

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي و البحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البلدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Master

Filière Électrotechnique

Spécialité Machine Électrique

présenté par

SAKHRI Riadh

&

METTOUCHI Ahmed Sedik

Diagnostic d'un champ solaire photovoltaïque par réseaux de neurones artificiels

Proposé par : CHEGGAGA Nawal

Année Universitaire 2017-2018

Remerciements

Tout d'abord, nous remercions Dieu Tout-Puissant qui nous a aidés à terminer ce mémoire.

En premier, nous adressons nos plus vifs remerciements à notre encadreur Mme CHEGGAGA Nawal enseignante à l'USDB pour son soutien, son encouragement et son aide qu'elle nous a prodiguée durant toute cette année.

Nous adressons tous nos remerciements aux membres du jury, pour avoir acceptés de faire partie du jury de ce mémoire.

À nos parents qui nous ont aidés avec tout ce qu'ils pouvaient pour nous amener à ce niveau et sans eux nous n'aurions pas réussi à atteindre ce succès, Nous leur exprimons notre gratitude et nous les remercions pour tout ce qu'ils nous ont donné.

A tous nos enseignants qui nous ont permis d'arriver au terme de notre formation, nous exprimons notre gratitude pour leurs sérieux et leurs abnégations indéfectibles.

ملخص: في هذه المذكرة نقتراح الكشف و التشخيص عن نظام الطاقة الشمسية الكهروضوئية عن طريق حساب ومقارنة الأخطاء بين النواتج المحاكية بواسطة شبكات من الخلايا العصبية الاصطناعية والبيانات التي يتم قياسها في الوقت الحقيقي.

يستند هذا التصنيف إلى معلمتين رئيسيتين تمثلان تيار نقطة القوة القصوى والجهد الكهربائي لنقطة القدرة القصوى. يتم الحصول على البيانات الفعلية من محطة الطاقة الضوئية في الجزائر. ويستند التصنيف على بيانات فترة من ثلاث ساعات و أربعين دقيقة من شهر تم التقاطها بشكل جيد. عدد التخصيصات التي اقترحناها هو خمسة ، والتي تنطبق على فشل السلسلة وأربعة أنواع من وحدات الدوائر القصيرة.

كلمات المفاتيح: نظام الطاقة الشمسية الكهروضوئية ، النمذجة ، الكشف ، التشخيص ، المقارنة ، التصنيف .

Résumé : Dans ce papier nous proposons la détection et le diagnostique du système solaire photovoltaïque par le calcul et la comparaison de erreurs entre des sorties simulés par réseaux de neurones artificiels (ANN) et les données mesurés en temps réel. Cette classification est basée sur deux paramètres majeurs représentant le courant du point de puissance maximal et la tension du point de puissance maximal. Les données sont réelles obtenues d'un station photovoltaïque en Algerie. La classification est basée sur des données de période de trois heures quarante minutes du mois bien capté. Le nombre d'attribues que nous avons proposé est cinq s'appliquant sur la panne string et quatre types de modules court circuiter.

Mots clés : système photovoltaïque, Modélisation, détection, diagnostique, comparaison, classification, ANN.

Abstract: In this paper we propose the detection and the diagnosis of the solar photovoltaic system by the computation and the comparison of errors between simulated outputs by networks of artificial neurons (ANN) and the data measured in real time. This classification is based on two major parameters representing the current of the point of maximum power and the voltage of the point of maximum power. The actual data is obtained from a photovoltaic station in Algeria. The classification is based on data of period of three hours forty minutes of the month well captured. The number of assignments we proposed is five, which applies to the string failure and four types of short circuit modules.

Key words: photovoltaic system, Modeling, detection, diagnosis, comparison, classification, ANN.

Listes des acronymes et abréviations

PV : Photovoltaïque ;

STC: Standard Test Conditions; W_c : Watt Crete;

AM: Masse d'air;

E_g : Energie de gap;

I_{ph} : Photo-courant;

I_d : Courant de diode;

Φ_{ref} : Flux lumineux de référence 1000 [W/m²] ;

T_c : Température de la cellule [K];

K_{tcc} : Coeficeint de température de court-circuit de la cellule [A/K].

N_{oct} : Condition de température nominale de fonctionnement de la cellule ;

T_a : Température ambiante;

I_s : Courant de saturation de la diode[A];

A: Facteur de qualité de la diode;

q: Charge de l'électron = $1,602 \cdot 10^{-19}$ [Coulomb];

k: Constante de Boltzmann = $1,38 \cdot 10^{-23}$ [J/K] ;

R_s : Resistance serie [ohm];

R_{sh} : Resistance shunt [ohm];

I_{cc} : Courant de court-circuit [A];

V_{oc} : Tension du circuit-ouvert [V];

FF : Facteur de forme ;

f_1 : Fonction du nombre d'air-masse;

f_2 : Fonction de l'angle d'incidence du rayonnement sur le capteur PV;

I_{SCr} : Courant de court-circuit de référence ;

V_{ocr} : Tension de circuit ouvert de référence ;

V_{MPr} : Tension de point de puissance maximale de référence ;
 I_{MPr} : Courant de point de puissance maximale de référence ;
 I_{sc} : Coefficient de dépendance en température du courant de court circuit;
 V_{oc} : Coefficient de dépendance en température de la tension de circuit ouvert ;
 V_{mp} : Coefficient de dépendance en température de la tension de puissance maximale ;
 I_{mp} : Coefficient de dépendance en température du courant de puissance maximale;
 $C_0; C_1; C_2; C_3$: Coefficients déterminés expérimentalement;
 $P_1; P_2; P_3; P_4$: Paramètres à déterminer expérimentalement;
 V_b : Tension de claquage de diode (-10 V à -40 V);
 n_c : Nombre des cellules non défectueuses;
 V_{cb} : Tension des cellules non défectueuses;
 I_{cb} : Courant des cellules non défectueuses;
 n_g : Nombre des groupes non défectueux;
 n_m : Nombre des modules non défectueux;
 $N_{stb}; n_s$: Nombre des strings non défectueux;
 N_{std} : Nombre des strings défectueux;
 I_{bypass} : Courant qui traverse la diode by-pass;
 $I_{groupeND}$: Courant du groupe non défectueux ;
 $I_{groupeND}$: Courant du groupe non défectueux ;
 N_{string} : String PV avec au moins un groupe sain;
 N_{md} : Nombre des modules défectueux ;
 N_{gd} : Nombre des groupes défectueux ;
 N_{stb}^0 : String contiennent au moins un groupe non défectueux;
 N_{std}^0 : String où tous ses groupes sont défectueux;
 P_{dccc} : Perte de puissance due au défaut de court-circuit des cellules;
 P_{GPDccc} : Puissance résultante du générateur PV lors d'un défaut de court-circuit des cellules ;

$P_{\text{GPV}_{\text{sain}}}$: Puissance résultante du générateur PV pour un fonctionnement sain ;

$n_{\text{cellule}_{\text{ecc}}}$: Nombre d des cellules en court-circuit dans le générateur PV ;

P_{cellule} : Puissance d'une seule cellule;

N_{cellules} : Nombre d des cellules dans le module;

$N_{\text{string}_{\text{serie}}}$: Nombre d des modules en série dans un string;

$N_{\text{string}_{\text{parallele}}}$: Nombre d des strings en parallèle;

$P_{\text{module}_{\text{sain}}}$: Puissance nominale du module;

$V_{\text{cod}_{\text{ccc}}}$: Perte de la tension de circuit-ouvert due par le défaut de court-circuit des cellules.

$V_{\text{coGPV}_{\text{dccc}}}$: Tension de circuit-ouvert du générateur PV lors d'un défaut de court-circuit des

$V_{\text{coGPV}_{\text{sain}}}$: Tension de circuit-ouvert du générateur PV en fonctionnement sain.

$V_{\text{comodule}_{\text{sain}}}$: Tension du circuit ouvert du module dans les condition STC.

$V_{\text{co}_{\text{cellules}}}$: Tension de circuit-ouvert d'une seule cellule.

η_{GPVs} : Rendement du générateur PV en fonctionnement sain.

P_{dccb} : Perte de puissance due au défaut de court-circuit des diodes by-pass.

$P_{\text{GPV}_{\text{dccb}}}$: Puissance résultante du générateur PV lors d'un défaut de court-circuit des diodes by-passes cellules.

n_{dbcc} : Nombre d des diodes by-passes en court-circuit dans le generateur PV.

P_{groupe} : Puissance d'une seule groupe.

$I_{\text{ccGPV}_{\text{sain}}}$: Courant de court-circuit du generateur photovoltaïque en fonctionnement sain.

$I_{\text{ccGPV}_{\text{dcoa}}}$: Courant de court-circuit du generateur photovoltaïque en presence de circuit-ouvert de la diodes anti-retour.

$I_{\text{cc}_{\text{dcoa}}}$: Perte en courant de court-circuit due au defaut de circuit-ouvert des diodes anti-retour.

$I_{\text{cc}_{\text{string}_{\text{sain}}}}$: Courant de court-circuit du string photovoltaïque en fonctionnement sain.

n : nombre d'échantillons

Datam : données mesurées

Datos : données simulées

table des matières :

Introduction générale	1
1. Chapitre 01 : L'état de l'art de la production photovoltaïque	3
1.1 Introduction	3
1.2 Ressource solaire	3
1.2.1 Normalisation.....	4
1.3 Cellules photovoltaïques	4
1.3.1 L'effet photovoltaïque	5
1.3.3 Principe de fonctionnement d'une cellule photovoltaïque	6
1.3.4 Technologie d'une cellule photovoltaïque	7
1.4 Caractéristiques de la cellule photovoltaïque	11
1.4.1 Puissance crête d'une cellule PV	12
1.4.2 Courant de court-circuit, I_{cc}	12
1.4.3 Tension de circuit-ouvert, V_{oc} :	12
1.4.4 Facteur de forme, FF	12
1.4.5 Rendement de conversion, η	13
1.5 Module photovoltaïque	13
1.5.1 Association en série	13
1.5.2 Association en parallèle	14
1.5.3 Association hybride en (série/parallèle)	15
1.6 Systèmes PV	16
1.6.1 Composants d'un système PV	17
1.6.2 Système de protection	17
1.7 Défauts dans les systèmes photovoltaïques	Error! Bookmark not defined.
2. Chapitre 2 : les réseaux de neurones artificiels	19
2.1 Introduction	19
2.2 Le neurone biologique et le neurone artificiel	19
2.3 Réseaux de neurones artificiels	20
2.3.1 L'élément de traitement	21
2.3.2 L'architecture d'un réseau	22
2.3.3 Apprentissage et adaptation	24
2.4 Certaines considérations pratiques pour le choix du réseau de neurone adéquat	26
a. Choix et dimensionnement d'un réseau	26
b. Paramètre d'apprentissage ou pas de correction η	26
c. Poids initiaux	27
d. Minimums locaux	27
e. Saturation du réseau	27
3. Chapitre 03 : Modélisation et classification des systèmes PV	28
3.1. Introduction	28
3.2. Pannes du système solaire photovoltaïque	29
3.3. Technique proposée pour le diagnostique des pannes	29
3.4. Partie simulée	31
3.5. La modélisation des systèmes par réseaux de neurones	32
3.5.1 La modélisation d'un modèle tension sain (healthy system)	33
3.5.2 La modélisation des modèles défectueux (tensions)	34
3.5.3. La modélisation d'un modèle courant sain (healthy system)	35
3.5.4 La modélisation de modèle défectueux (panne string)	35
3.6 La validation des modèles développés	36
3.6.1 La validation de modèle sain en tension	36

3.6.2 La validation des modèles défectueux en tension :	38
3.7 Exploitation des résultats	47
3.7.1 définition d'erreur relative moyenne	47
3.7.2 Classification du système par calcul et comparaison d'erreur relative moyenne Erm	47
Conclusion générale	54

Bibliographie

Liste des figures

1.1	Analyse spectrale du rayonnement solaire	4
1.2	Schéma d'une jonction PN	5
1.3	Description d'une photopile ou cellule photovoltaïque	6
1.4	Cellule en silicium mono-cristallin	7
1.5	Cellule en silicium Poly-cristallin	8
1.6	Cellule en silicium amorphe	9
1.7	Schéma équivalent d'une cellule photovoltaïque	11
1.8	Influence des résistances shunts et série s sur la caractéristique courant-tension d'une cellule photovoltaïque	11
1.9	Cellules identiques en série	14
1.10	Cellules identiques en parallèle	15
1.11	Caractéristique I-V résultante d'un groupement hybride de (np+ ns) cellules identiques.....	16
1.12	Composantes d'un champ de modules photovoltaïques	16
1.13	Composantes d'un système PV alimentant une charge	18
2.1.	Structure artificielle du réseau neurone	20
2.2.	Architecture d'un réseau multicouche à interconnexion totale	22
2.3.	Architecture d'un réseau récurrent mono-couche à interconnexion totale	23
2.4.	Architecture d'un réseau topologique.....	23
2.5.	Principe de l'entraînement du réseau de neurone par rétro propagation de l'erreur	25
3.1 :	Schéma synoptique de système de diagnostique intelligent Première étape, dite modélisation consiste à injecté dans les réseaux de neurones	30
3.2.	variation de température captée au cours d'un mois.....	31
3.3.	variation d'irradiation captée au cours d'un mois.....	32
3.4.	paramètres de panneaux solaires utilisé.....	32
3.5.	la structure du modèle par réseau de neurones artificiels	33
3.6.1.	Modélisation d'un modèle sain par réseau de neurone	36
3.6.2.	Écart entre vmpp mesuré sain et vmpp simulé sain en fonction du temp	37

3.6.3. Modélisation d'un modèle défectueux à un modèle court circuité par réseau de neurone	38
3.6.4. vmpp mesuré a un seul module cc et vmpp simulé simulé a un seul module cc en fonction de temps	39
3.6.5. Modélisation d'un modèle défectueux à deux modèles court circuité par réseau de neurone	40
3.6.6. Vmpp mesuré a deux modules cc et vmpp simulé a deux modules cc en fonction de temps	40
3.6.7. Modélisation d'un modèle défectueux à quatre modèles court circuité par réseau de neurone	41
3.6.8. Vmpp mesuré a quatre modules cc et vmpp simulé a quatre modules cc en fonction de temps	42
3.6.9. Modélisation d'un modèle défectueux à six modèles court circuité par réseau de neurone	43
3.6.10 écart entre Vmpp mesuré a six modules cc et vmpp simulé a six modules cc en fonction de temps.....	43
3.6.11. Modélisation d'un modèle sain courant par réseau de neurone	44
3.6.12 écart entre impp mesuré sain et impp simulé sain en fonction du temps	45
3.6.13. Modélisation d'un modèle de la panne string par réseau de neurone	46
3.6.14. l'ecart entre impp mesuré string et impp simulé string en fonction du temps ...	47
3.6.15. Déférentes cas possible de fonctionnement	48
3.6.16. Classe 1 de la classification de tension maximale du point de puissance.	49
3.6.17. Classe 5 de la classification de tension maximale du point de puissance.	50
3.6.18. Déférentes cas possible de fonctionnement	51
3.6.19. Classe 6 de la classification de courant maximale du point de puissance.....	52
3.6.18. Class non définie	53

Liste des tableaux :

3.1. Type de pannes et leurs symboles	29
3.2. Paramètres de type avec des symboles et des classes.....	30
3.3. Diagnostic du système.....	31
3.3. Diagnostic du système.....	47

1.1 Introduction générale

Au cours des dix dernières années, le marché du photovoltaïque a connu une croissance très remarquable, grâce aux différents facteurs stimulants : réduction des coûts de production et politiques de soutien. Ces facteurs stimulants rendent le retour sur l'investissement d'une installation photovoltaïque de plus en plus intéressant. Or, comme tous les autres processus industriels, un système photovoltaïque peut être soumis, au cours de son fonctionnement, à différents défauts et anomalies conduisant à une baisse de la performance du système et voire à l'indisponibilité totale du système. Toutes ces conséquences défavorables vont évidemment réduire la productivité de l'installation, et donc réduire le profit de l'installation, sans compter le coût de maintenance pour remettre le système en état normal.

A l'heure actuelle, il existe des systèmes de monitoring qui permettent de calculer la puissance fournie par les panneaux et l'énergie associée par l'intermédiaire de capteurs de tension et de courant. Il existe même des services qui permettent de faire la corrélation entre la production d'une installation et les conditions météorologiques. Un satellite mesure l'ensoleillement émis sur le site et compare avec la productivité du champ. Les informations sont mensuelles et lorsqu'un écart important apparaît, l'utilisateur est informé. Ce genre de service est une première étape intéressante vers une supervision précise de l'installation mais montre des limites car il ne permet pas de détecter et localiser dans un temps bref suite à l'apparition d'un défaut quelconque [1].

L'étude bibliographique a montré que de nombreuses études ont portées sur l'évaluation de l'impact des différents défauts par l'analyse de la caractéristique I-V (caractéristique statique) résultante. Par contre, l'utilisation d'une telle caractéristique pour remonter à la nature des défauts n'est pas largement répandue. Deux raisons principales peuvent être citées comme barrière à l'application d'une telle méthode pour faire le diagnostic : la difficulté d'obtention de la caractéristique complète I-V et le manque d'une base des données pertinente sur les causalités entre défauts et modifications de la caractéristique I-V [1].

Ce mémoire comprend :

Le chapitre 1 a pour but de traiter l'état d'art de la production photovoltaïque, nous présenterons un rappel et une description générale sur l'unité de production photovoltaïques ainsi que les circuits équivalents électriques du générateur photovoltaïque.

Le 2eme chapitre consacré nous sommes intéressés à l'outil de modélisation à savoir les réseaux de neurones non récurrent

3eme chapitre en ferme les résultats de la modélisation de modèle sain ainsi que le modèle de 5 panne sont la panne string et quatre types de modules court circuiter.

En fin nous présentons des cas d'identification de panne grâce à notre approche

Chapitre 01

Chapitre 01 : L'état de l'art de la production photovoltaïque

1.1 INTRODUCTION :

L'énergie photovoltaïque est l'un des enjeux de la politique énergétique de notre siècle, qui résulte de la transformation directe de la lumière du soleil en énergie électrique, au moyen d'une photopile.

Cette photopile, qu'on appelle aussi, cellule solaire ou cellule photovoltaïque, est fabriquée à l'aide de matériaux semi-conducteurs, comme les transistors ou les puces dans un ordinateur.

Les cellules photovoltaïques sont fabriquées généralement à base de "silicium cristallin", qui reste la filière la plus avancée sur le plan technologique et industriel, pour la raison que le silicium est l'un des éléments les plus abondants sur la terre, sous forme de silice non toxique.

Nous allons consacrer ce chapitre à la description d'une unité de la production photovoltaïque.

1.2 RESSOURCE SOLAIRE :

Le soleil émet un rayonnement électromagnétique, compris dans une bande de longueur d'onde variant de 0,22 à 10 (μm). La figure 1.1 représente la variation de la répartition spectrale énergétique. L'énergie associée à ce rayonnement solaire se décompose approximativement au :

- 9% dans la bande des ultraviolets ($<0,4 \mu\text{m}$),
- 47% dans la bande visible ($0,4 \text{ à } 0,8 \mu\text{m}$),
- 44% dans la bande des infrarouges ($>0,8 \mu\text{m}$).

L'atmosphère terrestre reçoit ce rayonnement à une puissance moyenne de 1,37 kilowatt par mètre carré (kW/m^2), à plus ou moins 3 %, selon que la terre s'éloigne ou se rapproche du soleil dans sa rotation autour de celui-ci. L'atmosphère absorbe toutefois une partie, de sorte que la quantité d'énergie atteint la surface terrestre dépasse rarement $1,2 \text{ kW}/\text{m}^2$ ($1200 \text{ W}/\text{m}^2$). La rotation et l'inclinaison de la terre font également que l'énergie disponible en un point donné, varie selon latitude, longitude et la saison. Enfin, les nuages, le brouillard, les particules Atmosphériques et divers autres phénomènes météorologiques, causent des variations horaires et quotidiennes qui tantôt augmentent, tantôt diminuent le rayonnement solaire et le rendent diffus.

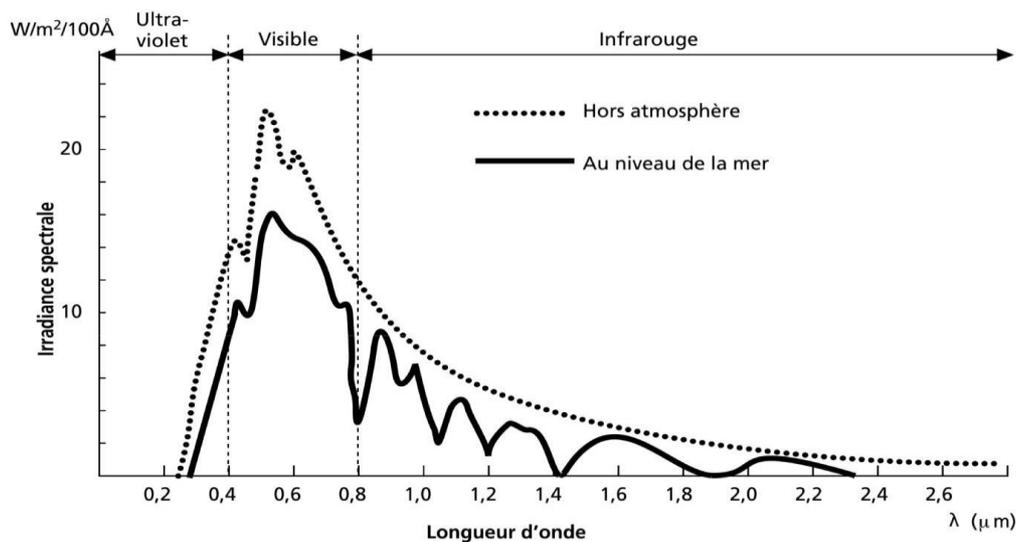


Figure 1.1. Analyse spectrale du rayonnement solaire [2]

L'utilisation du rayonnement solaire comme source d'énergie, pose donc un problème bien particulier. En effet, le rayonnement solaire n'est pas toujours disponible, en outre, on ne peut l'emmagasiner, ni le transporter. Le concepteur d'un système qui emploie le rayonnement solaire comme source d'énergie, doit donc déterminer la quantité l'énergie solaire disponible à l'endroit visé, et le moment où cette énergie est disponible [2].

1.2.1 NORMALISATION :

Les conditions standards de qualification des modules photovoltaïques sont :

- Un spectre AM 1.5 ;
- Un éclairement de $1000\text{W}/\text{m}^2$;
- Une température de 25°C .

Les constructeurs des panneaux solaires spécifient les performances de leurs matériels dans les conditions normalisées citées ci-dessus (S.T.C : Standard Test Conditions) [5].

1.3 CELLULES PHOTOVOLTAÏQUES :

Les cellules photovoltaïques (photon : grain de lumière et volt : unité de tension) convertissent directement l'énergie lumineuse en électricité (courant continu basse tension). Comme l'énergie lumineuse vient du soleil, on parle alors des cellules solaires [4].

1.3.1 L'EFFET PHOTOVOLTAÏQUE

L'effet photovoltaïque est un phénomène physique, qui convertit la lumière (photons) en électricité grâce à l'utilisation d'un matériau semi-conducteur. Ce dernier possède des propriétés électroniques particulières. Pour constituer une cellule photovoltaïque il faut, à partir de ce matériau, constituer d'une jonction avec une couche supérieure présentant un excès d'électrons (zone dopée n) et une couche inférieure comportant un déficit d'électrons (zone dopée p) ou inversement, figure 1.2. L'exposition du semi-conducteur au rayonnement solaire, va créer un excès de charges électriques dans les deux couches, et la mise en contact de deux matériaux de propriété électronique déférente, va provoquer un champ électrique [3].

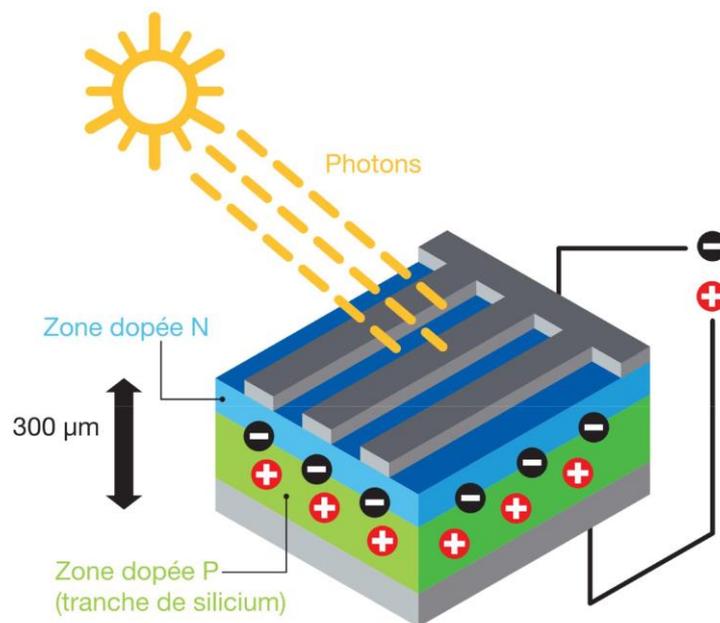


Figure 1.2. Schéma d'une jonction PN

1.3.3 PRINCIPE DE FONCTIONNEMENT D'UNE CELLULE PHOTOVOLTAÏQUE :

On peut représenter une cellule photovoltaïque, comme une diode plate sensible à la lumière, quand un photon de lumière d'énergie suffisante, heurte un atome sur la partie négative de cette diode, elle excite un électron et l'arrache de sa structure moléculaire, créant ainsi un électron libre sur cette partie.

Une photopile est fabriquée de manière à ce que cet électron libre, ne puisse se recombiner facilement avec un atome à charge positive, avant qu'il n'ait accompli un travail utile en passant dans un circuit extérieur. Comme une pile chimique, la cellule photovoltaïque produira de l'électricité à courant continu, mais son énergie produite sera principalement en fonction de la lumière reçue par la photopile [2], comme montre la figure suivante :

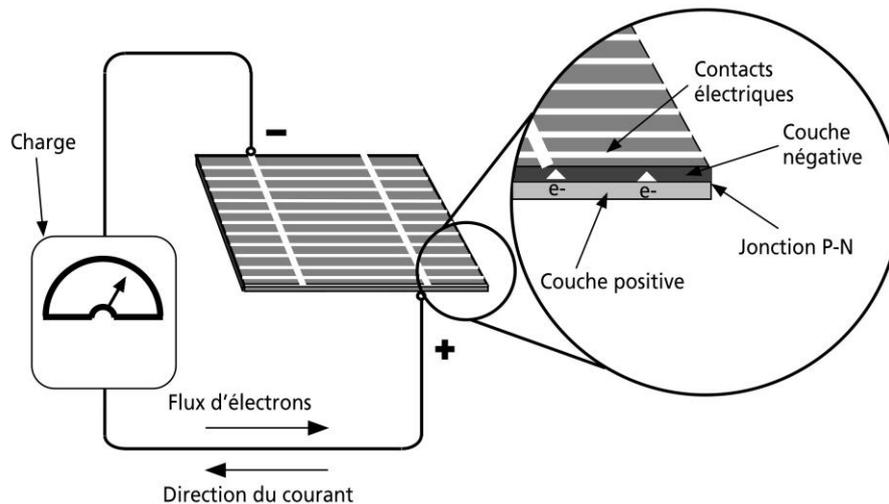


Figure 1.3. Description d'une photopile ou cellule photovoltaïque

1.3.4 TECHNOLOGIE D'UNE CELLULE PHOTOVOLTAÏQUE

a) Silicium mono-cristallin

Les cellules en silicium mono-cristallin représentent la première génération des générateurs photovoltaïques, figure 1.4.

Pour les fabriquer, on fait fondre la silice du silicium. Lors d'un refroidissement lent et maîtrisé, le silicium

(métallurgique MG-Si) se solidifie en ne formant qu'un seul cristal (silicium Solaire So-Si) de grande dimension (sous forme de barreau). On découpe ensuite le cristal en fines tranches qui donneront les cellules. Ces dernières sont en général d'un bleu uniforme, leur durée de vie est de 20 à 30 ans [6].

Son avantage :

- Bon rendement, de 12% à 18% ;
- Bon ratio Wc/m^2 (environ $150 Wc/m^2$) ce qui permet un gain de place si nécessaire ;
- Nombre de fabricants élevé.

Son inconvénient :

- Coût élevé ;
- Rendement faible sous un faible éclairement [6].



Figure 1.4. Cellule en silicium mono-cristallin [6]

b) Silicium poly cristallin (multi cristallin)

Ce dernier est issu de l'étape de refroidissement du silicium dans une lingotière, d'où la formation de plusieurs cristaux. Cette cellule photovoltaïque est d'aspect bleuté, mais pas uniforme, on distingue des motifs créés par les différents cristaux, figure 1.5. Son avantage :

- Cellule carrée permettant un meilleur foisonnement dans un module ;
- Moins cher qu'une cellule mono-cristalline.

Son inconvénient :

- Un rendement moins bon qu'une cellule mono-cristalline : 11% à 15% ;
- Ratio Wc/m^2 moins bon que pour le mono-cristallin (environ $100 Wc/m^2$) ;
- Rendement faible sous un faible éclairement.



Figure 1.5. Cellule en silicium Ploy-cristallin [6]

Ce sont les cellules les plus utilisées pour la production électrique (meilleur rapport qualité-prix). Durée de vie de 20 à 30 ans [6].

c) Silicium amorphe

Le silicium lors de sa transformation, produit un gaz, qui est projeté sur une feuille de verre, Pour former une cellule grise très foncée, figure 1.6. Comme les cellules qui se trouvent dans les Calculatrices et les montres dites "solaires".

Son avantage :

- Fonctionne avec un éclairage faible ou diffus (même par temps couvert) ;
- Un peu moins chère que les autres technologies ;
- Intégration sur supports souples ou rigides.

Son inconvénient :

- Rendement faible en plein soleil, de 6% à 8% ;
- Nécessité de couvrir des surfaces plus importantes que lors de l'utilisation de silicium cristallin (ratio Wc/m^2 plus faible, environ $60 Wc/m^2$) ;
- Performances qui diminuent avec le temps (environ 7%) [6].

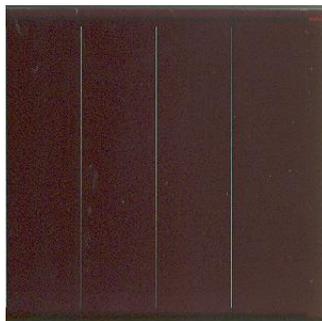


Figure 1.6. Cellule en silicium amorphe [6]

d) Couches minces

Les cellules en couches minces sont fabriquées en déposant une ou plusieurs couches semi-conductrices ou photosensibles sur un support de verre, de plastique, d'acier...etc., Cette technologie permet de diminuer le coût de fabrication, mais son rendement est inférieur à celui des cellules en silicium cristallin (il est de l'ordre de 5 à 13 %). Plusieurs technologies existent [7] :

- Le Tellure de Cadmium (CdTe) ;
- Le Cuivre/Indium/Sélénium ou Cuivre/Indium/Gallium/Sélénium (CIS ou CIGS) Les cellules à double (tandem) ou à triple jonction (3a-si) ;
- Les cellules à base d'oxyde de Titane ;
- Les cellules en couches minces les plus répandues sont en silicium amorphe.

e)Nouvelles technologies

On utilise de plus en plus de matériaux organiques dans le domaine de l'optoélectronique, avec des perspectives d'électronique organique. Ainsi, bien que cette filière soit vraiment récente, les progrès annuels sont spectaculaires.

Les matériaux organiques, moléculaires ou polymériques, à base de carbone, d'hydrogène et d'azote, sont particulièrement intéressants en termes d'abondance, de coût, de poids et de mise en œuvre [8].

1.4 CARACTERISTIQUES DE LA CELLULE PHOTOVOLTAÏQUE

Le schéma équivalent d'une cellule photovoltaïque peut être schématisé ci-dessous :

Pour une cellule idéale l'équation de courant, est :

$$I_{out}(V_{out}) = I_{ph}(\varphi) - I_d(V) \quad (1.1)$$

Ou :

I_{out} : Courant fournie par la cellule [A] ;

V_{out} : Tension aux bornes de la jonction [V] ;

$I_{ph}(\varphi)$: Courant produit par la photopile, ce courant est proportionnel au flux lumineux (φ) [A].

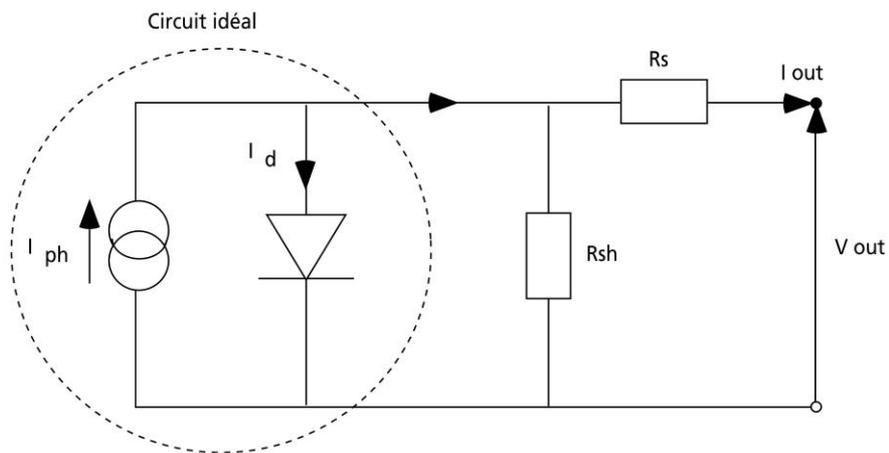


Figure 1.7. Schéma équivalent d'une cellule photovoltaïque

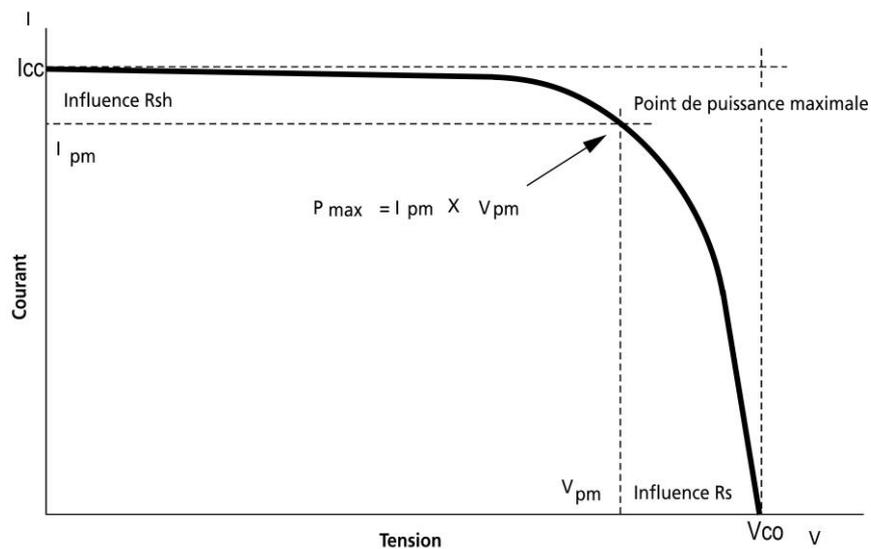


Figure 1.8. Influence des résistances shunts et série s sur la caractéristique courant-tension d'une cellule photovoltaïque

La figure 1.8 représente la caractéristique I(V) d'une photopile idéale. Cette dernière comporte en réalité une résistance série (R_s) et une résistance de dérivation ou shunt (R_{sh}). Ces résistances auront une certaine influence sur la caractéristique I-V de la photopile, figure 1.8 [2] [5] :

- **La résistance série** : est la résistance interne de la cellule ; elle dépend principalement de la résistance du semi-conducteur utilisé, de la résistance de contact des grilles collectrices et de leurs résistivités ;
- **La résistance shunt** : est due à un courant de fuite au niveau de la jonction ; elle dépend de la façon dont celle-ci a été réalisée.

1.4.1 PUISSANCE CRÊTE D'UNE CELLULE PV

La puissance crête d'une photopile, notée W_c (Watt crête) ou W_p (Watt peak), c'est la puissance mesurée dans les conditions de test standard "STC", tel que l'éclairement $\phi = 1000 \text{ W/m}^2$, la température $T = 25^\circ\text{C}$, avec une répartition spectrale du rayonnement dit AM 1,5[9].

1.4.2 COURANT DE COURT-CIRCUIT, I_{cc}

Il s'agit du courant obtenu en court-circuitant les bornes de la cellule (en prenant $V = 0$ dans le schéma équivalent). Il croît linéairement avec l'intensité d'illumination de la cellule et dépend de la surface éclairée, de la longueur d'onde du rayonnement, de la mobilité des porteurs et de la température [5].

1.4.3 TENSION DE CIRCUIT-OUVERT, V_{oc}

La tension à circuit-ouvert est obtenue quand le courant qui traverse la cellule est nul. Elle dépend de la barrière d'énergie et de la résistance shunt. Elle décroît avec la température et varie peu avec l'intensité lumineuse [5] :

$$V_{co} = \frac{KT}{q} \ln \frac{I_{cc}}{I_s} + 1 \quad (1.5)$$

1.4.4 FACTEUR DE FORME, FF

On appelle facteur de forme FF (fill factor), le rapport entre la valeur maximale de la puissance pouvant être extraite (I_m, V_m) de la photopile sous les conditions de mesures standardisées, et le produit (I_{cc}, V_{co}) :

$$FF = \frac{V_m \cdot I_m}{V_{co} \cdot I_{co}} \quad (1.6)$$

Pour une cellule de fabrication industrielle, le facteur de forme est de l'ordre de 70% [11].

1.4.5 RENDEMENT DE CONVERSION, H

Le rendement η des cellules PV, désigne le rendement de conversion en puissance. Il est défini comme étant le rapport de la puissance maximale délivrée par la cellule et la puissance lumineuse incidente P_{IN} [9] :

$$\eta = \frac{A \cdot FF \cdot V_{co} \cdot I_{cc}}{P_{IN}} \quad (1.7)$$

P_{IN} : Puissance incidente [W] ;

$\frac{P_{IN}}{A}$: Densité de puissance incidente [W/m^2] ;

A : Section de la cellule [cm^2].

1.5 MODULE PHOTOVOLTAÏQUE

La cellule solaire de forme ronde ou carrée est l'élément de base d'un système photovoltaïque. Un ensemble de cellules forme un module solaire, dans un module les cellules sont reliées électriquement entre elles et encapsulées, donc protégées contre les agents extérieurs. Plusieurs modules forment un string PV et plusieurs string PV forment un champ ou générateur PV ¹, auxquels viennent s'ajouter des protections, un régulateur, un système de stockage de l'énergie (batterie), des appareils de contrôle et de mesure, un onduleur, etc. [11].

1.5.1 ASSOCIATION EN SÉRIE

En additionnant des cellules ou des modules identiques en série, le courant de la branche reste le même, mais la tension augmente proportionnellement au nombre des cellules /modules en série, figure 1.9 [11].

$$V_{OCN_s} = N_s \times V_{OC}$$

$$I_{CC} = I_{CCN_s}$$

Avec :

V_{OCN_s} : Somme des tensions en circuit-ouvert en série ;

I_{CCN_s} : Courant de court-circuit des cellules en série ;

N_s : Nombre des cellules en série.

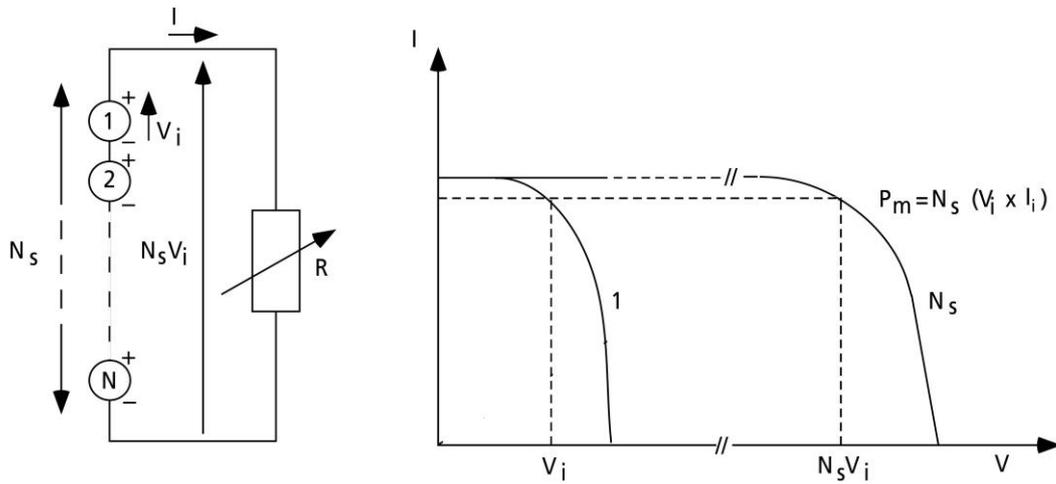


Figure 1.9. Cellules identiques en série [2]

1. Le terme générateur photovoltaïque "GPV" est utilisé pour désigner, selon l'application considérée, un module ou un string. Toutefois, il peut faire allusion au champ photovoltaïque tout entier. Pour la suite de ce mémoire, on utilisera le terme "GPV" pour désigner un champ photovoltaïque.

1.5.2 ASSOCIATION EN PARALLÈLE

En additionnant des modules identiques en parallèle, la tension de la branche est égale à la tension de chaque module, mais l'intensité du courant augmente proportionnellement au nombre de modules en parallèle dans la branche, figure 1.10 [11] [5].

$$I_{ccNp} = N_p \times I_{cc} \quad (1.10)$$

$$V_{oc} = V_{ocNp} \quad (1.11)$$

Avec :

I_{ccNp} : Sommes des courants en court-circuit en parallèle ;

I_{ccNs} : Courant de court-circuit des cellules en série ;

N_s : Nombre des cellules en parallèle.

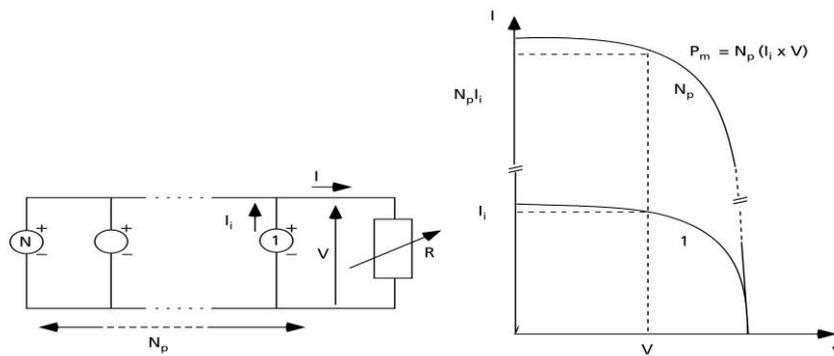


Figure 1.10. Cellules identiques en parallèle [2]

1.5.3 ASSOCIATION HYBRIDE EN (SÉRIE/PARALLÈLE)

Selon l'association série et/ou parallèle des cellules, les valeurs du courant de court-circuit total et de la tension à vide totale, sont données par les relations suivantes [5] :

$$I_{cc}^t = n_p \cdot I_{cc} \quad (1.12)$$

$$V_{oc}^t = n_s \cdot V_{oc} \quad (1.13)$$

D'où :

I_{cc}^t : Sommes des courants en court-circuit en parallèle

Selon l'association en série et/ou parallèle de ces cellules, les valeurs du courant de court-circuit I_{cc} , et de la tension à vide V_{oc} , sont plus ou moins importantes. La caractéristique d'un générateur PV est constituée de plusieurs cellules à une allure générale assimilable à celle d'une cellule élémentaire, sous réserve qu'il n'y ait pas de déséquilibre entre les caractéristiques de chaque cellule (irradiation et température uniformes), figure 1.11 [10].

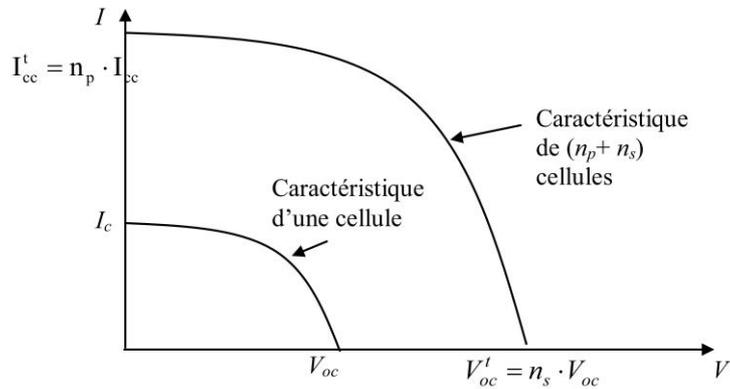


Figure 1.11. Caractéristique I-V résultante d'un groupement hybride de $(n_p + n_s)$ cellules identiques [5]

1.6 SYSTEMES PV

Les cellules PV sont les éléments de base de tout système photovoltaïque. Ils peuvent être branchés en série pour augmenter leur tension d'utilisation et en parallèle pour augmenter leur courant l'ensemble est appelé le modules PV, l'association de plusieurs modules donne naissance à un champ PV figure 1.12 . L'énergie fournie par le champ peut être utilisée pour charger des batteries qui fourniront l'électricité au moment voulu. Elle peut aussi être utilisée en reliant directement les modules à la charge sans les batteries (ex. : pour une pompe solaire, l'eau sert de stockage), ou en les branchant sur un réseau électrique.

Il est également possible de combiner la sortie du champ PV avec d'autres sources d'énergie telles une génératrice ou une éolienne qui serviront d'appoint, si l'ensoleillement n'est pas suffisant [5].

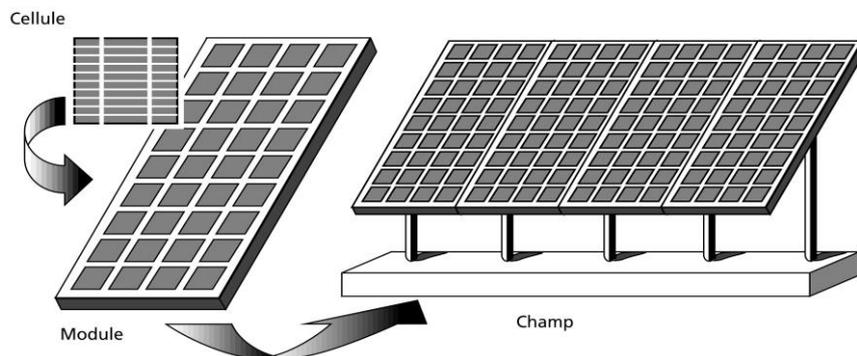


Figure 1.12. Composantes d'un champ de modules photovoltaïques

1.6.1 COMPOSANTS D'UN SYSTÈME PV

Le synoptique électrique d'un système PV alimentant une charge est illustré dans la Figure 1.17. Nous le décrivons en considérant les différents composants suivants [1] :

- Générateur PV.
- Convertisseur.
- Câblage et boîte de jonction.
- Système de protection y compris la diode bypass, diode anti-retour et les autres dispositifs de sectionnement.
-

1.6.2 SYSTÈME DE PROTECTION

Comme pour les autres centrales électriques, il existe plusieurs sortes de protection pour une installation photovoltaïque, protection des intervenants, protection contre la foudre, protection du générateur PV [1]. Du fait que notre travail est porté uniquement sur des défauts conduisant à une baisse de production, nous nous intéressons donc qu'aux composants servant à la protection du générateur PV.

A) Diode by-pass

La diode by-pass est connectée en antiparallèle avec un groupe de cellules, à fin de protéger les plus faibles entre eux contre la polarisation inverse.

B) Diode anti-retour

La tension produite par chaque string peut être différente . Lors de la mise en parallèle de ces strings pour former un champ PV, le string avec la tension la plus faible peut absorber un courant inverse provenant des autres strings. Cela conduit donc à une baisse de production, Les modules du string traversés par le courant inverse pourraient être également susceptibles de la défaillance. Pour éviter ces courants inverses, une diode anti-retour est placée au bout de chaque string, figure 1.14.

L'utilisation de la diode anti-retour introduit pourtant une perte dans la production du fait de la chute de tension causée par cette diode pendant le fonctionnement normal du champ PV. De plus, ces diodes peuvent se mettre en défaut et demandent par conséquent un contrôle régulier, un fusible est parfois utilisé à la place de la diode anti-retour. Par contre, l'utilisation du fusible ne permet pas de protéger le string contre le courant inverse.

Le fusible doit être dimensionné afin que les composants du string (module, câble, connecteur) puissent supporter l'intensité du courant inverse lorsque ce dernier existe. Le choix de l'un des deux composants réside donc sur la tolérance entre la perte en fonctionnement normal (pour le cas d'utilisation de la diode anti-retour) et la perte causée par le courant inverse (lors de l'utilisation du fusible) [1].

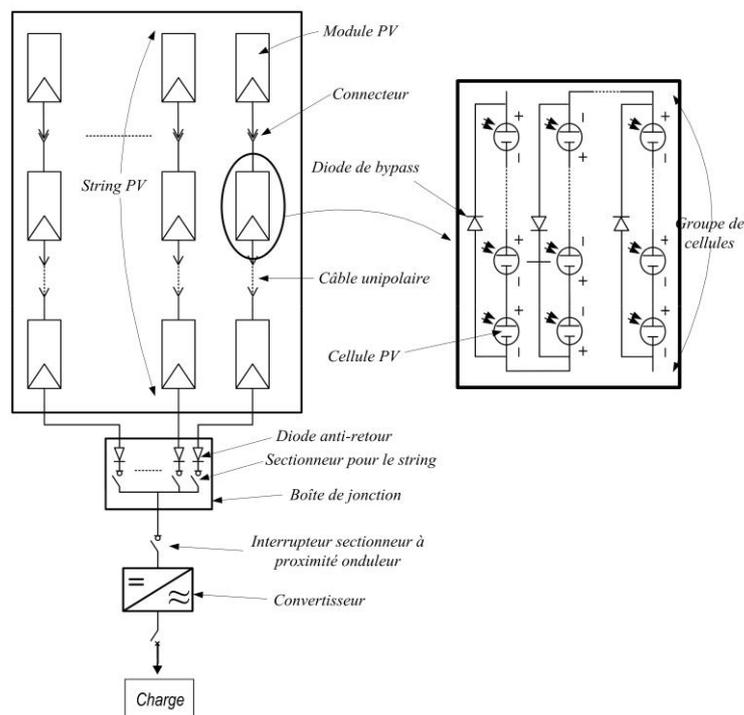


Figure 1.13. Composantes d'un système PV alimentant une charge [1]

Chapitre 02

Chapitre 2 : les réseaux de neurones artificiels

2.1 INTRODUCTION

Depuis longtemps, la nature a toujours été une source d'inspiration pour l'homme qui a toujours essayé de tirer profit de ce qui l'entourait. Sans doute, sa plus grande entreprise était de recopier le cerveau humain afin de créer une intelligence artificielle à l'image de celle rencontrée dans la nature.

Le développement, dans les années 40, des réseaux de neurones artificiels (RNA) résulte des travaux de plusieurs chercheurs visant à reproduire un comportement intelligent à partir d'un modèle neuronal simplifié [14,15]. En effet le plus grand avantage des RNA par rapport à d'autres techniques de modélisation est leur capacité à modéliser des processus complexes, non linéaires, sans avoir à apprendre la forme de la relation entre les variables d'entrée et de sortie [17].

Dans ce chapitre, une description générale des réseaux de neurones, ainsi que leur caractéristique seront présentées. Nous nous sommes intéressés principalement aux réseaux non récurrents ou Multilayer.

2.2 LE NEURONE BIOLOGIQUE ET LE NEURONE ARTIFICIEL

Un réseau de neurones artificiels (RNA) est un processeur parallèle de traitement d'informations distribuées, qui présente une propension naturelle à la mémorisation et à l'exploitation de connaissances relatives à l'environnement dans lequel il est immergé [17].

Sa structure repose sur une interconnexion massive de cellules élémentaires de traitement d'information, appelées neurones formels ou modèle de *Pits* et *MC-Culloch*, dont la représentation est un graphe dirigé [19, 20, 21],

L'analogie entre un réseau de neurones formels et le cerveau humain se résume par les trois caractéristiques suivantes [18, 21] :

L'acquisition des connaissances d'un réseau de neurone artificiel se fait par apprentissage, au cours duquel le réseau peut être amené à modifier sa structure en créant ou supprimant des neurones ou des liaisons entre neurones.

La connaissance acquise par un réseau de neurones est encodée par les forces ou intensités évolutives des connexions établies entre neurones formels. Les forces de ces connexions reliant les neurones se réfèrent aux valeurs des poids ou coefficients synaptiques qui définissent les paramètres du modèle interne du réseau.

Etant donné que le modèle du problème considéré est inconnu ou difficile à formaliser. Un ensemble d'exemples, constitue l'entrée du problème auxquelles sont associées des solutions fournies par un expert, est néanmoins accessible.

2.3 RESEAUX DE NEURONES ARTIFICIELS

Une manière simple de définir un réseau de neurones consiste à considérer qu'il s'agit d'un système de traitement de l'information composé d'un grand nombre de processeurs interconnectés appelés cellules. Chacune de ces cellules calcule sa sortie sur la base d'informations qui lui sont transmises à partir des autres cellules qui sont connectées à elle et des poids de ces connexions [16].

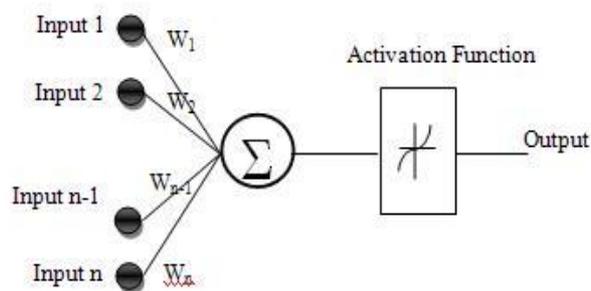


Figure 2.1. Structure artificielle du réseau neurone

Comme il est illustré sur la structure artificielle, chaque neurone est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance des neurones amont (afférents). A chacune de ces entrées est associée un poids W abréviation de weight (poids en anglais) représentatif de la force (ou bien de la pondération) de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones aval (efférents) ce qui est à l'image du neurone biologique [13].

La sortie du neurone est décrite par formulation mathématique suivante :

$$S = f \left(\sum_{j=1}^i W_j . E_j \right) \quad (2.1)$$

Où

S: est la sortie du neurone

E_j : est la $j^{\text{ème}}$ entrée du neurone, elle caractérise la donnée communiquée par le capteur (test de Détection) ou par l'expert (diagnostic et base de faits et de connaissance).

f : fonction d'activation

W_j : poids de connections avec les entrées.

Un réseau de neurones peut-être complètement décrit par la spécification des quatre éléments suivants [20] :

- L'élément de traitement,
- L'architecture ou topologie du réseau qui correspond au schéma d'interconnexions,
- Le type d'apprentissage,
- Le schéma d'activation du système.

2.3.1 L'ÉLÉMENT DE TRAITEMENT

Il est décrit par une fonction de transfert, appelée également fonction d'activation, qui établie une correspondance entre les valeurs présentées à l'entrée de la cellule et la valeur de sortie [21].

2.3.2 L'ARCHITECTURE D'UN RÉSEAU

Elle est déterminée par la topologie de connexions des neurones dans le réseau. Il existe trois classes d'architectures de réseaux qui peuvent être considérées à savoir : les réseaux mono- et multicouches, les réseaux récurrents et les réseaux topologiques [19, 18].

a. Réseaux statiques ou multicouches

Dans ce type de réseau, les neurones sont arrangés par couches. De plus aucune connexion entre neurones d'une même couche n'est admise. Les connexions ne se font qu'avec les neurones des couches avalent.

Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante de manière exclusive [13].

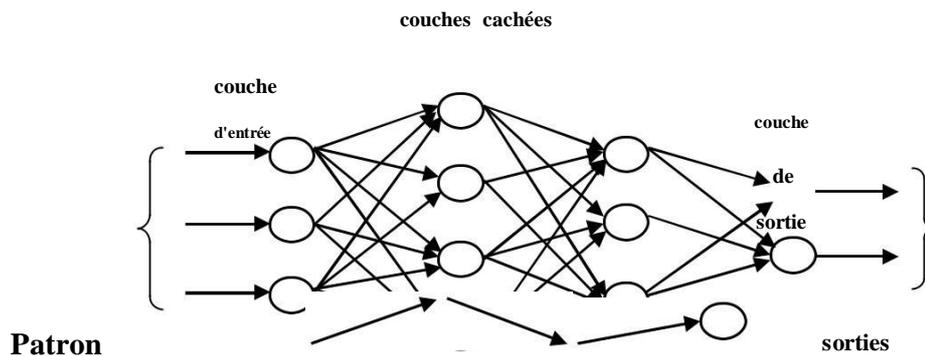


Figure 2.2. Architecture d'un réseau multicouche à interconnexion totale

b. Réseaux dynamiques ou récurrents

Les connexions récurrentes imposent la transmission de l'information dans le réseau considéré en arrière par rapport au sens de propagation défini dans un réseau multicouche.

Les réseaux récurrents sont appelés aussi réseaux dynamiques en raison de leur caractéristique dynamique. En effet, ces réseaux évoluent dans le temps étant donné que la sortie actuel $y(t)$ de ces réseaux dépend aussi des valeurs de sorties précédente $y(t-1)$. Par conséquent, la notion du temps dans de tels réseaux est importante [13].

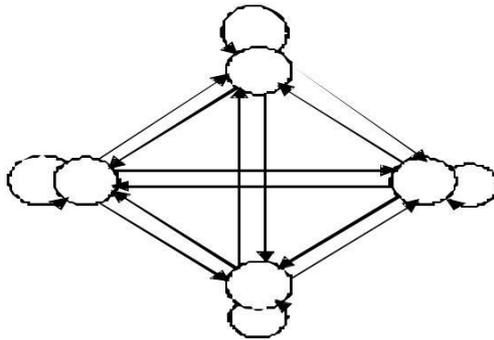


Figure 2.3. Architecture d'un réseau récurrent mono-couche à interconnexion totale.

c. Réseaux topologiques

C'est la structure d'interconnexion la plus générale. En effet, dans ce cas, chaque neurone est connecté à tous les neurones du réseau, ainsi qu'à lui-même (fig 2.4).

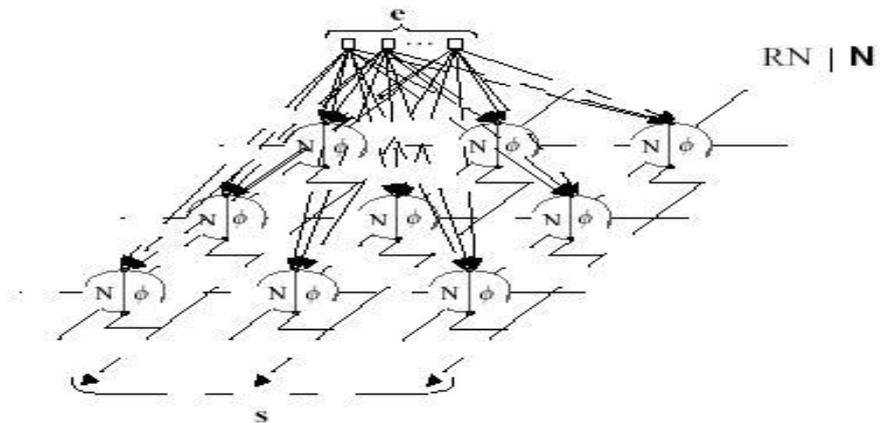


Figure 2.4. Architecture d'un réseau topologique.

2.3.3 APPRENTISSAGE ET ADAPTATION

L'apprentissage est le processus par lequel le réseau de neurones acquiert la capacité d'effectuer certaines tâches et ce, en ajustant ses paramètres internes (poids synaptiques) selon un schéma d'apprentissage spécifique. En fin de ce processus d'apprentissage, le réseau est susceptible de nous fournir des sorties aussi proches que possible des sorties désirées. Il permet également au réseau de modifier dynamiquement son comportement afin de répondre à de nouvelles attentes ou de nouvelles situations [18].

La nuance de sens accordée au terme d'adaptation dans le domaine des réseaux de neurones est liée à la prise en considération ou non du facteur temps dans le processus d'apprentissage. Cet apprentissage, qu'il soit supervisé ou non supervisé [18].

a. Apprentissage supervisé

Un apprentissage supervisé est lié à la disponibilité d'exemples, ou de modèles de réponses qui seront présentés au réseau à adapter lors d'un tel processus. Et cela, afin de lui permettre d'acquérir les aptitudes attendues par le superviseur. L'ensemble des exemples utilisés pour l'apprentissage se présente sous forme de couples $(\mathbf{x}, \mathbf{y}^*)$, où \mathbf{y}^* est la réponse désirée du réseau à l'entrée \mathbf{x} [13].

Les poids du réseau sont ajustés au fur et à mesure, suite à un signal d'erreur qui représente la différence entre la sortie estimée par le réseau et la sortie désirée par le modèle fournie par un algorithme approprié dit algorithme d'apprentissage.

Ainsi le réseau réalise une approximation de la fonction qui lui a servi de professeur. De plus les caractéristiques de l'algorithme neuronal lui permettent de généraliser et de répondre à une entrée quelconque, même si elle n'appartient pas au jeu d'apprentissage [13].

b. Apprentissage non supervisé

La détermination des poids, dans ce cas, n'est pas en fonction des erreurs, mais en présentant au réseau une quantité suffisante d'exemples contenant des corrélations de telle sorte que celui-ci en dégage les régularités automatiquement. Ces réseaux sont souvent appelés "auto-organiseurs" (self-organizing neural networks) ou encore à apprentissage compétitif [13, 12].

c. Différents algorithmes d'apprentissage des Réseaux de Neurones Artificiels

La phase d'apprentissage est une étape déterminante dans la conception du réseau de neurones. Pour cela, des algorithmes appropriés ont été élaborés et développés et dont chacun se trouve être spécifique à un type de réseau déterminé [13].

Il existe plusieurs types d'algorithmes dont les plus fréquemment utilisés sont :

- L'algorithme de rétro propagation.
- L'algorithme de Levenberg-Marquardt

Algorithme de rétro propagation

L'algorithme de rétro propagation de l'erreur est le plus utilisé dans le cas d'apprentissage supervisé des réseaux de neurones multicouches. Il a été proposé en 1980 par Rumelaha, Binton et Williams et est également appelé la méthode rétro propagation, cela en référence à l'erreur qui se "rétro propage" à travers les couches du réseau comme le montre la figure (2.5) [18].

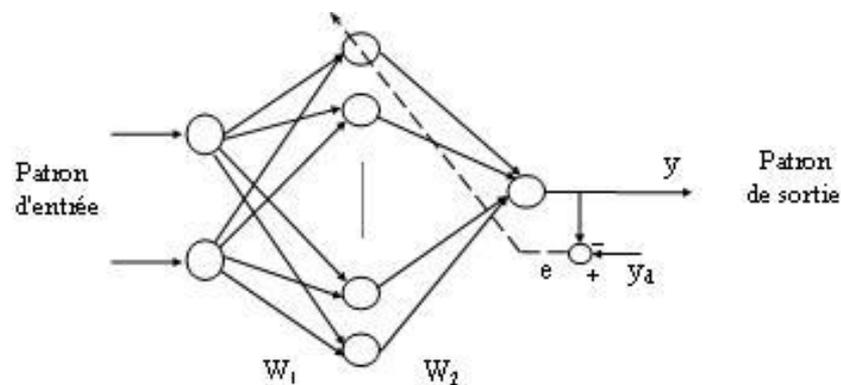


Figure 2.5. Principe de l'entraînement du réseau de neurone par rétropropagation de l'erreur.

Malheureusement il est important de noter que toute la difficulté pour effectuer une descente du gradient dans un réseau multicouche consiste à pouvoir calculer la dérivée de l'erreur quadratique par rapport à un poids donné. Les recherches ont prouvé que l'utilisation de neurone à fonction d'activation dérivable permettait de régler ce problème [18].

Méthode de Levenberg-Marquardt

Afin de bénéficier des avantages de chacune des méthodes présentées précédemment, le chercheur Marquardt proposa une stratégie qui bénéficie à la fois d'une convergence rapide et d'une indépendance des résultats vis-à-vis du vecteur initial [18].

La méthode de Levenberg-Marquardt est l'une des méthodes les plus utilisées, qui consiste à considérer la surface d'erreur quadratique en se basant sur la fonction d'énergie.

2.4 Certaines considérations pratiques pour le choix du réseau de neurone adéquat

Avant de procéder à l'apprentissage d'un réseau de neurones artificiels, un certain nombre de paramètres doivent être fixés entre autres : dimensionnement du réseau, pas d'apprentissage, ...etc. cela au risque d'engendrer et/ou de compromettre le processus d'entraînement dans le cas d'un mauvais choix. Ces considérations se résument en :

A. CHOIX ET DIMENSIONNEMENT D'UN RESEAU

D'une manière générale, il n'existe pas de méthode systématique pour la détermination du nombre de couches dans le réseau ou le nombre de neurones par couche. Néanmoins, il existe dans ce sens des règles pratiques tirées à partir de l'expérience, parmi lesquelles nous pouvons citer :

Règle 1 : le nombre de neurones par couche doit être d'autant plus élevé que la relation entre ces entrées et sortie sont complexes [18].

Règle 2 : le nombre de couches cachées doit être égal au nombre de relations qui existent entre les neurones de la couche d'entrée et ceux de la couche de sortie [18].

B. PARAMETRE D'APPRENTISSAGE OU PAS DE CORRECTION H

Le choix du paramètre d'apprentissage η a un effet important sur les performances du réseau. Généralement, il prend des valeurs petites de l'ordre de 0.05 à 0.25, afin d'assurer une certaine convergence [19]. Ce paramètre présente en réalité un dilemme : s'il est trop grand, il peut entraîner des oscillations, s'il est trop petit, le temps d'apprentissage devient infini. Par

conséquent, le paramètre η est choisi variable à partir d'une valeur grande que l'on diminue progressivement [18].

C. POIDS INITIAUX

Les poids initiaux sont choisis aléatoirement entre -0.5 et 0.5. Par ailleurs, il est recommandé de ne pas initialiser les poids synaptiques à une même valeur.

D. MINIMUMS LOCAUX

L'algorithme d'apprentissage peut éventuellement, converger vers un minimum local du critère d'erreur. Dans ce cas, l'erreur stagnera autour d'une valeur relativement grande, et les performances requises ne seront jamais atteintes. Pour remédier à ce problème, il existe plusieurs alternatives à savoir : changer le pas de correction, changer les poids initiaux, utiliser rétro-propagation avec momentum, changer la fonction d'activation, augmenter le nombre de couches cachées ou bien augmenter le nombre de neurones par couche.

E. SATURATION DU RÉSEAU

Etant donné que, les fonctions d'activation dans un réseau de neurones sont généralement bornées et fournissent des sorties comprises entre 0 et 1 ou entre -1 et 1, il est de ce fait nécessaire de mettre à l'échelle les données présentées en entrée.

Chapitre 03

Chapitre 03 : Modélisation et classification des systèmes PV

3.1. Introduction

Dans le présent travail, nous proposons toutes les pannes court-circuit, que parmi, la panne string existe qui n'a jamais été étudié lors d'un diagnostic par intelligence artificielle ; alors le retour du terrain prouve que c'est une panne très fréquente.

Le générateur photovoltaïque que nous avons utilisé dans notre étude est un générateur composé de seize modules connectés en deux branches comportant chaque branche huit modules en série. Le type de module utilisé est l'Isoton106-12, composé de 72 cellules. Les paramètres que nous avons utilisé les courants de point de puissances maximal et les tensions de point de puissance maximal.

La campagne de mesure a duré un mois de l'année 2008. C'est donné ont été modélisé par des réseaux de neurones artificiels, tout en injectant température et éclairage à la couche d'entrée pour chaque cas et accueillir courant du point de puissance maximale et tension de point de puissance maximale à la couche de sortie, cela représente la première étape.

La seconde étape, consiste à détecter les pannes tout en calculant l'écart entre les données mesurées et les données simulées par réseaux de neurones artificiels, cet écart est comparé au seuil qui doit être soit fixé pour éviter les fausses alarmes provoquées par les variations du symptôme dans la zone tolérée correspondant au fonctionnement normal du système [43]; soit comme utilisé dans notre étude doit être fixé pour qu'un défaut de sévérité minimale soit détectable.

La troisième étape, représente le diagnostic du système solaire photovoltaïque, par la méthode de classification en utilisant la méthode de l'erreur quadratique (RMSE root mean square error) et la méthode de l'erreur relative (Er)

Dans notre étude, le diagnostic et classification par RMSE et ERM nécessite à la couche d'entrée les différentes pannes simulées par ANN pour avoir une classification à la sortie du système.

Quand on travail par les réseaux de neurones on doit passer par :

- le choix de type du réseau de neurone (nous avons choisi le type perceptron multicouche)

- le choix de type d'apprentissage (on a choisi l'apprentissage supervisé)
- la déroulement d'apprentissage de type levenberg marquited en ' matlab '
- la validation de réseaux de neurone
- l'exploitation des résultats obtenue

Nom de panne	Symbole
Modèle sain	Class 1
Mauvais fonctionnement due à un seul module court circuité (one panel)	Class 2
Mauvais fonctionnement due à deux modules court circuité (two panels)	Class 3
Mauvais fonctionnement due à quatre modules court circuité (four panels)	Class 4
Mauvais fonctionnement due à six modules court circuité (six panels)	Class 5
Mauvais fonctionnement due à panne string	Class 6

Table 3.1.Type de pannes et leurs symboles

3.2. Pannes du système solaire photovoltaïque

Principalement les pannes qui apparaissent dans un système photovoltaïque sont dans le réseau électrique, dans le système de stockage, les plus répondu sont dans les onduleurs et/ou le générateur photovoltaïque qui est le cas dans notre étude où nous avons traité les pannes de la connection des modules qui sont les plus souvent rencontrer, le nom de ces pannes et leurs symboles sont montrées dans le tableau 3.1.

3.3. Technique proposée pour le diagnostique des pannes

La technique développée dans notre étude consiste à identifier le cas sain et cinq cas défectueux, par la comparaison des réponses du système entre le cas mesuré et le cas simulé par réseau de neurone artificiel, puis la comparer à un seuil pour pouvoir détecter une panne. L'analyse des principaux attributs dans la caractéristique V en fonction de temps et la caractéristique I en fonction de temps de chaque branche mène à l'identification et la localisation des pannes. Le schéma synoptique globale détaillé de la figure ci-dessous montre le système intelligent du diagnostique des pannes

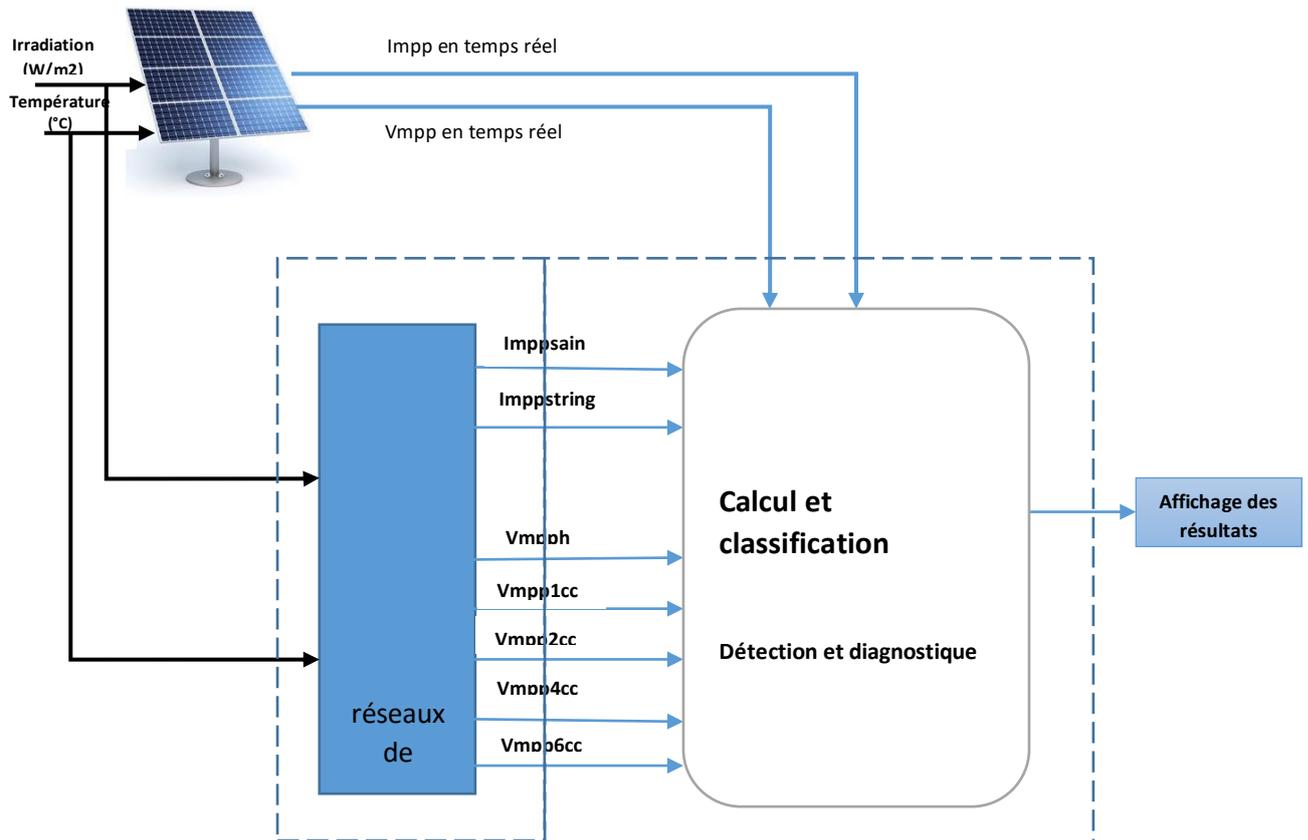


Figure 3.1. Schéma synoptique de système de diagnostic intelligent

Première étape, dite modélisation consiste à injecté dans les réseaux de neurones précédemment élaboré, les données météorologiques en temps réel à savoir la température et l'éclairement. La sortie des réseaux de neurones artificiels sont les deux paramètres utilisé Vmpp et Impp. Ces paramètres sont montrés dans le tableau 3.2 :

Symboles	Paramètres	Classes
Impps	Courant de point de puissance maximum sain	Calss1
Imppstring	courant maximal de la panne string	Calss6
Vmpp	Tension maximale du point de puissance maximale sain	Calss1
Vmpp1cc	tension de point de puissance maximale d'un court-circuit de panneau	Calss2
Vmpp2cc	tension maximale du point de puissance de deux panneaux court-circuit	Calss3
Vmpp4cc	tension de point de puissance maximale de quatre panneaux court-circuit	Calss4
Vmpp6cc	tension maximale du point de puissance de six panneaux en court-circuit	Calss5

Table 3.2. Paramètres de type avec des symboles et des classes

En suite les données v_{mpp} mesuré seront comparés par RMSE et Er avec V_{mpps} , V_{mpp1cc} , V_{mpp2cc} , V_{mpp4c} , V_{mpp6cc} , et les données I_{mpp} mesurés seront comparés à I_{mpps} et $I_{mppstring}$. La compilation permettra une classification en temps réel.

le tableau3, montre les différentes classes des deux paramètres avec la décision finale du système

I_{mpp}	V_{mpp}	Systeme
I_{mpph}	V_{mpph}	Systeme sain
I_{mpph}	V_{mpp1sc}	La détection de la panne se réfère à un court-circuit de panneau
I_{mpph}	V_{mpp2sc}	La détection de la panne se réfère à deux panneaux court-circuit
I_{mpph}	V_{mpp4sc}	La détection de la panne se réfère à quatre panneaux court-circuit
I_{mpph}	V_{mpp6sc}	La détection de la panne s se réfère à six panneaux en court-circuit
$I_{mppstring}$	V_{mpph}	La détection de la panne se réfère à la chaîne

Table 3.3. Diagnostic du système

3.4. PARTIE SIMULEE

Notre travail nécessite des entrées météorologiques réelles (Température et éclairement) captés chaque minute pendant 2 heures et quarante minutes équivaux à 220 données pour des paramètres d'un mois a la station photovoltaïque CDER d'alger en Algérie .La température varie entre 12-48 °C, et l'éclairément atteint 1000W/m2 pour chaque midi.

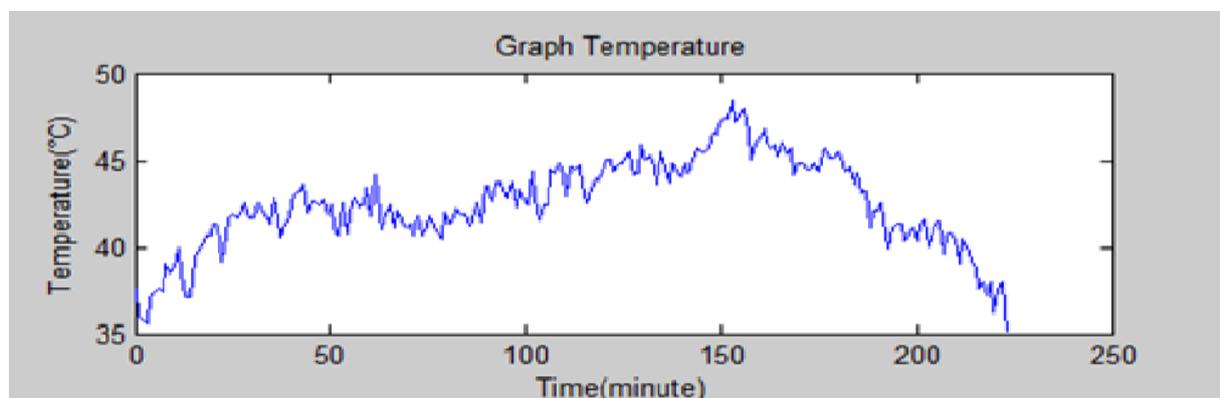


Figure 3.2. Variation de température captée au cours d'un mois

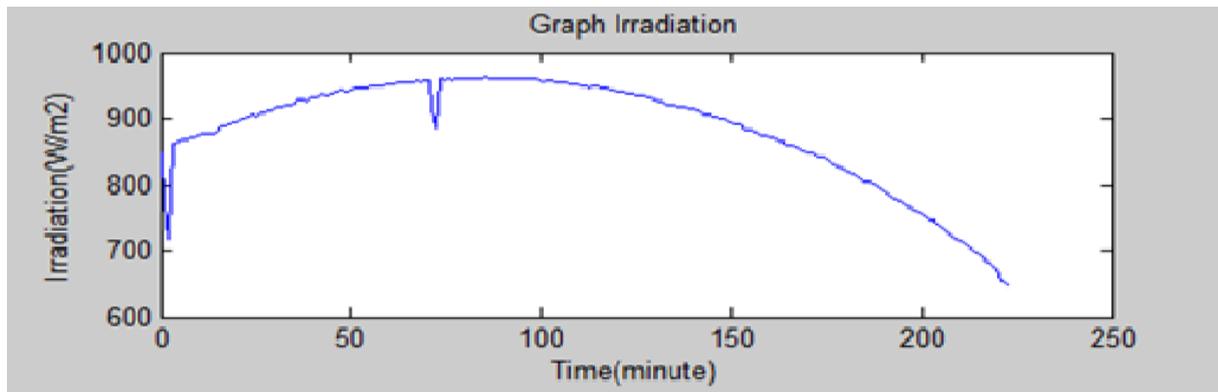


Figure 3.3. Variation d’irradiation captée au cours d’un mois

Notre modèle simule les caractéristiques du : courant de point de puissance maximal et tension de point de puissance maximal de différentes pannes expérimentalement validées de la station citer précédemment, est composé de 16 modules monocristallins de type Isoton106-12 partager en deux branches comportant chaque 8 modules photovoltaïque connectées en série.

Parameters	Value
Maximum Power module (Pm)	106 W
Short current circuit module (Isc)	6,54 A
Voltage open circuit module (Voc)	21,6 V
Temperature coefficient of Isc (α)	0,042 %/°C
Temperature coefficient of Voc (β)	-0,328 %/°C
Series cell	36
Parallel cell	2
Short current circuit cell	3,27 A
Voltage open circuit cell	0,6 V

Figure 3.4. Paramètres de panneaux solaires utilisés

Dans notre travail nous sommes passés par deux étapes essentielles, Modélisation et classification. Notre base de données se compose de 220 données pour chaque défaut, nous avons employé 220 données pour la modélisation et les 250 autres pour la classification.

Notre système consiste à avoir :

3.5. LA MODELISATION DES SYSTEMES PAR RESEAUX DE NEURONES

Parmi toutes données dont nous avons tiré profit, 220 données ont été conservé pour l’apprentissage et la validation. Tous les cas étudié (sain et défectueux) ont été modélisé par réseaux de neurones artificiels à partir des entrées température et éclairément montrer dans la fig 3.5.

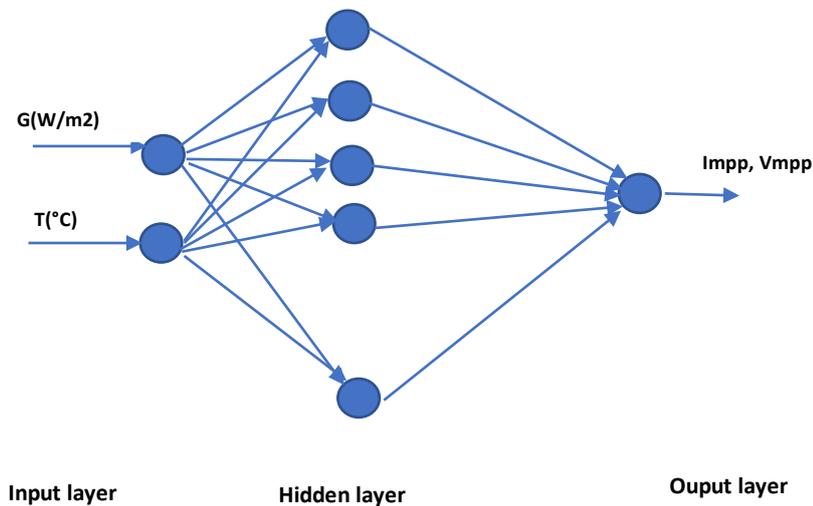


Figure 3.5. La structure du modèle par réseau de neurones artificiels

Pour la modélisation du réseau de neurone artificiel de notre projet nous avons choisis un réseau multicouche non récurrent. Les calculs se produisent seulement dans une direction, il n'y a pas un retour en arrière. Cette réseau est constitué par trois couches de neurones nommées : couche d'entrée elle est responsable de recevoir les données contient une matrice de deux variables d'entrée (2 neurones), couche de sortie elle est responsable d'envoyer les données par la sortie du système contient un neurone sa sortie est un vecteur et a une fonction d'activation et couches cachées contient 'n' neurones avec une fonction d'activation.

L'apprentissage d'un réseau de neurone peut être considéré comme une action de la mise à jour de ses poids des connexions synaptiques, afin de résoudre le problème demandé. L'apprentissage est la caractéristique principale des réseaux de neurones et il peut se faire de différentes manières et selon différentes règles.

3.5.1 LA MODELISATION D'UN MODELE TENSION SAIN (HEALTHY SYSTEM)

Pour la modélisation du **modèle sain** nous avons choisi un réseau de neurone multicouche non récurrent. Cette réseau est constitué par trois couches de neurones nommées : couche d'entrée contient 2 neurones reçoit une matrice de deux variables d'entrée la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur 'Vmp_{psain}' 'tension de point de puissance maximale sain' capturé en cas de fonctionnement sain avec une fonction d'activation 'Purline' et couche cachée contient de 40 neurones avec une fonction d'activation 'logsig'. Nous avons utilisé un apprentissage supervisé de type 'levenberg marquardt'.

3.5.2 LA MODÉLISATION DES MODÈLES DÉFECTUEUX (TENSIONS)

a. La modélisation d'un système avec un module court circuité

Pour la modélisation de ce modèle nous avons choisi le même réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient deux neurones reçoit une matrice de deux variables se sont la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur 'V_{mpp 1 cc}' simulé 'tension de point de puissance maximale avec un module court circuité' avec une fonction d'activation 'Purline' et couche cachée de 40 neurones avec une fonction d'activation est appelé 'logsic'. Nous avons utilisé un apprentissage supervisé de type 'levenberg marquardt'

b. La modélisation d'un système avec deux modules court circuité

Pour cette modélisation nous avons choisi le même réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient deux neurones reçoit une matrice de deux variables se sont la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur 'V_{mpp 2 cc}' simulé 'tension de point de puissance maximale avec deux modules court circuité' avec une fonction d'activation 'Purline' et couche cachée de 40 neurones avec une fonction d'activation 'logsic'. L'apprentissage associé de ce cas est supervisé de type 'levenberg marquardt'

c. La modélisation d'un système avec quatre modules court circuité

La modélisation de ce système nous choisissons le même réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient deux neurones reçoit une matrice de deux variables se sont la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur 'V_{mpp 4 cc}' simulé 'tension de point de puissance maximale avec quatre modules court circuité' avec une fonction d'activation est appelé 'Purline' et couche cachée contient 40 neurones avec une fonction d'activation est appelé 'logsic'. Nous avons utilisé un apprentissage supervisé de type 'levenberg marquardt'

d. La modélisation d'un système avec six modules court circuité

Pour la modélisation de ce système on a choisissais le même réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient deux neurones reçoit une matrice de deux variables se sont la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortieest un vecteur appelé 'Vmpp 6 cc' 'tension de point de puissance maximale avec six modules court circuité' avec une fonction d'activation 'Purline' et couche cachée de 40 neurones avec une fonction d'activation 'logsic' avec un apprentissage supervisé de type 'levenberg marquardt' .

3.5.3. LA MODÉLISATION D'UN MODÈLE COURANT SAIN (HEALTHY SYSTEM)

Pour la modélisation du **modèle courant sain** on utilisons un réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient 2 neurones reçoit une matrice de deux variable d'entrée la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur 'Impp sain' simulé 'courant de point de puissance maximale sain' capturé en cas de fonctionnement sain avec une fonction d'activation 'Purline' et couche cachée de 40 neurones avec une fonction d'activation 'logsic' .avec un apprentissage supervisé de type 'levenberg marquardt' .

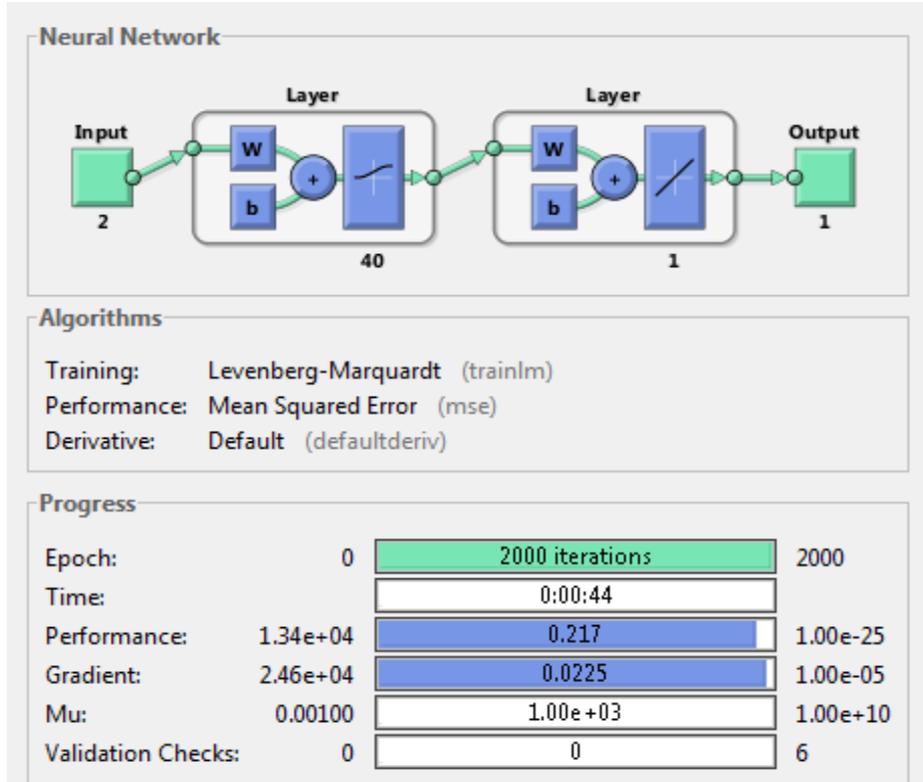
3.5.4 LA MODELISATION DE MODELE DEFECTUEUX (PANNE STRING)

La modélisation de la panne string nécessite un réseau de neurone multicouche non récurrent constitué de trois couches de neurones nommées : couche d'entrée contient 2 neurones reçoit une matrice de deux variable d'entrée la température 'T' et la irradiation 'I', couche de sortie contient un neurone sa sortie est un vecteur que on appele 'Impp panne string' 'courant de point de puissance maximale de la panne string' avec une fonction d'activation est appelé 'Purline' et couche cachée contient 40 neurones avec une fonction d'activation est appelé 'logsic' .avec un apprentissage supervisé de type 'levenberg marquardt'

3.6 LA VALIDATION DES MODELES DEVELOPPES

3.6.1 LA VALIDATION DE MODELÉ SAIN EN TENSION

Après le déroulement de programme de modélisation de modèle sain nous obtenons les figures suivantes :



Le réseau de neurones il est entraîné par l'apprentissage pour cas modèle sain

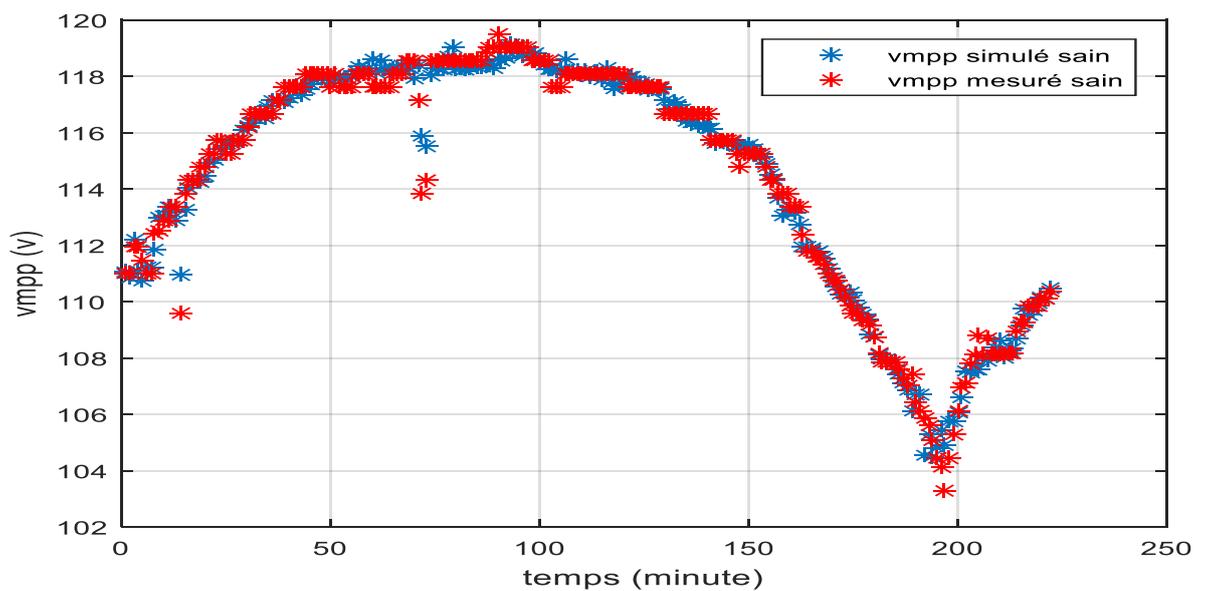


Figure 3.6.1. Modélisation d'un modèle sain par réseau de neurone

Sur ce figure 3.6.1 l'axe de x décrit le temps en minutes et l'axe de Y décrit la V_{mpp} (tension de point maximale).

Le graphe en rouge c'est le v_{mpp} mesuré sain et en bleu c'est la sortie obtenue par le réseau de neurone v_{mpp} simulé sain.

Le graphe de la tension de point maximale simulé sain se superpose sur le graphe de tension de point maximale mesuré sain donc on peut dire que le modèle développé a bien réagit et l'écart entre le v_{mpp} mesuré sain et v_{mpp} simulé sain est négligeable voir figure 3.6.2

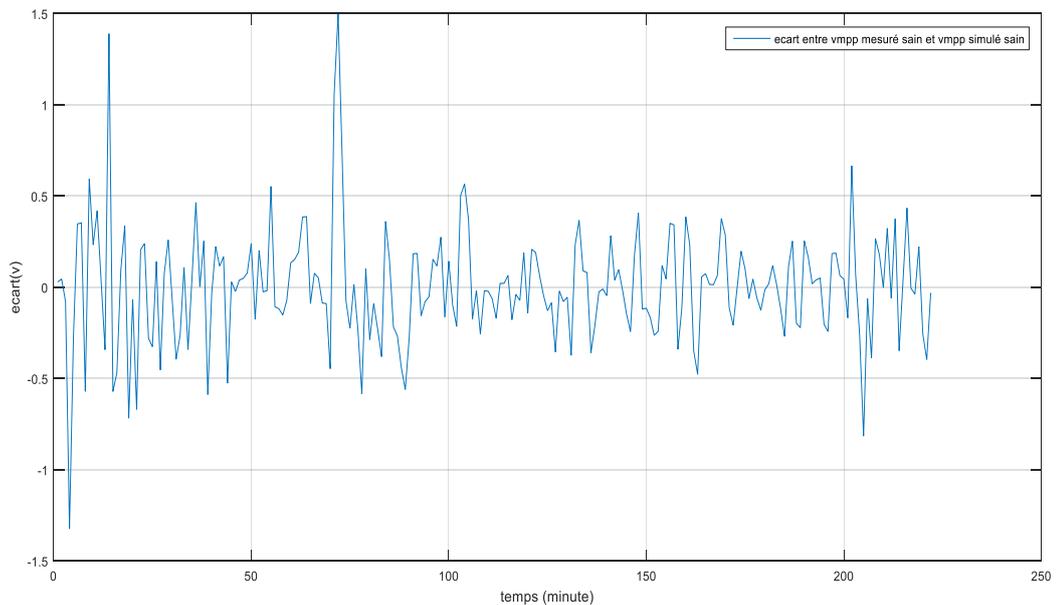


Figure 3.6.2. Écart entre v_{mpp} mesuré sain et v_{mpp} simulé sain en fonction du temps

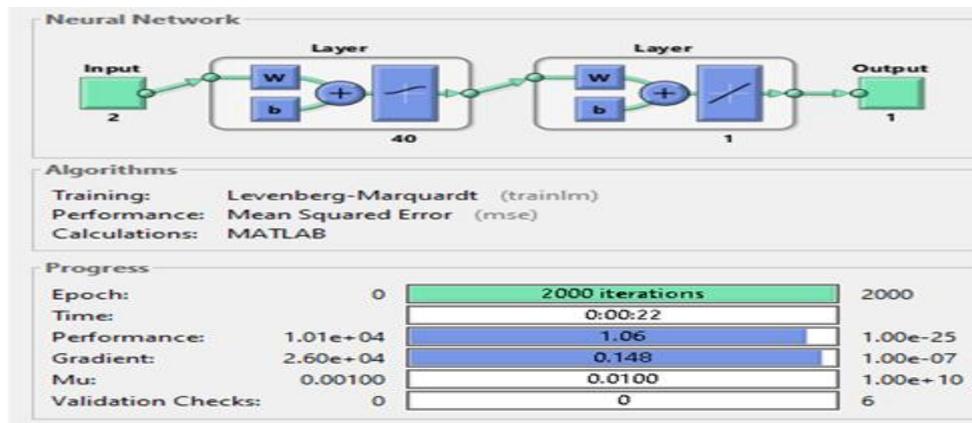
Sur ce figure 3.6.2 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart v_{mpp} mesuré sain et v_{mpp} simulé sain en volt

Alors on peut dire que ce modèle a fait un bon apprentissage

3.6.2 LA VALIDATION DES MODELES DEFECTUEUX EN TENSION

a. La validation de modèle à un seul module court circuité

Le déroulement de script de modélisation en programme de simulation matlab affiche la fenêtre d'apprentissage de réseau de neurones suivante :



Le réseau de neurones il est entraîné par l'apprentissage pour cas de modèle à un seul module court circuit

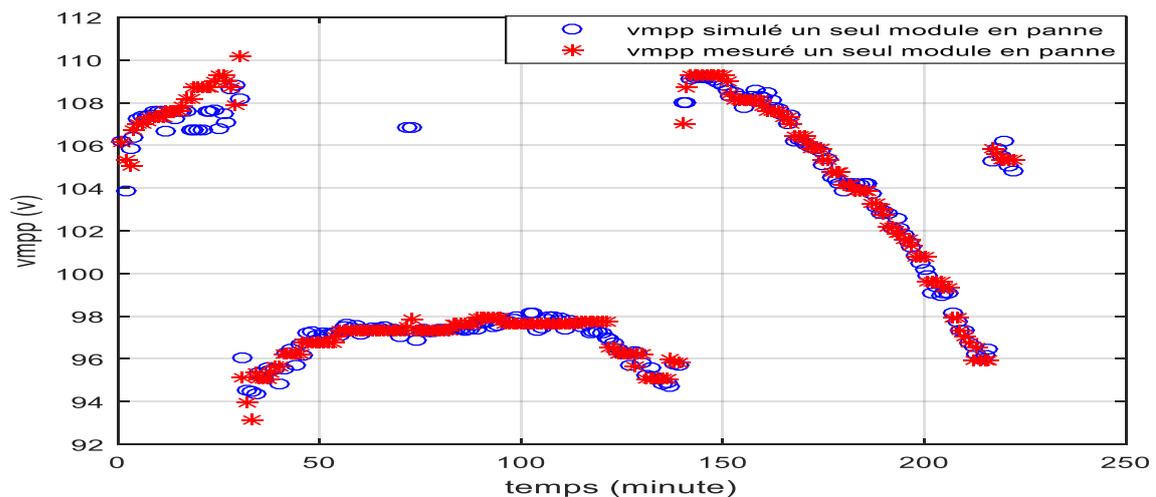


Figure 3.6.3. Modélisation d'un modèle défectueux à un modèle court circuité par réseau de neurone

Sur la figure 3.6.3 l'axe de x décrit le temps en minutes et l'axe de Y décrit la V_{mpp} (tension de point maximale a un module cc)

Le graphe en rouge c'est le v_{mpp} mesuré avec un seul module court circuité et en bleu c'est la sortie obtenue par le réseau de neurone v_{mpp} simulé avec un seul module court circuité .

Le graphe de la tension de point maximale simulé a un seul module court circuité se superpose sur le graphe de tension de point maximale mesuré a un seul module court circuité donc on conclue que le modèle développé a bien réagit et l'écart entre le v_{mpp} mesuré simulé a un seul

module court circuité et vmpp simulé simulé a un seul module court circuité est négligeable voir figure 3.6.4

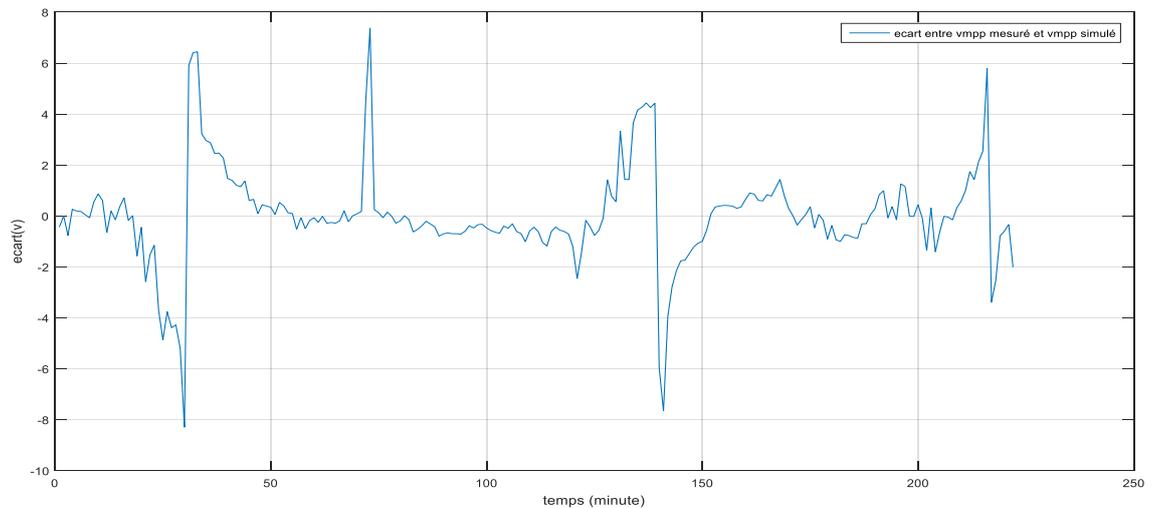


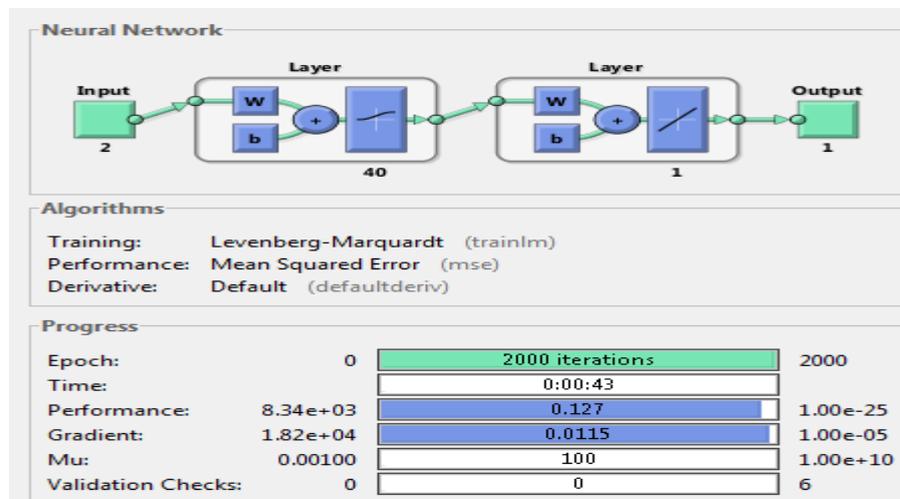
Figure 3.6.4. vmpp mesuré a un seul module cc et vmpp simulé simulé a un seul module cc en fonction de temps

Sur ce figure 3.6.4 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart en volt entre vmpp mesuré simulé a un seul module court circuit et vmpp simulé simulé a un seul module court circuit

Alors on peut dire que ce modèle a fait un bon apprentissage

b. La validation de modèle à deux modules court circuité

Le déroulement de script de modélisation en programme de simulation matlab affiche la fenêtre d'apprentissage de réseau de neurones suivante :



Le réseau de neurones il est entraîné par l'apprentissage pour cas de modèle à deux modules court circuit

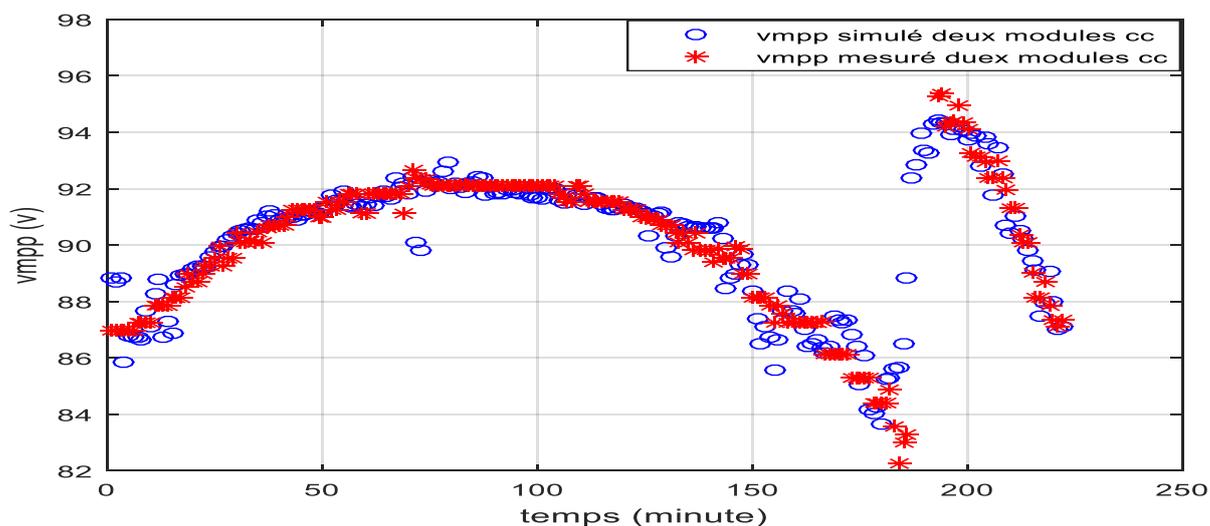


Figure 3.6.5. Modélisation d'un modèle défectueux à deux modèles court circuité par réseau de neurone

Sur la figure 3.6.5 l'axe de x décrit le temps en minutes et l'axe de Y décrit la V_{mpp} (tension de point maximale a deux modules court circuité).

Le graphe en rouge c'est le v_{mpp} mesuré avec un deux modules court circuité et en bleu c'est la sortie obtenue par le réseau de neurone v_{mpp} simulé avec deux modules court circuité

Le graphe de la tension de point maximale simulé a deux modules court circuité se superpose sur le graphe de tension de point maximale mesuré a deux modules court circuité donc on conclue que le modèle développé a bien réagit et l'écart entre le v_{mpp} mesuré a deux modules court circuité et v_{mpp} simulé a deux modules court est négligeable voir figure 3.6.6

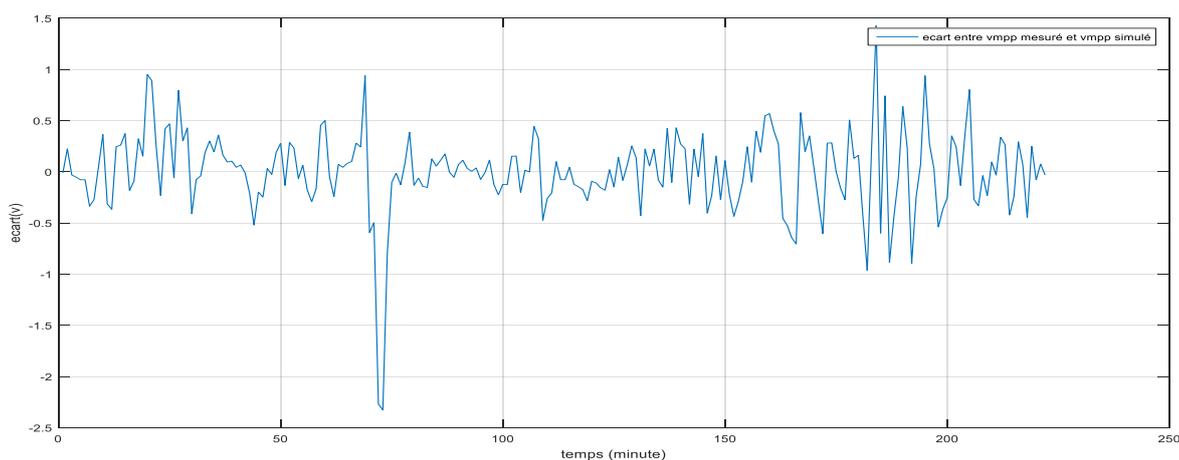


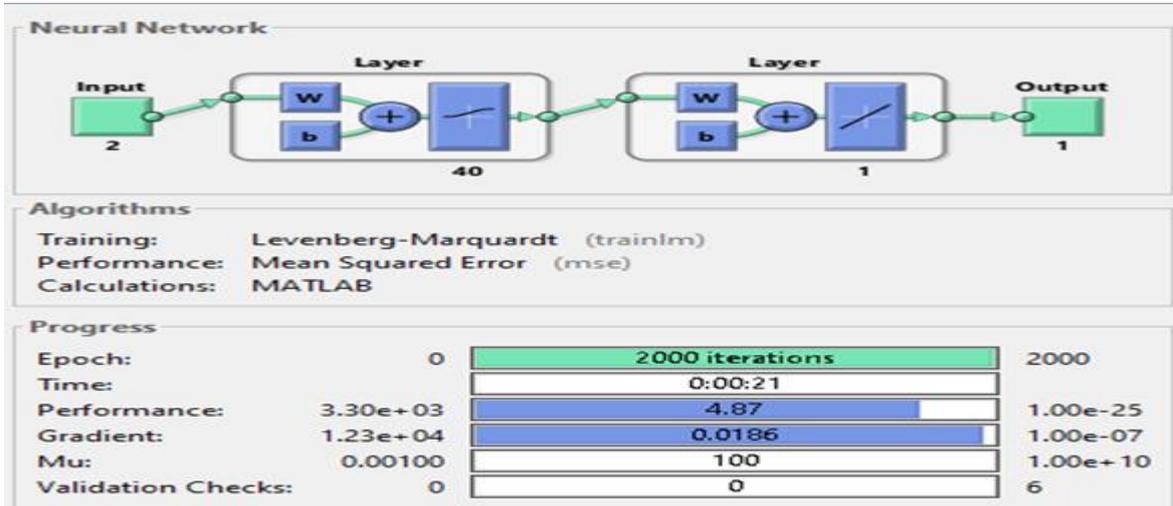
Figure 3.6.6. V_{mpp} mesuré a deux modules cc et v_{mpp} simulé a deux modules cc en fonction de temps

Sur ce figure 3.6.6 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart en volte entre v_{mpp} mesuré simulé a deux modules cc et v_{mpp} simulé a deux modules cc

Alors on peut dire que ce modèle a fait un bon apprentissage

c. La validation de modèle à quatre modules court circuité :

Le déroulement de script de modélisation en programme de simulation matlab affiche la fenêtre d'apprentissage de réseau de neurones suivante :



Le réseau de neurones il est entraîné par l'apprentissage pour cas de modèle à quatre modules court circuit

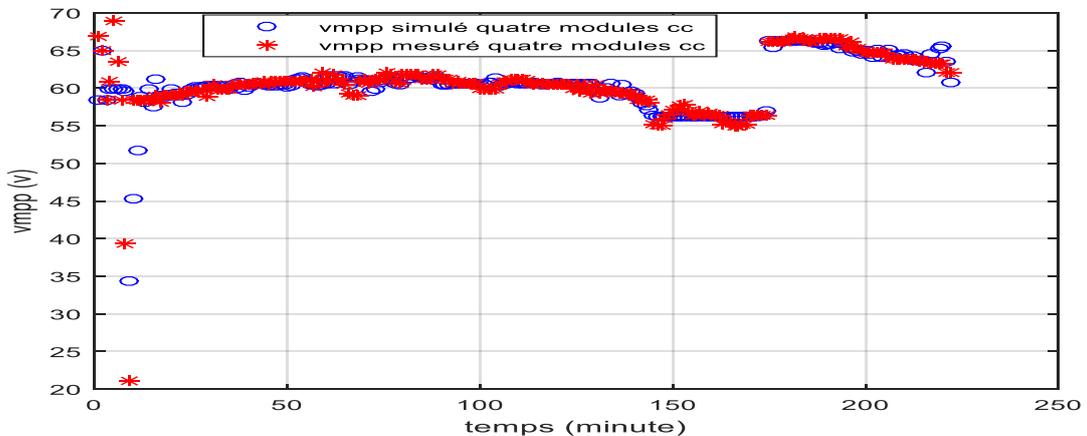


Figure 3.6.7. Modélisation d'un modèle défectueux à quatre modèles court circuité par réseau de neurone

Sur la figure 3.6.7 l'axe de x décrit le temps en minutes et l'axe de Y décrit la Vmpp (tension de point maximale a quatre modules cc)

Le graphe en rouge c'est le vmpp mesuré avec un deux modules court circuité et en bleu c'est la sortie obtenue par le réseau de neurone vmpp simulé avec deux modules court circuité

Le graphe de la tension de point maximale simulé a deux modules court circuité se superpose sur le graphe de tension de point maximale mesuré a deux modules court circuité donc on conclue que le modèle développé a bien réagit et l'écart entre le vmpp mesuré a quatre modules court circuité et vmpp simulé a quatre modules court est négligeable voir figure 3.6.8

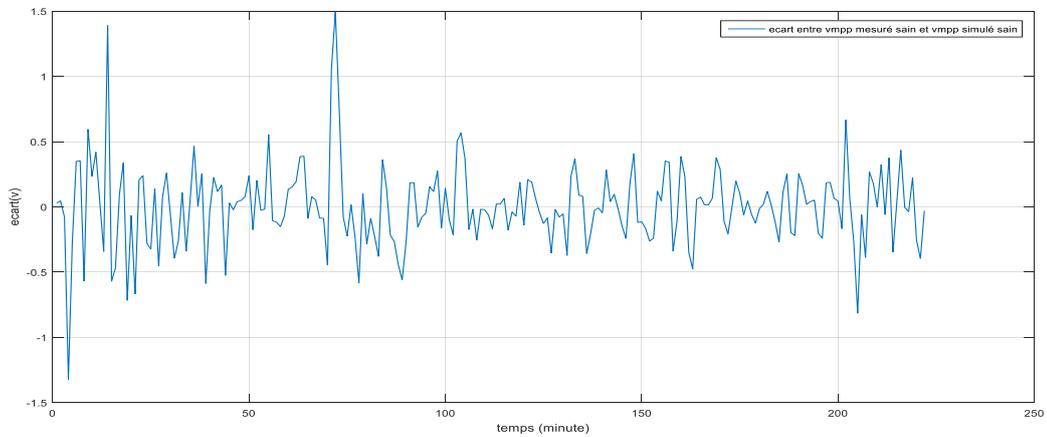


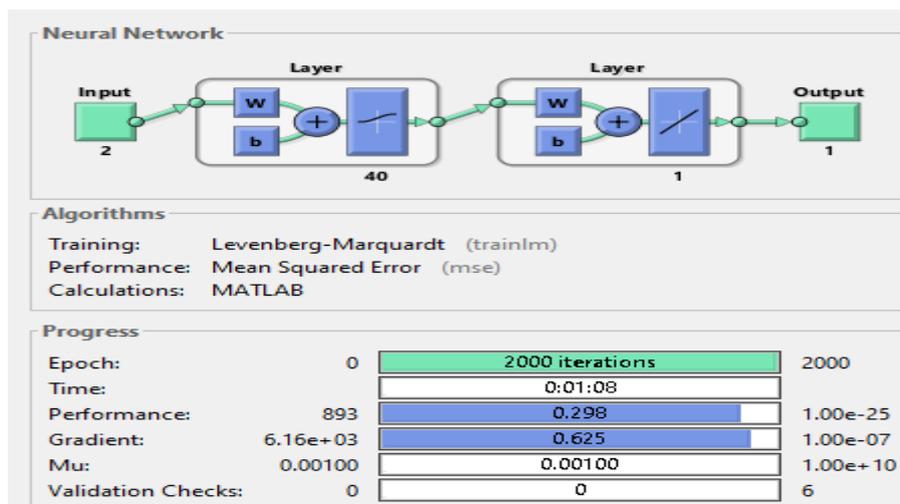
Figure 3.6.8. Ecart entre Vmpp mesuré a quatre modules cc et vmpp simulé a quatre modules cc en fonction de temps

Sur ce figure 3.6.8 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart en volte entre vmpp mesuré simulé a quatre modules cc et vmpp simulé a quatre modules cc

Alors on peut dire que ce modèle a fait un bon apprentissage

e. La validation de modèle à six modules court circuité

Le déroulement de script de modélisation en programme de simulation matlab affiche la fenêtre d'apprentissage de réseau de neurones suivante :



Le réseau de neurones il est entraîné par l'apprentissage pour cas de modèle à six modules court circuit

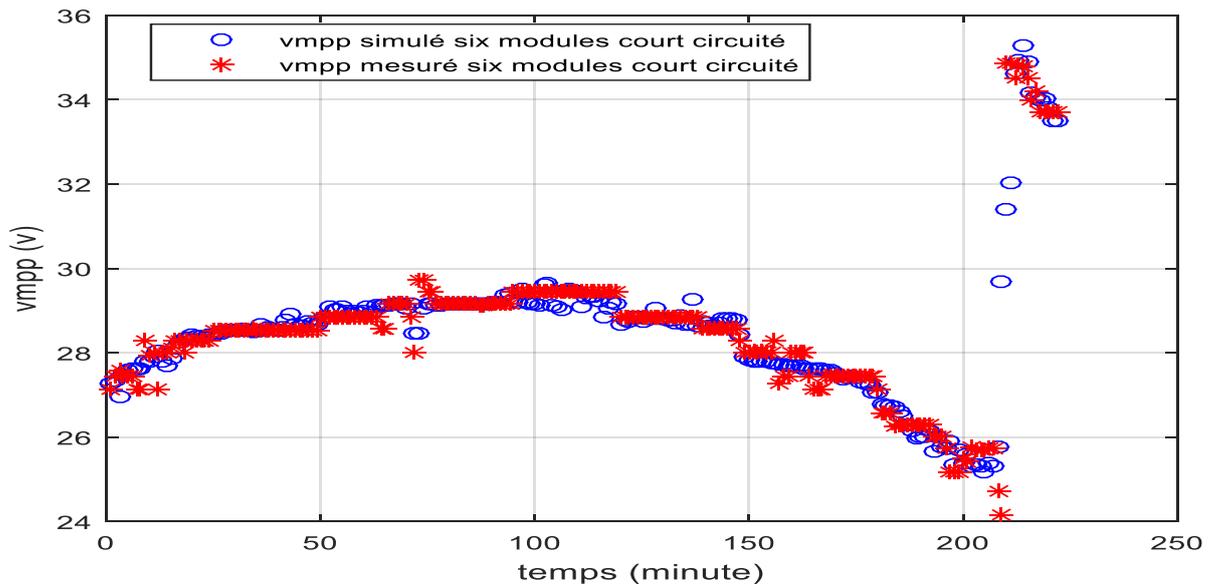


Figure 3.6.9. Modélisation d'un modèle déféctueux à six modèles court circuité par réseau de neurone

Sur la figure 3.6.9. l'axe de x décrit le temps en minutes et l'axe de Y décrit la V_{mpp} (tension de point maximale a six modules cc).

Le graphe en rouge c'est le v_{mpp} mesuré avec un deux modules court circuité et en bleu c'est la sortie obtenue par le réseau de neurone v_{mpp} simulé avec deux modules court circuité

Le graphe de la tension de point maximale simulé a deux modules court circuité se superpose sur le graphe de tension de point maximale mesuré a deux modules court circuité donc on conclue que le modèle développé a bien réagit et l'écart entre le v_{mpp} mesuré a deux modules court circuité et v_{mpp} simulé a deux modules court est négligeable voir figure 3.6.10

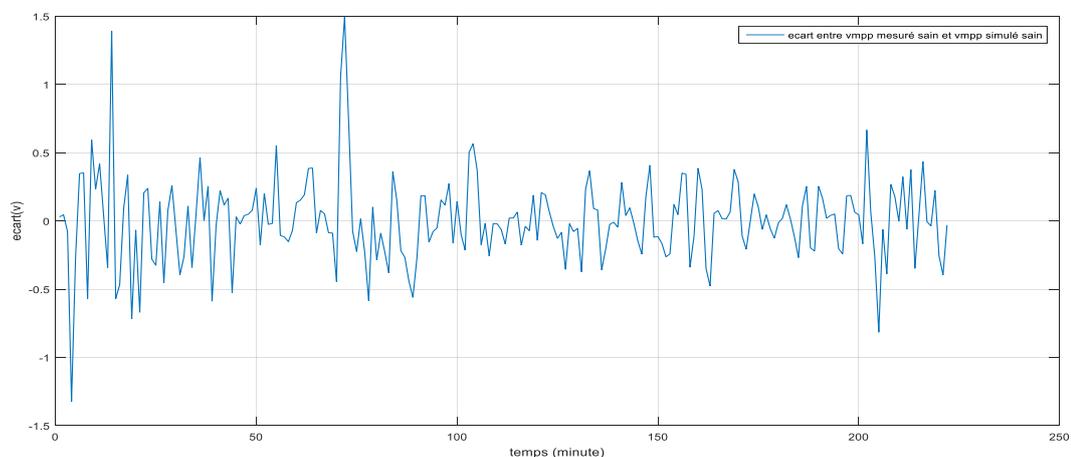


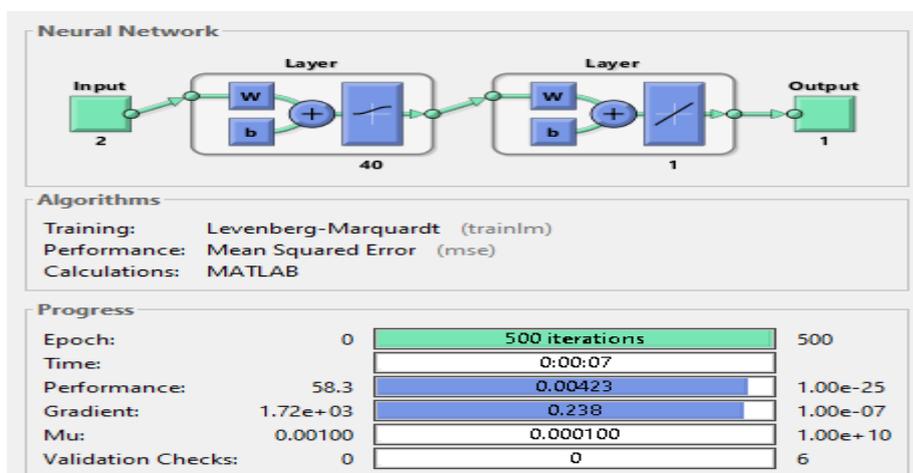
Figure 3.6.10. écart entre V_{mpp} mesuré a six modules cc et v_{mpp} simulé a six modules cc en fonction de temps

Sur ce figure 3.6.10 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart en volte entre v_{mpp} mesuré simulé a six modules cc et v_{mpp} simulé a six modules cc

Alors on peut dire que ce modèle a fait un bon apprentissage

f. La validation de modelé sain en courant

Après le déroulement de programme de modélisation de modèle sain nous obtenons les figures suivantes :



Le réseau de neurones il est entrainé par l'apprentissage pour cas de modèle courant sain

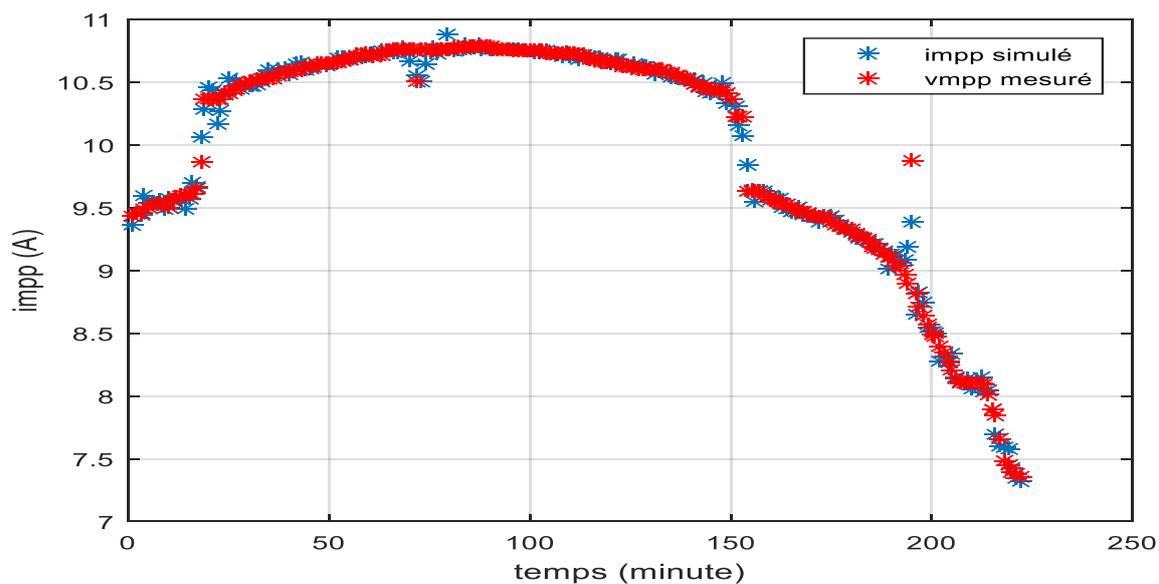


Figure 3.6.11. Modélisation d'un modèle sain courant par réseau de neurone

Sur ce figure 3.6.11 l'axe de x décrit le temps en minutes et l'axe de Y décrit la Imp_{pp} (courant de point maximale).

Le graphe en rouge c'est le imp_{pp} mesuré sain et en bleu c'est la sortie obtenue par le réseau de neurone imp_{pp} simulé sain.

Le graphe de le courant de point maximale simulé sain se superpose sur le graphe de courant de point maximale mesuré sain donc on conclue que le modèle développé a bien réagit et l'écart entre le imp_{pp} mesuré sain et imp_{pp} simulé sain est négligeable voir figure 3.6.12

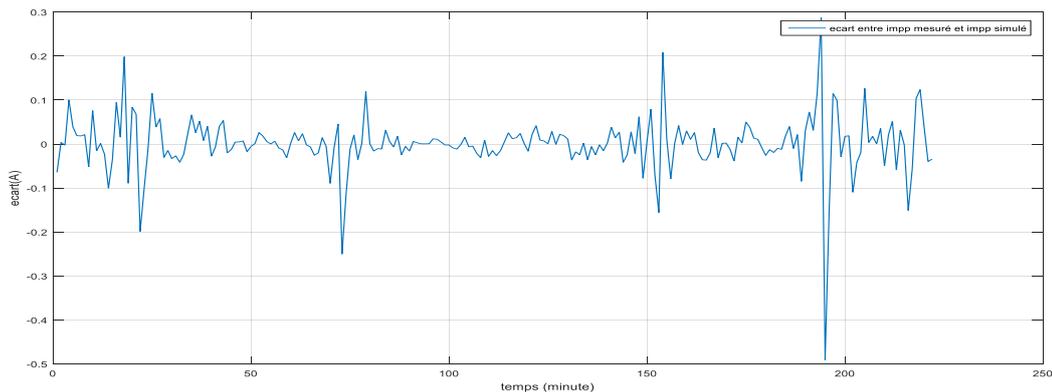


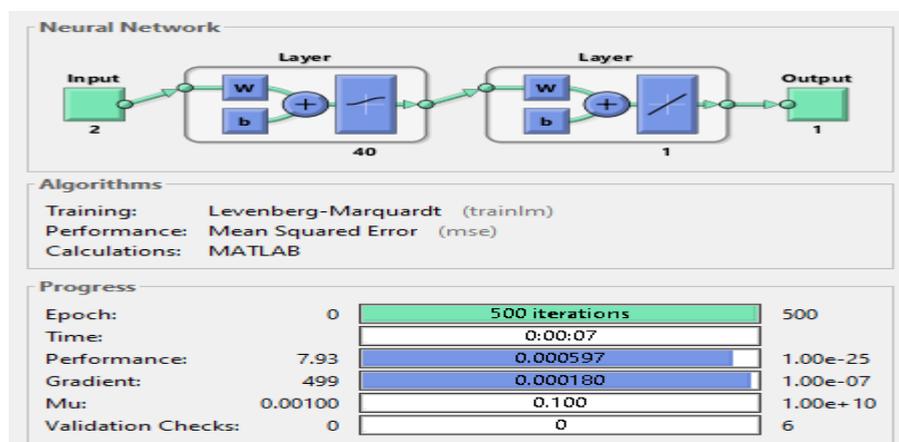
Figure 3.6.12. écart entre imp_{pp} mesuré sain et imp_{pp} simulé sain en fonction du temps

Sur ce figure 3.6.12 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart imp_{pp} mesuré sain et imp_{pp} simulé sain en volte

Alors on peut dire que ce modèle a fait un bon apprentissage

g. La validation de modèle défectueux (panne string)

Après le déroulement de programme de modélisation de modèle sain nous obtenons les figures suivantes :



Le réseau de neurones il est entraîné par l'apprentissage pour cas de panne string

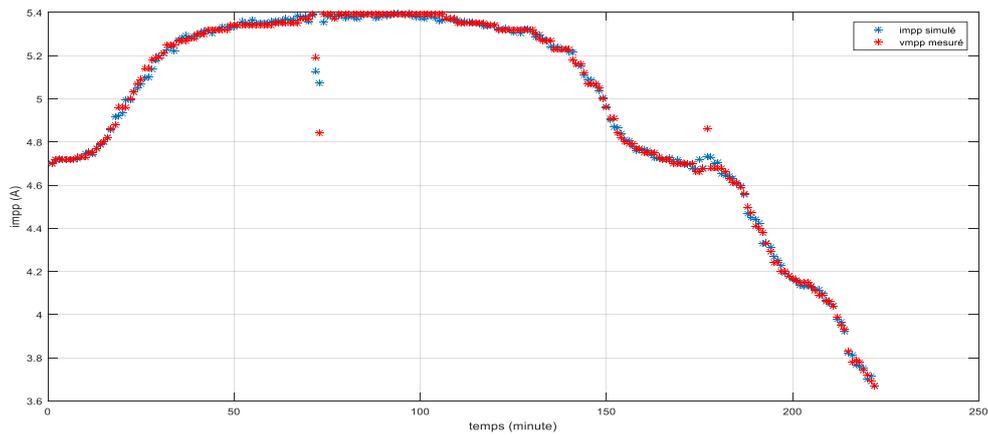


Figure 3.6.13. Modélisation d'un modèle de la panne string par réseau de neurone

Sur ce figure 3.6.13 l'axe de x décrit le temps en minutes et l'axe de Y décrit la $Impp$ (courant de point maximale).

Le graphe en rouge c'est le $impp$ mesuré string et en bleu c'est la sortie obtenue par le réseau de neurone $impp$ simulé string

Le graphe du courant de point maximale simulé string se superpose sur le graphe de courant de point maximale mesuré string donc ont conclu que le modèle développé a bien réagit et l'écart entre le $impp$ mesuré string et $impp$ simulé string est négligeable , voir figure 3.6.14

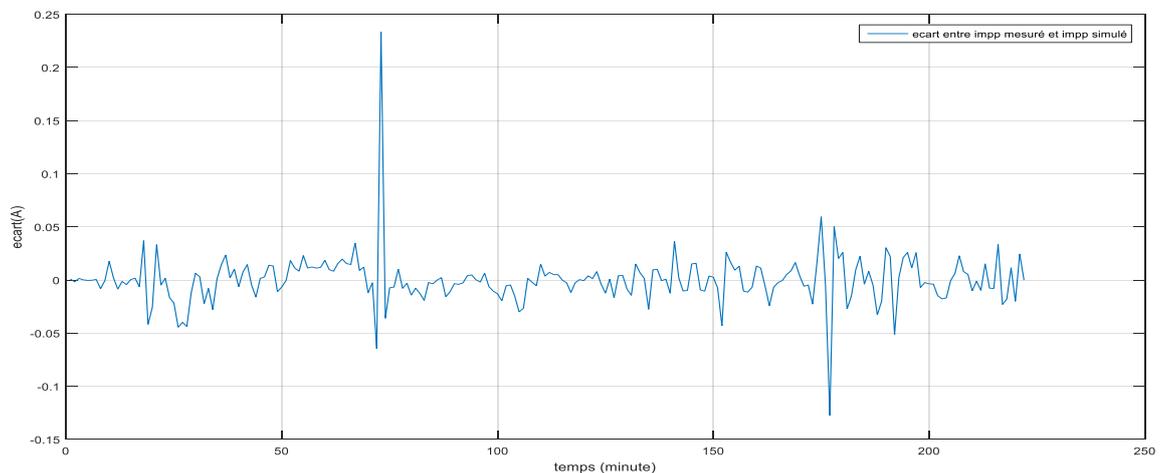


Figure 3.6.14. l'écart entre $impp$ mesuré string et $impp$ simulé string en fonction du temps

Sur ce figure 3.6.14 l'axe de x décrit le temps en minutes et l'axe de Y décrit écart entre $impp$ mesuré string et $impp$ simulé string en volte

Alors on peut dire que ce modèle a fait un bon apprentissage

3.7 EXPLOITATION DES RESULTATS

3.7.1 DÉFINITION D'ERREUR RELATIVE MOYENNE

L'erreur relative n'a pas d'unité ; elle nous indique la qualité (l'exactitude) du résultat obtenu. Elle s'exprime généralement en % (pour cent). [22]

L'équation de l'erreur relative moyenne :

$$Erm = \left(\frac{1}{n} \sum_{i=1}^n \frac{|Datam - Datas|}{Datam} \right) * 100$$

Où :

n : nombre d'échantillons

Datam : données mesurées

Datas : données simulées

Le résultat en pourcentage

3.7.2 CLASSIFICATION DU SYSTEME PAR CALCUL ET COMPARAISON D'ERREUR RELATIVE MOYENNE ERM

Dans les figures ci-dessous, nous sommes passés à la phase de classification et diagnostique du système par calcul de d'erreur relative moyenne et la comparaison entre Erm avec une valeur bien préciser pour classer

Le tableau 3, montre les différentes classes des deux paramètres avec la décision finale du système :

Impp	Vmpp	Système
Impph	Vmpph	Système sain
Impph	Vmpp1sc	La détection de la panne se réfère à un court-circuit de panneau
Impph	Vmpp2sc	La détection de la panne se réfère à deux panneaux court-circuit
Impph	Vmpp4sc	La détection de la panne se réfère à quatre panneaux court-circuit
Impph	Vmpp6sc	La détection de la panne s se réfère à six panneaux en court-circuit
Imppstring	Vmpph	La détection de la panne se réfère à la chaîne

Table 3. 3. Diagnostique du system

a. Cas sain avec leurs pannes (tension)

Figure 3.6.14 regroupé le graphe de cas sain avec quatre différentes pannes

- Cas un seul module court circuité
- Cas de deux modules court circuité
- Cas de quatre modules court circuité
- Cas de six modules court circuité

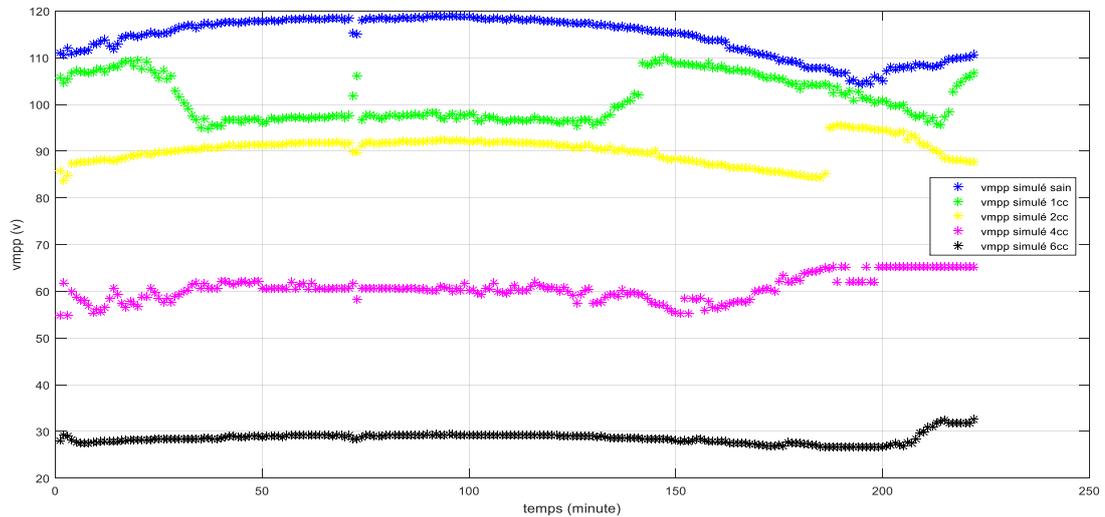


Figure 3.6.15. Différentes cas possible de fonctionnement

Sur ce figure 3.6.15 l'axe de x décrit le temps en minutes et l'axe de Y vmpp simule (tension de point maximale simule).

Le graphe en bleu c'est le vmpp simule sain tension et en vert c'est le vmpp simulé avec un seul module cc, le jaune c'est vmpp simulé avec deux module cc, le violet vmpp simulé avec quatre module cc et en noire vmpp simulé avec six module court circuit

b. Cas du système avec un module court circuité

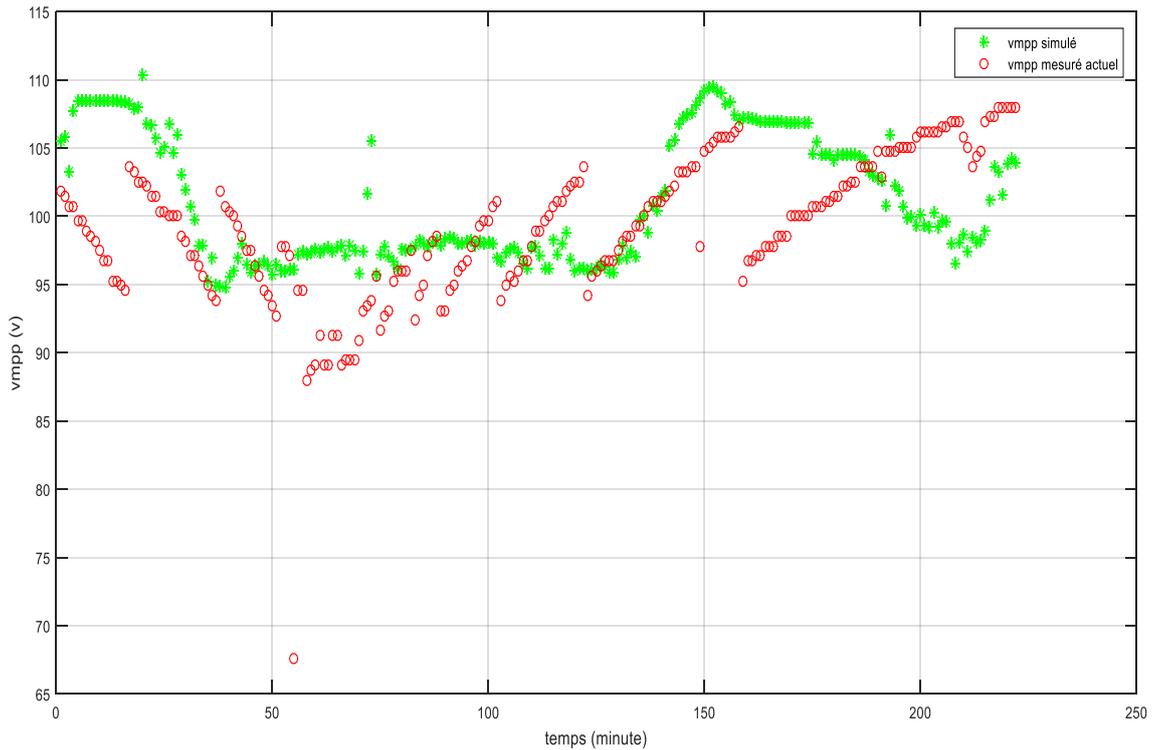


Figure 3.6.16. Classe 1 de la classification de tension maximale du point de puissance.

Sur ce figure 3.6.16. L'axe de x décrit le temps en minutes et l'axe de Y $vmpp$ (tension de point maximale).

Le graphe vert c'est le $vmpp$ simulé avec un seul module cc et le rouge c'est le $vmpp$ capturé a classifié

Nous remarquons que le graphe en rouge est souvent trouvé dans la zone de un module court-circuité donc en peut dire que la nature de la panne est un panne class 2 (un module court circuité)

Résultat affiché commande Window :

```
class 2 : détection de panne se réfère à un court-circuit de panneau
erreur relative moyenne = 4.5911 %
>>
```

c. cas du système avec six modules court circuité

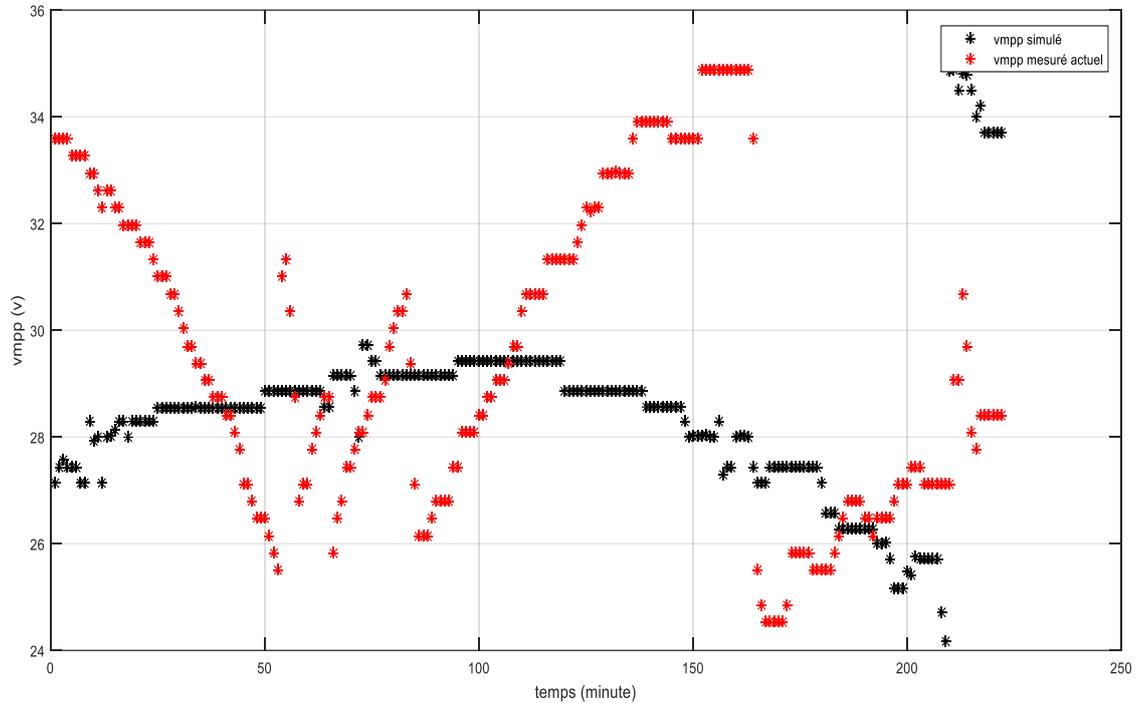


Figure 3.6.17. Classe 5 de la classification de tension maximale du point de puissance.

Sur ce figure 3.6.17 l'axe de x décrit le temps en minutes et l'axe de Y vmpp simule (tension de point maximale simule).

Le graphe en noire vmpp simulé avec six module cc et avec le rouge le vmpp de classification (données six modules cc)

Nous remarquons que le graphe en rouge est souvent trouvé dans la zone de six modules cc donc en peut dire que la nature de la panne est une panne class 6 (six modules cc)

Résultat affiché commande Window :

```
class 5 : détection de panne se réfère à six panneaux court-circuit  
erreur relative moyenne = 8.48 %
```

d. Cas de courant sain avec quelque panne

La classification de courant se base sur le calcul et comparaison de l'erreur quadratique moyenne (RMSE)

❖ Définition de RMSE

L'erreur quadratique moyenne (RMSE) (également appelée écart quadratique moyen, RMSD) est une mesure fréquemment utilisée de la différence entre les valeurs prédites par un modèle et les valeurs réellement observées à partir de l'environnement en cours de modélisation. Ces différences individuelles sont également appelées résidus, et le RMSE sert à les agréger en une seule mesure du pouvoir prédictif. [22], Et peuvent être écrites comme :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Dat_{as} - Dat_{am})^2}$$

Où :

Dat_{am} : données mesurées

Dat_{as} : données simulées

n : nombre d'échantillons validés

La figure 3.6.16 combiné entre le graphe de cas sain courant avec la panne string

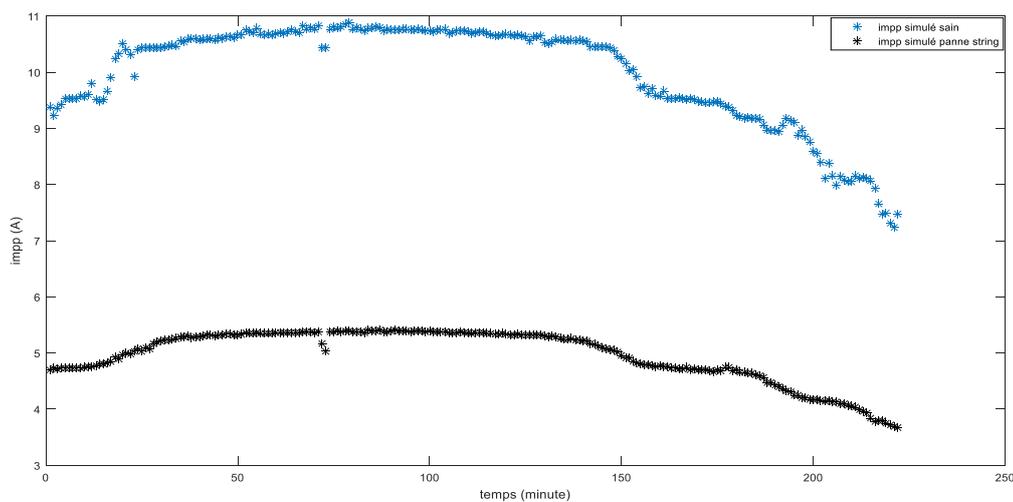


Figure 3.6.18. Différentes cas possible de fonctionnement

Sur ce figure 3.6.18 l'axe de x décrit le temps en minutes et l'axe de Y impp simule (tension de point maximale simule).

Le graphe en bleu c'est le impp simule sain courant et en noire impp string

On remarque voit qu'il ya un grand écart entre impp sain et impp string

e. cas du système avec une panne string

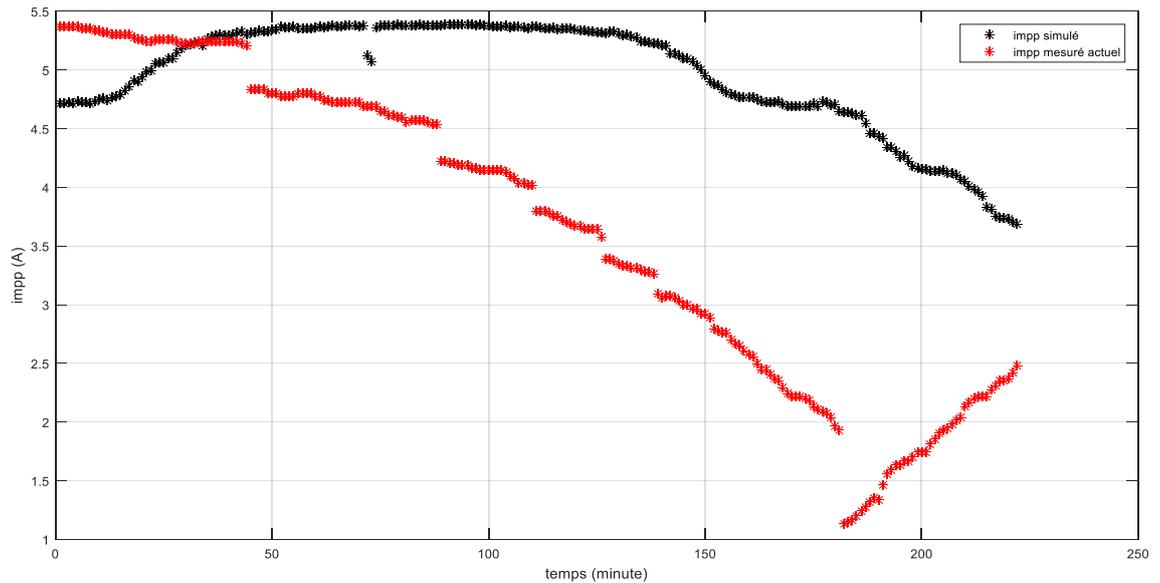


Figure 3.6.19. Classe 6 de la classification de courant maximale du point de puissance.

Sur ce figure 3.6.19. L'axe de x décrit le temps en minutes et l'axe de Y impp simule (tension de point maximale simule).

Le graphe en noire impp simulé avec le modèle de la panne string et avec le rouge le impp a classifie

```
class 6 : Mauvais fonctionnement due à panne string
erreur quadratique moyenne = 1.6725 .
^^
```

f. Cas du système avec une autre panne de courant

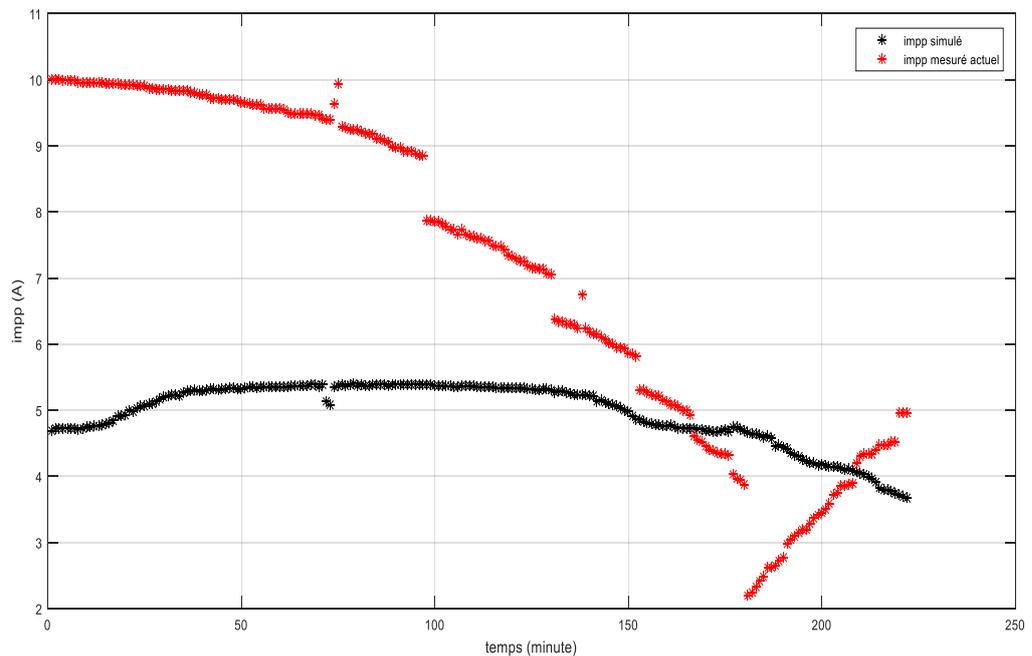


Figure 3.6.20. Class non définie

Sur ce figure 3.6.20 l'axe de x décrit le temps en minutes et l'axe de Y impp simule (tension de point maximale simule).

Le graphe en noire c'est le impp simulé en cas de panne string et on rouge impp capté a classifie
Nous remarquons que le graphe en rouge se ne trouve hors et écarté de la zone de la panne string donc en peut rien (class de la panne de courant non définie)

```
class non définie : Mauvais fonctionnement due à une autre panne de courant  
erreur quadratique moyenne = 3.1234 .
```

Conclusion générale

L'énergie solaire photovoltaïque est classée parmi les trois premières énergies renouvelables au monde après les énergies hydraulique et éolienne. Cette énergie atteint une capacité cumulée mondiale de 177GW à la fin 2014.

Chaque type de ces énergies rencontre des pannes durant leur cycle de vie, pour cela il faut détecter puis diagnostiquer le système à chaque instant, afin d'éviter toute perte de rendement, d'énergie, de matériel et d'indice de performance de l'installation photovoltaïque qui représente une valeur très importante pour la qualité du système.

Pour le moment, les techniques d'intelligence artificielle s'imposent pour le diagnostic du système solaire photovoltaïque, un réseau de neurone artificiel est utilisé en ordre pour modéliser des différents types de pannes apparus dans un champ photovoltaïque et pour l'identification des modules court-circuit avec réseaux de neurones artificiels

Dans le présent travail, nous proposons toutes les pannes court-circuit que nous avons nommé plus tôt, que parmi, la panne string (courant) existe qui n'a jamais été étudiée lors d'un diagnostic par intelligence artificielle, cette panne il faut la détecter et classer et ça notre objectif

Pour pouvoir arriver à la détection et la classification de ces pannes il faut passer d'abord par la création puis la modélisation du réseau neurone approprié

On a opté pour ce type de méthode de diagnostic basé sur le calcul et la comparaison de l'erreur relative moyenne pour la classification de tension et le courant en utilisant l'erreur quadratique moyenne et on a obtenu des résultats très satisfaisants

Selon nos connaissances est parmi les premiers précurseurs ce diagnostic a été fait à notre connaissance par une intelligence artificielle

Bibliographie

- [1] L. Bun. "Détection et localisation de défauts dans un système photovoltaïque". Thèse de Doctorat. Université de Grenoble, 2011.
- [2] E.Schiller. "Le pompage photovoltaïque, manuel de cours à l'intention des ingénieurs et des techniciens". Université d'Ottawa, 1998.
- [3] J.P.Joly. "Focus Technique Photovoltaïque Un Nouvel Éclairage". L'Institut National de l'Energie Solaire (INES) Paris, mars 2011.
- [4] A.Zerga. "Optimisation du rendement d'une cellule solaire à base de silicium monocristallin de type n+p". Mémoire de Magister. Université de Tlemcen, 1998.
- [5] Z.Bendjellouli. "Contribution à la modélisation d'une cellule solaire". Mémoire de Magister. Université de Bechar, 2009.
- [6] A.Bisker et M.Chiri. "Commande d'un système photovoltaïque en mode isolé et en mode Connecté au réseau". Mémoire de Master école nationale polytechnique, 2012.
- [7] O.Ernst et N.Young. "Étude de développement de l'énergie Solaire". Rhône-Alpes, december 2010.
- [8] S. Petibon. "Nouvelles architectures distribuées de gestion et de conversion de l'énergie pour les applications photovoltaïques". Université de Toulouse, 2009.
- [9] M. Belhadj. "Modélisation d'un système de captage photovoltaïque". Mémoire de Magister. Université de Béchar, 2008.

- [10] P. Sabaiter. "Contribution à l'optimisation, la gestion et le traitement de l'énergie". Université –Toulous III, décembre 2003.
- [11] M.Boukhli, O.Hacen. "Conception et réalisation un Générateur PV Muni d'un convertisseur MPPT pour une meilleure gestion énergétique". Mémoire de Magister. Université Aboubaker Bel Kaid Telemcen 2011.
- [12] Martin A.Green « Silicon solar cells: At the crossroads ». Progress in Photovoltaics; Research and applications . Vol. 8, pp 443-440 . 2000.
- [13] Richard C.Neville. Solar Energy Conversion: The Solar Cell, vol. 1 of Studies in Electrical and Electronic Engineering. Elsevier Scientific Publishing Company, New York, N Y, 1978.
- [14] B.K. Bose, « Fuzzy logic and Neural Networks», IEEE Industry Applications Magazine, pp.57-61, may/juin 2000.
- [15] B.K. Bose, « Artificial Neural Network Applications in Power Electronics»,IEEE Industrial Electronics Society, pp. 1631-1638, 2001.
- [16] N.DRIR, L. Barazane, M.Loudini: « Optimizing Operation of Photovoltaic System Using Neural Network and Fuzzy Logic». International conference of electrical engineering, Paris 2014.
- [17] Mellit, A., S.A. Kalogirou, L. Hontoria and S.Shaari « Artificial intelligence techniques for sizing photovoltaic systems» Renewable and Sustainable Energy Reviews, Vol. 13 n°2, (2009), pp. 406-419
- [18] L.Barazane, « Application des systèmes Emergents à la commande d'un moteur Asynchrone», Thèse de Doctorat d'état, ENP, Alger, 2003
- [19] J.G. Taylor, « The promise of neural networks», Springer-Verlag, New York, 1983.
- [20] E. Davalo, P. Naim « Des Réseaux de Neurones», Edition Eyrolles, 1993
- [21] D. GRAHAM and R.C. LATHROP: « The synthesis of optimum transient response : criteria and standard forms». Transactions of the American Institute of Electrical Engineers, Part2: Applications and Industry, 72 (1953), 273–288.

