

République Algérienne Démocratique et Populaire  
Ministère de l'enseignement supérieur et de la recherche scientifique  
Université djilali bounaama khemis miliana



Faculté des sciences et de la technologie

Département de la technologie

Mémoire du projet de fin d'étude

Pour l'obtention du diplôme de

**Master**

*En*

<< Génie électrique >>

*Option :*

<< Electrotechnique industrielle >>

*Titre :*

**Détection des pannes photovoltaïques par les réseaux de neurones  
probabiliste**

**Réalisé par :**

Hassani Fateh.

Noura Mohamed Islam.

**Encadré par :**

Karamostefa-khelil C.

**Co-encadreur :**

Hamzaoui I.

Année universitaire : 2017/2018

## **REMERCIEMENTS**

NOUS RENDONS NOS PROFONDES  
GRATITUDES À DIEU QUI NOUS A AIDÉS À  
RÉALISER CE MODESTE TRAVAIL. NOUS  
EXPRIMONS NOS PROFONDES  
GRATITUDES À NOS PARENTS POUR  
LEURS ENCOURAGEMENTS, LEURS  
SOUTIENS ET POUR LES SACRIFICES  
QU'ILS ONT ENDURÉ. NOUS REMERCIONS  
NOS ENCADREURS \* KARAMOSTEFA-  
KHELIL \* POUR LE EFFORT QU'ILS ONT  
DÉPLOYÉS, POUR NOUS AIDER,  
CONSEILLER, ENCOURAGER ET  
CORRIGER. NOUS REMERCIONS AUSSI  
TOUT LE CORPS ENSEIGNANT ET  
ADMINISTRATIF QUI A CONTRIBUÉ À  
NOTRE FORMATION UNIVERSITAIRE.

## *Dédicace*

*Nous consacrons CE MODESTE TRAVAIL*

*A :*

*Nos chers parents*

*Nos sœurs et nos frères*

*Toutes nos familles*

*Tous nos amis*

*Tous les enseignants qui m'ont aidé de proche  
ou de loin pour être un jour ingénieur  
d'électrotechnique*

## **Table des matières :**

Introduction général ..... 01

### **Chapitre I : L'énergie renouvelable**

I.1 Introduction ..... 03

I.2 Les ressource des énergies renouvelables .....03

I.3 Définition d'énergie renouvelable ..... 04

I.4 Notion du soleil : .....04

    I.4.1 Caractéristique du soleil ..... 04

I.5 Mouvements de la terre ..... 05

I.6 Rayonnement solaire ..... 05

    I.7.1 Les composantes de rayonnement solaire .....06

    I.7.2 Caractéristiques du rayonnement solaire ..... 07

    I.7.3 Spectre du rayonnement ..... 07

    I.7.4.Durée d'insolation .....08

I.8 L'énergie solaire ..... 09

I.9 conclusion .....09

### **Chapitre II : Système photovoltaïque**

II.1 Introduction ..... 10

II.2 L'effet photovoltaïque ..... 10

    II.2.1 La cellule photovoltaïque ..... 11

        II.2.2.1 Principe de fonctionnement ..... 12

        II.2.2.2 Les type des cellules.....13

II.3 Générateur photovoltaïque (GPV) .....14

II.3.1 Protections classiques d'un GPV .....15

    II.3.1.1 Protection lors de la connexion en parallèle de plusieurs GPV .....15

II.3.1.2 Protection du GPV constituée de la mise en série d'un grand nombre de cellules PV.....	16
II.4 Avantages et inconvénients de l'énergie solaire photovoltaïque.....	19
II.4.1 Avantage .....	19
II.4.2 Inconvénients .....	20
II.5 Conclusion.....	20

### **Chapitre III : L'apprentissage et réseaux de neurones**

III.1. Introduction .....	22
III.2 Apprentissage Machine .....	23
III.3 Types d'apprentissage .....	24
III.3.1 Apprentissage non supervisé.....	24
III.3.2 Apprentissage supervisé.....	25
III.3.3 Apprentissage semi-supervisé .....	26
III.3.4 Apprentissage partiellement supervisé .....	26
III.3.5 Apprentissage par renforcement .....	27
III.4 Apprentissage par réseaux de neurones .....	28
III.4.1 Choix de l'échantillon d'apprentissage .....	29
III.5 Réseaux de neurones multi couches .....	29
III.6 Réseaux de neurones probabiliste .....	31
III.6.1 Motivation pour les réseaux probabilistes .....	31
III.6.2 La stratégie de bayes pour la classification des motifs .....	32
III.6.3 Cohérence des estimations de densité .....	33
III.7 Principes de base pour les réseaux probabilistes .....	37
III.8 Architecture d'un réseau probabiliste .....	38

III.9 Avantages et inconvénients des réseaux probabilistes .....	40
III.10 Conclusion .....	41
<b>Chapitre IV : Résultat et simulation</b>	
IV.1 Description du système PV .....	42
IV.2 Stratégie de détection et de diagnostic .....	44
IV.3 Méthode basée sur PNN pour la détection de défauts et le diagnostic dans les systèmes PV .....	45
IV.3.1 Elaboration de base de données .....	45
IV.3.2 La construction de réseaux .....	48
IV.3.3 Phase d'apprentissage .....	50
IV.3.4 Phase de test .....	50
IV.4 Conclusion .....	56
<b>V. Conclusion général .....</b>	<b>57</b>
<b>Références bibliographiques .....</b>	<b>58</b>
<b>Résumé .....</b>	<b>62</b>

## **Liste des figures :**

### **Chapitre: I**

Figure (I.1) : Schématisation des mouvements de la Terre autour du Soleil.....	05
Figure (I.2) : Rayonnement solaire dans le monde en KWh/m <sup>2</sup> .An.....	06
Figure (I.3) : Composante du rayonnement global sur un plan horizontal.....	07
Figure (I.4) : spectre solaire hors atmosphère .....	08

### **Chapitre: II**

Figure (II.1) : Structure basique d'une cellule solaire.....	11
Figure (II.2) : Le principe de fonctionnement d'une cellule solaire.....	13
Figure (II.3) : Schématisation d'un GPV élémentaire avec diodes by-pass et diode anti-retour.....	14
Figure (II.4) : Caractéristiques I-V d'une cellule solaire ensoleillée et dans l'obscurité.....	16
Figure (II.5) : Caractéristiques I-V des sous-réseaux A et B du module PV dans une situation d'irradiation non homogène. ....	17
Figure (II.6) : Caractéristique I-V résultante de la mise en série de deux sous-réseaux de cellules avec une cellule du sous-réseau A sous-irradiée et les deux demi-modules protégés par diode by-pass .....	19

### **Chapitre III :**

Figure (III.1): Schéma général pour l'apprentissage machine.....	23
Figure (III.2): Le paradigme du professeur-élève dans l'apprentissage supervisé.....	25
Figure (III.3): Cas pour l'apprentissage partiellement supervisé .....	26
Figure (III.4) : Effet de lissage des différentes valeurs de $\sigma$ sur un PDF estimé à partir d'échantillons .....	35
Figure (III.5): Architecture générale d'un réseau probabiliste.....	39

## Chapitre IV :

Figure (IV.1) : Installation photovoltaïque à l'étude .....	43
Figure (IV.2) : 30 modules photovoltaïques Isofoton 106W-12V montés en 2 chaînes parallèles, chaque chaîne est composée de 15 modules PV en série .....	44
Figure (IV.3) : caractéristique d'un système PV en état sain .....	46
Figure (IV.4) : caractéristique de système PV en cas de panne branche complètement déconnecté .....	46
Figure (IV.5) : caractéristique de système en cas de panne 2 modules PV court-circuités .....	47
Figure (IV.6) : caractéristique de système en cas de panne 4 modules PV court-circuités .....	47
Figure (IV.7) : caractéristique de système en cas de panne 6 modules PV court-circuités .....	48
Figure (IV.8) : Structure de classificateur PNN .....	49
Figure (IV.9) : le PNN construit par le matlab .....	49
Figure (IV.10) : Classification de cas sain .....	51
Figure (IV.11) : résultat simulé de la teste en cas de panne string .....	52
Figure (IV.12) : deux modules PV court-circuités. ....	53
Figure (IV.13) : quatre modules PV court-circuités. ....	54
Figure (IV.14) : six modules PV court-circuités. ....	55

## Liste des tableaux :

<b>Tableau III.1:</b> Interprétation géométrique des neurones cachés dans un espace à deux dimensions.....	31
<b>Tableau IV.1 :</b> Les paramètres électriques du module PV Isofoton 106-12 dans des conditions d'essai standard .....	42

<b>Tableau IV.2:</b> Les cas étudié et leurs codes. ....	51
<b>Tableau IV.3 :</b> les résultats obtenus du classificateur PNN .....	56

## Nomenclature

### **Symboles:**

$C_k$  : poids de l'unité de sortie pour le numéro de décision k.

$I_{Co}$  : Courant de court-circuit.

$I_{max}$  : Courant qui correspond à la puissance maximale (A).

$N_p$  : Nombre de modules dans le panneau en parallèle.

$N_s$  : Nombre de modules dans le panneau en série.

$P_{max}$  : La puissance maximale produite PV (W).

$R_p$ : Résistances parallèle shunt. ( $\Omega$ )

$R_s$  : Résistance série ( $\Omega$ ) de la cellule.

$R_{sh}$ : Résistance parallèle de la cellule

$T$  : Température de la jonction des cellules PV ( $^{\circ}K$ )

$T_c$  : Température de la cellule ( $C^{\circ}$ )

$V_m, I_m$  : Tension et courant au point de puissance maximale.

$V_{max}$  : Tension qui correspond à la puissance maximale (V).

$V_{Co}$  : Tension de circuit ouvert.

### **Abréviation utilisées:**

PV: Panneau Photovoltaïque.

GPV: Générateur Photovoltaïque.

DC: Courant Continu (Direct Current).

AC: Courant Alternatif (Alternative Current).

MPPT: (Maximum Power Point Tracking).

PNN : réseau de neurones probabiliste.

MLP : Multi-Layer Perceptron.

RBF : Radial Basis Function.

## **Introduction général :**

La quantité d'installations photovoltaïques (PV) dans le monde a augmenté de manière très remarquable ces dernières décennies. Ceci est principalement dû aux préoccupations soulevées pour résoudre les problèmes de pollution de l'environnement, les changements climatiques et l'épuisement des sources d'énergie fossile. En effet, les sources d'énergie traditionnelles, telles que le nucléaire, le pétrole et le charbon, ont des effets indésirables sur la biodiversité de l'écosystème, la santé humaine et le changement climatique. En revanche, les sources d'énergie renouvelables, telles que les systèmes PV, sont durables, sûres et respectueuses de l'environnement, avec des émissions de CO<sub>2</sub> nulles. Une étude d'enquête faite par Masson et Al. A révélé que plus de 53 millions de tonnes d'émissions de CO<sub>2</sub> pourraient être évitées en Europe en 2012 en produisant 100 GW de systèmes photovoltaïques.

Les systèmes photovoltaïques, en particulier les «panneaux photovoltaïques» côté courant continu, sont conçus pour fonctionner dans des conditions extérieures difficiles, telles que les intempéries, les effets des vibrations du vent sur les modules PV, les rayons ultraviolets et la corrosion. Malgré tout, dans de telles conditions, plusieurs dysfonctionnements et défaillances peuvent se produire, entraînant une réduction de la durée de vie des modules PV, une diminution du rendement énergétique total, une perte de disponibilité et des risques pour la sécurité. En raison des considérations ci-dessus, la détection des défauts et le diagnostic de PV ont suscité un intérêt particulier au cours des dernières décennies.

Le réseau neuronal probabiliste (PNN) a été reconnu comme une stratégie efficace pour résoudre les problèmes de classification. Il a plusieurs avantages importants tels que sa vitesse de calcul et sa simplicité au cours du processus de formation. Ceci est principalement dû à la nécessité d'ajuster les poids. En outre, ce réseau peut classer tout nouvel échantillon entrant sans répéter de manière exhaustive tout le processus de formation.

Dans le présent travail, une approche de système photovoltaïque connectée au réseau, la détection de défaut et le diagnostic basée sur un classificateur PNN, est proposée. Dans cette approche, un modèle fiable de systèmes PV fonctionnels est d'abord établi. Après validation expérimentale du modèle de générateur PV, des échantillons sains ainsi que des échantillons défectueux sont générés puis utilisés comme entrées dans le classificateur PNN. Cette stratégie a

été testée à partir de données expérimentales réelles collectées à partir d'un système photovoltaïque raccordé au réseau de 9,54 kWc, situé au Centre de Développement des Energies Renouvelables de la CDER à Alger, en Algérie. Cette méthode a été testée dans cinq cas de fonctionnement: système sain, deux modules court-circuités en une chaîne, quatre modules court-circuités en une chaîne, six modules court-circuités en une chaîne, et une chaîne déconnectée du réseau.

Le présent document est agencé de la manière suivante. L'énergie solaire, les caractéristiques de système photovoltaïque, puis Apprentissage machine et réseaux de neurones. Enfin, simulation et résultat.

# **CHAPITRE I: L'énergie solaire**

## **I.1 Introduction :**

L'énergie solaire est la fraction de l'énergie électromagnétique provenant du soleil et traversant l'atmosphère, qui absorbe une partie de l'énergie, et parvenant à la surface de la Terre.

Sur Terre, l'énergie solaire est à l'origine du cycle de l'eau, du vent et de la photosynthèse réalisée par le règne végétal, dont dépend le règne animal via les chaînes alimentaires. Le Soleil est à l'origine de la plupart des énergies sur Terre à l'exception de l'énergie nucléaire et de la géothermie profonde.

Les sources d'énergie issues indirectement de l'énergie solaire sont notamment : l'énergie hydraulique, dérivée de l'énergie cinétique de l'eau dont le cycle dépend du Soleil, l'énergie marémotrice issue principalement de l'effet des forces de gravitation de la Lune et plus faiblement de celle du Soleil et dépendant d'autres paramètres tels que la géographie des côtes. Il y a également l'énergie éolienne provenant de l'énergie cinétique du vent lié à l'échauffement, et à l'évaporation de l'eau, générés par le Soleil, la rotation de la Terre et l'effet Coriolis, l'énergie hydrolienne et l'énergie des vagues liées aux mouvements des océans et des cours d'eau, le bois énergie et l'énergie de la biomasse ainsi que la géothermie de très basse température, provenant des couches superficielles du sol réchauffées par le Soleil. On peut ajouter les énergies fossiles provenant de matières organiques créées par photosynthèse (charbon, pétrole, gaz naturel...) auxquelles s'ajoute l'énergie biochimique de la matière organique vivante.

## **I.2 Les ressources des énergies renouvelables :**

Le développement et l'exploitation des énergies renouvelables ont connu une forte croissance ces dernières années. D'ici 20-30 ans, tout système énergétique durable sera basé sur l'utilisation rationnelle des sources traditionnelles et sur un recours accru aux énergies renouvelables. Ces énergies satisfont quant à elles 13 % de la demande, dont 10 % pour hydraulique. Comparé aux énergies classiques (fossiles et nucléaires), les énergies renouvelables présentent le double avantage de ne pas être source d'émissions de gaz à effet de serre lors de leur utilisation et de présenter des gisements renouvelables donc inépuisables. Ce sont des énergies de flux, par opposition aux énergies dites de stock (gaz, fioul, charbon, uranium, ...) [4]. La production d'électricité décentralisée par sources d'énergies renouvelables offre une plus

grande sûreté d'approvisionnement des consommateurs tout en respectant l'environnement [5][6].

### **I.3 Définition d'énergie renouvelable :**

On considère qu'une énergie est renouvelable, toute source d'énergie qui se renouvelle assez rapidement pour être considérée comme inépuisable (d'où son nom) c'est-à-dire, sa vitesse de formation doit être plus grande que sa vitesse d'utilisation [5], [7]. Les énergies renouvelables sont issues de phénomènes naturels réguliers ou constants provoqués principalement par le Soleil (l'énergie solaire mais aussi hydraulique, éolienne et biomasse...), la Lune (énergie marémotrice, certains courants : énergie hydrolienne...) et la Terre (géothermique profonde...), à l'échelle de la durée de vie de l'humanité .Ce n'est pas le cas pour les combustibles fossiles et nucléaires [5], [8], [4].

### **I.4 Notion du soleil :**

Le soleil est l'origine principale de toute forme d'énergie sur terre. Ceci étant vrai autant pour les énergies conventionnelles d'origine fossile, comme les hydrocarbures qui sont la conséquence de la photosynthèse ; que pour les énergies non conventionnelles dite renouvelables, comme l'énergie solaire, l'énergie éolienne, la biomasse, et l'énergie géothermique. L'astre soleil est de constitution gazeuse, de forme sphérique de  $1391 \times 10^3$  km de diamètre, sa masse est de l'ordre de  $2 \times 10^{30}$  kg. Il est constitué principalement de 80% d'hydrogène, de 19% d'hélium, le 1% restant est un mélange de plus de 100 éléments [2.3].

#### **I.4.1 Caractéristique du soleil :**

Le soleil est une étoile de forme pseudo sphérique composé de matière gazeuse, essentiellement de l'hydrogène et de l'hélium, il est le siège de réactions de fusion nucléaire permanentes, Elles transforment à chaque seconde  $564.10^6$  tonnes d'hélium, la différence de 4 millions de tonnes est dissipée sous forme d'énergie ( $E = m.C^2$ ), ce qui représente une énergie totale de  $36.10^{22}$  KW. La terre étant à une distance de  $150.10^6$  km du soleil, elle reçoit une énergie de  $1.8.10^{17}$  W On notera que 98 % du rayonnement solaire est émis dans des longueurs d'onde inférieures à  $2.5 \mu\text{m}$  et comme première approximation, le rayonnement solaire peut être assimilé au rayonnement d'un corps noir à une température de  $5777 \text{ }^\circ\text{K}$  [4.5].

## I.5 Mouvements de la terre :

La trajectoire de la Terre autour du Soleil est une ellipse. Le plan de cette ellipse est appelé l'écliptique. L'excentricité de cette ellipse est faible ce qui fait que la distance Terre/Soleil ne varie que de  $\pm 1,7\%$  par rapport à la distance moyenne qui est de  $(149\,675 \times 10^6 \text{ km})$ . La Terre tourne également sur elle-même autour d'un axe appelé l'axe des pôles. Le plan perpendiculaire à l'axe des pôles et passant par le centre de la Terre est appelé l'équateur. L'axe des pôles n'est pas perpendiculaire à l'écliptique : l'équateur et l'écliptique font entre eux un angle appelé inclinaison et qui vaut  $23^\circ 27'$ . Les mouvements de la Terre autour de son axe et autour du Soleil sont schématisés par la figure (I.1). [7]

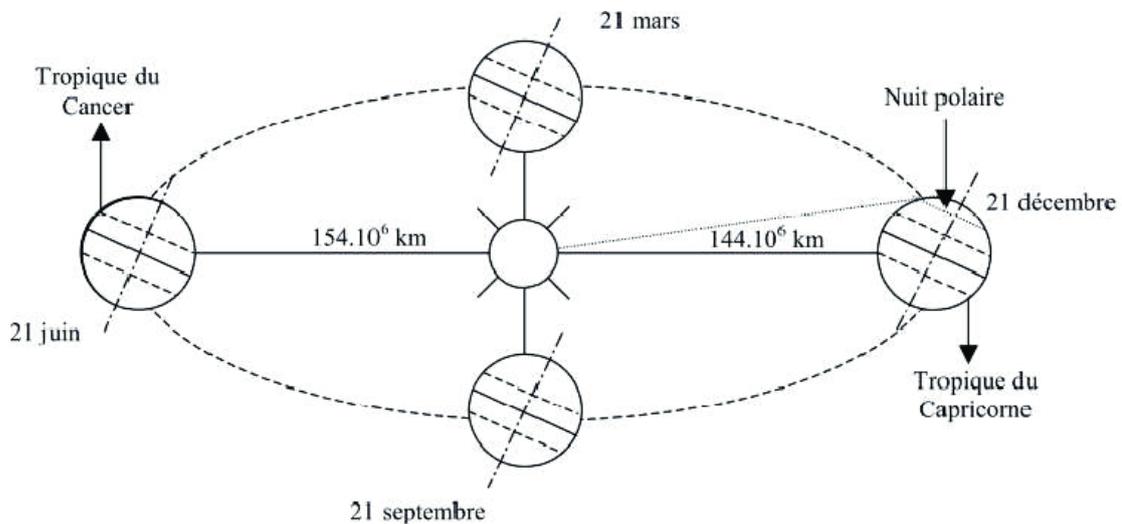


Figure (I.1) : Schématisation des mouvements de la Terre autour du Soleil [7]

## I.6 Rayonnement solaire :

Le rayonnement solaire est la matière première de l'énergie solaire. C'est une propagation d'une onde de longueur qui varie entre  $0.2$  et  $0.4 \mu\text{m}$ . Sans la nécessité d'un support physique pour se déplacer, il arrive au sol après la perte d'une grande partie de son intensité, à cause d'une partie d'ultraviolet, qui l'absorbe.

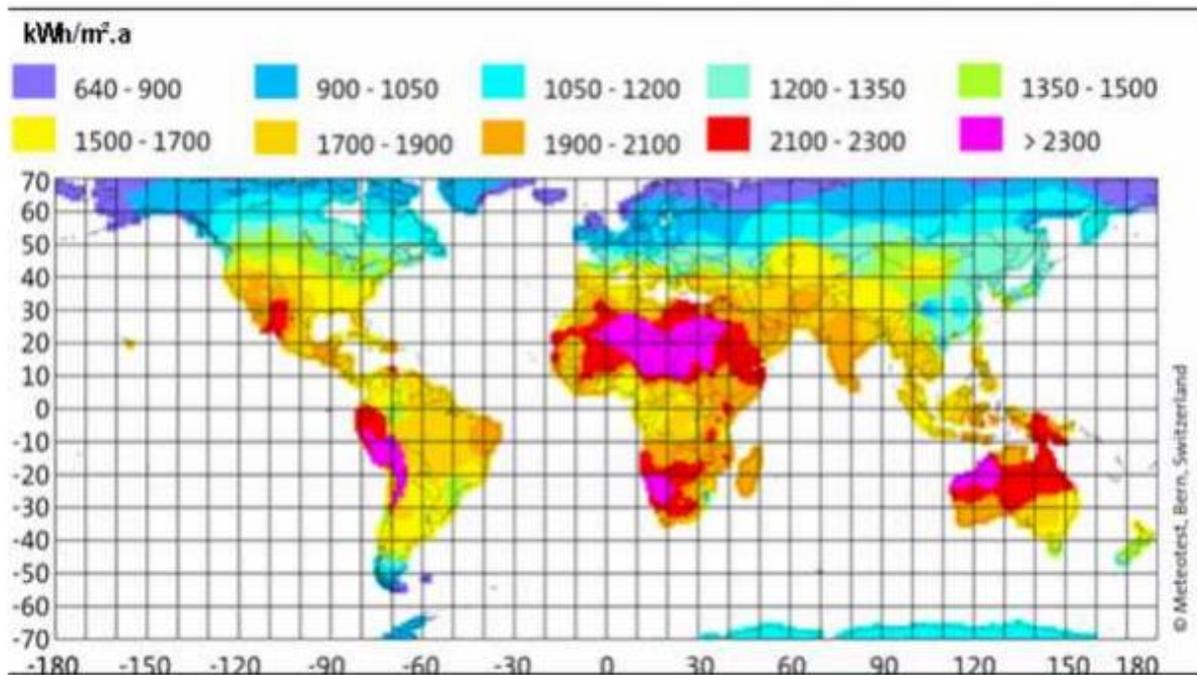


Figure (1.2) : Rayonnement solaire dans le monde en kWh/m<sup>2</sup>.An[6]

## I.7.1 Les composantes de rayonnement solaire :

### a) Le rayonnement direct:

Est reçu directement du Soleil, sans diffusion par l'atmosphère. Ses rayons sont parallèles entre eux, il forme donc des ombres et peut être concentré par des miroirs. Il peut être mesuré par un pyrhéliomètre.

### b) Le rayonnement diffus:

Est constitué par la lumière diffusée par l'atmosphère (air, nébulosité, aérosols). la diffusion est le phénomène qui répartit un faisceau parallèle en une multitude de faisceaux partant dans toutes les directions. Dans le ciel, ce sont à la fois les molécules d'air, les gouttelettes d'eau (nuages) et les poussières qui produisent cet «éclatement» des rayons du soleil. Cela dépend donc avant tout des conditions météorologiques.

### c) Le rayonnement solaire réfléchi:

Où l'albédo du sol est le rayonnement qui est réfléchi par le sol ou par des objets se trouvant à sa surface. Cet albédo peut être important par les sols particulièrement réfléchissants (eau, neige).

#### d) 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. Les stations météorologiques généralement mesurer le rayonnement global horizontal par un Pyranomètre placé horizontale à l'endroit requis [7.8].

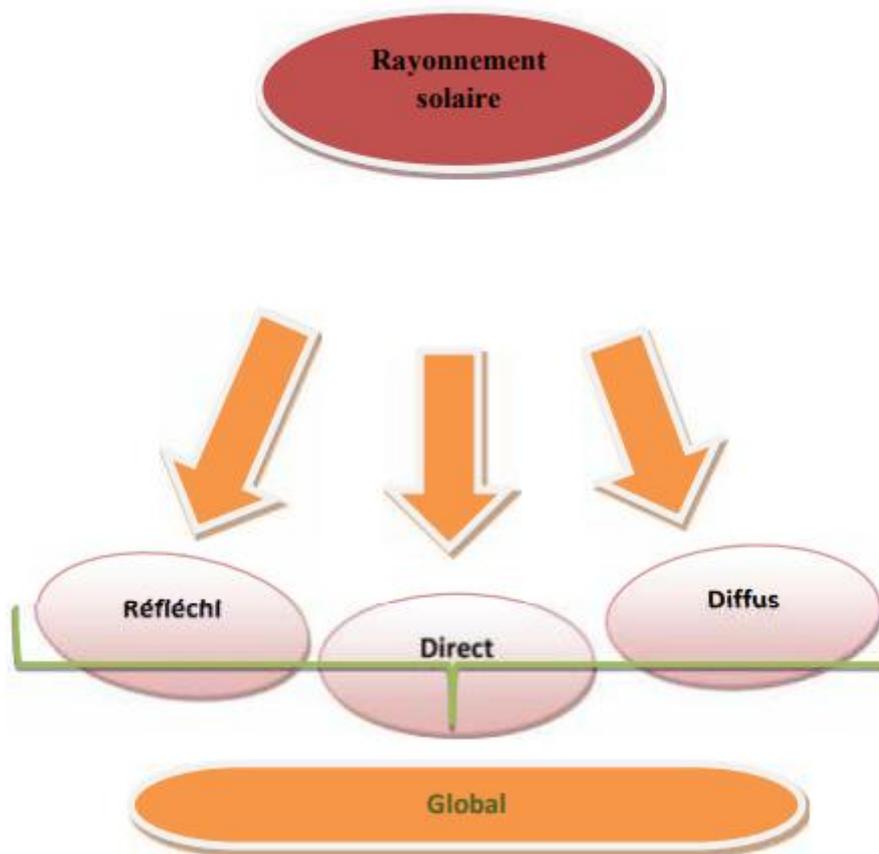


Figure (I.3) : Composante du rayonnement global sur un plan horizontal

#### I.7.2 Caractéristiques du rayonnement solaire:

A la limite de l'atmosphère terrestre, l'éclairement énergétique reçu par une surface placée perpendiculairement aux rayons solaires est en moyenne de  $1367\text{W/m}^2$  à l'extérieur de l'atmosphère terrestre. et arrive à  $AM_0 \text{ W/m}^2$  sur la surface de la terre. Cette donnée est appelée constante solaire.

#### I.7.3 Spectre du rayonnement:

Le rayonnement électromagnétique est composé de «grains» de lumière appelés photons. L'énergie de chaque photon est directement liée à la longueur

d'onde : Le spectre du rayonnement extraterrestre correspond environ à l'émission d'un corps noir porté à 5800°K. Une courbe standard, compilée selon les données recueillies par les satellites, est désignée sous le nom de AM<sub>0</sub>. Sa distribution en énergie est répartie en:[9]

\* Ultraviolet UV  $0.20 < \lambda < 0.38 \mu\text{m}$  6.4%

\*Visible  $0.38 < \lambda < 0.78 \mu\text{m}$  48.0%

\*Infrarouge IR  $0.78 < \lambda < 10 \mu\text{m}$  45.6%

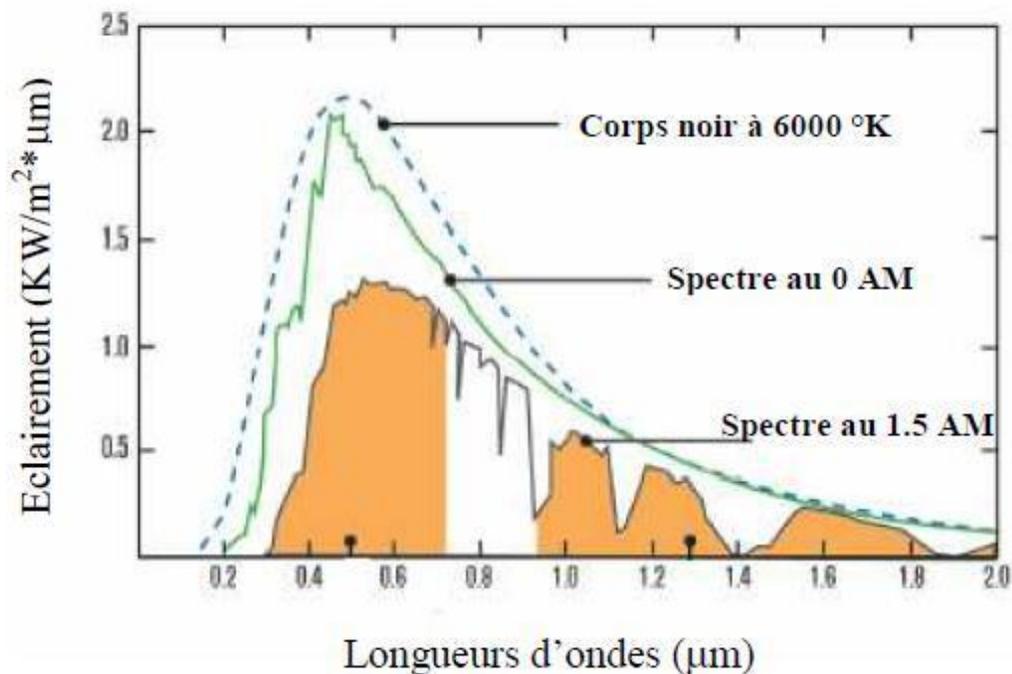


Figure (I.4) : spectre solaire hors atmosphère [9].

#### I.7.4.Durée d'insolation :

La durée d'insolation correspond au nombre d'heures dans la journée, entre le lever et le coucher du soleil, où celui-ci est bien visible. Le relevé est fait au moyen de l'héliographe de Campbell– Stokes dans lequel une sphère de cristal concentre les rayons du soleil sur un papier qu'il brûle en se déplaçant. Ainsi, seuls les moments où le soleil est bien visible sont enregistrés, on parle alors de durée d'insolation réelle ou effective et dépend du fait que le soleil levé soit visible du point d'observation ou caché par les nuages. Au défaut de l'héliographe, il est possible à partir du calcul du mouvement astronomique relatif du soleil et de la terre d'évaluer la durée théorique du jour ; c'est-à-dire, celle qu'il y aurait si les nuages ne cachaient pas le soleil.

## **I.8 L'énergie solaire:**

L'énergie solaire est produite et utilisée selon plusieurs procédés:

\* L'énergie solaire thermique : qui consiste tout simplement à produire de la chaleur grâce à des panneaux sombres. On peut aussi produire avec de la vapeur à partir de la chaleur du soleil puis convertir la vapeur en électricité.

\* L'énergie solaire photovoltaïque : qui consiste à produire directement de l'électricité à partir de la lumière à l'aide de panneaux solaires. Cette forme d'énergie est déjà exploitée dans de nombreux pays, surtout dans les pays ou les régions ne disposant pas de ressources énergétiques conventionnelles tels que les hydrocarbures ou le charbon. [1]

## **II.9 Conclusion:**

Dans ce chapitre, nous avons présenté les types des énergies renouvelables, les notions solaires et ses caractéristiques, la composition du rayonnement solaire. L'éclairement et la température sont les deux entrées principales de ce qu'on va étudier dans le deuxième chapitre.

## **Chapitre II : Système photovoltaïque**

### **II.1 Introduction :**

L'énergie solaire photovoltaïque provient de la transformation directe d'une partie du rayonnement solaire en énergie électrique. Cette conversion d'énergie s'effectue par le biais d'une cellule dite photovoltaïque (PV) basée sur un phénomène physique appelé effet photovoltaïque qui consiste à produire une force électromotrice lorsque la surface de cette cellule est exposée à la lumière. La tension générée peut varier en fonction du matériau utilisé pour la fabrication de la cellule. L'association de plusieurs cellules PV en série/parallèle donne lieu à un générateur photovoltaïque (GPV) qui a une caractéristique courant-tension (I-V) non linéaire présentant un point de puissance maximale [1].

Dans ce chapitre, nous commencerons par la Notion du soleil puis la construction des cellules photovoltaïques et leur effet ainsi principe de fonctionnement. Puis nous présentons les différents types des cellules photovoltaïques. Enfin les avantages et inconvénients de l'énergie solaire photovoltaïque.

### **II.2 L'effet photovoltaïque :**

Le terme photovoltaïque est formé à partir de deux mots : « Photos », qui signifient lumière. « Volta », du nom du physicien Alessandro Volta (1745-1827, inventeur de la pile électrique). Appelé aussi « module photovoltaïque » ou PV, c'est un panneau solaire qui est destiné à récupérer les rayonnements du soleil pour les transformer en électricité (Courant continu DC). L'effet photovoltaïque constitue la conversion directe de l'énergie du rayonnement solaire en énergie électrique au moyen de cellules généralement à base de silicium. Pour obtenir une puissance suffisante, les cellules sont reliées entre elles et constituent le module solaire. L'ensemble de panneaux photovoltaïques interconnectés forme le générateur. Celui-ci est caractérisé par sa puissance exprimée en kilowatt (kW). [1]

#### **II.2.1 La cellule photovoltaïque :**

La cellule PV ou encore photopile est le plus petit élément d'une installation photovoltaïque. Elle est composée de matériaux semi-conducteurs et transforme directement l'énergie lumineuse en énergie électrique.

Les cellules photovoltaïques sont constituées :

- D'une fine couche semi-conductrice (matériau possédant une bande interdite, qui joue le rôle de barrière d'énergie que les électrons ne peuvent franchir sans une excitation extérieure, et dont il est possible de faire varier les propriétés électroniques) tel que le silicium, qui est un matériau présentant une conductivité électrique relativement bonne.
- D'une couche antireflet permettant une pénétration maximale des rayons solaires.
- D'une grille conductrice sur le dessus ou cathode et d'un métal conducteur sur le dessous ou anode.

Les plus récentes possèdent même une nouvelle combinaison de multicouches réfléchissants justes en dessous du semi-conducteur, permettant à la lumière de rebondir plus longtemps dans celui-ci pour améliorer le rendement.

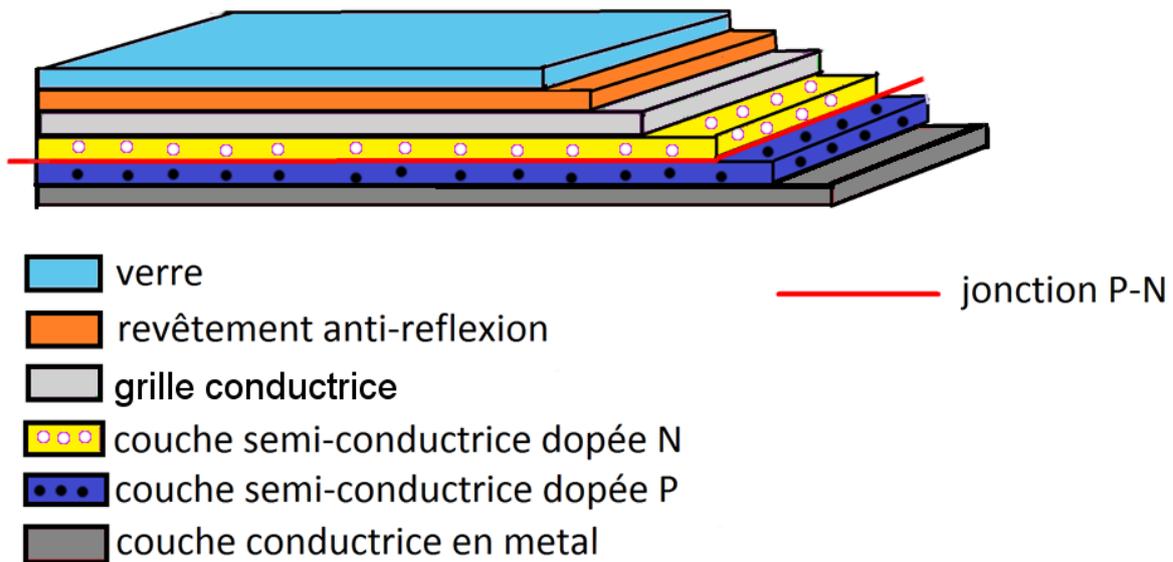


Figure (II.1) : Structure basique d'une cellule solaire.

Une cellule photovoltaïque est basée sur le phénomène physique appelé effet photovoltaïque qui consiste à établir une force électromotrice lorsque la surface de cette cellule est exposée à la lumière. La tension générée peut varier entre 0.3 V et 0.7 V en fonction du matériau utilisé et de sa disposition ainsi que de la température et du vieillissement de la cellule. [1]

### II.2.2.1 Principe de fonctionnement :

Il existe différentes techniques permettant la conversion directe de la lumière solaire en électricité, la plus connue est la conversion photovoltaïque effectuée à l'aide de matériaux semi-conducteurs tel que le silicium (Si), le germanium (Ge), le sélénium (Se) ou les composés semi-conducteurs tel que l'arséniure de gallium (GaAs), le tellure de cadmium (CdTe). Les cellules solaires de type GaAs sont très coûteuses dans leur fabrication, leur utilisation est aujourd'hui essentiellement limitée aux applications spatiales. La majorité des cellules photovoltaïques sont fabriquées à partir du silicium cristallin, car il possède la caractéristique d'être non toxique contrairement au cadmium ou au sélénium, en plus, il permet d'atteindre des efficacités de conversion remarquables, il constitue environ 28% de l'écorce terrestre sous forme de composés (silicates, silice), ce qui en fait une source quasi inépuisable. La cellule solaire à semi-conducteur est un dispositif permettant de débiter un courant électrique dans une charge externe lorsque celui-ci est exposé à la lumière. Son principe de fonctionnement se résume comme suit : Lorsque la cellule est exposée au rayonnement solaire, les photons d'énergie ( $E_{ph} = h\nu$ ) pénétrant dans la cellule solaire transmettent leur énergie aux atomes de la jonction. Si cette énergie est suffisamment élevée, elle peut faire passer les électrons de la bande de valence à la bande de conduction du matériau semi-conducteur et créer ainsi des paires «électron- trou». Les électrons (charges N) et les trous (charges P), sont alors maintenus séparés par un champ électrique qui constitue une barrière de potentiel. Si une charge est placée aux bornes de la cellule, les électrons de la zone N rejoignent les trous de la zone P via la connexion extérieure, donnant naissance à une différence de potentiel et un courant électrique. Figure (II-2) [1]

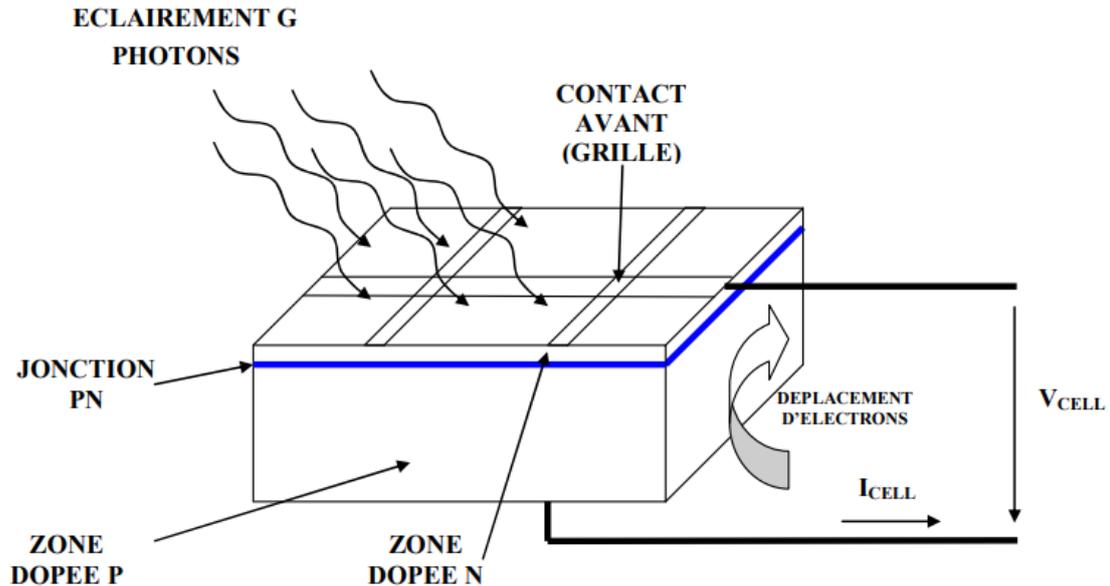


Figure (II.2) : Le principe de fonctionnement d'une cellule solaire.

### II.2.2.2 Les type des cellules:[10]

Il existe trois grands types de silicium : mono cristallin, poly cristallin et amorphe.

#### a) Cellule au silicium monocristallin:

Pour ce genre d'applications technologiques, le silicium pur est obtenu à partir de la silice de quartz ou de sable par transformation chimique métallurgique. Le silicium a un rendement électrique et une durée de vie de l'ordre de deux fois celle du silicium amorphe, mais il est nettement plus cher.

#### a) Cellule au silicium polycristallin:

Le silicium poly-cristallin est un matériau composé de cristaux juxtaposés obtenus par moulage. Ce matériau est moins coûteux (que le monocristallin). Les cellules carrées ou rectangulaires sont faciles à utiliser.

#### b) Cellule au silicium amorphe:

Le silicium absorbe le rayonnement solaire jusqu'à 100 fois mieux qu'en état cristallin; les cellules sont constituées par des couches très minces.

## II.3 Générateur photovoltaïque (GPV) :

L'association de plusieurs cellules PV en série/parallèle donne lieu à un GPV. Si les cellules se connectent en série, les tensions de chaque cellule s'additionnent, augmentant la tension totale du générateur. D'une autre part, si les cellules se connectent en parallèle, c'est l'ampérage qui augmentera.

La plupart des panneaux PV commerciaux sont constitués par des sous-réseaux de cellules connectés en série. Chacun de ces sous-réseaux est lui-même constitué d'un groupe de cellules PV connectés en série. Le nombre de cellules par sous-réseaux est le fruit d'un compromis économique entre protection et pertes d'une partie importante du GPV en cas de défaut partiel.

Nous pouvons remarquer que comme pour une cellule, la caractéristique électrique  $I(V)$  d'un GPV est non linéaire et présente un point de puissance maximale (PPM). Ce point a également un courant et une tension associés appelés  $I_{opt}$  et  $V_{opt}$  respectivement. Le point de fonctionnement d'un GPV est fonction de l'impédance de la charge qu'il alimente. Cette charge pourrait être une charge résistive ou un bus de tension continue (par exemple, connecté sur une batterie). Dans le cas d'une batterie, c'est elle qui impose le point de fonctionnement du GPV lors d'une connexion directe.

La figure II.3 montre la schématisation classiquement adoptée pour un GPV élémentaire. Pour tous les essais que nous avons menés dans cette thèse, nous avons eu à notre disposition des modules PV référencés BP585 constitués de deux fois 18 cellules PV. Leur environnement de fonctionnement traditionnel comprend la connexion de deux diodes by-pass et d'une diode anti-retour. Les connexions physiques permettent de travailler avec ou sans les diodes en fonction des conditions souhaitées.

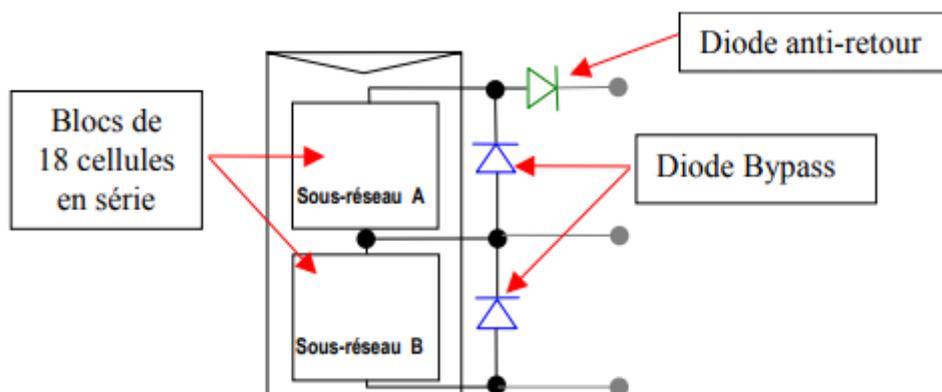


Fig. II.3 : Schématisation d'un GPV élémentaire avec diodes by-pass et diode anti-retour.

### **II.3.1 Protections classiques d'un GPV :**

Lorsque nous concevons une installation photovoltaïque, nous devons assurer la protection électrique de cette installation afin d'augmenter sa durée de vie en évitant notamment des pannes destructrices liées à l'association des cellules et de leur fonctionnement en cas d'ombrage. Pour cela, deux types de protections sont classiquement utilisées dans les installations actuelles :

- la protection en cas de connexion en parallèle de modules PV pour éviter les courants négatifs dans les GPV (diode anti-retour)

- la protection lors de la mise en série de modules PV permettant de ne pas perdre la totalité de la chaîne (diode by-pass) et éviter les points chauds.

Nous rappelons dans les paragraphes suivants le fonctionnement de ces deux protections.

#### **II.3.1.1 Protection lors de la connexion en parallèle de plusieurs GPV :**

Dans le cas de plusieurs chaînes de cellules mises en parallèle sur une charge, le risque est que des chaînes de cellule éclairées débitent dans des chaînes ombrées ou que la charge ne se décharge à travers le générateur. On dispose pour cela de diodes anti-retour mises en série avec le GPV (de blocage) comme le montre la figure II.4. Cette diode est indispensable quand la charge du module PV est une batterie. En fait, cette diode évite que la batterie ne débite sur le module PV pendant la nuit. La figure II.5 montre les caractéristiques  $I(V)$  d'une cellule solaire, ensoleillée, puis dans l'obscurité.

Comme nous pouvons le voir, quand la cellule est dans l'obscurité, une batterie pourrait se décharger à travers la cellule si nous ne disposons pas d'une diode de blocage.

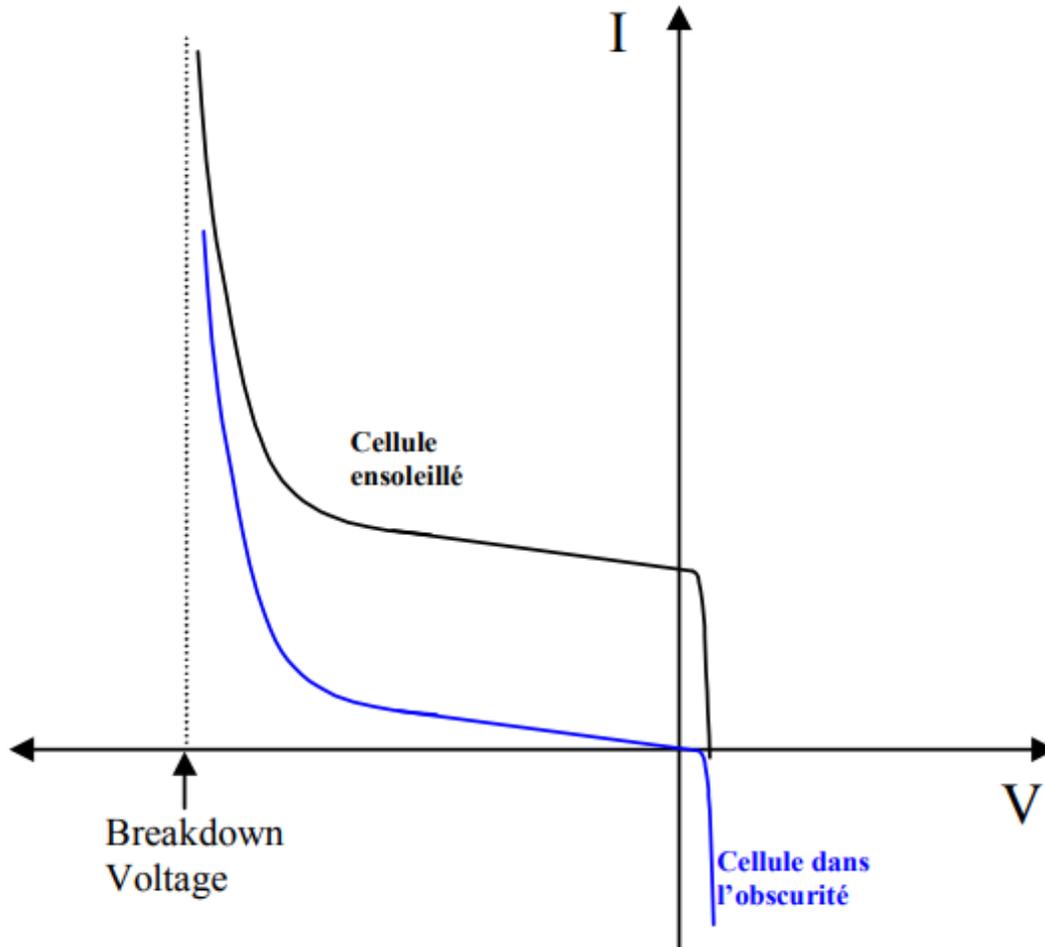


Fig. II.4 : Caractéristiques I-V d'une cellule solaire ensoleillée et dans l'obscurité.

**Remarque :** la présence d'une diode anti retour entre un GPV et la charge provoque la dissipation d'une certaine quantité d'énergie due à la chute de tension à l'état passant de la diode.

### II.3.1.2 Protection du GPV constituée de la mise en série d'un grand nombre de cellules PV :

La mise en série de cellules PV implique que le courant traversant chaque cellule soit le même que celui que l'ensemble du GPV associé. Ainsi, quand un GPV ou une partie de ce GPV (par exemple, une cellule) est ombrée, cette partie sous-irradiée du module peut se trouver polarisée en inverse et devenir réceptrice, dissipant alors la puissance ne pouvant pas être extraite. Cette dissipation a comme effet immédiat un échauffement de la zone sous irradiée. Cet échauffement local peut donner lieu à des « points chauds » (hot spot en anglais) [13, 14, 15] qui peuvent endommager la zone affectée et dégrader définitivement les performances du module PV entier. Pour éviter ces effets

indésirables, des diodes by-pass sont associées à un sous-réseau de cellules comme le montre la figure II.4.

La figure II.6 montre les caractéristiques I-V du module PV de la figure II.4 divisé en deux demi-modules A et B. Nous avons représenté séparément les caractéristiques des sous réseaux A et B. Le sous-réseau A se trouvant sous condition d'irradiation nominale est représenté avec un comportement normal (en rouge). Le sous-réseau B a une cellule qui est soumise à un taux d'ensoleillement inférieur aux 17 autres cellules formant ce sous-réseau. La caractéristique I-V résultante de ce sous-réseau est représentée en couleur bleu. Nous avons représenté en noir les caractéristiques I-V de la cellule ombrée et des 17 autres cellules qui se trouvent sous condition d'irradiation nominale.

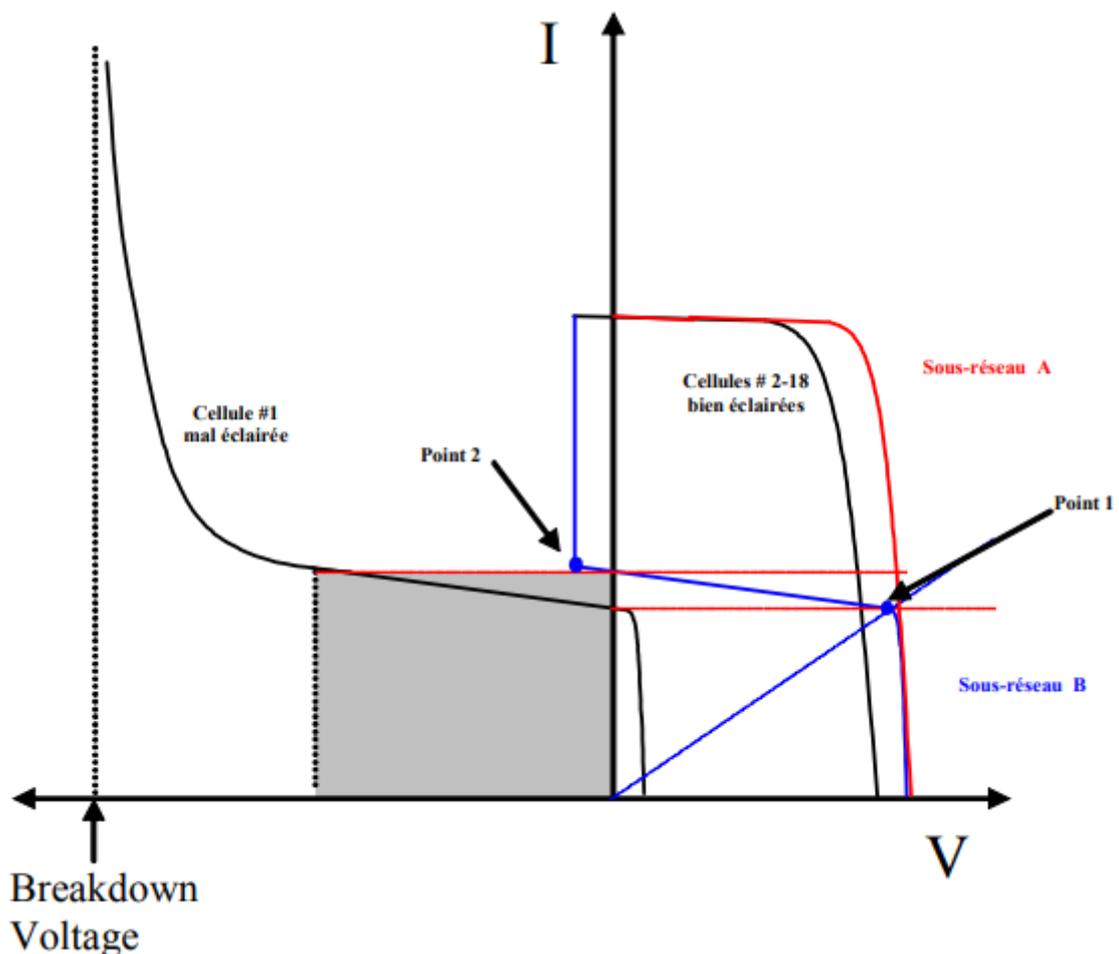


Fig. II.5 : Caractéristiques I-V des sous-réseaux A et B du module PV dans une situation d'irradiation non homogène. (1 cellule sous-irradiée).

La caractéristique résultante d'un réseau de cellules s'obtient de la variation du courant du GPV de sa valeur nulle jusqu'au courant de court-circuit en

additionnant les tensions associées aux deux caractéristiques I-V. Quand le courant de la caractéristique I-V du sous réseau B atteint le courant de court-circuit de la cellule ombrée, il apparaît le point de rupture 1 sur la caractéristique résultante de ce sous-réseau et à partir de ce point, la caractéristique résultante suit le comportement de la caractéristique en inverse de la cellule ombrée, comme nous le voyons sur la figure II.5 C'est à ce moment-là que la cellule ombrée dissipe de la puissance et peut être endommagée par la création des « points chauds ».

La caractéristique en inverse d'une cellule dépend fortement de la technologie de fabrication [13, 14, 15]. Dans notre cas, nous avons une diode by-pass sur chaque sous-réseau de cellules. Quand la tension du sous-réseau B excède la tension en directe de la diode bypass celle-ci se met en état passant. Ceci implique une limitation de la tension qui peut se voir comme la montée verticale de la caractéristique résultante du sous-réseau B à partir du point de rupture 2.

Ainsi nous pouvons limiter la tension inverse maximale aux bornes de la cellule ombrée en protégeant cette cellule de fonctionner en inverse. La figure II.6 montre en vert la caractéristique résultante du module PV de la figure II.3 avec la protection des diodes by-pass.

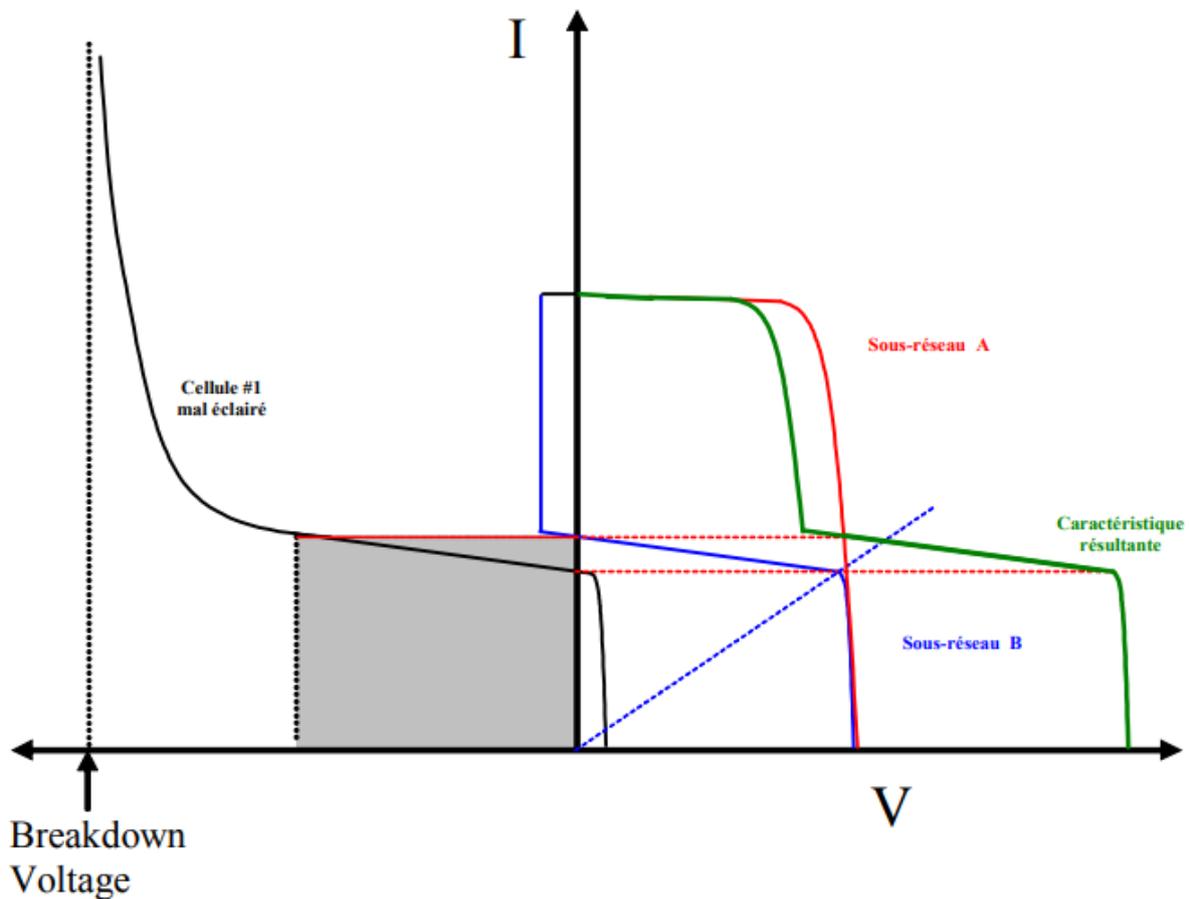


Fig. II.6 : Caractéristique I-V résultante de la mise en série de deux sous-réseaux de cellules avec une cellule du sous-réseau A sous-irradiée et les deux demi-modules protégés par diode by-pass.

De la caractéristique I-V de la figure II.6, nous pouvons déduire qu'il existe alors deux maximums de puissances quand le module se trouve soumis à une irradiation non-homogène.

## II.4 Avantages et inconvénients de l'énergie solaire photovoltaïque:

Tout système de production d'énergie photovoltaïque a ses avantages et ses inconvénients.

### II.4.1 Avantage :

\* D'abord, une haute fiabilité. L'installation ne comporte pas de pièces mobiles qui la rendent particulièrement appropriée aux régions isolées. C'est la raison de son utilisation sur les engins spatiaux.

\* Ensuite, le caractère modulaire des panneaux photovoltaïques permet un montage simple et adaptable à des besoins énergétiques divers. Les systèmes peuvent être dimensionnés pour des applications de puissances allant du milliwatt au mégawatt.

\* Le cout de fonctionnement est très faible vu les entretiens réduits et il ne nécessite ni combustible, ni son transport, ni personnel hautement spécialisé.

\* La technologie photovoltaïque présente des qualités sur le plan écologique car le produit fini est non polluant, silencieux et n'entraîne aucune perturbation du milieu, si ce n'est pas l'occupation de l'espace pour les installations de grandes dimensions

#### **II.4.2 Inconvénients :**

\* La fabrication du module photovoltaïque relève de la haute technologie et requiert des investissements d'un cout élevé.

\* le rendement réel de conversion d'un module est faible, de l'ordre de 10-15%, avec une limite théorique pour une cellule de 28%. Les générateurs photovoltaïques ne sont compétitifs par rapport au générateur diesel que pour les faibles demandes d'énergie en régions isolées.

\* Tributaire des conditions météorologiques.

\* Lorsque le stockage de l'énergie électrique sous forme chimique (batterie) est nécessaire, le cout du générateur est accru. Le stockage de l'énergie électrique pose encore de nombreux problèmes. [11]

#### **II.5 Conclusion:**

Dans ce chapitre, nous avons étudié le principe de l'effet photovoltaïque, la cellule photovoltaïque, et enfin les avantages et inconvénients de l'énergie solaire photovoltaïque.

Dans ce mémoire, nous nous sommes intéressés à détecter les pannes dans les systèmes photovoltaïque par les réseaux de neurones probabiliste a la base de quatre entrés, la température, l'éclairement, ce sont les entrés de système photovoltaïque et ces sortie, la tension et le courant.

## Chapitre III : L'apprentissage et réseaux de neurones

### III.1. Introduction :

Le réseau de neurones probabiliste (PNN) a été introduit par D. F. Specht. En raison de leurs propriétés pour les problèmes de classification, ils sont vite devenus une référence dans le domaine de classification neuronale. Les PNNs offrent de nombreux avantages: ils ne souffrent pas du problème des minima locaux comme pour les MLP (perceptron à multicouches) par exemple, l'apprentissage est très rapide puisque le réseau est créé après un seul passage sur l'ensemble d'apprentissage, ils peuvent être utilisés interactivement et le principe lui-même a une base mathématique très solide. D'autre part, il y a quelques inconvénients importants : le nombre de neurones cachés est égal au nombre d'échantillons de l'apprentissage. Cela peut être très restrictif pour certains problèmes avec un ensemble d'apprentissage très grand qui contient dans la majorité du temps beaucoup de redondances. Un autre problème est le choix du paramètre de lissage qui peut affecter sérieusement la généralisation du réseau. Beaucoup de travail a été fait pour résoudre le problème de généralisation ainsi que celui du choix des paramètres dans les réseaux de neurones probabilistes. M. Kim dans son article [référence et titre] a proposé une nouvelle architecture pour améliorer la généralisation du PNN standard. Dans, un algorithme a été utilisé pour l'apprentissage d'un PNN afin de rendre la taille du réseau plus petit. D'autres exemples de variantes PNNs sont le PNN flou et l'optimisation stochastique pour le choix des paramètres du PNN. Toutes ces approches ne permettent qu'une résolution partielle du problème et soulève en général un autre problème. En fait, en modifiant l'algorithme d'apprentissage de certaines façons, le réseau perd certains de ses atouts majeurs. Ont des bonnes qualités de généralisation que l'on prétend être comparé aux SVM (dans le cas d'un nombre réduit de classes) mais l'apprentissage est très lent, même pour les petits ensembles d'apprentissage et le réseau ne supporte pas l'ajout de nouvelles classes et / ou des échantillons, dans ce cas tout le processus d'apprentissage doit être repris avec le nouvel ensemble. L'application de ce type de réseaux d'une manière interactive semble impossible. L'algorithme d'apprentissage présenté dans ce papier réduit le nombre de neurones cachés, sans affecter l'architecture du réseau, ceci signifie que l'ajout de nouveaux échantillons ou de classes est possible à tout moment et sans refaire l'apprentissage du début. Cet algorithme d'apprentissage peut être utilisé pour

un large éventail de problèmes tels que la biométrie, la reconnaissance de caractères et la reconnaissance vocale.

### III.2 Apprentissage Machine :

L'apprentissage machine vise à concevoir des machines dotées de capacités d'apprentissage. Il fait référence au développement, à l'analyse et à l'implémentation de méthodes qui permettent à une machine (au sens large) d'évoluer grâce à un processus d'apprentissage (Figure III.1), et ainsi de remplir des tâches qu'il est difficile ou impossible de remplir par des moyens algorithmiques classiques. Les contours de ce thème de recherche sont maintenant bien établis, grâce aux travaux formalisant les objectifs de l'apprentissage et leur réalisation, qualifiée et quantifiée par la capacité d'apprendre [4]. Du point de vue des machines, on dira qu'une machine apprend dès lors qu'elle change sa structure, son programme ou ses données en fonction de données en entrée ou de réponses à son environnement de sorte à ce que ses performances futures deviennent meilleures. L'objectif de l'apprentissage artificiel étant de concevoir des programmes (machines) pouvant s'améliorer automatiquement avec l'expérience [17].

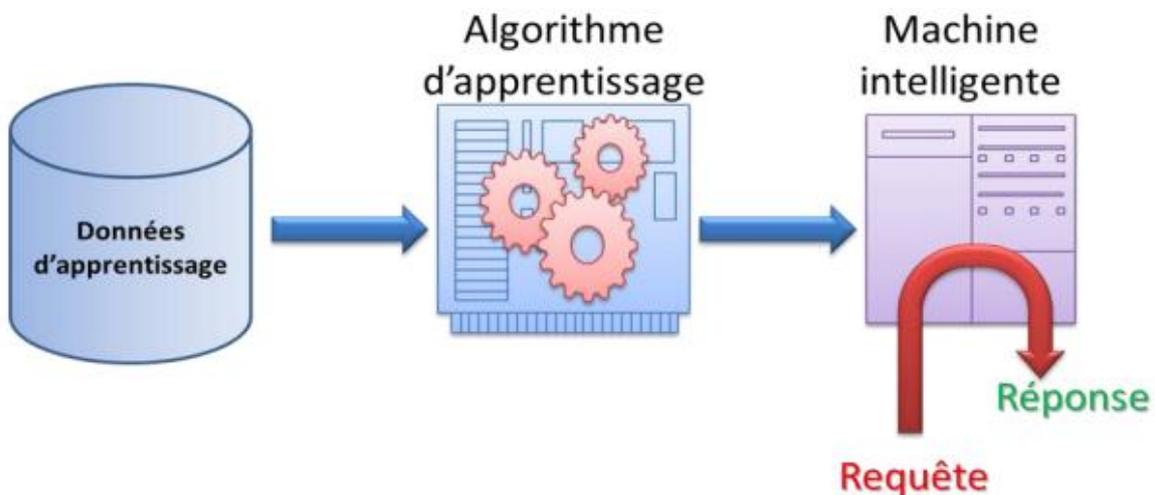


Figure III.1: Schéma général pour l'apprentissage machine.

La mise en œuvre des procédures d'apprentissage a considérablement mûri dans les deux dernières décennies, avec des avancées majeures, comme les méthodes à noyau ou le boosting [18] [19].

### III.3 Types d'apprentissage :

La technique d'apprentissage à adopter est généralement influencée par deux facteurs :

1. Le type de données d'apprentissage disponible dans la base d'apprentissage (étiquetées ou non étiquetées). Les données étiquetées impliquent généralement un apprentissage supervisé mais l'étiquetage des données est souvent très coûteux du fait qu'il faut une intervention d'experts pour cette tâche.

2. Le deuxième facteur concerne la disponibilité des données d'apprentissage au début de l'apprentissage : si par exemple le système doit agir à des situations au fur et à mesure durant son existence (nouvelles situations/classes). Ici, il est préférable d'utiliser un apprentissage par renforcement.

Selon ces deux facteurs, on peut distinguer plusieurs types d'apprentissage :

#### III.3.1 Apprentissage non supervisé :

Les algorithmes d'apprentissage non-supervisé utilisent un ensemble d'apprentissage  $D$  de  $n$  instances  $D = \{x_i\}_{i=1}^n$  sans avoir de professeur qui supervise le processus d'apprentissage en fournissant les sorties désirés ( $\hat{y}_i=f(x_i)$ ). En général, l'apprentissage non-supervisé peut réaliser les tâches suivantes :

- Le groupage (clustering) (former des groupes) ; le but étant de séparer  $n$  instances en groupes. C'est une des tâches les plus importantes de l'apprentissage non supervisé. L'algorithme de groupage le plus simple et le plus répandu est l'algorithme des  $K$  moyennes [20] (K-means algorithm).

- Détection de nouveautés : identifications de quelques instances qui sont très différents de la majorité des échantillons [21].

- Réduction de dimension : représenter chaque instance par un vecteur de dimension inférieur en gardant les caractéristiques principales de l'échantillon d'apprentissage [22].

#### III.3.2 Apprentissage supervisé :

Dans le cas où l'ensemble d'apprentissage  $D$  est constitué de paires  $D=\{(x_i,\hat{y}_i)\}_{i=1}^n$  (ensemble étiqueté), le problème d'apprentissage consiste à

chercher la forme de la fonction de transfert  $f/ y_i = f(x_i)$ . Ce problème est très commun qu'il a différents noms suivant la discipline. Par exemple : approximation de fonction, apprentissage inductif et régression non-paramétrique [23].

En réseau de neurones, le problème est appelé « apprentissage supervisé ». La fonction est construite à partir des exemples fournis par un superviseur (professeur). L'ensemble  $D$  est constitué de paires de variable indépendante (entrée)  $x_i$  et de sa variable dépendante (sortie)  $y_i$ . Par exemple, la variable indépendante correspond à un vecteur et la variable dépendante correspond à un scalaire. Dans le cas général, les entrées et les sorties sont des vecteurs. Dans ce cas, les sorties multiples sont traitées de façon spéciale pour réduire la redondance [23]. La Figure III.2: Le paradigme du professeur-élève dans l'apprentissage supervisé. Représente l'idée générale pour l'apprentissage supervisé.

La notation  $\hat{y}_i$  désigne une estimation ou une valeur incertaine de  $y_i$ . Ceci est justifié par le fait que l'ensemble d'apprentissage est biaisé par le bruit. En d'autres termes, la valeur exacte  $y_i$  correspondant à  $x_i$  est inconnue.

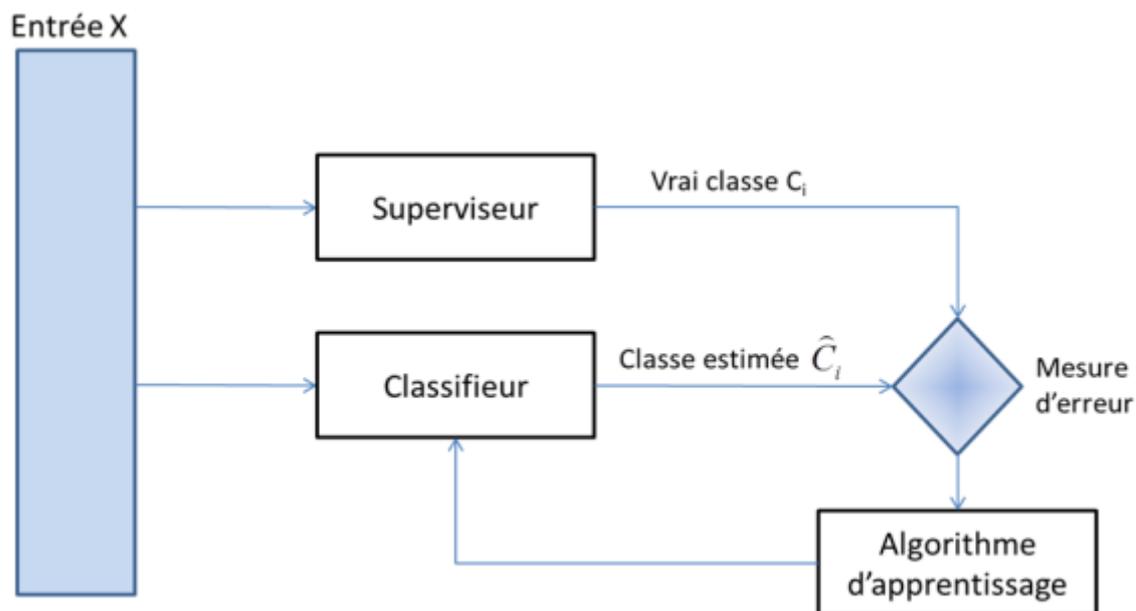


Figure III.2: Le paradigme du professeur-élève dans l'apprentissage supervisé.

### III.3.3 Apprentissage semi-supervisé :

En réduisant le sur-apprentissage, la régularisation est en quelque sorte une façon de compenser pour le manque de données. Effectivement, l'approche la plus sûre pour améliorer la généralisation d'un modèle serait d'augmenter la

quantité de données étiquetées utilisées en entraînement. Malheureusement, en pratique, le coût associé à la tâche d'étiquetage est souvent très élevé, puisque qu'elle requiert un travail manuel de classification par un expert humain qualifié. Cependant, en plus des données étiquetées  $D$ , il est souvent aussi possible d'obtenir un ensemble de données non-étiquetées  $U$ , ne contenant que des entrées  $x_i$  sans cibles  $y_i$  associées. De plus, on vient de voir qu'il est possible d'améliorer la performance de généralisation d'un modèle en incorporant de l'apprentissage non-supervisé à un critère d'entraînement supervisé. Ainsi, plutôt que de n'utiliser que les entrées de l'ensemble  $D$  dans le critère non-supervisé, on pourrait facilement choisir d'y ajouter les données de  $U$ . On dit de cette approche qu'elle procède par apprentissage semi-supervisé [24].

D'une façon générale, l'apprentissage semi-supervisé consiste à utiliser un ensemble d'exemples non-étiquetés  $U$ , en plus de l'ensemble des exemples étiquetés  $D$ , afin d'influencer la procédure d'un algorithme d'apprentissage et d'améliorer sa performance.

### III.3.4 Apprentissage partiellement supervisé :

On parle d'apprentissage partiellement supervisé quand l'étiquetage des données est partiel (par exemple quand le vecteur de variable dépendantes  $y_i$  n'est pas défini complètement et il manque quelques valeurs :  $y_{ij} = ?$ ) (Figure III.3). C'est le cas par exemple quand un modèle énonce qu'une donnée n'appartient pas à une classe A, mais peut-être à une classe B ou C (A, B et C étant 3 maladies par exemple évoquées dans le cadre d'un diagnostic différentiel). Dans ce cas, le vecteur de sortie n'est pas explicitement défini préalablement mais on a tout de même quelques informations sur un certain nombre de ses paramètres.

X				Y		
5.2	3.4	2.1	0.6	0	1	0
3.1	2.5	5.5	0.3	0	?	1
9.3	8.0	6.5	0.7	?	1	1
3.4	2.7	5.5	0.4	0	0	1
2.5	2.9	4.9	1.1	?	?	?
4.5	2.1	5.8	1.2	1	0	1
1.9	1.7	4.7	0.9	?	?	?

Figure III.3: Cas pour l'apprentissage partiellement supervisé.

### **III.3.5 Apprentissage par renforcement :**

L'apprentissage par renforcement (reinforcement learning) a comme objectif d'entraîner un agent à se comporter de façon intelligente dans un environnement donné. Cet agent interagit avec l'environnement en choisissant, à chaque temps donné, d'exécuter une action parmi un ensemble d'actions permises. Le comportement intelligent que doit apprendre cet agent est donné implicitement via un signal de renforcement qui, après chaque décision de l'agent, indique s'il a bien ou mal agi. L'agent doit donc se baser sur ce signal afin d'améliorer son comportement, qui est dicté par sa politique d'actions. À chaque temps donné, l'agent a normalement à sa disposition un ensemble de caractéristiques ou indicateurs d'entrée, décrivant l'environnement. Par exemple, si l'agent correspond à un robot, ces indicateurs pourraient être obtenus à partir de capteurs sensoriels brossant un portrait de l'endroit où il se trouve [25].

Les concepts d'action et de signal de renforcement sont probablement ceux qui distinguent le plus l'apprentissage par renforcement des apprentissages supervisé et non supervisé. Contrairement à l'apprentissage supervisé, le comportement intelligent à apprendre n'est pas explicitement donné par une cible à prédire mais doit plutôt être défini par l'utilisateur à l'aide d'un signal de renforcement [26]. Cependant, contrairement à l'apprentissage non-supervisé dont l'objectif est de modéliser la structure statistique des entrées, l'apprentissage par renforcement s'intéresse à la notion d'action qui est différente de celle d'entrée, de la même façon que le concept de cible de l'apprentissage supervisé est différent du concept d'entrée [27].

### **III.4 Apprentissage par réseaux de neurones :**

Les réseaux de neurones, en tant que système capable d'apprendre, mettent en œuvre le principe de l'induction, c'est-à-dire l'apprentissage par l'expérience. Par confrontation avec des situations ponctuelles, ils infèrent un système de décision intégré dont le caractère générique est fonction du nombre de cas d'apprentissages rencontrés et de leur complexité par rapport à la complexité du problème à résoudre. Par opposition, les systèmes symboliques capables d'apprentissage, s'ils implémentent également l'induction, le font sur base de la logique algorithmique, par complexification d'un ensemble de règles déductives [28].

Grâce à leur capacité de classification et de généralisation, les réseaux de neurones sont généralement utilisés dans des problèmes de nature statistique, tels que la classification automatique de codes postaux ou la prise de décision concernant un achat boursier en fonction de l'évolution des cours. Autre exemple, une banque peut générer un jeu de données sur les clients qui ont effectué un emprunt constituées : de leur revenu, de leur âge, du nombre d'enfants à charge... et s'il s'agit d'un bon client. Si ce jeu de données est suffisamment grand, il peut être utilisé pour l'entraînement d'un réseau de neurones [28]. La banque pourra alors présenter les caractéristiques d'un potentiel nouveau client, et le réseau répondra s'il sera bon client ou non, en généralisant à partir des cas qu'il connaît.

- Les réseaux de neurones artificiels ont besoin de cas réels servant d'exemples pour leur apprentissage (on appelle cela la base d'apprentissage). Ces cas doivent être d'autant plus nombreux que le problème est complexe et que sa topologie est peu structurée. Par exemple, on peut optimiser un système neuronal de reconnaissance manuscrite en utilisant le découpage manuel d'un grand nombre de mots écrits à la main par différentes personnes. Chaque caractère peut alors être présenté sous la forme d'une image brute, disposant d'une topologie spatiale à deux dimensions, ou d'une suite de segments presque tous liés. La topologie retenue, la complexité du phénomène modélisé, et le nombre d'exemples doivent être en rapport. Sur un plan pratique, cela n'est pas toujours facile car les exemples peuvent être soit en quantité absolument limitée ou trop onéreux à collecter en nombre suffisant (coût d'étiquetage) [29].

- Il y a des problèmes qui se traitent bien avec les réseaux de neurones, en particulier ceux de classification en domaines convexes (c'est-à-dire tels que si des points A et B font partie du domaine, alors tout le segment AB en fait partie aussi). Des problèmes comme "Le nombre d'entrées à 1 (ou à zéro) est-il pair ou impair ?" se résolvent en revanche très mal : pour affirmer de telles choses sur 2 puissance N points, si on se contente d'une approche naïve mais homogène, il faut précisément N-1 couches de neurones cachés, ce qui nuit à la généralité du procédé [16][17]. Considérons un neurone quelconque. Il reçoit des neurones en amont un certain nombre de valeurs via ses connexions synaptiques, et il produit une certaine valeur en utilisant une fonction de combinaison. Cette fonction peut donc être formalisée comme étant une fonction qui transforme un vecteur en une sortie scalaire, en effet :

- Les réseaux multicouches (MLP : Multi-Layer Perceptron) calculent une combinaison linéaire des entrées, c'est-à-dire que la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids synaptiques.

- Les réseaux à base radiale (RBF : Radial Basis Function) calculent la distance entre les entrées, c'est-à-dire que la fonction de combinaison renvoie la norme euclidienne du vecteur issu de la différence vectorielle entre les vecteurs d'entrées.

### **III.4.1 Choix de l'échantillon d'apprentissage :**

L'apprentissage d'un réseau de neurones sera d'autant meilleur qu'il s'effectuera sur un échantillon suffisamment riche pour présenter toutes les valeurs possibles des nœuds de toutes les couches du réseau, c'est-à-dire en particulier, toutes les modalités possibles de chaque variable en entrée ou en sortie. Un réseau n'est capable d'apprendre qu'à partir de configurations qu'il a rencontrées au cours de son apprentissage. Par exemple, si les clients de plus de 50.000 DA de découvert sont très risqués et si l'échantillon d'apprentissage n'en contient aucun, alors le réseau ne saura rien prédire à leur endroit. Cependant, il faut être conscient que le temps d'apprentissage augmente beaucoup avec la taille de l'échantillon, car le réseau doit parcourir plusieurs fois la base d'apprentissage.

Pour les variables en sortie, l'échantillon d'apprentissage doit contenir toutes les modalités en proportions égales, même si dans la population réelle, certaines modalités sont plus fréquentes. Dans un cas de reconnaissance manuscrite, la lettre «à» est relativement rare en français, mais elle doit exister en proportion égale à celle de la lettre «a» pour une bonne distinction.

### **III.5 Réseaux de neurones multi couches :**

L'archétype des réseaux de neurones est le perceptron multicouche (MLP). Il est particulièrement bien adapté au traitement des modèles complexes non linéaires. Un réseau MLP est capable d'approximer n'importe quelle fonction suffisamment régulière en utilisant une somme de fonctions sigmoïdes. En plus des couches d'entrée et de sortie, il comprend une ou plusieurs couches dites cachées. Un neurone de la couche  $n$  est connecté à tous les neurones de la couche  $n+1$ . Le nombre de neurones dans la couche d'entrée est égal au nombre de variable du modèle. Pour la couche cachée, le nombre de neurones dépend

généralement de l'application. Il n'existe, malheureusement, pas de règles rigoureuses pour le choix du nombre de neurones cachées (ainsi pour le nombre de couches cachées). Le Tableau I.1 montre l'impact du nombre de couches sur la région de décision pour un cas de classification [30].

Dans un réseau MLP, un poids est associé à chaque connexion. Ce dernier évolue au cours de l'apprentissage. Le réseau commence son apprentissage avec des valeurs aléatoires (il existe des algorithmes d'initialisation des poids pour les MLP) des poids et en calculant la valeur de sortie à partir d'un ensemble d'enregistrements pour lequel la valeur attendue en sortie est connue (données d'apprentissage étiquetées). La valeur calculée est alors comparée à celle attendue et une fonction d'erreur est calculée à partir des carrés des erreurs commises pour chaque individu de l'échantillon d'apprentissage :

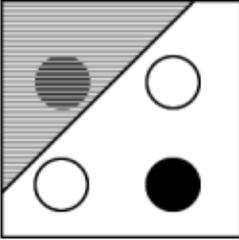
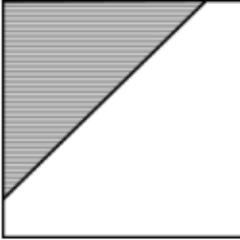
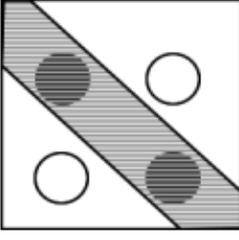
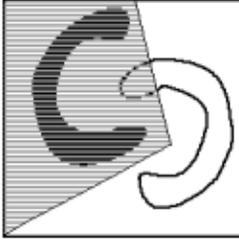
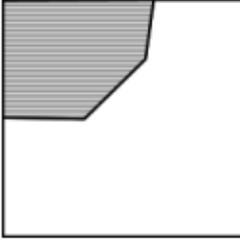
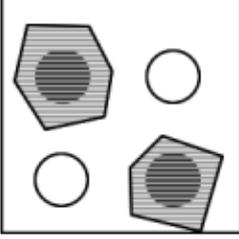
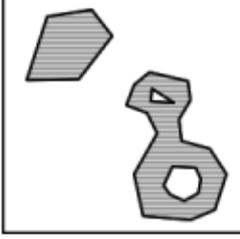
$$\sum_i \sum_j (A_{ij} - O_{ij})^2 \quad (\text{III.1})$$

- $A_{ij}$  est la valeur attendue du  $j^{\text{ème}}$  nœud pour le  $i^{\text{ème}}$  individu.
- $O_{ij}$  est la valeur obtenue du  $j^{\text{ème}}$  nœud pour le  $i^{\text{ème}}$  individu.

Ensuite, le réseau ajuste les poids en regardant à chaque fois si la fonction d'erreur augmente ou diminue. Comme dans une régression classique, il s'agit de résoudre un problème de moindres carrés.

Le principe d'apprentissage des réseaux MLP fut découvert simultanément par plusieurs chercheurs, en France et aux Etats-Unis. L'idée générale consiste à répartir les erreurs observées en sortie sur les neurones « fautifs » en retraçant à l'envers le cheminement de l'activation originale et en appliquant une correction à chaque nœud en fonction de son activation et des poids de ses liens. Le nom donné à ce processus est la rétro propagation du gradient [31].

**Tableau III.1:** Interprétation géométrique des neurones cachés dans un espace à deux dimensions.

Structure du réseau	Description des régions de décision	Problème du « ou exclusif »	Classes avec des régions chevauchées	Forme générale des régions de décision
 Une seule couche	Demi-plan limité par hyper-plans			
 Deux couches	Arbitraire Limité par le nombre des neurones cachés			
 Trois couches	Arbitraire Limité par le nombre des neurones cachés			

### III.6 Les réseaux de neurone probabiliste :

#### III.6.1 Motivations pour les réseaux probabilistes :

Remplacer la fonction d'activation sigmoïde souvent utilisée dans les réseaux de neurones à fonction exponentielle, un réseau neuronal probabiliste (PNN) capable de calculer des limites de décision non linéaires qui s'approchent de l'optimum de Bayes est formé. Des fonctions d'activation alternatives ayant des propriétés similaires sont également discutées. Un réseau neuronal à quatre couches de ce type proposé peut mapper n'importe quel modèle d'entrée à n'importe quel nombre de classifications. Les limites de décision peuvent être modifiées en temps réel en utilisant de nouvelles données à mesure qu'elles deviennent disponibles, et peut être mis en œuvre en utilisant du matériel artificiel (neurones) qui fonctionnent entièrement en parallèle. Des dispositions sont également prises pour estimer probabilité et la fiabilité d'une classification ainsi que prendre la décision.

### III.6.2 La stratégie de bayes pour la classification des motifs :

Une norme acceptée pour les règles de décision ou les stratégies utilisées pour classer les modèles est qu'ils le font d'une manière qui minimise le «risque attendu». De telles stratégies sont appelées "stratégies de Bayes" (Mood & Graybill, 1962) et peut être appliqué à des problèmes contenant un nombre quelconque de catégories.

Cette règle est définie comme suit. Si nous supposons que:

\* Il y a des échantillon de données  $(x) \in \mathbb{R}^n$  Qui est inclus dans l'un des classes prédéfinis  $(g) = 1, \dots, G$ .

\* La probabilité d'appartenance de  $(x)$  à la classe  $(g)$  est égale à  $p_g$ .

\* le coût de la classification  $(x)$  dans la classe  $(g)$  est  $(c_g)$ .

\* les fonctions de densité probables  $y_1(x), y_2(x), \dots, y_G(x)$ —pour toutes les classes sont connues.

Alors, selon le théorème de Bayes, quand  $g \neq h$ , le vecteur  $(x)$  est classé dans la classe  $(g)$ ,

Si :

$$p_g c_g y_g(x) > p_h c_h y_h(x). \quad (\text{III.2})$$

D'habitude :

$$p_g = p_h \text{ et } c_g = c_h, \quad (\text{III.3})$$

Donc si :

$$y_g(x) > y_h(x), \quad (\text{III.4})$$

Le vecteur  $(x)$  est classé dans la classe  $(g)$ . [32]

### III.6.3 Cohérence des estimations de densité :

L'exactitude des limites de décision dépend de la précision avec laquelle les PDF sous-jacents sont estimés. Parzen (1962) a montré comment on peut construire une famille d'estimations de  $f(\mathbf{X})$ .

$$f_n(\mathbf{X}) = \frac{1}{n\lambda} \sum_{i=1}^n \omega\left(\frac{\mathbf{X} - \mathbf{X}_{Ai}}{\lambda}\right) \quad (\text{III.5})$$

Qui est cohérent à tous les points  $\mathbf{X}$  où le PDF est continu. Soit  $\mathbf{X}_{At} \dots, \mathbf{X}_A \dots, \mathbf{X}_a \dots$ , des variables aléatoires indépendantes réparties identiquement comme une variable aléatoire  $\mathbf{X}$  dont la fonction de distribution  $F(\mathbf{X}) = P[\mathbf{x} \leq \mathbf{X}]$  est absolument continue, les conditions de Parzen sur la fonction de pondération  $\omega(y)$  sont :

$$\sup_{-x < y < x} |\omega(y)| < x_i \quad (\text{III.6})$$

Où sup indique le supérieur :

$$\int_{-\infty}^{+\infty} |\omega(y)| dy < \infty \quad (\text{III.7})$$

$$\lim_{y \rightarrow x} |y\omega(y)| = 0 \quad (\text{III.8})$$

$$\int_{-\infty}^{+\infty} |\omega(y)| dy = 1 \quad (\text{III.9})$$

Dans l'équation (4),  $2 = 2(n)$  est choisi en fonction de  $n$  tel que :

$$\lim_{n \rightarrow \infty} n\lambda(n) = \infty \quad (\text{III.10})$$

Et

$$\lim_{n \rightarrow \infty} n\lambda(n) = \infty \quad (\text{III.11})$$

Parzen a prouvé que l'estimation  $f_n(\mathbf{X})$  est cohérente en moyenne quadratique dans le sens où :

$$E|f_n(\mathbf{x}) - f(\mathbf{x})|^2 \rightarrow 0 \quad \text{Ainsi } n \rightarrow \infty \quad (\text{III.12})$$

Cette définition de la cohérence, qui dit que l'erreur attendue devient plus petite à mesure que l'estimation est basée sur un ensemble de données plus important, est particulièrement importante car elle signifie que la vraie distribution sera approchée d'une manière lisse.

Murthy (1965, 1966) a assoupli l'hypothèse de la continuité absolue de la distribution  $F(\mathbf{X})$  et a montré que la classe des estimateurs  $f_n(\mathbf{X})$  estime toujours la densité de tous les points de continuité de la distribution  $F(\mathbf{X})$ . Cacoullos (1966) a également étendu les résultats de Parzen pour couvrir le cas multivarié. Le théorème de Cacoullos (1966) montre comment les résultats de Parzen peuvent être étendus aux estimations dans la mesure particulière que le noyau multivarié est un produit de noyaux univariés. Dans le cas particulier du noyau de Gaussien, les estimations multivariées peuvent être exprimées :

$$f_a(\mathbf{x}) = \frac{1}{(2\pi)^{p/2} \sigma^p} \frac{1}{m} \sum_{i=1}^m \exp \left[ -\frac{(\mathbf{x} - \mathbf{x}_{Ai})(\mathbf{x} - \mathbf{x}_{Ai})}{2\sigma^2} \right] \quad (\text{III.13})$$

Où :

$i$  = numéro de modèle.

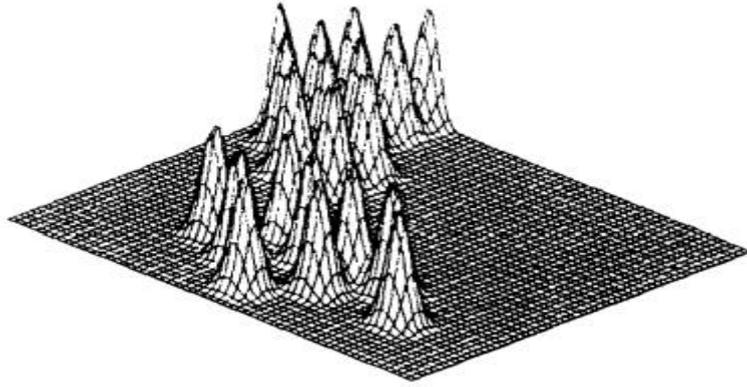
$m$  = nombre total de modèles d'entraînement.

$\mathbf{x}_{Ai}$  = le schéma d'entraînement de la catégorie OA.

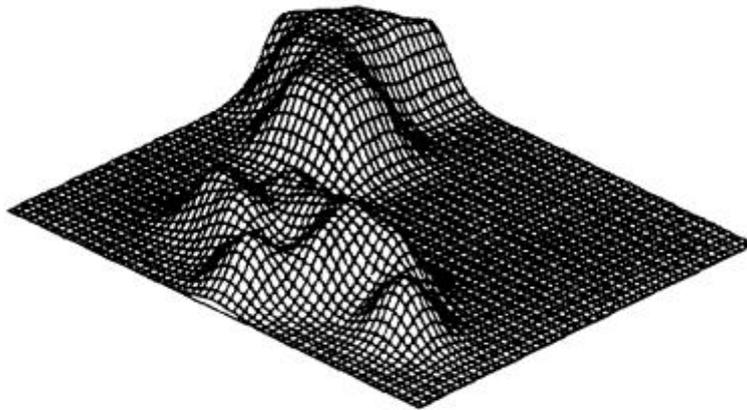
$\sigma$  = "paramètre de lissage".

$p$  = dimensionnalité de l'espace de mesure.

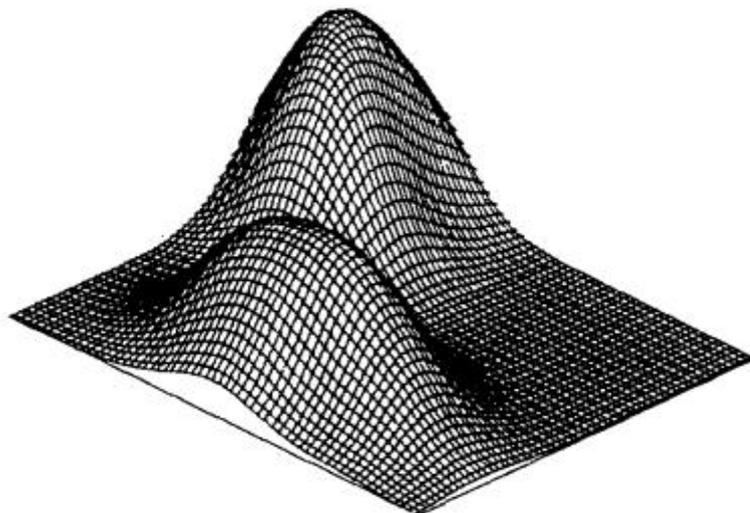
Notez que  $f_A(X)$  est simplement la somme de petites distributions gaussiennes multi variées centrées sur chaque échantillon d'apprentissage. Cependant, la somme ne se limite pas à être gaussien. Il peut, en fait, approcher n'importe quelle fonction de densité lisse. La figure III.4 illustre l'effet de différentes valeurs pour le paramètre de lissage  $\sigma$  sur  $f_A(X)$  pour le cas où la variable indépendante  $X$  est bidimensionnelle. La densité est tracée à partir de l'équation (III.13) pour trois valeurs de  $\sigma$  avec les mêmes échantillons d'entraînement dans chaque cas. Une petite valeur de  $\sigma$  fait que la fonction de densité parente estimée a des modes distincts correspondant aux emplacements des échantillons d'apprentissage. Une valeur plus grande de  $\sigma$ , comme indiqué sur la figure 1b, produit un plus grand degré d'interpolation entre les points. Ici, on estime que les valeurs de  $X$  proches des échantillons d'entraînement ont à peu près la même probabilité d'occurrence que les échantillons donnés. Une valeur encore plus grande de  $\sigma$ , comme indiqué sur la figure 1c, produit un plus grand degré d'interpolation. Une très grande valeur de  $\sigma$  ferait que la densité estimée soit gaussienne, quelle que soit la véritable distribution sous-jacente. La sélection de la quantité de lissage appropriée sera discutée dans la section "Conditions limites  $\sigma \rightarrow 0$  et ainsi  $\sigma \rightarrow \infty$ "



a. Une petite valeur de  $\sigma$  .



b. Une plus grande valeur de  $\sigma$  .



c. Une valeur encore plus grande de  $\sigma$  .

FIGURE III.4 : Effet de lissage des différentes valeurs de  $\sigma$  sur un PDF estimé à partir d'échantillons.

L'équation (III.13) peut être utilisée directement avec la règle de décision exprimée par eq (III.2). Des programmes informatiques ont été écrits pour effectuer des tâches de reconnaissance de formes en utilisant ces équations, et d'excellents résultats ont été obtenus sur des problèmes pratiques. Cependant, deux limitations sont inhérentes à l'utilisation d'eq (III.13): (a) l'ensemble d'entraînement doit être stocké et utilisé pendant les tests, et (b) la quantité de calcul nécessaire pour classer un point inconnu est proportionnelle à la taille de l'ensemble d'entraînement. Lorsque cette approche a été proposée et utilisée pour la reconnaissance de formes, les deux considérations limitaient sévèrement l'utilisation directe d'eq (III.13) dans des applications dédiées ou en temps réel. Les approximations devaient être utilisées à la place. La mémoire informatique est devenue suffisamment dense et peu coûteuse pour que le stockage de l'ensemble d'apprentissage ne soit plus un obstacle.

### **III.7 Principes de base pour les réseaux probabilistes :**

Le développement du réseau de neurones probabiliste repose essentiellement sur le classificateur à base de fenêtres de Parzen. Cette méthode est une procédure non paramétrique qui synthétise une estimation de la fonction de densité de probabilité par une superposition de plusieurs fenêtres qui représentent des fonctions simples (généralement des Gaussiennes) [38].

Une approche plus traditionnelle est de construire une estimation de la pdf (probability density function) à partir des données d'apprentissage [36]. La technique la plus triviale est d'assumer une certaine forme de la pdf (distribution normale par exemple) et de trouver les paramètres du modèle. Les paramètres d'une distribution normale peuvent être facilement trouvés par des techniques analytiques. Le problème dans cette idée est que la supposition de normalité ne soit pas souvent justifiée.

Une approche alternative est d'utiliser l'approximation à base de kernels (noyaux) [37][36][35]. On suppose que la présence d'un certain cas indique une densité de probabilité dans ce point. Ainsi, un groupe de cas proches l'un de l'autre indique une zone de grande densité [34]. En s'approchant d'un cas (voisinage), on a une grande espérance d'avoir une grande densité de probabilité. Dans une estimation basée sur les noyaux (kernel methods), des fonctions simples (généralement des gaussiennes) sont centrées sur chaque cas individuel, et leur somme représente la pdf générale. En effet, s'il existe suffisamment de points représentatifs dans l'ensemble d'apprentissage, on peut arriver à une bonne approximation de la densité [36].

### **III.8 Architecture d'un réseau probabiliste :**

L'architecture générale d'un réseau de neurones probabiliste est présentée dans la Figure III.5. Ce réseau comporte trois couches [38]:

**Une couche d'entrée :** le nombre de neurones dans cette couche est limité par le nombre de paramètres (variables) séparables nécessaires pour décrire la forme en entrée.

**Une couche de motifs (cachée) :** cette couche organise l'ensemble d'apprentissage en représentant chaque vecteur en entrée par un neurone caché qui enregistre les paramètres de ce vecteur.

**Une couche de sortie :** appelée aussi la couche de sommation. Dans cette couche, le nombre d'unités est égal au nombre de classes du modèle. Chaque unité est connectée à tous les neurones de la couche de motifs appartenant à cette classe.

On ajoute parfois une autre couche pour la normalisation du vecteur d'entrées si ces dernières ne le sont pas déjà [34]. En effet, comme pour les réseaux

multicouches, le vecteur d'entrée doit être normalisé pour donner une séparation adéquate dans la couche cachée.

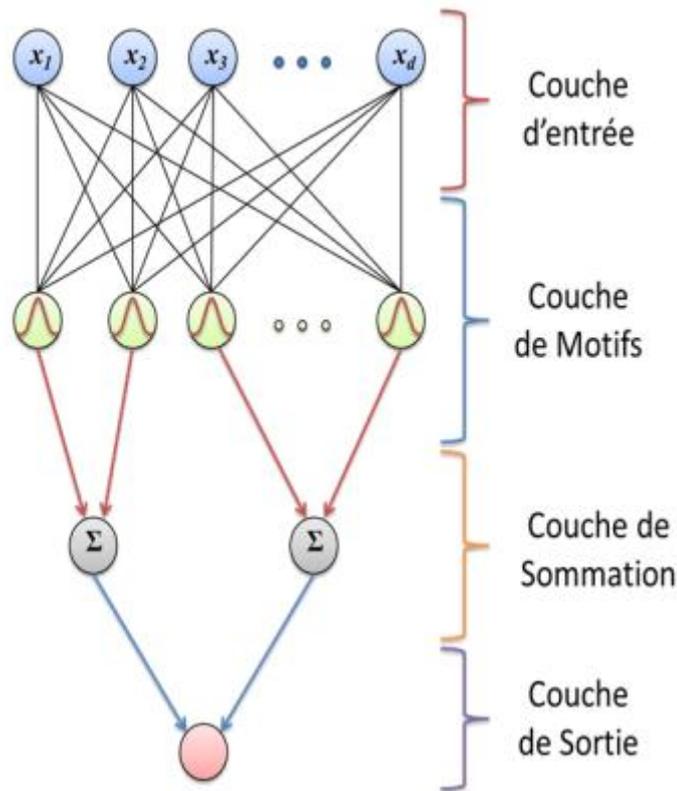


Figure III.5: Architecture générale d'un réseau probabiliste.

Les unités radiales sont copiées directement de l'ensemble d'apprentissage, un par cas. Chacun modélise une fonction gaussienne centrée sur l'échantillon d'apprentissage. Il y a une unité de sortie pour chaque classe connectée à toutes les unités cachées appartenant à cette classe et sans connexions avec les autres unités [28]. Les sorties sont proportionnelles aux fonctions de densités des différentes classes et normalisées pour former une somme égale à 1.

Les neurones de motifs (neurones de la couche cachée) utilisent une fonction d'activation gaussienne (voir la Figure II.6) [39]:

$$f(x) = e^{-\frac{(w_i - x_i)^2}{2\sigma^2}} \quad (\text{III.14})$$

Avec:

- Les  $w_i$  représentent les poids.
- Les  $x_i$  représentent les variables du modèle.
- Et  $\sigma$  est un paramètre de lissage.

### **III.9 Avantages et inconvénients des réseaux probabilistes :**

Cependant, il existe quelques points spécifiques pour les réseaux probabilistes qui méritent d'être mentionnés dans cette section.

Un des avantages les plus importants pour le réseau de neurone probabiliste est le fait que la sortie du réseau soit probabiliste [34]. Ceci peut rendre l'interprétation de la sortie plus facile et pondérée. En cas de classification par exemple, la sortie correspond à la probabilité d'appartenance à la classe et non pas à la classe elle-même. On a en plus de la classification de l'échantillon en entrée, une mesure de confiance (probabilité) concernant cette classification.

Un autre avantage des réseaux probabilistes est la rapidité d'apprentissage [35]. En effet, le processus d'apprentissage d'un réseau probabiliste se réduit à la copie directe des échantillons d'apprentissage dans la couche cachée du réseau qui est effectuée en un seul passage sur la base d'apprentissage. Ceci est en quelque sorte la vitesse limite qu'un algorithme d'apprentissage peut atteindre.

L'insertion de nouveaux exemples d'apprentissage est facile et ne pose aucune difficulté puisqu'il suffit d'ajouter des neurones dans la couche cachée ainsi que les liaisons vers ces neurones. On peut même ajouter des nouvelles classes en cas de nécessité [29].

Le réseau est robuste contre les échantillons bruités et converge toujours vers un classificateur optimal de Bayes (à ne pas confondre avec « naïve Bayes classifier ») s'il y a suffisamment d'exemples d'apprentissage [36].

L'inconvénient majeur pour les réseaux de neurones probabilistes est la taille du réseau qui dépend de la taille de la base d'apprentissage [34]. Le réseau contient tous les échantillons d'apprentissage dans sa structure. En matière des ressources de stockage, c'est le cas le plus défavorable [35].

Pour les réseaux probabilistes, le temps de calcul pour le test est relativement lent puisqu'il faut voir l'activation de tous les neurones du réseau pour pouvoir donner une conclusion. Cette tâche dépend essentiellement du nombre d'échantillons d'apprentissage. Cependant, l'activation des neurones dans la couche cachée peut se calculer d'une façon parallèle ce qui peut réduire d'avantage le temps de calcul si on met en œuvre un algorithme exploitant le parallélisme [35].

Specht a annoncé dans [28] que son réseau probabiliste de base n'est pas très influencé par le choix du paramètre de lissage. Cependant, d'autres recherches ont montré que pour certaines applications, ce paramètre devient très intéressant et peut affecter sérieusement la capacité de généralisation du réseau [37] [34]. Ainsi, beaucoup de méthodes ont été proposées pour fixer les paramètres du réseau afin d'optimiser les performances du réseau.

### **III.10 Conclusion :**

Dans ce chapitre, nous avons présenté quelques notions fondamentales sur l'apprentissage, les techniques d'apprentissage en réseau neuronal, les principes mathématiques solides derrière le réseau de neurones probabiliste, son architecture, et enfin Nous avons mentionné un certain avantage et incommode.

## Chapitre IV : Résultat et simulation

### IV.1 Description du système PV :

L'installation photovoltaïque à l'étude située au centre de développement des énergies renouvelables de la CDER à Alger. Cette installation photovoltaïque est une puissance de 9,54 kWp répartie en 3 sous-système de 3,18 kWp chacun. Chaque sous-système contient 30 modules photovoltaïques Isofoton 106W-12V montés en 2 chaînes parallèles, chaque chaîne est composée de 15 modules PV en série, ce dernier est connecté à un onduleur monophasé de 2,5 kW (IG30 Fronius). Les irradiations inclinées et horizontales sont mesurées à l'aide d'un pyranomètre thermoélectrique Kipp&Zonen CM11, tandis que la température du module PV est mesurée à l'aide d'un thermocouple de type K. Les variables météorologiques ainsi que les mesures de variables électriques sont effectuées par un enregistreur de données (Agilent 34970) comme illustré à la Fig. 1. Le tableau 1 résume les principaux paramètres électriques du module PV Isofoton 106-12 dans des conditions d'essai standard (STC) de 25 ° C et le niveau d'éclairement de 1000 W / m<sup>2</sup>). Dans ce travail, les données météorologiques et les mesures de coordonnées MPP (courant MPP et tension) ont été recueillies avec un temps d'échantillonnage de 1 min.

**Tableau IV.1:**

paramètres	$I_{mpp}$ [A]	$V_{mpp}$ [V]	$P_{mpp}$ [W]	$I_{sc}$ [A]	$V_{oc}$ [V]
valeur	6.4	17.4	106	6.54	21.6

**Tableau IV.1 : Les paramètres électriques du module PV Isofoton 106-12 dans des conditions d'essai standard**

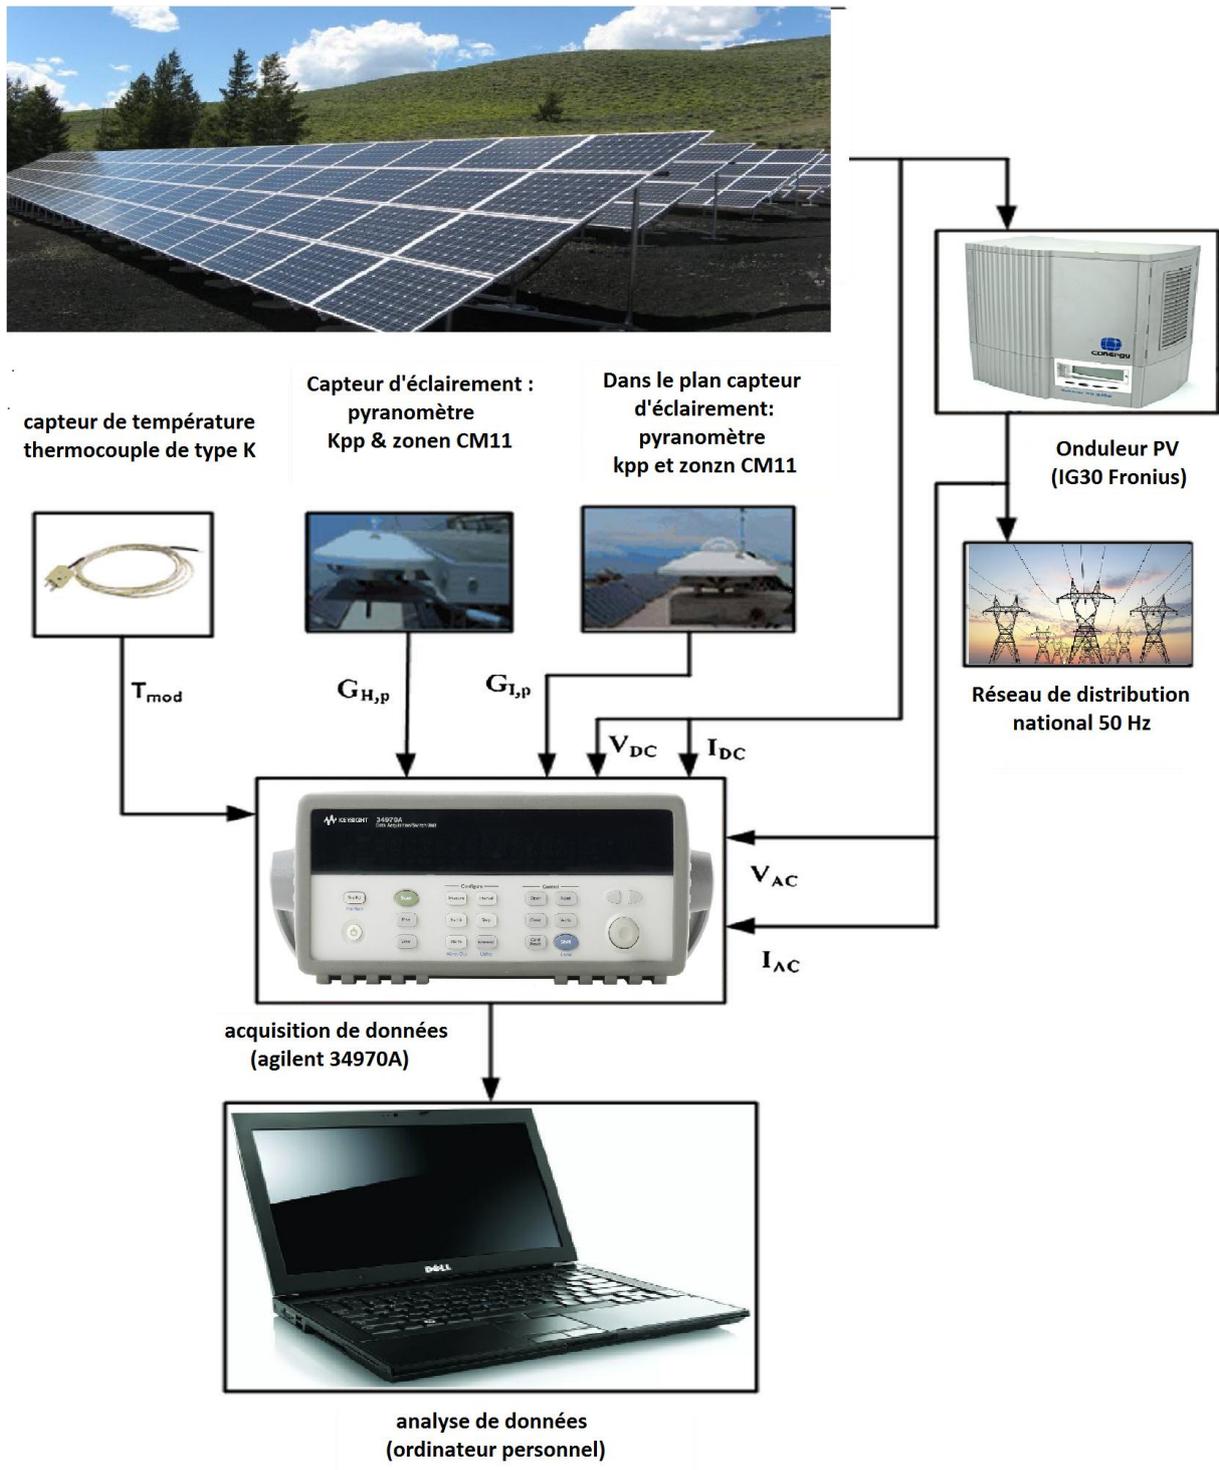


Figure IV.1 : Installation photovoltaïque à l'étude

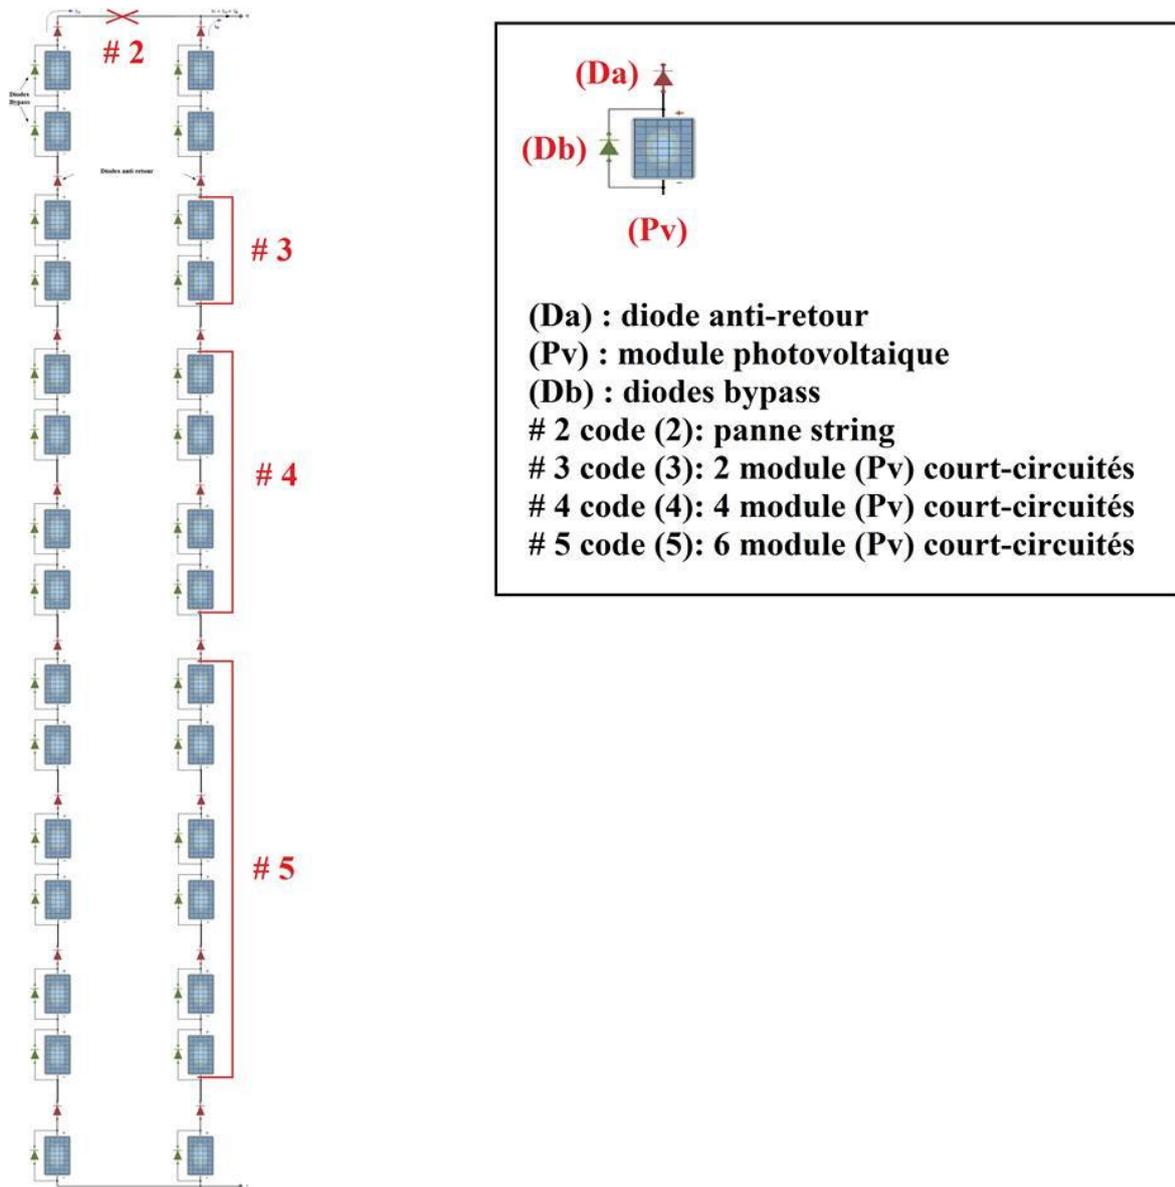


Figure IV.2 : 30 modules photovoltaïques Isofoton 106W-12V montés en 2 chaînes parallèles, chaque chaîne est composée de 15 modules PV en série

### IV.2 Stratégie de détection et de diagnostic :

L'objectif principal de ce travail est de concevoir une procédure efficace et fiable, basée sur le classificateur PNN, pour détecter les défauts dans un système photovoltaïque et diagnostiquer leur origine. Cependant, l'utilisation de ce type de méthode, pour traiter le problème de classification, nécessite la disponibilité d'une base de données de haute qualité qui décrit très bien le processus pour chaque classe.

### **IV.3 Méthode basée sur PNN pour la détection de défauts et le diagnostic dans les systèmes PV :**

L'utilisation du PNN comme approche de diagnostic et de détection des défaillances nécessite quatre étapes essentielles:

Élaboration d'une base de données pertinente contenant les données nécessaires pour former et tester le réseau, construction du réseau, formation du réseau à l'aide du kit d'apprentissage et enfin test de l'efficacité du réseau basé sur l'ensemble de test.

#### **IV.3.1 Elaboration de base de données :**

Cette étape consiste à élaborer une base de données de haute qualité qui décrit avec précision le comportement du système, dans des conditions normales et défectueuses. En plus, le modèle de système photovoltaïque validé est utilisé pour générer des échantillons sains et défectueux, en introduisant intentionnellement les défauts souhaités, avec des profils réels de température et d'éclairement quotidiens. Les échantillons enregistrés, correspondant à chaque condition de fonctionnement, comprennent quatre attributs climatique et électrique: température du module "T", Irradiation "G", courant à MPP " $I_{mpp}$ " et tension à MPP " $V_{mpp}$ " chaque attribut contient 1217 données pour chaque cas d'exploitation, ce qui signifie un total de 6085 données pour les cinq pannes. Tant dis que, l'ensemble des échantillons de test contient 323\_ données pour chaque cas étudier.

Les figures suivantes représentent notre déférents cas qu'on a étudié (courant et puissance) :

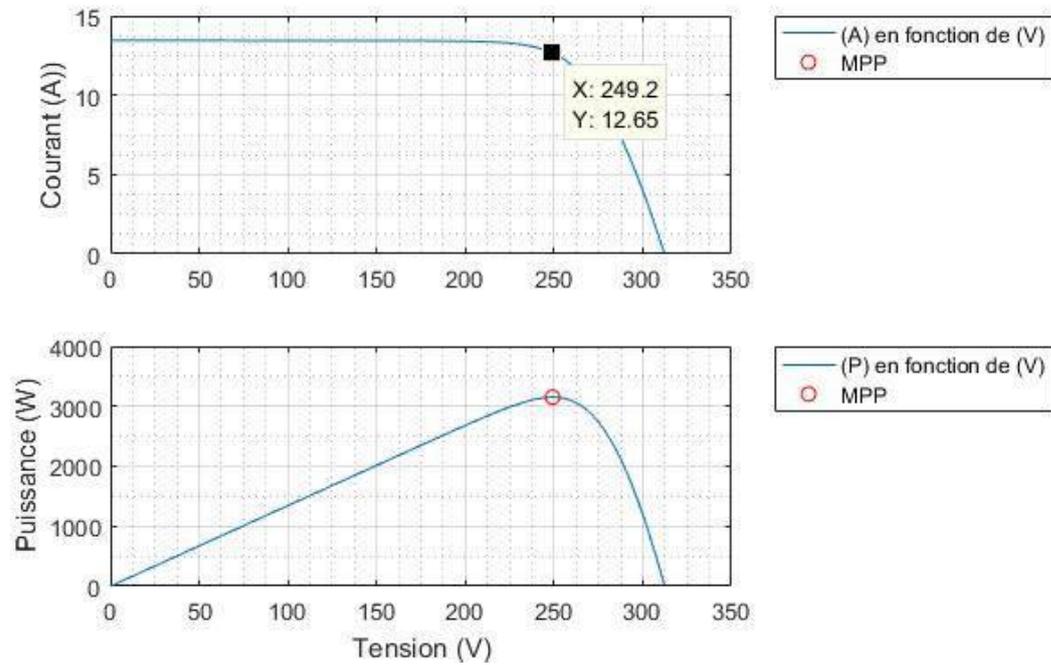


Figure IV.3 : caractéristique d'un système PV en état sain

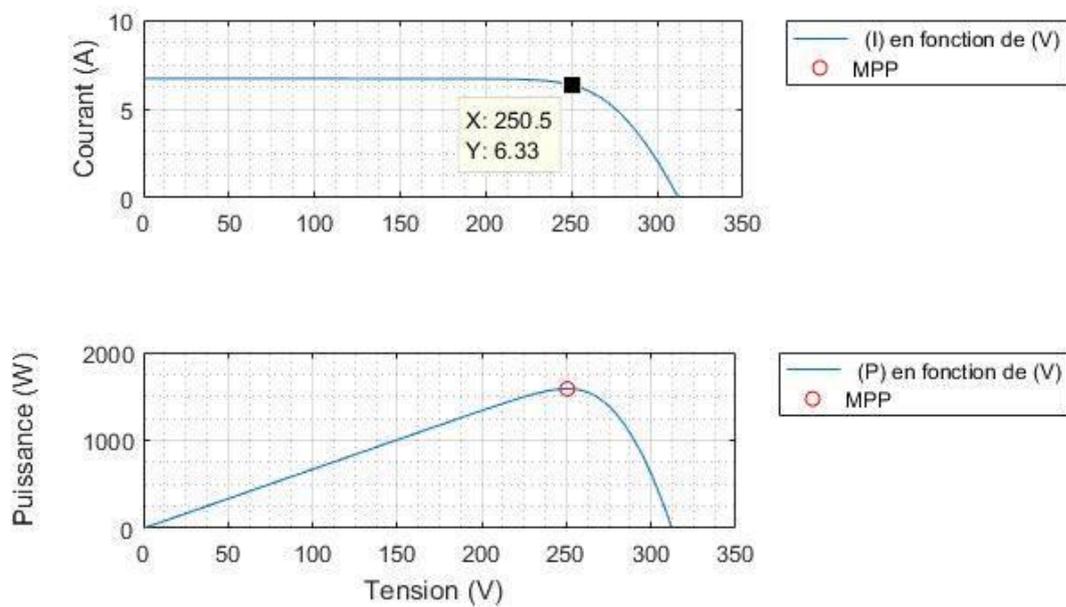


Figure IV.4 : caractéristique de système PV en cas de panne branche complètement déconnecté

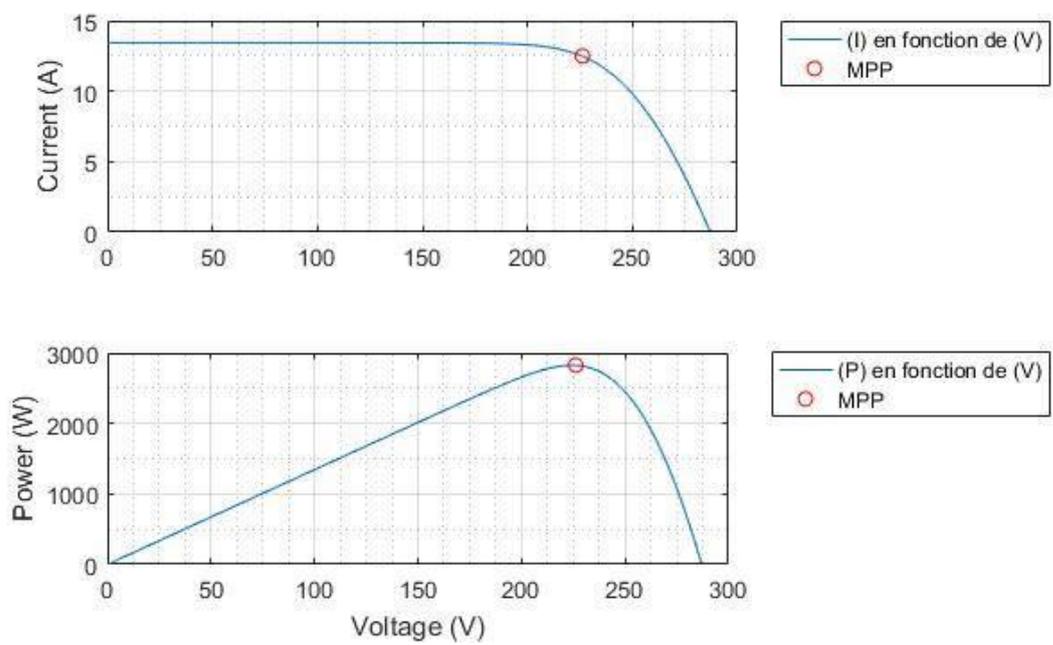


Figure IV.5 : caractéristique de système en cas de panne 2 modules PV court-circuités

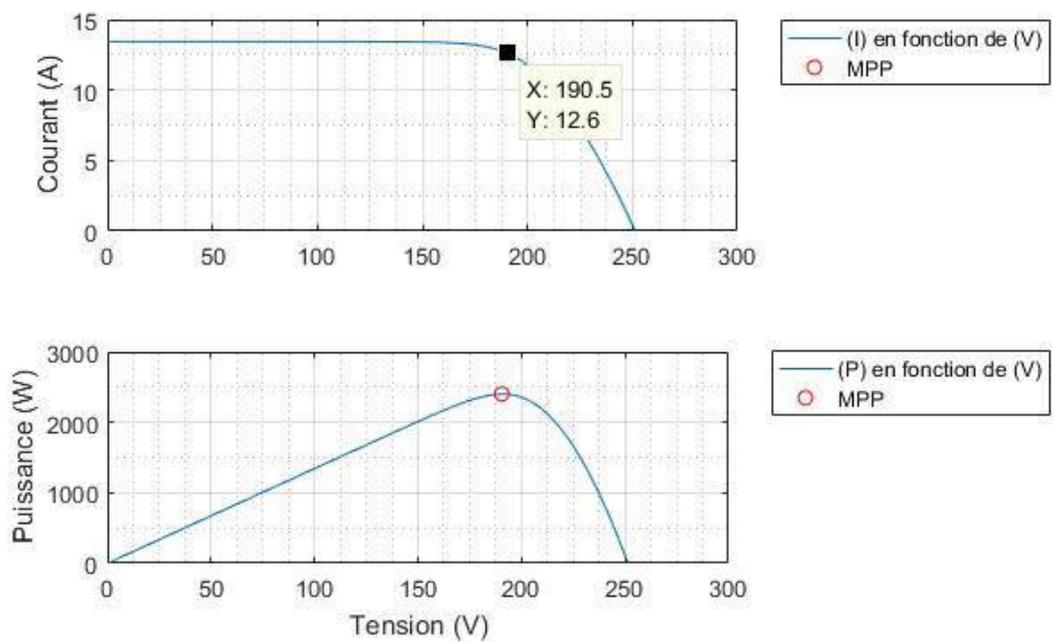


Figure IV.6 : caractéristique de système en cas de panne 4 modules PV court-circuités

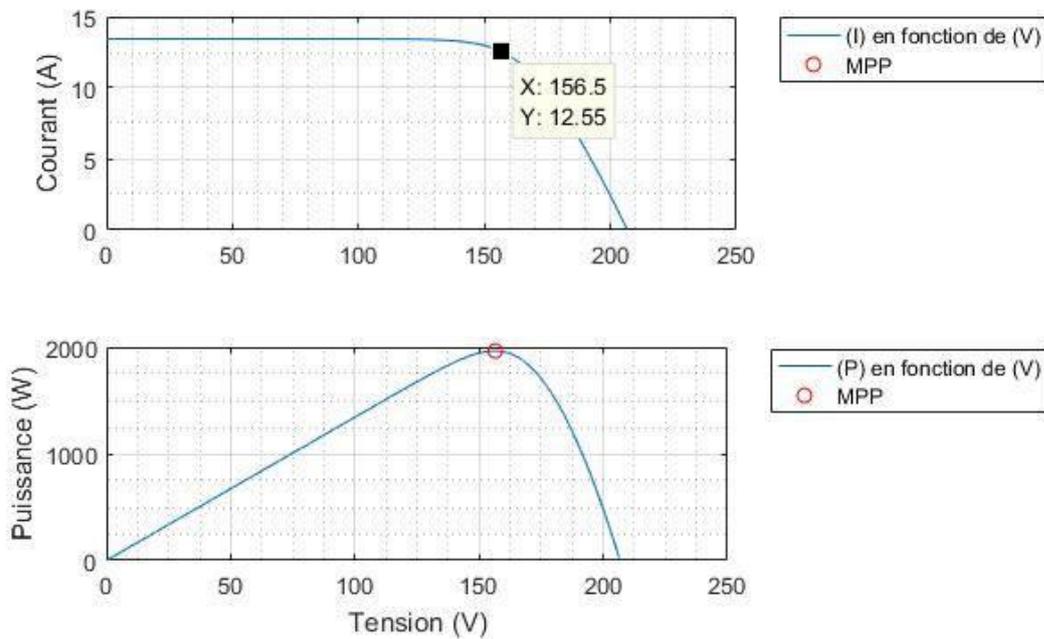


Figure IV.7 : caractéristique de système en cas de panne 6 modules PV court-circuités

### IV.3.2 Structure de réseaux :

Puisque le travail proposé vise à la fois la détection et le diagnostic des défaillances, un classificateur PNN est construit. En effet, l'apparition de défaut dans le système PV est détectée par le réseau neuronal (PNN).

Dans notre étude, Le classificateur PNN exige quatre neurone à son entrée, chaque neurone correspond à un attribut ( $T$ ,  $G$ ,  $I_{mpp}$  et  $V_{mpp}$ ) et un neurone à sa sortie correspondant à diagnostiqué les cinq cas étudier (état sain et quatre état défectueux). Ce neurone produit la classe qui correspond à la fonction de densité de probabilité la plus élevée dans les unités d'addition. Ce concept est expliqué par l'organigramme de la figure (IV.8), donné ci-dessous :

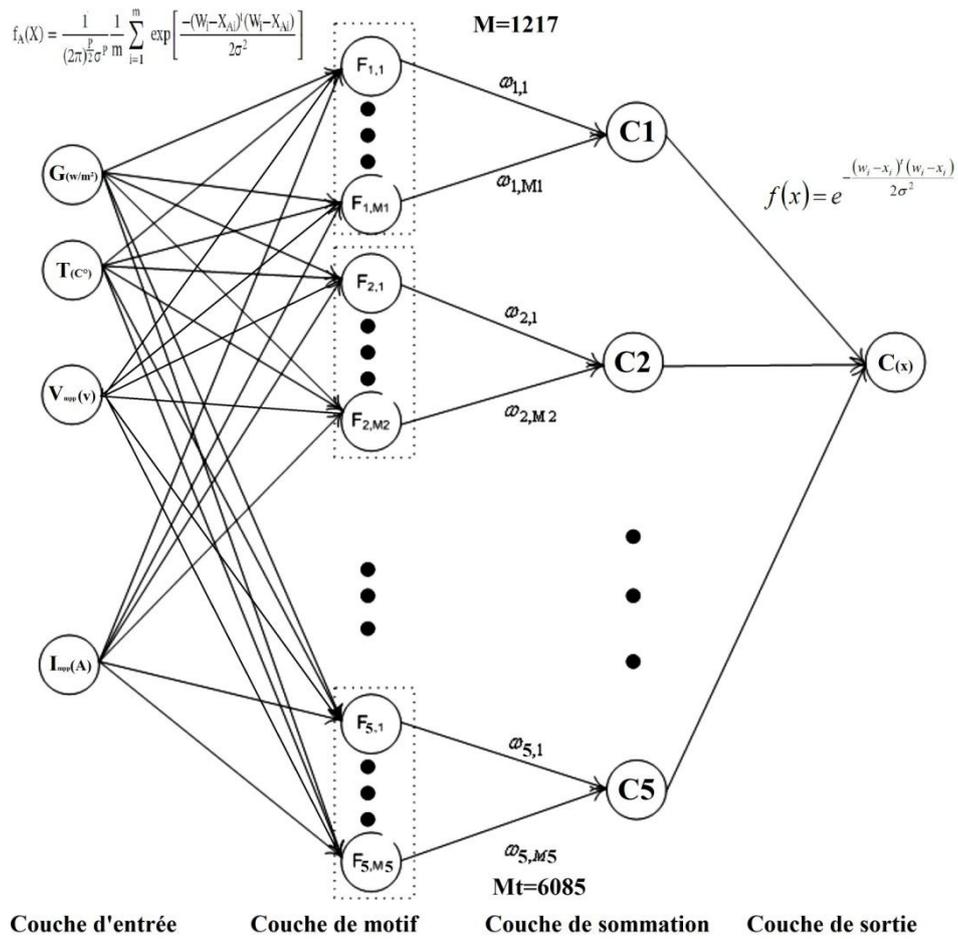


Figure IV.8 : Structure de classificateur PNN

La figure ci-dessous montre la simulation de classificateur PNN dans le MATLAB :

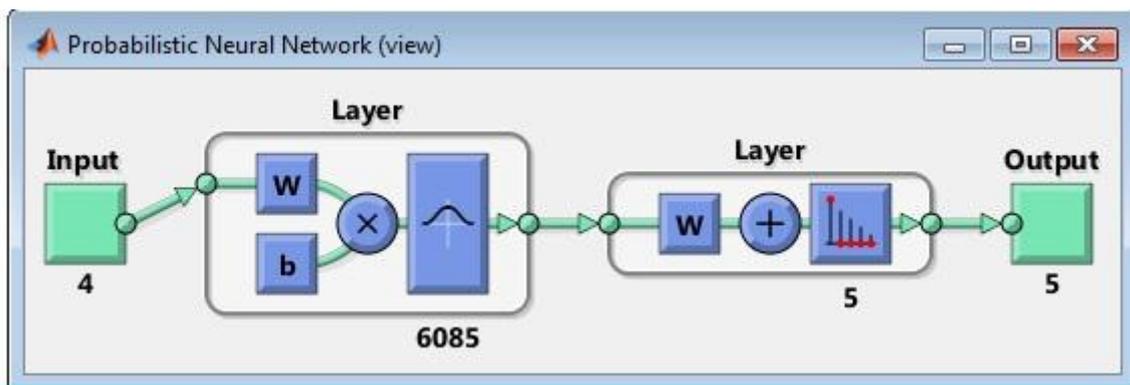


Figure IV.9 : le PNN construit par le matlab.

### **IV.3.3 Phase d'apprentissage :**

Maintenant, le réseau de détection et de diagnostic est formé en utilisant l'apprentissage d'un ensemble de données obtenu et ne pas être traité dans la phase d'apprentissage. Il convient de noter ici que:

D'une part, les données d'entrée ( $T$ ,  $G$ ,  $I_{mpp}$  et  $V_{mpp}$ ), sont de type continu et directement injecté dans le PNN. Et d'un autre côté, les sorties (état sain, défaut # 1, défaut # 2, défaut # 3 et défaut # 4) sont variables nominales qui ne sont pas supportées par ce type de réseaux. Pour Cette raison, des codes particuliers, choisis arbitrairement, ont été assignés à les sorties PNN comme mentionné ci-dessous:

- Système sain: code "1", et qui sera utilisé pour décrire le cas d'exploitation de bon état du bien.
- Défaut n ° 1: code "2", et qui sera utilisé pour décrire l'occurrence d'une déconnexion de chaîne complète dans le réseau PV.
- Défaut n ° 2: code "3", et qui sera utilisé pour décrire l'apparition de court-circuit de deux modules PV dans une chaîne PV.
- Défaut n ° 3: code "4", et qui sera utilisé pour décrire l'apparition de court-circuit de quatre modules PV dans une chaîne PV.
- Défaut n ° 4: code "5", et qui sera utilisé pour décrire l'apparition d'un court-circuit de six modules PV dans une chaîne PV.

Enfin, pour former le réseau de détection et de diagnostic, il est nécessaire de lui apprendre les valeurs des attributs et les vecteurs cibles (code de chaque classe) respectivement correspondants qui sont utilisés à l'entrée.

### **IV.3.4 Phase de test :**

Après avoir appris les classes de détection et de diagnostic sur le réseau, le La prochaine étape consiste à tester l'efficacité tout en utilisant l'ensemble de tests.

De même, à l'étape de l'apprentissage, les quatre attributs ( $T$ ,  $G$ ,  $I_{mpp}$  et  $V_{mpp}$ ) sont injectés dans le classificateur PNN, tandis que sa sortie représente ses classes estimées correspondantes.

Le tableau ci-dessous montre les cas opérationnel étudié ainsi que leurs codes :

Code de chaque cas étudié	Type de chaque cas étudié
1	<i>Modèle sain</i>
2	Panne string
3	2 pv modules court-circuités
4	4 pv modules court-circuités
5	6 pv modules court-circuités

Tableau IV.2: Les cas étudié et leurs codes.

Afin d'évaluer l'efficacité du réseau chacune figures ci-dessous montre une classification de cas étudié :

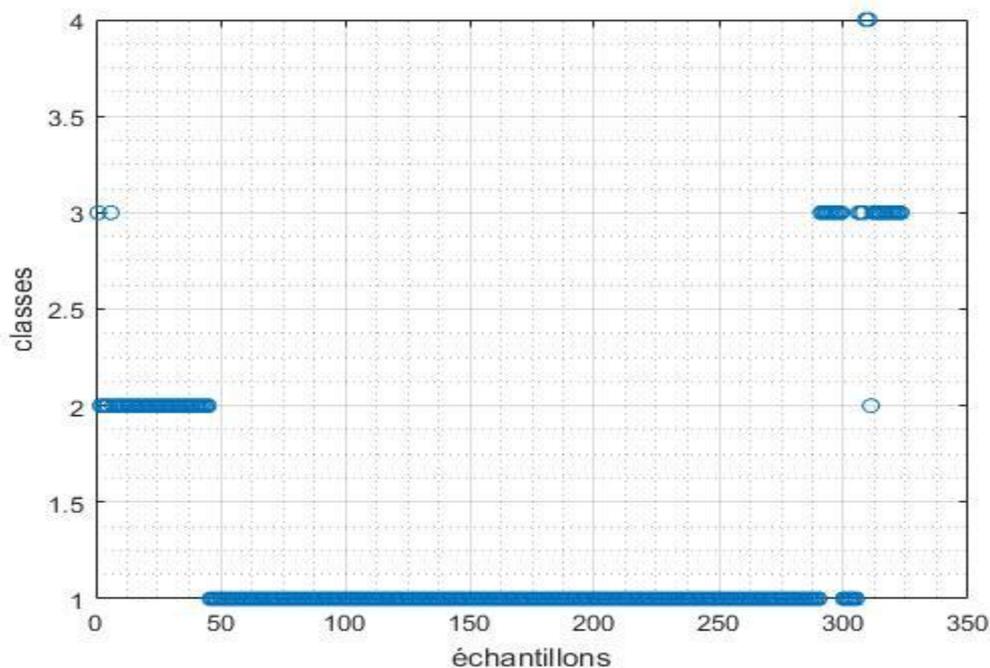


Figure IV.10 : Classification de cas sain

La figure (IV.10) montre la première tentative de tester le réseau avec des échantillons sain, ces résultats sont relativement corrects, compte tenu de la grande proportion d'échantillon bien classé

Les échantillons mal classés sont placés dans le plus proche voisin, classe (2) et classe (3)

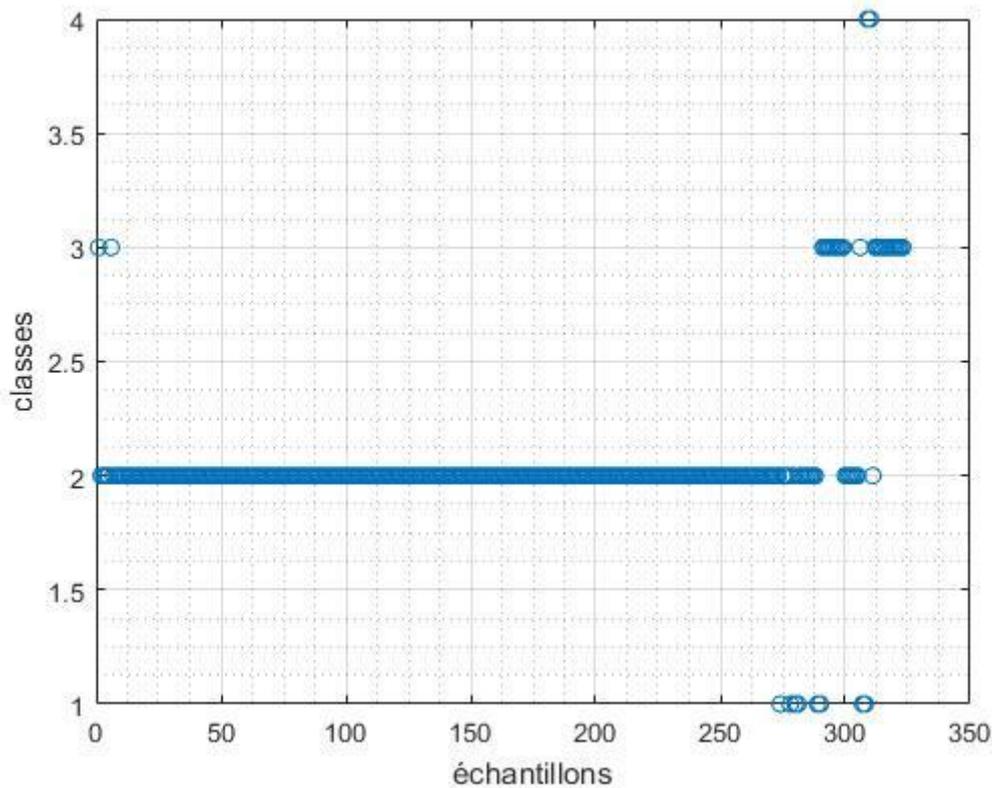


Figure IV.11 : résultat simulé de la teste en cas de panne string

La figure (IV.11) montre la deuxième tentative de tester le réseau avec des échantillons défectueux, dans ce cas c'était une chaîne complètement déconnectée (panne string), ces résultats ont une meilleure précision que le premier test, avec une précision de 89,78% et une erreur relative de 10,22%. Encore une fois les principaux échantillons mal classés sont placés dans le plus proche voisin.

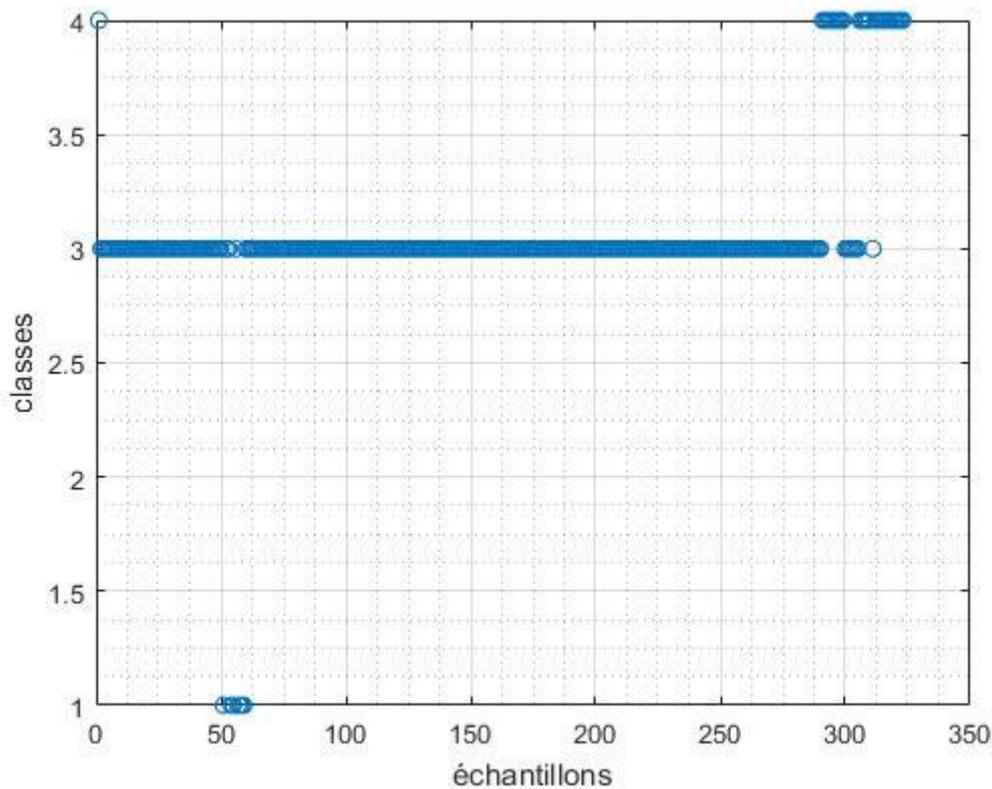


Figure IV.12 : deux modules PV court-circuités.

La figure (IV.12), montre la troisième tentative de tester le réseau, avec des échantillons défectueux, dans ce cas, ce sont les deux modules PV court-circuité, ces résultats ont une meilleure précision que le premier test, et même précision que la deuxième, la précision sera de 89,78 % et l'erreur relative était de 10,22%.

La différence entre le deuxième et le troisième était:

Dans le troisième test, les échantillons mal classés où juste dans deux autres classes et le pourcentage le plus élevé étaient dans le voisin proche (la classe (4) 8.35%).

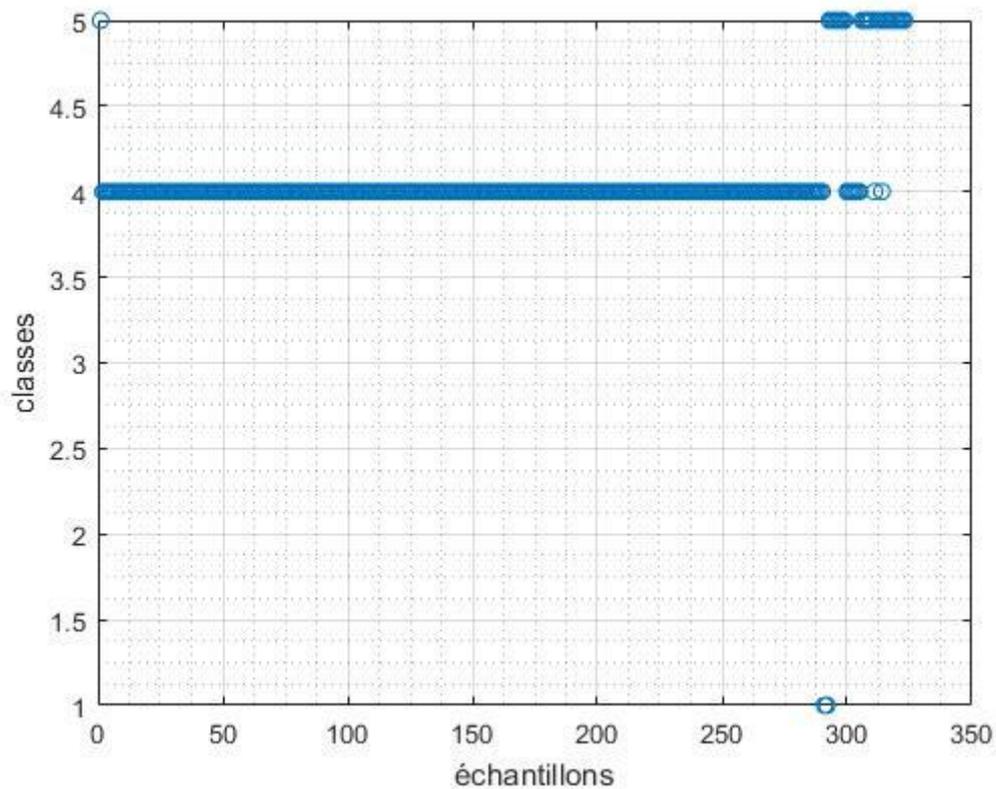


Figure IV.13 : quatre modules PV court-circuités.

La figure (IV.13), montre la quatrième tentative de tester le réseau, avec des échantillons défectueux, dans ce cas, ce sont les quatre modules PV court-circuité, le classificateur PNN a plus de précision, il a 297 bon classement, 24 échantillons dans la cinquième classe, et seulement deux dans la première classe.

Le pourcentage de réussite est de 91,96% .qui ne laisse que 8,04% d'échantillons mal classés

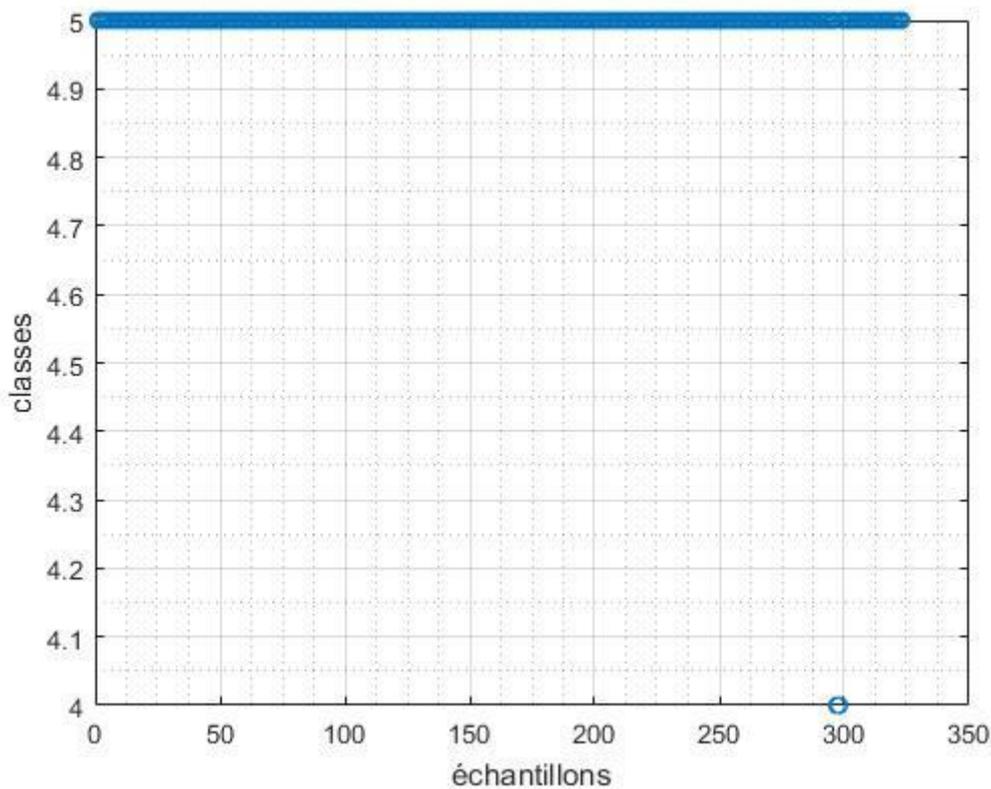


Figure IV.14 : six modules PV court-circuités.

La figure (IV.14), montre la dernière tentative de tester le réseau, avec des échantillons défectueux, dans ce cas, ce sont les six modules PV court-circuité, le classificateur PNN a plus de précision, il a 321 bon classement, et seulement deux dans la quatrième classe.

Le pourcentage de réussite est de 99,39%, ce qui laisse seulement 0,61% d'échantillons mal classés.

Dans le tableau ci-dessous, nous assemblons tous les résultats obtenus du classificateur PNN :

	Code N°(1)	Code N°(2)	Code N°(3)	Code N°(4)	Code N°(5)
Code N°(1)	(77.7%)	(13.63%)	(8.06%)	(0.61%)	(0%)
Code N°(2)	(2.47%)	(89.78%)	(7.14%)	(0.61%)	(0%)
Code N°(3)	1.87%	(0%)	(89.78%)	(8.35%)	(0%)

Code N°(4)	(0.61%)	(0%)	(0%)	(91.96%)	(7.43%)
Code N°(5)	(0%)	(0%)	(0%)	(0.61%)	(99.39%)

Tableau IV.3 : les résultats obtenus du classificateur PNN

La précision du système est donnée par l'équation ci-dessous :

$$p = \frac{\sum (77.7 + 89.78 + 89.78 + 91.96 + 99.39)}{5} = 89.72 \quad (\text{IV.1})$$

Le tableau précédent montre que l'exactitude de la classification après avoir injecté le réseau avec la base de données de test, eq (IV.1) nous donne le pourcentage global de succès après la classification. La précision globale donnée par le PNN est de 89,72%. Il est un pourcentage très élevé qui nous donne un bon classificateur.

#### IV.4 Conclusion:

Dans ce chapitre, nous exécutons le classificateur PNN avec une base de données réelles, d'éclairage, la température, la tension et le courant. Et cinq classes, Cinq modules de PV court-circuit, branche de complaisance, deux module de PV court-circuite, et six module de PV court-circuité. Les résultats était satisfaisant en raison de la haute précision a été donnée par le classificateur.

## **V. Conclusion général :**

Ce travail qui a été déjà proposé une approche améliorée basée sur l'apprentissage automatique pour la détection de pannes et le diagnostic des systèmes PV. Sur le plan opérationnel, l'avantage le plus important du réseau neuronal probabiliste est que l'entraînement est facile et instantané, il peut être utilisé en temps réel car dès qu'un modèle représentant chaque catégorie a été observé, le réseau peut commencer à généraliser. À mesure que d'autres modèles sont observés et stockés dans le réseau, la généralisation s'améliore et la limite de décision peut devenir plus complexe.

Le réseau neuronal probabiliste proposé ici peut, avec des variantes, être utilisé pour la cartographie, la classification, la mémoire associative, ou pour estimer directement les probabilités a posteriori.

## Références bibliographiques

- [1] : baroud kendo li, « état de l'art et modélisation des microcentrales », magister en électrotechnique de l'université mentouri de constantine 2007.
- [2] : Olivier Gergaud, « Modélisation énergétique et optimisation économique d'un système de production éolien et photovoltaïque couplé au réseau et associé à un accumulateur », Thèse de doctorat en Electrotechnique de l'Ecole Normale Supérieure de Cachan, 2002.
- [3]: Belhadj Mohammed, « Modélisation d'un Système de captage photovoltaïque autonome », Mémoire de Magister en Microélectronique – Photovoltaïque, centre universitaire de Bechar, 2008.
- [4]:SiteInternet, <http://www.scribd.com/doc/46661921/Les-energies-renouvelables>, consulté le 12/06/2013.
- [5]: B .Flèche, D. Delagnes, « énergie solaire photovoltaïque », STI ELT, juin 2007, énergie solaire photovoltaïque.pdf, consulté janv. 2014.
- [6] H. FATIHA et R. AICHA« Modélisation et simulation d'un système photovoltaïque» Mémoire master académique en Electrotechnique universite kasdi merbah ouargla 2014.
- [7]: J.M Chassériau, Conversion thermique du rayonnement solaire ; Dunod, 1984.
- [8] R. Bernard; G. Menguy; M. Schwartz, Le rayonnement solaire conversion thermique et applications ; Technique et documentation Lavoisier ,2 é édition 1980.
- [9] Anne Labouet et Michel villos , Energie solaire photovoltaïque ,Dunod , Paris (france) 2003.
- [10]. Y. Jannot, «thermique solaire». Livre solaire, Octobre 2003.
- [11] BRIHMAT Fouzia «L'Etude conceptuelle d'un système de conditionnement de puissance pour une centrale hybride PV/Eolien», Mémoire de Magister en Electrotechnique, Université Mouloud Mammeri de Tizi- 2012.
- [12]:J.Royer,T.dijako, E.schiller, B.sola «le pompage photovoltaïque.»Institut de l'énergie des pays francophone, 1998.

- [13] : A. Lobouret, M. Viloz, «Energie solaire photovoltaïque», Edition Dunod, 2006.
- [14] : M. Boudjemâa. « Application du formalisme Bond Graph à une chaîne de conversion d'énergie photovoltaïque».mémoire de magister, université de Constantine.2007.
- [15] M.L.Louazane ‘’Etude technico-économique d’un système de pompage photovoltaïque sur le site de Ouargla ‘’Mémoire de Magister Université El Hadj Lakhdar-Batna 16/06/2008.
- [16] lahlah salah « Etude comparative des techniques MPPT Perturbation and Observation (P&O), Incremental Conductance (Inc.CoN) et Hill climbing (H.C). » mémoire magister en électrotechnique université el hadj lakhdar Batna 2007
- [17] E. Alpaydin, Introduction to machine learning. MIT Press, 2004.
- [18] N. Zheng et J. Xue, Statistical Learning and Pattern Analysis for Image and Video Processing, 2009.
- [19] R. Khanchel et M. Limam, « Empirical Comparison of Boosting Algorithms », in Classification, the ubiquitous challenge: proceedings of the 28th Annual Conference of the Gesellschaft für Klassifikation eV, University of Dortmund, March 9-11, 2004, 2005, p. 161.
- [20] I. C. S. Institute, C. Chinrungrueng, et C. H. Séquin, Optimal adaptive k-means algorithm with dynamic adjustment of learning rate. International Computer Science Institute, 1991.
- [21] A. A. Ghorbani, Network Intrusion Detection and Prevention: Concepts and Techniques. Springer, 2009.
- [22] R. Sock et B. Vaxelaire, L’anticipation: à l’horizon du présent. Editions Mardaga, 2004.
- [23] I. C. S. Institute, C. Chinrungrueng, et C. H. Séquin, Optimal adaptive k-means algorithm with dynamic adjustment of learning rate. International Computer Science Institute, 1991.
- [24] I. C. S. Institute, C. Chinrungrueng, et C. H. Séquin, Optimal adaptive k-means algorithm with dynamic adjustment of learning rate. International Computer Science Institute, 1991.

- [25] D. J. C. MacKay, Information theory, inference, and learning algorithms. Cambridge University Press, 2003.
- [26] R. S. Sutton et A. G. Barto, Reinforcement learning: an introduction. MIT Press, 1998.
- [27] B. Ribeiro, R. F. Albrecht, et A. Dobnikar, Adaptive and natural computing algorithms: proceedings of the international conference in Coimbra, Portugal, 2005.
- [28] « Réseau de neurones artificiels - Wikipédia ». [Online]. Available: [http://fr.wikipedia.org/wiki/R%C3%A9seau\\_de\\_neurones\\_artificiels](http://fr.wikipedia.org/wiki/R%C3%A9seau_de_neurones_artificiels). [Accessed: 20- juill-2010].
- [29] X. Zhu et A. B. Goldberg, Introduction to Semi-Supervised Learning. Morgan & Claypool Publishers, 2009.
- [30] S. S. Haykin, Neural networks and learning machines. Prentice Hall, 2009.
- [31] B. Kosko et J. C. Burgess, « Neural networks and fuzzy systems », The Journal of the Acoustical Society of America, vol. 103, p. 3131, 1998.
- [32]. Parzen E (1962) On estimation of a probability density function and mode. Ann Math Stat 36:1065–1076.
- [33] ORIGINAL CONTRIBUTION Probabilistic Neural Networks DONALD F. SPECHT Lockheed Missiles & Space Company, Inc. (Received 5 August 1988; revised and accepted 14 June 1989)
- [34] Duda, Pattern Classification. Wiley India Pvt. Ltd., 2009.
- [35] C. Bishop, Pattern recognition and machine learning. New York: Springer, 2006.
- [36] D. F. Specht, « Probabilistic neural networks », Neural networks, vol. 3, no 1, p. 109– 118, 1990.
- [37] G. A. Babich, L. H. Sibul, et P. S. U. U. P. A. R. LAB, « Weighted Parzen windows for pattern classification », 1994.
- [38] M. M. Poulton, Computational neural networks for geophysical data processing. Elsevier, 2001.

- [39] A. Lotfi, « Probabilistic Neural Networks for Radar Target Detection in nonGaussian Noise », Thèse de Magister, Université des Sciences et de la Technologie d'Oran USTO-MB, Oran, 2005.
- [40] R. O. Duda, Pattern Classification 2nd Edition with Computer Manual 2nd Edition Set. John Wiley & Sons Inc, 2004.
- [36] J. Secretan, M. Georgiopoulos, et J. Castro, « A privacy preserving probabilistic neural network for horizontally partitioned databases », in International Joint Conference on Neural Networks, 2007. IJCNN 2007, 2007, p. 1554–1559.
- [37] A. LOTFI, K. MEZZOUG, et A. BENYETTOU, « Rotated Kernel Neural Networks for Radar Target Detection in Background Noise », Journal of Applied Sciences, vol. 10, p. 1331-1335, 2010.

## Résumé

L'objectif de ce travail est de détecter et diagnostiquer les défaillances d'un système PV on utilisant technique de l'intelligence artificielle, " le réseau de neurones probabiliste " Dans cette étude, nous avons pris comme exemple le générateur PV suivant: Isofoton 106-12 avec une puissance maximale de 106 watts, une courant optimal de 6,54 ampères et une tension optimal de 17,4 volts dans des conditions normales d'essai (STC) de 25°C et un niveau d'éclairement de 1000 W/m<sup>2</sup>). Nous avons étudié cinq cas différents, l'un est le système saint, et quatre autres cas défectueux.

**Mots-clés:** Système PV – réseau de neurones probabiliste- défaillances- diagnostiqué.

## الملخص

الهدف من هذا العمل هو اكتشاف وتشخيص اعطال النظام الكهروضوئي باستعمال تقنية الذكاء الاصطناعي الشبكة العصبية الاحتمالية في هذه الدراسة ، أخذنا كمثال المولد الكهروضوئي التالي:  
17.4 أمبير, بجهد [6.54](#): مع أقصى استطاعة تقدر: 106 واط ، وتيار يقدر ب Isofoton 106-12 W / m<sup>2</sup>). درجة مئوية ومستوى الإضاءة (STC) 25 1000 فولت (تحت شروط الاختبار القياسية درسنا خمس حالات مختلفة ، الأولى هي النظام السليم ، وأربعة حالات معيبة أخرى .  
الكلمات المفتاحية : النظام الكهروضوئي – الشبكة العصبية الاحتمالية – اعطال – تشخيص.

## Abstract

The goal of this work is to detect and diagnose failure of a PV system by using artificial intelligence technique "probabilistic neural network" In this study, we took the following PV generator as an example, Isofoton 106-12 with a maximum power of 106 watts ,optimal courant of [6.54](#) ampere and an optimal voltage of 17.4 volts under Standard Test Conditions (STC) of 25°C and Illumination Level of 1000 W/m<sup>2</sup>). We study five different cases; one is saint system, and other four defective cases.

**Keywords:** PV system - probabilistic neural network - failures – diagnose.