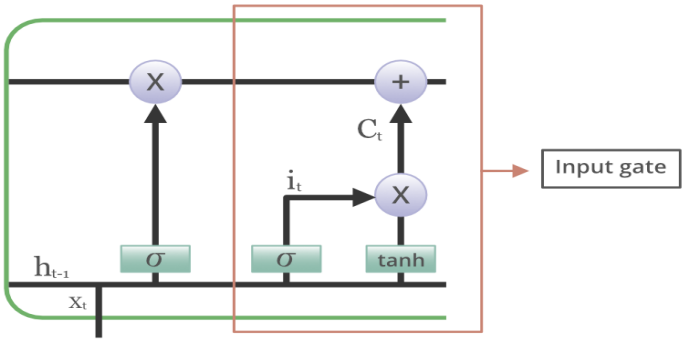

Figure III-8: porte d'entrée *[61]*

L'équation de la porte d'entrée est la suivante :

$$i_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_i)$$

$$\hat{C}_t = \tanh(W_t \cdot [h_{t-1}, X_t] + b_c)$$

Nous multiplions l'état précédent par f_t , sans tenir compte des informations que nous avions précédemment choisi d'ignorer. Ensuite, nous incluons $i_T . \hat{C}_t$. Cela représente les valeurs candidates mises à jour, ajustées en fonction du montant que nous avons choisi pour mettre à jour chaque valeur d'état.

$$Ct = f_t \odot C_{t-1}, + i_T \odot \hat{C}_t$$

où

- $\odot$ désigne une multiplication par éléments
- tanh est la fonction d'activation de tanh

❖ **Porte de sortie**

La tâche d'extraction des informations utiles de l'état actuel de la cellule à présenter en sortie est effectuée par la porte de sortie. Tout d'abord, un vecteur est généré en appliquant la fonction tanh sur la cellule. Ensuite, les informations sont régulées à l'aide de la fonction sigmoïde et filtrées par les valeurs à retenir à l'aide des entrées h_{t-1}, et X_t . Enfin, les valeurs du vecteur et les valeurs régulées sont multipliées pour être envoyées en sortie et en entrée à la cellule suivante.

L'équation de la porte de sortie est la suivante :

$$0_t = \sigma(W_0 \cdot [h_{t-1}, X_t] + b_0)$$

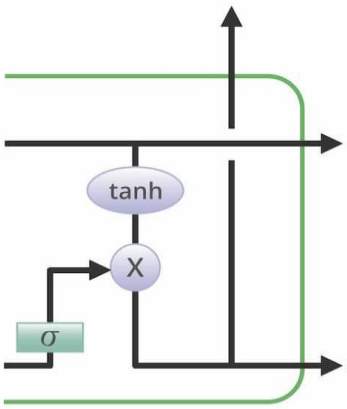

Figure III-9 : porte de sortie *[61]*

III.8 Contexte expérimental :

Dans le processus de mise en œuvre de notre système, nous avons d'abord déterminé le matériel nécessaire et le logiciel de programmation à utiliser que nous vous présentons par la suite. Ensuite, nous avons mis en avant une base de données spécifique. Pour l'entrainement de notre model LSTM Cité précédemment.

III.8.1 Google Colab :

Google Colab ou Colaboratory est un service cloud, offert par Google (gratuit), basé sur Jupyter Notebook et destiné à la formation et à la recherche dans l'apprentissage automatique. Cette plateforme permet d'entraîner des modèles de Machine Learning directement dans le cloud. Sans avoir besoin d'installer quoi que ce soit sur notre ordinateur à l'exception d'un navigateur [62].

III.8.2 Kaggel:

Une plateforme cloud qui fournit du temps de calcul gratuit pour l'entraînement des réseaux de neurones. Cela en fait une excellente plateforme pour apprendre et expérimenter de nouvelles techniques. De plus, Kaggle dispose d'une grande communauté de scientifiques des données qui partagent leurs carnets de notes et collaborent sur des projets. Cela permet aux utilisateurs de voir comment d'autres ont abordé des problèmes similaires et d'apprendre de leurs approches [62].

III.8.3 Python :

L'un des langages de programmation les plus couramment utilisés par les professionnels de la donnée, simple, puissant et facile à apprendre. Son premier avantage est d'utiliser des fonctions en anglais.

De plus, la syntaxe de Python a beau présenter quelques subtilités, elle est beaucoup moins lourde et rigide que celle des autres langages. L'apprentissage de Python est donc très accessible (même pour les débutants), et c'est souvent avec Python qu'on débute la programmation [63].

III.8.4 Bibliothèques utilisé [63]:

- **pandas** est utilisé pour manipuler les données sous forme de DataFrame, ce qui est pratique pour le nettoyage et la transformation des données.
- **numpy** est utilisé pour les opérations numériques et pour manipuler des tableaux.
- **tqdm** fournit une barre de progression utile pour visualiser l'avancement des boucles. **os** permet d'interagir avec le système de fichiers pour lire et gérer les fichiers de données.
- **scikit-learn, LabelEncoder** et **train_test_split**, sont utilisées respectivement pour encoder les étiquettes en valeurs numériques et pour diviser les données en ensembles d'entraînement et de test.
- **scipy.signal** fournit des outils pour le traitement des signaux, comme les filtres numériques.
- **torch:** Le module principal de PyTorch, utilisé pour les opérations de tenseurs et l'autograd (différentiation automatique).
- **torch.autograd:** Permet la différentiation automatique des tenseurs pour le calcul du gradient.
- **torch.nn:** Contient les modules et les couches de réseaux neuronaux.
- **torch.nn.functional**: Contient des fonctions non linéaires, des fonctions de perte, etc.
- **torch.optim:** Contient des algorithmes d'optimisation.
- **torch.utils.data:** Fournit des utilitaires pour manipuler les données, notamment des classes pour créer des datasets et des data loaders.
- **sklearn.metrics**: Contient des fonctions pour calculer les métriques de classification comme le rapport de classification et la matrice de confusion.
- **sklearn.preprocessing:** Offre des outils pour prétraiter les données, comme l'encodage des labels.
- **sklearn.model_selection:** Fournit des outils pour diviser les ensembles de données, comme **train_test_split** pour séparer les données en ensembles d'entraînement et de test.
- **time:** Fournit des fonctions pour manipuler le temps.
- **matplotlib.pyplot** et **seaborn** sont utilisés pour la visualisation des données, ce qui aide à explorer et comprendre les données graphiquement

III.9 Description du dataset :

Le dataset utilisé dans notre projet provient de **GPVS-Faults** (données collectées à partir d'expériences en laboratoire sur des défauts dans un système de micro-panneaux photovoltaïques), les données sont collectées à partir de divers capteurs dans le système PV, les regroupant tous dans 16 fichiers de données au format .csv dont chacun correspond à un scénario de défaillances. Qui sont deviser en deux groupes de fichier de sept défauts [64].

le premier groupe comprend sept défauts en mode de fonctionnement IPPT

le second groupe comprend sept défauts en mode de fonctionnement MPPT

Ces défauts bien sûr ont été introduites manuellement au cours de chaque expérience et les mesures à haute fréquence sont bruitées, avec des perturbations et des variations de température et d'insolation.

III.9.1 Structuration des données :

Chaque fichier de données est étiqueté comme (**Fxy**) dont **x** est le type de défaut représenté en chiffre de 1 jusqu'à 7 (le 0 est une expérience sans l'introduction de défaut) et le **y** représente le mode de fonctionnent du PV illustré comme suite :

Tableau III-1: Type des défauts et leurs caractéristique

Libellé de panne	Type de panne	Description	Caractéristiques supplémentaires potentielles
F0	Aucune panne	Système fonctionne normalement	N/A (Aucune caractéristique de panne supplémentaire applicable)
F1	Défaut de cellule ouverte	Interruption du chemin électrique dans un module ou une chaîne, entraînant une perte de puissance	- Durée de la panne (temps pendant lequel la panne persiste) - Gravité de la panne (ampleur de la perte de puissance) - Analyse du domaine fréquentiel (motifs/signatures associés aux défauts de cellule ouverte)
F2	Court-circuit	Connexion involontaire à faible résistance dans un module ou une chaîne, provoquant une surintensité	- Durée de la panne (temps pendant lequel la panne persiste) - Gravité de la panne (ampleur de la surintensité) - Analyse du domaine fréquentiel (motifs/signatures associés aux courts-circuits)
F3	Défaut de diode de dérivation	Défaillance de la diode de dérivation, entraînant une surchauffe du module	- Durée de la panne (temps pendant lequel la panne persiste) - Changement de température (taux d'augmentation de la température du module) - Analyse du domaine fréquentiel (motifs/signatures

			associés aux défauts de diode de dérivation)
F4	Défaut de mise à la terre	Connexion électrique entre un conducteur sous tension et la terre, présentant un risque de sécurité	- Durée de la panne (temps pendant lequel la panne persiste) - Courant de terre (ampleur du courant circulant vers la terre) - Analyse du domaine fréquentiel (motifs/signatures associés aux défauts de mise à la terre)
F5	Défaut du convertisseur DC-AC	Dysfonctionnement du convertisseur DC-AC, entraînant une perte de puissance totale	- Durée de la panne (temps pendant lequel la panne persiste) - Fluctuations de tension/courant (changements de tension ou de courant DC/AC) - Analyse du domaine fréquentiel (motifs/signatures associés aux défauts du convertisseur DC-AC)
F6	Défaut du réseau	Problèmes avec le réseau électrique, perturbant le flux d'électricité	- Durée de la panne du réseau (temps pendant lequel la panne du réseau persiste) - Fluctuations de tension/fréquence (changements de tension ou de fréquence du réseau) - Analyse du domaine fréquentiel (motifs/signatures associés aux défauts du réseau)
F7	Ombrage	Blocage partiel/complet de la lumière du soleil, réduisant la production d'énergie	- Zone d'ombrage (étendue de la zone d'ombrage sur le champ PV) - Intensité d'ombrage

			(réduction de l'intensité lumineuse due à l'ombrage) - Analyse du domaine temporel (changements de la production d'énergie au fil du temps dus à l'ombrage)

Tableau III-2 : Exemple de défauts en mode IPPT et MPPT

Étiquette de défaut	Type de défaut
F0L	Aucun défaut - Faible consommation
F0M	Aucun défaut - Puissance moyenne
F1L	Circuit ouvert - Faible consommation
F1M	Circuit ouvert - Puissance moyenne
F2L	Court-circuit - Faible puissance

Ces données ont été répertorier dans des tableaux et chaque tableau du fichier est constitué de 15 colonnes de : **Time, Ipv, Vpv, Vdc, ia, ib, ic, va, vb, vc, Iabc, If, Vabc, Vf** et **label.**

- **Temps** : Temps en secondes, échantillonnage moyen T_s = 9.9989 μs.
- **Ipv** : Mesure du courant de l'ensemble de panneaux photovoltaïques.
- **Vpv** : Mesure de la tension de l'ensemble de panneaux photovoltaïques.
- **Vdc** : Mesure de la tension continue.
- **ia, ib, ic** : Mesures du courant en triphasé.
- **va, vb, vc** : Mesures de la tension en triphasé.
- **Iabc** : Amplitude du courant.
- **If** : Fréquence du courant.
- **Vabc** : Amplitude de la tension.
- **Vf** : Fréquence de la tension.

Out[10]:

	Time	Ipv	Vpv	Vdc	ia	ib	ic	va	vb	vc	Iabc	If	Vabc	Vf	label
0	0.000028	1.572327	101.348877	144.140625	-0.135133	0.490112	-0.354985	41.744537	-149.872894	109.064585	1.000000	50.000000	1.000000	50.000000	F0L
1	0.000128	1.503265	101.458740	143.554688	-0.108277	0.510254	-0.388555	46.831512	-150.716705	105.829976	1.000000	50.000000	1.000000	50.000000	F0L
2	0.000228	1.492859	101.574707	143.554688	-0.168702	0.496826	-0.334844	51.074677	-152.018585	102.543132	1.000000	50.000000	1.000000	50.000000	F0L
3	0.000328	1.558136	101.312256	143.261719	-0.135133	0.510254	-0.361699	55.848236	-152.585144	98.143260	1.000000	50.000000	1.000000	50.000000	F0L
4	0.000428	1.631927	101.141357	143.847656	-0.202271	0.503540	-0.321416	60.055237	-152.609253	94.261729	1.000000	50.000000	1.000000	50.000000	F0L
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1093407	14.399588	1.440826	101.574707	142.675781	0.469115	-0.537109	0.061274	-129.862518	139.530182	-9.430593	0.525074	49.937214	155.541659	50.004734	F7L
1093408	14.399688	1.496643	101.916504	142.675781	0.422118	-0.463257	0.027705	-133.177490	137.878723	-6.416982	0.525074	49.937214	155.541659	50.004734	F7L
1093409	14.399788	1.484344	102.484131	142.968750	0.475829	-0.523682	0.027705	-135.576324	134.346771	0.755412	0.524933	49.944112	155.545206	50.004216	F7L
1093410	14.399888	1.507996	101.788330	142.968750	0.448974	-0.429688	0.000850	-137.818451	132.273407	6.023204	0.524933	49.944112	155.545206	50.004216	F7L
1093411	14.399988	1.492859	101.751709	142.968750	0.489257	-0.490112	0.007563	-139.964142	129.657593	10.559692	0.524933	49.944112	155.545206	50.004216	F7L

1093412 rows × 15 columns

Figure III-10 : données de défauts en mode IPPT

Out[11]:

	Time	Ipv	Vpv	Vdc	ia	ib	ic	va	vb	vc	Iabc	If	Vabc	Vf	label
0	0.000041	2.369843	90.429688	147.949219	0.616820	-0.530396	-0.160283	-146.003418	120.255127	25.595601	1.000000	50.000000	1.000000	50.000000	F0M
1	0.000141	2.449310	90.161133	148.535156	0.603393	-0.543823	-0.193853	-147.052155	117.362061	29.951274	1.000000	50.000000	1.000000	50.000000	F0M
2	0.000241	2.345245	90.740967	147.656250	0.630248	-0.503540	-0.193853	-149.463043	113.564911	35.094503	1.000000	50.000000	1.000000	50.000000	F0M
3	0.000341	2.176849	91.003418	147.656250	0.636962	-0.496826	-0.213994	-149.559479	112.058105	39.361776	1.000000	50.000000	1.000000	50.000000	F0M
4	0.000441	2.226044	91.113281	147.363281	0.643676	-0.483398	-0.227422	-151.982422	106.271973	45.336761	1.000000	50.000000	1.000000	50.000000	F0M
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1070063	14.399531	2.460663	86.895752	144.726562	0.012572	0.584106	-0.603398	-34.403381	-111.949615	148.864339	0.688260	49.956302	155.361272	50.003623	F7M
1070064	14.399631	2.362274	86.975098	144.726562	0.019286	0.550537	-0.536260	-29.497223	-116.361542	147.365570	0.688260	49.956302	155.361272	50.003623	F7M
1070065	14.399731	2.302673	86.694336	144.726562	-0.034425	0.610962	-0.583257	-24.301758	-118.688049	146.180216	0.688260	49.956302	155.361272	50.003623	F7M
1070066	14.399831	2.293213	87.225342	144.726562	-0.034425	0.584106	-0.502690	-19.925995	-122.473145	144.540812	0.688232	49.962691	155.362644	50.003537	F7M
1070067	14.399931	2.304565	87.414551	144.433594	-0.067994	0.631104	-0.556401	-15.152435	-124.835815	142.314758	0.688232	49.962691	155.362644	50.003537	F7M

1070068 rows × 15 columns

Figure III-11 : données de défauts en mode MPPT

III.10 Prétraitement des Données :

Le prétraitement des données est une étape cruciale dans tout projet d'apprentissage automatique. Il s'agit de transformer les données brutes en un format qui peut être facilement et efficacement analysé pour extraire des informations pertinentes. Pour cela nous allons diviser notre code en plusieurs cellule pour nous faciliter la manipulation comme suite :

III.10.1 Création de fenêtres glissantes :

```
import pandas as pd
import numpy as np
from tqdm import tqdm
import os

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import LabelEncoder

from scipy.signal import butter, filtfilt
import matplotlib.pyplot as plt
import seaborn as sns
```

Dans cette première cellule nous importons toutes les bibliothèques nécessaires pour le prétraitement de nos données.

```
dataset_folder = '/kaggle/input/gpvs-fault/GPVS-Faults/GPVS-Faults'
filenames = os.listdir(dataset_folder)
class_names = [filename[:3] for filename in filenames]
le = LabelEncoder()
le.fit(class_names)
le.classes_
```

Cette cellule de code sert à préparer les étiquettes de classe pour notre ensemble de données. D'abord, nous donnons le chemin du dossier où se trouvent nos données.

Ensuite, nous récupèrerons tous les noms des fichiers dans ce dossier avec pour chaque nom de fichier, nous extrons les trois premiers caractères, qui correspondent souvent à l'identifiant de la classe pour cet échantillon.

```
output : array(['F0L', 'F0M', 'F1L', 'F1M', 'F2L', 'F2M', 'F3L', 'F3M', 'F4L',
    'F4M', 'F5L', 'F5M', 'F6L', 'F6M', 'F7L', 'F7M'], dtype='<U3')
```

Par exemple, si un fichier s'appelle "F0L" ça représente la classe. Ensuite, ces identifiants de classe sont convertis en valeurs numériques grâce à LabelEncoder de scikit-learn.

Enfin, nous affichons les classes uniques pour comprendre quelles catégories sont présentes dans nos données comme présenté ci-dessus.

```
def sliding_window(df: pd.DataFrame, seq_len=100, stride=1) -> np.ndarray:
    columns = df.columns
    np_df = df.to_numpy()
    ts = np.empty(shape=((len(df)-seq_len)//stride, seq_len, len(columns)))
    for index in tqdm(range((len(df)-seq_len)//stride)):
        ts[index, :, :] = np_df[index*stride:(index*stride)+seq_len, :]
    return ts
```

Cette fonction, sliding_window, découpe les séries temporelles en fenêtres glissantes.

nous spécifions la longueur de chaque séquence avec le paramètre seq_len et le pas de décalage entre les fenêtres avec le paramètre stride.

La fonction itère sur le DataFrame pour extraire les fenêtres glissantes de la taille spécifiée, stockées dans le tableau numpy ts.

```
seq_len = 200
stride = 15

label = filenames[0][:3]
# On charge les données à partir du premier fichier CSV dans le dossier spécifié
df = pd.read_csv(os.path.join(dataset_folder, filenames[0]), index_col=0)[6.7:]
# On utilise la fonction sliding_window pour créer des fenêtres glissantes
X = sliding_window(df, seq_len, stride)
# On initialise les étiquettes avec le label du premier fichier
y = np.full((X.shape[0], 1), label)
```

Dans cette cellule nous définissons la longueur de chaque séquence seq_len et le pas de décalage stride. Ensuite, on charge les données à partir du premier fichier CSV dans le dossier spécifié. en utilisant la fonction sliding_window pour créer des fenêtres glissantes à partir de ces données.

Les caractéristiques sont stockées dans X et les étiquettes correspondantes dans y.

```
for filename in filenames[1:]:
    label = filename[:3]
    # On charge les données à partir du fichier CSV actuel
    df = pd.read_csv(os.path.join(dataset_folder, filename), index_col=0)[6.7:]
    # On utilise la fonction sliding_window pour créer des fenêtres glissantes
    x = sliding_window(df, seq_len, stride)
    # On ajoute les nouvelles caractéristiques et étiquettes aux ensembles existants
    X = np.concatenate((X, x))
    y = np.concatenate((y, np.full((x.shape[0], 1), label)))
```

Dans cette boucle, nous parcourons les autres fichiers dans le dossier. Pour chaque fichier, on charge les données, on utilise sliding_window pour créer des fenêtres glissantes, puis on ajoute ces nouvelles données aux ensembles existants X et y.

Ces étapes nous permettent de préparer les données en utilisant des fenêtres glissantes pour ensuite passer à l'étapes suivante du filtrage des données.

III.10.2 Filtrage des données : filtre passe-bas

Un filtre passe-bas est un filtre qui laisse passer les basses fréquences et qui atténue les hautes fréquences, c'est-à-dire les fréquences supérieures à la fréquence de coupure.

Le concept de filtre passe-bas est une transformation mathématique appliquée à des données (un signal). L'implémentation d'un filtre passe-bas peut se faire numériquement ou avec des composants électroniques.

Nous avons utilisé le filtrage passe-bas pour supprimer le bruit et les fluctuations haute fréquence des données de séries chronologiques. Cela aide à obtenir une représentation plus fluide du comportement du système photovoltaïque.

```
T = 1e-4          # Période d'échantillonnage (pas totalement sûr)
fs = 1/T        # Taux d'échantillonnage, en Hz
cutoff = 3*1e2      # Fréquence de coupure désirée du filtre, en Hz
nyq = 0.5 * fs  # Fréquence de Nyquist
order = 2       # Un signal sinusoïdal peut être approximé par un polynôme de degré 2
n = 200 #int(T * fs) # Nombre total d'échantillons
```

Ce programme initialise les paramètres du filtre et des données.

Cela inclut la période d'échantillonnage **T**, qui est la période entre chaque mesure de nos données, le taux d'échantillonnage **fs**, qui est le nombre de mesures par seconde, la fréquence de coupure **cutoff**, qui est la fréquence à partir de laquelle on veut filtrer nos données, la fréquence de **Nyquist nyq**, qui est la moitié du taux d'échantillonnage, l'ordre du filtre **order**, qui détermine comment notre filtre va atténuer les fréquences supérieures à la fréquence de coupure, et le nombre total d'échantillons **n**, qui est le nombre total de points de données que l'on a.

```
def butter_lowpass_filter(data, cutoff, fs, order):
    normal_cutoff = cutoff / nyq
    # On obtient les coefficients du filtre
    b, a = butter(order, normal_cutoff, btype='low', analog=False)
    y = filtfilt(b, a, data)
    return y
```

Cette fonction butter_lowpass_filter prend nos données brutes, ainsi que la fréquence de coupure, le taux d'échantillonnage et l'ordre du filtre en entrée.

Elle calcule ensuite les coefficients du filtre en utilisant la fonction butter de SciPy, puis applique le filtre aux données en utilisant filtfilt, qui est une méthode pour filtrer un signal sans décalage temporel.

```
X_filtered = np.empty(shape=X.shape)
n_samples, _, n_features = X.shape
for j in tqdm(range(n_samples)):
    for i in range(n_features):
        X_filtered[j,:,i] = butter_lowpass_filter(X[j,:,i], cutoff, fs, order)
```

Dans cette boucle, nous itèrons à travers chaque échantillon de données et chaque caractéristique de ces échantillons. Pour chaque caractéristique, on applique le filtre passe-bas Butterworth défini précédemment à l'aide de butter_lowpass_filter. Les données filtrées sont ensuite stockées dans X_filtered.

Maintenant on commence par créer une figure avec 15 sous-graphes organisés en une grille de 5 lignes et 3 colonnes, avec une taille de figure définie à 14 pouces de large et 7 pouces de haut, puis on aplatie la grille pour faciliter l'itération. Ensuite, on sélectionne un index aléatoire pour choisir un échantillon des données filtrées et des données originales, stockés respectivement dans synthetic et real. Comme le montre le code :

```
def plot(original, filtered):
    fig, axes = plt.subplots(nrows=5, ncols=3, figsize=(14, 7))
    axes = axes.flatten()

    idx = np.random.randint(filtered.shape[0])
    synthetic = filtered[idx]
    real = original[idx]
```

Pour chaque caractéristique définie dans feature_columns, on crée un sous-graphe affichant les signaux réels et filtrés en utilisant pd.DataFrame.plot, avec des styles de ligne différents afin de les distinguer. On utilise sns.despine[] pour enlever les bordures supérieures et droites des sous-graphes,

Puis on ajoute une légende globale en bas de la figure pour identifier les signaux réels et filtrés. Les axes supplémentaires inutilisés (13 et 14) sont supprimés, et fig.tight_layout[] est utilisé pour ajuster automatiquement la disposition des sous-graphes afin d'éviter le chevauchement et d'assurer une présentation soignée. Grace a la boucle suivante :

```
feature_columns = ['Ipv', 'Vpv', 'Vdc', 'ia', 'ib', 'ic', 'va', 'vb', 'vc', 'Iabc', 'If', 'Vabc', 'Vf']
for j, ticker in enumerate(feature_columns):
    (pd.DataFrame({'Real': real[:, j],
                   'Synthetic': synthetic[:, j]})
     .plot(ax=axes[j],
           title=ticker,
           secondary_y='Synthetic', style=['-', '--'],
           lw=1,
           legend=None))
    line_real, = axes[j].plot([], [], '-', lw=1, label='Original signal')
    line_synthetic, = axes[j].plot([], [], '--', lw=1, label='Filtered signal')
```

```
sns.despine()
fig.legend(handles=[line_real, line_synthetic], labels=['Original signal', 'Filtered signal'], loc='lower center', prop={'size': 15})

fig.delaxes(axes[13])
fig.delaxes(axes[14])
#fig.suptitle(f'Fault {label_encoder.inverse_transform([label])[0]}')
fig.tight_layout()
```

Nous allons voir maintenant ensemble les résultats à savoir les données filtrées, bien sur dans des graphes comme nous l'avons expliqué au par avant. En utilisant la fonction **`plot`** avec **`X`** et **`X_filtered`** pour visualiser et comparer les signaux originaux et filtrés.

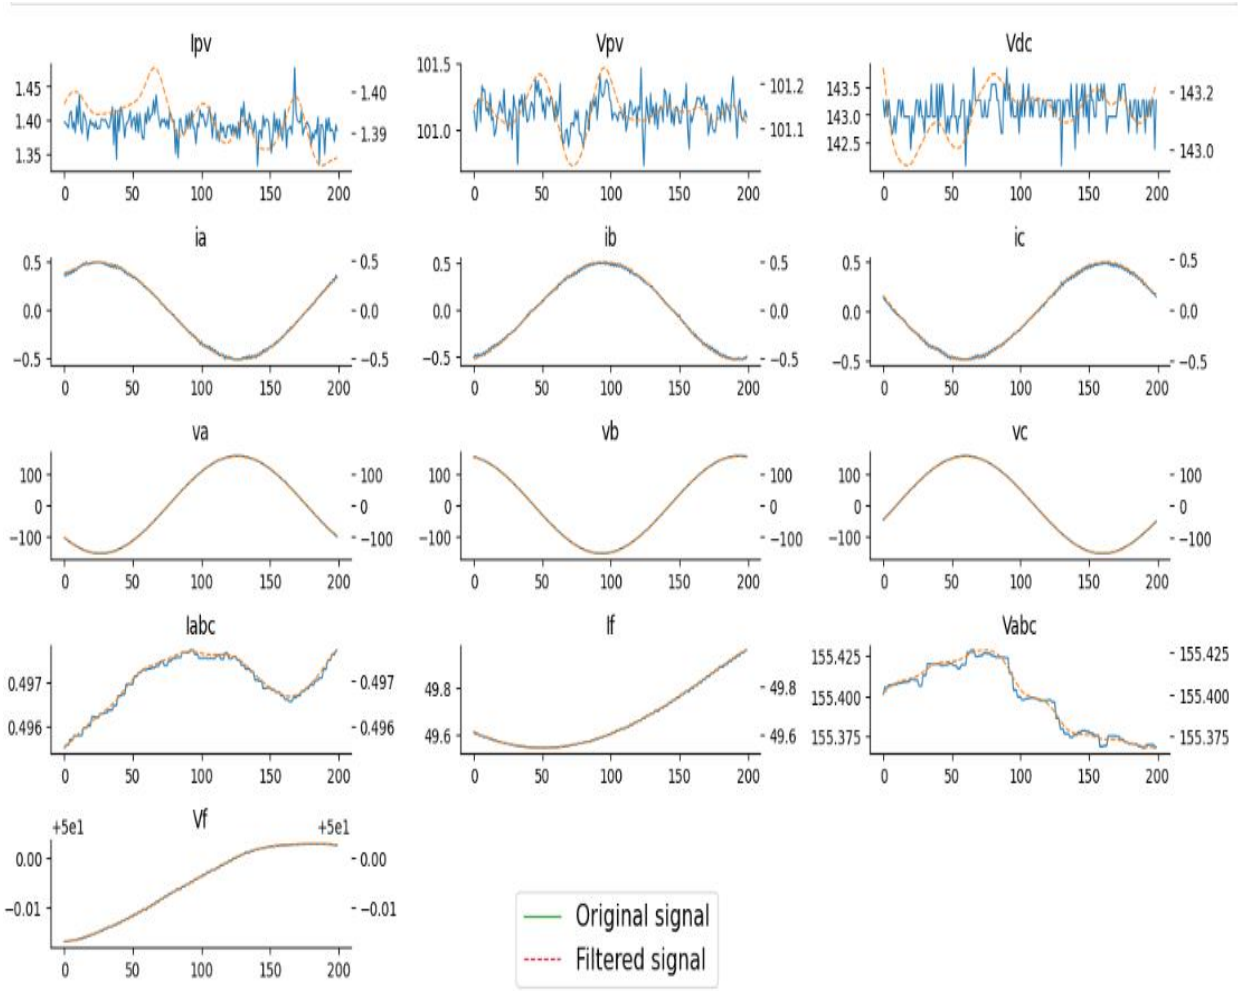

Figure III-12 :signal filtré en rouge et signal non filtré**.**

III.10.3 Division l'ensemble de données en ensembles d'entrainement et de teste :

Lors de la préparation d'un modèle d'apprentissage automatique, il est crucial de diviser correctement les données disponibles en ensembles d'entraînement et de test. Cette division permet de former le modèle sur un sous-ensemble des données (ensemble d'entraînement) et de le tester sur un sous-ensemble séparé (ensemble de test).

Cette approche aide à évaluer la performance du modèle sur des données qu'il n'a jamais vues, garantissant ainsi que le modèle généralise bien aux nouvelles données.

Pour se faire nous utilisons le programmes ci-dessous :

```python
from sklearn.model_selection import train_test_split
import numpy as np
import os

# Split the dataset into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X_filtered, y, test_size=0.33, random_state=42)
print(X_train.shape, y_train.shape, X_test.shape, y_test.shape)
# Output should be:
# (48597, 200, 13) (48597, 1) (23937, 200, 13) (23937, 1)

# Define the output folder for saving the datasets
output_folder = ''

# Save the training and testing sets as .npy files
np.save(os.path.join(output_folder, 'X_train.npy'), X_train)
np.save(os.path.join(output_folder, 'y_train.npy'), y_train)
np.save(os.path.join(output_folder, 'X_test.npy'), X_test)
np.save(os.path.join(output_folder, 'y_test.npy'), y_test)
```

Nous commencons par importer les bibliothèques nécessaires, y compris train_test_split de sklearn.model_selection et numpy ainsi que os.

Ensuite, nous divisons le dataset filtré X_filtered et les étiquettes y en ensembles d'entraînement et de test en utilisant train_test_split, en spécifiant 33% des données pour l'ensemble de test et en fixant random_state à 42 pour assurer la reproductibilité.

Après la division, on affiche les dimensions des ensembles de données résultants, qui devraient être (48597, 200, 13) pour X_train, (48597, 1) pour y_train, (23937, 200, 13) pour X_test, et (23937, 1) pour y_test. Ensuite, on définit le dossier de sortie où les fichiers seront sauvegardés.

Exemple de Dimensions des Ensembles de Données :

`X_train : (48597, 200, 13)`

- **48597** : Il y a 48,597 échantillons d'entraînement. Chaque échantillon représente une instance dans le dataset après division.

- **200** : Chaque échantillon contient 200 pas de temps. Cela indique que chaque instance est une séquence temporelle de longueur 200.
- **13** : Il y a 13 caractéristiques pour chaque pas de temps. Chaque pas de temps est décrit par 13 variables ou mesures différentes (comme **`Ipv`**, **`Vpv`**, etc.).

Enfin, nous utilisons np.save pour enregistrer les ensembles de données d'entraînement et de test en tant que fichiers .npy, en les plaçant dans le dossier spécifié.

III.11 Conclusion :

Ce chapitre a démontré comment l'intelligence artificielle, et plus précisément les réseaux de neurones LSTM, peuvent révolutionner l'analyse et l'optimisation des systèmes photovoltaïques. En examinant en détail les types de données collectées et le prétraitement nécessaire pour entraîner efficacement notre modèle.

Les résultats obtenus grâce à ces étapes de prétraitement serviront de base pour l'entraînement de notre modèle, dont les détails seront explorés dans le chapitre 4. Ces résultats prometteurs ouvrent la voie à de nouvelles recherches et applications, confirmant l'énorme potentiel de l'IA dans le secteur des énergies renouvelables.

Chapitre 4 : Entrainement du modèle et Interprétation des résultats

IV.1 Introduction :

Dans le chapitre 4, nous aborderons en détail l'architecture de notre modèle de réseau de neurones. Nous commencerons par décrire la structure et les caractéristiques spécifiques de notre réseau, en expliquant les choix de conception et les différentes couches utilisées.

Ensuite, nous présenterons le processus d'entraînement de notre modèle, y compris les algorithmes et les paramètres d'optimisation employés.

Enfin, nous discuterons des résultats obtenus, en analysant les performances du modèle et en comparant nos observations avec les attentes initiales.

IV.2 Architecture du model utilisée :

```
class LSTM_FCN(nn.Module):
    def __init__(self, n_features, n_classes, n_hidden=512, n_layers=4):
        super().__init__()

        self.lstm = nn.LSTM(
            input_size = n_features,
            hidden_size = n_hidden,
            batch_first = True,
            num_layers = n_layers, # Stack LSTMs
            dropout = 0.25  # This model works on a lot of regularisation
        )

        self.classifier = nn.Linear(n_hidden, n_classes)

    def forward(self, x):
        self.lstm.flatten_parameters()  # For distrubuted training

        _, (hidden, _) = self.lstm(x)
        # We want the output from the last layer to go into the final
        # regressor linear layer
        out = hidden[-1]

        return self.classifier(out)
```

IV.3 configuration du LSTM :

Nous configurons le LSTM avec *n_features* (Les caractéristiques ou paramètres) comme taille d'entrée et *n_classes* (les étiquettes de classe de défauts) comme taille de sortie comme le montre la figure ci-dessous :

```
le.classes_
```

```
array(['F0L', 'F0M', 'F1L', 'F1M', 'F2L', 'F2M', 'F3L', 'F3M', 'F4L',
       'F4M', 'F5L', 'F5M', 'F6L', 'F6M', 'F7L', 'F7M'], dtype=object)
```

```
feature_columns = ['Ipv', 'Vpv', 'Vdc', 'ia', 'ib', 'ic', 'va', 'vb', 'vc', 'Iabc', 'If', 'Vabc',
'Vf']
```

Nous avons construit notre model avec 4 couches empilées, dont 512 neurones par couche Nous utilisons un dropout de 0.25 pour la régularisation.

Enfin, nous utilisons une couche linéaire pour la classification finale, qui transforme les 512 neurones de la dernière couche LSTM en probabilités de classes de sortie.

IV.4 Entrainement et interprétation des résultats :

IV.4.1 Entrainement :

Pour l'entrainement de notre model nous utilisons un ensemble de données d'entraînement de 48597 échantillants, un ensemble de validation 11968 échantillant et un ensemble de test de 11969.

pour évaluer et optimiser le modèle, afin de maximiser sa précision de classification tout en évitant le surajustement, nous avons utilisé ce qui suit :

- la fonction de perte de CrossEntropy, pour évaluer la différence entre les prédictions du modèle et les étiquettes réelles.
- L'optimiseur Adam pour optimiser les paramètres du modèle, avec un taux d'apprentissage initial de 1e-4, permettant un apprentissage efficace des poids du réseau.
- Un planificateur de taux d'apprentissage pour ajuster dynamiquement le taux d'apprentissage pendant l'entraînement, réduisant ce taux lorsque la performance du modèle cesse de s'améliorer, basé sur un seuil de patience de 3.

En plus de ces éléments essentiels, nous avons défini les hyperparamètres suivants pour performer d'avantage le processus d'apprentissage de notre modèle :

```
learning_rate = 1e-4
num_epoch = 60
batch_size = 128
gan = False
sampler = False
```

- **learning_rate :** Nous avons fixé le taux d'apprentissage initial à 1e-4, déterminant la taille des pas que l'algorithme d'optimisation (Adam) prend lors de la mise à jour des poids du réseau.
- **num_epoch :** Nous avons décidé d'entraîner le modèle sur 60 époques, c'est-à-dire de parcourir l'ensemble de données d'entraînement 60 fois au total.
- **batch_size** : Nous utilisons une taille de lot de 128, ce qui signifie que le modèle est mis à jour après avoir vu 128 exemples d'entraînement. Ce paramètre influence la stabilité de l'entraînement et la vitesse de convergence du modèle.
- **gan :** Ce paramètre est actuellement défini sur False, indiquant que nous n'utilisons pas de GAN (Generative Adversarial Network) dans cette configuration d'entraînement.

- **sampler :** De même, le paramètre sampler est également défini sur False, ce qui signifie que nous n'utilisons pas d'échantillonneur spécifique pour contrôler la sélection des exemples d'entraînement.

IV.4.2 Interprétation des résultats d'entrainement :

Apres l'entrainement de notre model nous avons obtenu les résultats suivants :

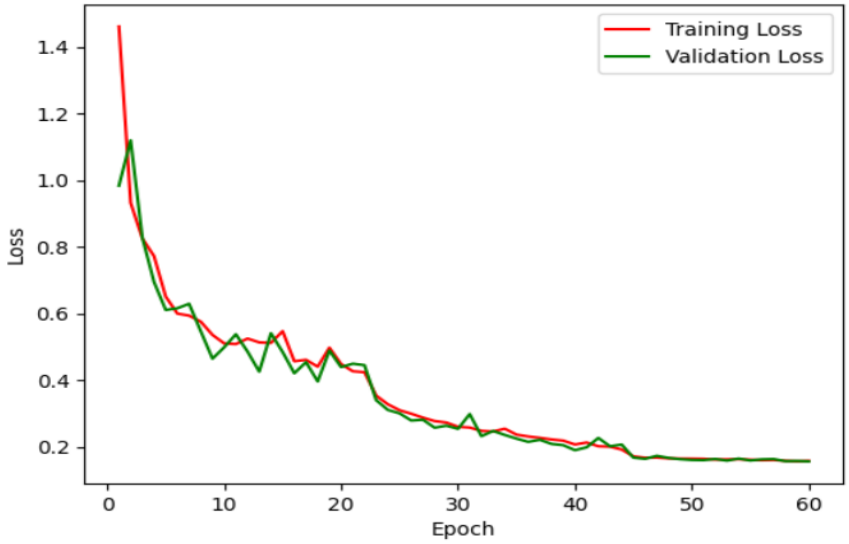

Figure IV-1 :graphe de perte en entrainement et en validation

- **Tendance :**

Les pertes d'entraînement et de validation diminuent toutes deux avec le temps, ce qui indique que le modèle apprend et améliore ses performances.

Initialement, la perte d'entraînement commence haute et diminue rapidement, ce qui est attendu car le modèle commence à apprendre à partir des données d'entraînement.

La perte de validation suit un schéma similaire, diminuant à mesure que le modèle s'améliore.

- **Convergence :** :

Autour de l'époque 30, les pertes d'entraînement et de validation commencent à se stabiliser et à converger, ce qui indique que le modèle atteint un point où une formation supplémentaire n'améliore pas significativement les performances.

- **Surapprentissage :** :

Il n'y a pas de divergence significative entre la perte d'entraînement et la perte de validation, ce qui suggère que le modèle ne fait pas de surapprentissage. Le surapprentissage serait indiqué par une perte d'entraînement qui continue de diminuer alors que la perte de validation commence à augmenter.

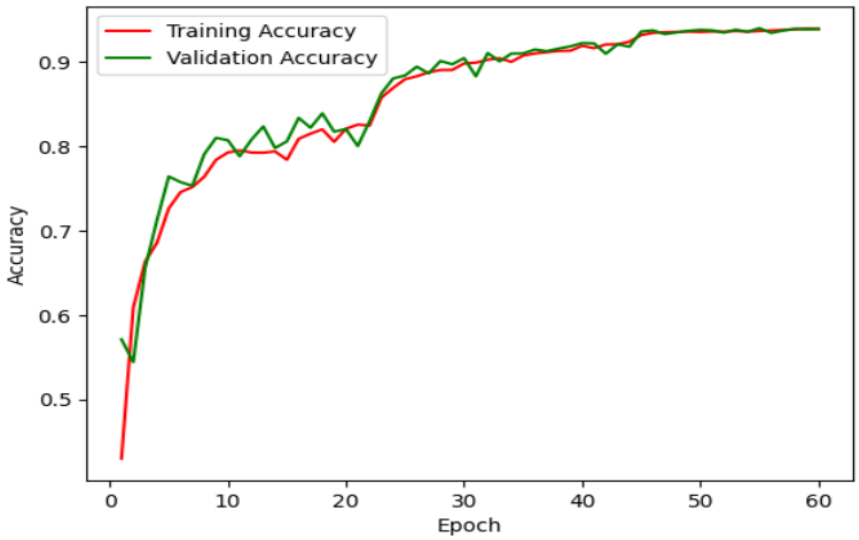

Figure IV-2 : graphe de précision en entrainement et validation.

Les courbes de précision pour les ensembles d'entraînement et de validation évoluent de manière cohérente, ce qui suggère que le modèle ne surapprend pas excessivement. En particulier, la précision de validation reste stable autour de 90% après environ 40 époques, ce qui est encourageant. Cela signifie que notre modèle se comporte bien non seulement sur les données d'entraînement, mais aussi sur de nouvelles données.

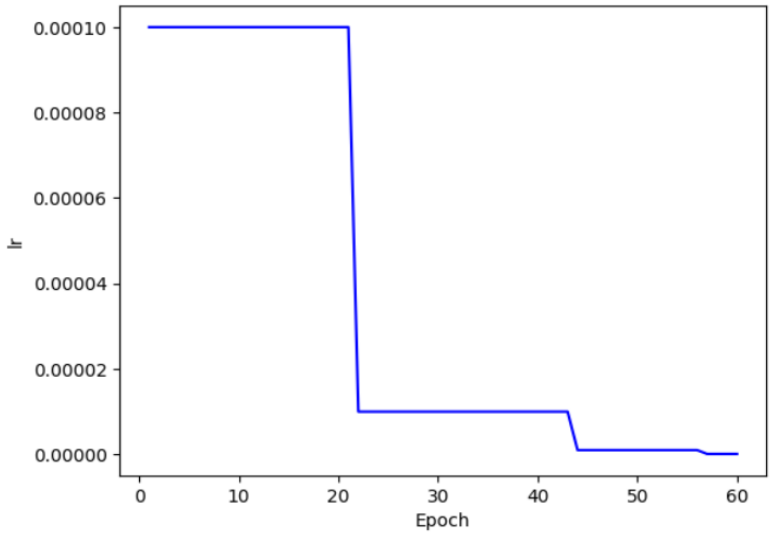

Figure IV-3 : Courbe du taux d'apprentissage.

On remarque que le taux d'apprentissage diminue de façon significative vers l'époque 20, puis à nouveau vers l'époque 40, ce qui l'utilisation d'une technique de réduction du taux d'apprentissage (learning rate scheduling) pour aider le modèle à converger de manière plus stable.

La réduction progressive du taux d'apprentissage aide à éviter les oscillations autour du minimum global de la fonction de perte et permet d'atteindre une meilleure performance finale.

IV.5 Evaluation des résultats du test :

IV.5.1 Définition des Métriques :

1. **Accuracy (Exactitude)** :
   - Proportion de prédictions correctes sur le total des prédictions. D'où :
     Accuracy= $\frac{TP+TN}{TP+TN+FP+FN}$ Où :
     - TP : Vrais positifs (True Positives)
     - TN : Vrais négatifs (True Negatives)
     - FP : Faux positifs (False Positives)
     - FN : Faux négatifs (False Negatives)

2. **Precision (Précision)** :
   - Proportion de prédictions positives correctes sur le total des prédictions positives. D'où :

$$Precision = \frac{TP}{TP+FP}$$

3. **Recall (Rappel)** :
   - Capacité du modèle à identifier toutes les instances positives. D'où :

$$Recall = \frac{TP}{TP+FN}$$

4. **F1-score** :
   - Moyenne harmonique de la précision et du rappel, combinant les deux métriques en une seule valeur. D'où *:*

$$F1\text{-}score=2.\frac{Precision\ .Recall}{Precision+Recall}$$

5. **Support** :
   - Nombre total d'exemples réels dans chaque classe.

IV.5.2 Matrice de confusion :

IV.5.2.1 Définition :

La matrice de confusion est un outil simple mais puissant qui fournit une vue d'ensemble des performances d'un modèle de classification en mettant en évidence les prédictions correctes et incorrectes pour chaque classe. Elle permet de comparer les valeurs réelles des classes (ou étiquettes) avec les valeurs prédites par le modèle, offrant ainsi une visualisation claire des résultats de classification. Principalement utilisée pour les problèmes de classification.

IV.5.2.2 Interprétation de la matrice donnée :

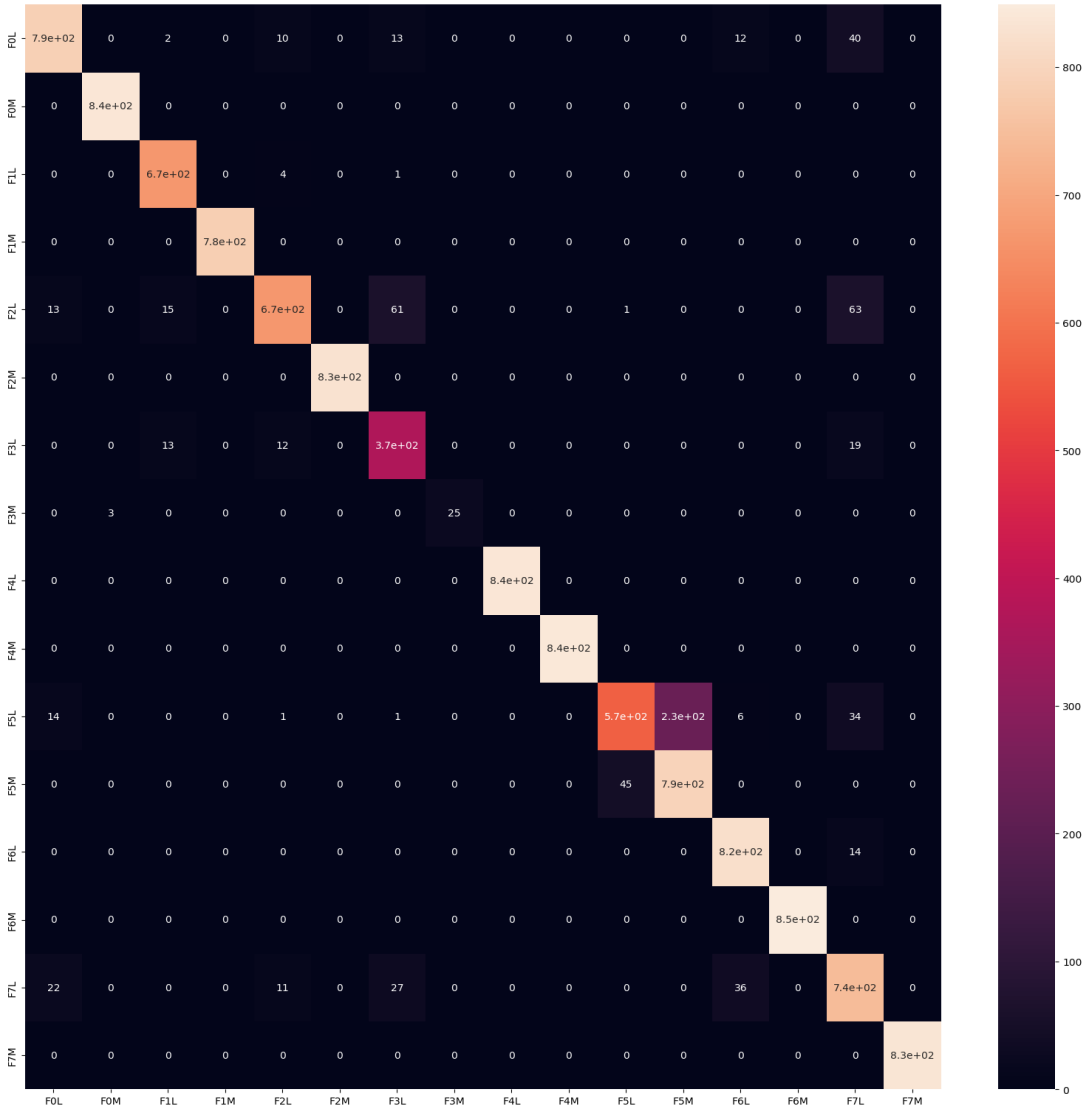

Figure IV-4 : matrice de confusion.

- Les lignes représentent les classes réelles (les vraies étiquettes).
- Les colonnes représentent les classes' prédites par le modèle.

IV.5.2.2.1 Analyse et remarques :

Les valeurs sur la diagonale principale représentent les cas correctement classés, par exemple, pour la classe F0M, il y a 790 exemples correctement classés.

Les valeurs hors de la diagonale principale indiquent les erreurs de classification, par exemple la classe F5L semble confondue avec F5M (230 exemples), ce qui peut indiquer que ces classes sont similaires ou que le modèle a du mal à les différencier.

Selon la matrice, le modèle de classification présente une bonne performance globale, avec la majorité des classes ayant une précision élevée, comme en témoignent les fortes valeurs

sur la diagonale principale. Cependant, il y a des confusions notables entre certaines classes indiquant des zones d'amélioration potentielles.

IV.5.3 Évaluation des Performances du Modèle de Classification par Classe :

	precision	recall	f1-score	support
F0L	0.94	0.91	0.93	863
F0M	1.00	1.00	1.00	837
F1L	0.96	0.99	0.97	674
F1M	1.00	1.00	1.00	784
F2L	0.95	0.81	0.87	821
F2M	1.00	1.00	1.00	828
F3L	0.78	0.89	0.83	410
F3M	1.00	0.89	0.94	28
F4L	1.00	1.00	1.00	836
F4M	1.00	1.00	1.00	840
F5L	0.92	0.66	0.77	854
F5M	0.77	0.95	0.85	838
F6L	0.94	0.98	0.96	835
F6M	1.00	1.00	1.00	849
F7L	0.81	0.89	0.85	839
F7M	1.00	1.00	1.00	833
accuracy			0.94	11969
macro avg	0.94	0.94	0.94	11969
weighted avg	0.94	0.94	0.94	11969

Figure IV-5 : récapitulatif des performances du modèle de classification pour chaque classe

Comme nous pouvons le constater dans ce récapitulatif, notre modèle montre une performance globale solide avec une exactitude de 94%. Les scores de précision, de rappel et F1 sont élevés pour la majorité des classes, indiquant que notre modèle fait un bonne classification en distinguant correctement les différentes classes.

Mais il pourrait bénéficier de certains ajustements pour mieux gérer les classes problématiques. Cela pourrait inclure des améliorations dans les caractéristiques utilisées, des ajustements d'hyperparamètres.

IV.6 Conclusion :

Les résultats obtenus par notre modèle d'intelligence artificielle attestent de la pertinence et de l'efficacité des méthodes d'entraînement employées. Les performances du modèle, mesurées à travers diverses métriques d'évaluation, montrent une nette amélioration par rapport a chaque étape d'entraînement de notre model. Toutefois, certaines limitations subsistent, indiquant des pistes d'amélioration futures. Ces résultats prometteurs ouvrent la voie à des applications concrètes et à de nouvelles perspectives de recherche dans le domaine.

Conclusion général :

En conclusion, ce projet de fin d'études intitulé "Détection et classification des défauts dans les panneaux photovoltaïques " a exploré en profondeur les étapes nécessaires à l'établissement d'un système efficace de détection et de classification des défauts spécifiques aux panneaux solaires.

La détection et la classification des défauts dans les panneaux photovoltaïques à l'aide de méthodes LSTM représentent une avancée significative dans le domaine de la maintenance prédictive et de l'efficacité énergétique. Les réseaux LSTM (Long Short-Term Memory) permettent de capturer les patterns temporels complexes présents dans les données générées par les panneaux solaires, facilitant ainsi une détection précise des défauts tels que les cellules défectueuses, les points chauds et les ombrages partiels.

Grâce à leur capacité à analyser des séquences de données temporelles, les LSTM peuvent non seulement détecter la présence de défauts mais aussi classifier leur nature et leur gravité avec une précision accrue. Cette approche permet aux opérateurs et aux ingénieurs de planifier des interventions de maintenance proactive, réduisant ainsi les temps d'arrêt et augmentant la durabilité des installations photovoltaïques.

En résumé, l'utilisation des méthodes LSTM pour la détection et la classification des défauts dans les panneaux solaires représente une technologie prometteuse qui contribue à optimiser la performance et la fiabilité des systèmes photovoltaïques tout en soutenant la transition vers une énergie plus propre et durable.

Bibliographie :

[1] C. Dusanter, «opera energie,» 19 avril 2024. [En ligne]. [Accès le 27 Mai 2024].

[2] [En ligne]. Available: https://www.habitatpresto.com/. [Accès le 29 05 2024].

[3] [En ligne]. Available: https://www.futura-sciences.com/planete/definitions/developpement-durable-panneau-solaire-thermique-7975/. [Accès le 4 juin 2024].

[4] [En ligne]. Available: https://www.lenergietoutcompris.fr/actualites-conseils/solaire-thermodynamique-fonctionnement-et-types-de-centrales-48118. [Accès le 29 Mai 2024].

[5] D. t.-C. E. n°03, *1*, 2000.

[6] Halouni.A, *2*, , mémoire de master, 2017.

[7] t. d. s. jimmy royer, *3*, université d'ottawa, 1998.

[8] M. A. Z. &. H. W. ZENDAGUI, *Amélioration expérimentale du transfert thermique par le chauffage solaire à air*, 2022.

[9] B. M. &. M. H. Mefti A., *Évaluation du Potentiel énergétique Solaire*, 2002.

[10] [En ligne]. Available: https://fr.wikipedia.org/wiki/Irradiation_solaire. [Accès le 27 MAI 2024].

[11] «planete energies,» 23 mai 2024. [En ligne]. [Accès le 26 mai 2024].

[12] u. c. d. louvain, «cellule photovoltaique :modéle,» [En ligne]. Available: https://sites.uclouvain.be/e-lee/FR/realisations/EnergiesRenouvelables/FiliereSolaire/PanneauxPhotovoltaiques/Cellule/Modele.htm. [Accès le 29 mai 2024].

[13] U. c. d. l. louvain, «cellule photovoltaiqe : modéle,» [En ligne]. Available: https://sites.uclouvain.be/e-lee/FR/realisations/EnergiesRenouvelables/FiliereSolaire/PanneauxPhotovoltaiques/Cellule/Modele.htm. [Accès le 29 mai 2024].

[14] ExaCompre, «Quls sont les defferents type de cellules photovoltaique,» [En ligne]. Available: https://sites.uclouvain.be/e-lee/FR/realisations/EnergiesRenouvelables/FiliereSolaire/PanneauxPhotovoltaiques/Cellule/Modele.htm. [Accès le 29 mai 2024].

[15] «Caractéristiques électriques des cellules et des modules photovoltaïques,» 9 août 2010. [En ligne]. [Accès le 29 Mai 2024].

[16] M. T. F. O, *DIMENSIONNEMENT ET INSTALLATION D'UN SYSTEME PHOTOVOLTAIQUE (APPLICATION A LA F.G.E.I.)*, 2009.

[17] Thèses magistère 'Bengjllali zakaria, *faculté des sciences et thermologie Univ-Bechar*, 2008 -2009.

[18] *Notes de cours, Azoui, Master Energies renouvelables 2019/2020.*

[19] B. Abderrahmen, *Détection et isolation de défauts pour une installation photovoltaïque,* 2021/2022.

[20] «Régulateurs MPPT : tout savoir sur les régulateurs de charge solaire,» 6 févr 2022. [En ligne]. [Accès le 29 mai 2024].

[21] Adouane, *Etude et conception d'une stratégie de commande d'un onduleur connecté au réseauMémoire de magistère Ecole Nationale Polytechnique Alger Algérie,* Mémoire de magistère Ecole Nationale Polytechnique Alger Algérie, 2008.

[22] Alain Ricaud, *« Modules et systèmes photovoltaïques », Sept 2008, Président de Screen.*

[23] W. Boucheritte, *« Convertisseurs multi niveaux dans les systèmes PV Connectés au.*

[24] R. Merahi, *« Modélisation d'un diapositif MPPT pour l'étude de l'augmentation de la.*

[25] *Thèses magistère 'Bengjllali zakaria, faculté des sciences et thermologie Univ-Bechar 2008-.*

[26] A. A.-B.-B. Triki-Lahiani UN, .*Systèmes de détection et de surveillance des défauts pour les installations photovoltaïques.,* 2018.

[27] G. R. R. T. S. H. J. S. A. S. C. A. M. C. E. J. C. S. S. e. a. Venkatakrishnan, « "Détection, localisation et diagnostic de différents défauts dans un grand système solaire photovoltaïque : un examen.",» *Journal international des technologies à faible émission de carbone,*, vol. 18, pp. 659-674., 2023.

[28] K. Abdul Mawjoud, S. S. Refat et G. T. Morsi, «Détection et prédiction des défauts dans les panneaux photovoltaïques : une revue,» chez *2018 12e conférence internationale de l'IEEE sur la compatibilité, l'électronique de puissance et l'ingénierie de puissance (CPE-POWERENG 2018)*, 2018.

[29] S. Sarikh, M. Raoufi et U. N. e. c. Bennouna, «Décoloration et fissures photovoltaïques : impact expérimental sur la dégradation de la courbe IV,» chez *Conférence internationale sur l'ingénierie électronique et les énergies renouvelables*, 2018.

[30] S. Abd, G. Allah et E. Gharabawy, « Revue sur la corrosion des panneaux solaires,» *Réseau intelligent Int J,* vol. 2, p. 218, 2018.

[31] D. Singh et R. S. Kathurie, « Techniques de prévision et d'analyse des défauts des cellules solaires et des modules photovoltaïques,» *Int J Eng Sci Res Technol,* vol. 7, p. 384–399, 2018.

[32] H. Yang, J. Chang et H. e. c. Wang, « Dégradation de puissance causée par les traînées d'escargots dans les systèmes énergétiques photovoltaïques urbains,» *Procedia Energy,* vol. 88, p. 422–428, 2016.

[33] B. U. N. Long, «Détection et localisation de défauts dans un système photovoltaïque,» Grenoble, 2011.

[34] T. Péi et X. Hao, « Une méthode de détection de défauts pour les systèmes photovoltaïques basée sur l'observation et l'évaluation de la tension et du courant,» *Énergies,* vol. 12, p. 1712, 2019.

[35] A. Y. Appiah, X. Zhang, B. B. K. Ayawli et e. coll., « Examen et évaluation des performances des techniques de détection et de diagnostic des défauts des panneaux photovoltaïques,» vol. 2019, pp. 1-19, 2019.

[36] R. Mahalakshmi, M. Karuppasamypandiyan, U. N. Bhuvanesh et e. coll., «Classification et détection des défauts dans un système photovoltaïque connecté au réseau,» *International Journal of Science and Engineering Research,* vol. 7, pp. 149-154, 2016.

[37] P. Sonawane, P. Jogging, S. Shete et e. coll., «Un examen complet de la détection et du diagnostic des défauts dans les systèmes photovoltaïques,» *Journal IOSR d'ingénierie électronique et des communications (IOSR-JECE),* vol. 14, pp. 31-43, 2019.

[38] N. Aouchiche, «Défauts liés aux systèmes photovoltaïques autonomes et techniques de diagnostic - État de l'art,» *Revue des Energies Renouvelables,* vol. 21, n° %12, pp. 247-265, 2018.

[39] A. Djalab, «Diagnostic des défauts d'un système d'énergie renouvelable basée sur les techniques d'intelligence artificielle : Application sur un système photovoltaïque,» Djelfa, 2020.

[40] [En ligne]. Available: https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcRwFg75QhcfeEbSG2Y6ixdliHm94_pQPRfiBQ&s. [Accès le 5 juin 2024].

[41] E. Batzélis, K. Samaras, G. Vokas et e. coll., «Défauts de l'onduleur hors réseau : diagnostic, symptômes et cause de panne,» *Forum Mater Sci,* vol. 856, pp. 315-321, 2016.

[42] M. Melloul et B. Soufi, «Détection et localisation des défauts dans les panneaux photovoltaïques,» ADRAR, 2022.

[43] C. F. V. C. Tina GM, *Monitoring and diagnostics of photovoltaic power plants.,* 2015.

[44] K. S. P. C. J. U. B. K. K. K. F. T. L. H. I. M. W. J. M. D. K. M. H. P. R. F. B. N. H. W. B.-L. C. R. G. F. G. Köntges M, *Köntges M, Kurtz S, Packard C, Jahn U, Berger K, Kato K, Friesen T, Liu H, Iseghem MV, Wohlgemuth J, Miller D, Kempe M, Hacke P, Reil F, Bogdansk N, Herrmann W, Buerhop-Lutz C, Razongles G, Friesen G (2014),* 2014.

[45] «Techniques de détection des défauts des systèmes photovoltaïques : une revue,» [En ligne]. Available: https://link.springer.com/article/10.1007/s00521-023-09041-7#Bib1. [Accès le 25 mai 2024].

[46] T. G. K. S. Mellit A, *Fault detection and diagnosis methods for photovoltaic systems: a review.,* 2018.

[47] E.-R. MA, *An efficient and portable solar cell defect detection system,* 2022.

[48] E. M. T. A. A. G. S. R. K. A. Y. N. S. S. Kandeal AW, *Infrared thermography-based condition monitoring of solar photovoltaic systems: a mini review of recent advances,* 2021.

[49] D. C. D. D. M.-D. A. Li B, *Application of artificial neural networks to photovoltaic fault detection and diagnosis: a review,* 2021.

[50] NetAPP, «Qu'est-ce que l'intelligence artificielle ?,» 2023. [En ligne]. Available: https://www.netapp.com/fr/artificial-intelligence/what-is-artificial-intelligence/.

[51] A. &. M. L. Cornuéjols, «Apprentissage artificiel : concepts et algorithmes,» E. Eyrolles, Éd., Paris, 2014.

[52] [En ligne]. Available: https://jjude.com/ml-intro/ (l'apprentissage automatique).

[53] [En ligne]. Available: https://fr.mathworks.com/discovery/machine-learning.html (l'apprentissage automatique/ l'apprentissage non supervisé).

[54] «L'apprentissage non supervisé,» [En ligne]. Available: http://colleges.planetetp.com/IMG/pdf/fiche_ressource_n03_cle889a33.pdf.

[55] M. -. M. -. MC, «Commission d'enrichissement de la langue française,» 2020. [En ligne]. Available: https://www.education.gouv.fr/bo/19/Hebdo6/CTNR1832601K.htm.

[56] C. Deluzarche, «Deep Learning : qu'est-ce que c'est ?,» 2021. [En ligne]. Available: : https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/.

[57] B. Grossfeld, «Deep learning vs machine learning,» [En ligne]. Available: https://www.zendesk.fr/blog/machine-learning-and-deep-learning/.

[58] I. : Ghania, «Régression et modélisation par les réseaux de neurones,» Constantine, 30 juin 2009.

[59] B. L, «Lebigdata,» 5 avril 2019. [En ligne]. Available: https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition. [Accès le 6 Juin 2024].

[60] «Réseaux de neurones,» [En ligne]. Available: :https://www.data-bird.co/blog/reseaux-de-neurones. [Accès le 07 juin 2024].

[61] GeeksforGeeks, « Deep Learning: Introduction to Long Short Term Memory,» [En ligne]. Available: https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/. [Accès le 94 juin 2024].

[62] S. Gavare, « Comparing Google Colab, Kaggle, and Vertex AI: Which platform is right for your neural network?,» 2023. [En ligne]. Available: https://medium.com/@samantagavare/comparing-google-colab-kaggle-and-vertex-ai-which-platform-is-right-for-your-neural-network-42eb8329771c. [Accès le 4 juin 2024].

[63] Data-Bird, « Langage Python,» [En ligne]. Available: https://www.data-bird.co/blog/langage-python. [Accès le 4 juin 2024].

[64] A. B. W. G. A. &. M. S. Bakdi, «Real-time fault detection in PV systems under MPPT using PMU and high-frequency multi-sensor data through online PCA-KDE-based multivariate KL Divergence,» *International Journal of Electrical Power & Energy Systems*, 2020.