



# Apprentissage par réseau de neurone pour l'extraction des paramètres du module photovoltaïque Uni-solar 64Wc

Sabrina BELAID<sup>#1</sup>, Abdelhamid BOUALIT<sup>#1</sup>  
<sup>#1</sup>Unité de recherche appliquée en énergie renouvelables URAER

Garaat ataam BP N° 88, Noumerat, Ghardaïa,

[sabribelaid@yahoo.fr](mailto:sabribelaid@yahoo.fr)

[hboualit@yahoo.fr](mailto:hboualit@yahoo.fr)

**Résumé**— Vu que les paramètres électriques des panneaux photovoltaïques dépendent essentiellement de l'éclairement et de la température, et pour les extraire, nous devons résoudre des équations non linéaires de l'évolution du courant  $I$  en fonction de la tension  $V$ . Alors, pour se passer de la résolution de ces équations et avoir une meilleure précision, on fait appel aux techniques de l'intelligence artificielle telle que les réseaux de neurones. Le réseau ainsi choisit est entraîné une fois à partir de quelques ensembles de données courant-tension, ensuite, il est utilisé afin d'extraire les paramètres électriques du panneau photovoltaïque pour différents couple d'éclairement et de température sans passer par la résolution de certaines équations décrites à partir du circuit électrique équivalent. A fin de vérifier la conformité de l'apprentissage de notre réseau de neurones, nous avons effectué une comparaison entre les valeurs mesurées de courant-tension et celles déduites du modèle du réseau.

**Mots clés**— Panneaux photovoltaïque, caractérisation, réseau de neurones

## I. INTRODUCTION

La modélisation des cellules photovoltaïques demeure toujours d'une importance capitale pour le bon dimensionnement et fonctionnement des installations solaires. La cellule photovoltaïque est généralement représentée par un circuit équivalent dont les paramètres sont calculés expérimentalement en utilisant la caractéristique courant-tension,  $I$ - $V$ , mais la détermination exacte de ces paramètres à toujours été un challenge pour les chercheurs et pour ça, de nombreux travaux ont été menés ([1], [2], [3], [4], [5]) pour la modélisation mathématiques via des schémas électriques équivalent dédiées à la caractérisation paramétriques de ces cellules solaires qui représentent un comportement très fortement non linéaire, qui changent en fonction de la température et de l'éclairement. Parmi ces modèles, nous avons les modèles caractéristiques à une diode et à deux diodes qui sont fortement utilisés.

Dans cet article, l'objectif est de définir les différents paramètres électriques caractérisant le module Uni-solar dans son fonctionnement réel à savoir ; le courant de saturation, le

photo-courant, la résistance série, la résistance parallèle, et le facteur d'idéalité de la diode, pour différents éclaircements et températures en utilisant les réseaux de neurones.

Des mesures expérimentales ont été d'abord effectués sur le panneau solaire Uni-solar 64Wc, à Ghardaïa, et les caractéristiques courants-tensions ont été prise à l'aide d'une charge électronique qui nous permet d'avoir 100 points pour chaque courbe  $I/V$  (Courant-Tension), cette charge est accompagné d'une cellule calibré pour la mesure directe de l'éclairement  $G$  sur le plan du module et de sa température  $T$  (température de la cellule).

Dans la première partie, une méthode numérique est utilisée pour la résolution de l'équation non linéaire de la caractéristique  $I$ - $V$  afin de déterminer les paramètres électriques, qui seront ensuite exploités pour l'apprentissage du réseau de neurone dans la deuxième partie.

## II. MODELISATION D'UN ENSEMBLE DE DONNEES

### COURANT-TENSION

Afin de déterminer le comportement électrique d'un module photovoltaïque, le modèle classique à une diode est appliqué [6], le circuit électrique est montré par la Fig.1.

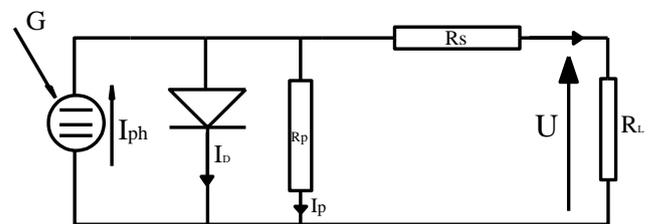


Fig.1 : Circuit équivalent d'une cellule photovoltaïque

En appliquant la loi de Kirchoff au circuit ci-dessus, le modèle d'équation pour une cellule solaire est comme suit :

$$I = I_{ph} - I_s \left[ \exp\left(\frac{q \cdot (U + R_s \cdot I)}{n \cdot k \cdot T}\right) - 1 \right] - \frac{U + R_s \cdot I}{R_p} \dots (1)$$



# Le 2<sup>ème</sup> Séminaire International sur les Energies Nouvelles et Renouvelables

## The 2<sup>nd</sup> International Seminar on New and Renewable Energies

Unité de Recherche Appliquée en Energies Renouvelables,  
Ghardaïa – Algérie 15, 16 et 17 Octobre 2012



De nouveaux paramètres ont été introduits dans l'équation (1), en posant : [7]

$$I_{ph} + I_s = a, \quad I_s = -b, \quad c = q/(n.k.T), \quad d = c \cdot R_s, \quad R_p = f$$

I : Courant, A

U : Tension, V

G : Eclairement sur la cellule, W/m<sup>2</sup>

R<sub>s</sub> : Résistance série, Ω

I<sub>s</sub> : Courant de saturation de la diode, A

R<sub>L</sub> : Résistance de charge, Ω

n : Facteur d'idéalité de la diode

I<sub>ph</sub> : Photo courant, A

R<sub>p</sub> : Résistance parallèle, Ω

q : Charge de l'électron, 1,602.10<sup>-19</sup> Ws/V

T : Température de la cellule, K

k : Constante de Boltzmann, 1,3806.10<sup>-23</sup> J/K

L'équation simplifiée est comme suit :

$$I = a + b \cdot \exp(cU + dI) - (U + dI / c) / f \quad \dots\dots\dots(2)$$

L'équation (2) a été adaptée et exploitée pour un ensemble de donnée courant-tension pris sur le module amorphe Uni-solar.

Pour la détermination des paramètres a, b, c, d, et f, pour chaque ensemble de donnée courants tensions, nous avons utilisé un algorithme d'optimisation non linéaire, pour minimiser l'erreur quadratique entre les valeurs mesurées et celle déterminées par le modèle (moindre carrée pour un problème non linéaire).

La figure.2 montre la caractéristique I-V mesurée ainsi que celle du modèle (2) pour le module Uni-solar à la température 22°C et un éclairement de 951 W/m<sup>2</sup>.

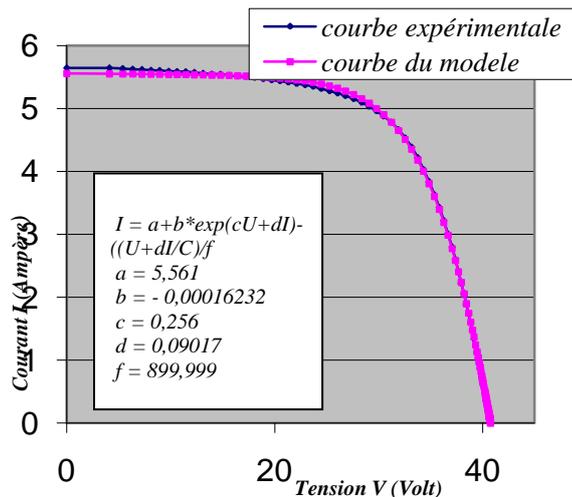


Fig.2 : Caractéristiques I-V du module Uni-Solar 64 Wc

A partir des paramètres a, b, c, d, f obtenus, on peut déterminer les paramètres physiques du module :

$$I_{ph} = 5.561 \text{ A}$$

$$I_s = 1.623 \text{ E-04 A}$$

$$R_p = 899.99 \text{ } \Omega$$

$$R_s = 0.352 \text{ } \Omega$$

$$n = 143.46$$

$$n_{cell} = 143.46 / 72 = 1.993$$

De la même manière, on procèdera pour quelques ensembles de données courant tension pris sur le module pour une température comprise entre 18°C et 24.6°C, et un éclairement compris entre 771 W/m<sup>2</sup> à 1035 W/m<sup>2</sup>.

Pour notre travail, nous avons pris 9 échantillons de mesures I-V qui serviront ensuite pour l'apprentissage de notre réseau de neurone.

Les résultats sont montrés dans le tableau 1.

TABLEAU 1

le photo courant **I<sub>ph</sub>**, le courant de saturation **I<sub>s</sub>**, le facteur d'idéalité **n**, la résistance série **R<sub>s</sub>**, et la résistance parallèle **R<sub>p</sub>** à différents éclairement **G** et température **T**.

T	G	n	I <sub>s</sub>	I <sub>ph</sub>	R <sub>p</sub>	R <sub>s</sub>
18.0	771	3.4825	3.35E-05	4.1401	96.2291	0.3206
20.3	820	3.3849	3.14E-05	4.4507	95.0000	0.3186
20.2	865	3.6076	6.55E-05	4.7667	66.6703	0.2773
21.6	909	3.5900	7.31E-05	5.0696	61.9717	0.2804
22.0	951	3.5813	7.42E-05	5.3204	60.4767	0.2853
23.1	984	3.5832	8.44E-05	5.5506	55.9436	0.2796
24.0	1 011	3.5726	8.96E-05	5.7215	53.6857	0.2810
24.6	1 027	3.5570	8.95E-05	5.8113	53.2711	0.2814
23.5	1 035	3.6074	9.39E-05	5.8379	52.3716	0.2802

### III. RÉSEAUX DE NEURONES

#### A. Historique

En 1943, deux biophysiciens de Chicago, McCulloch et Pitts inventent le premier neurone formel déduit à partir du neurone biologique qui est un type de cellule constituant l'unité fonctionnelle du système nerveux et qui assure la transmission du signal (influx nerveux).

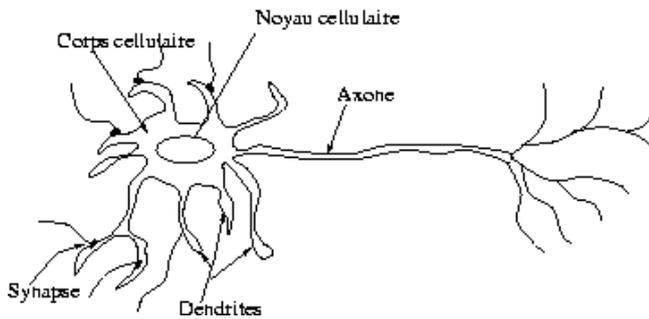


Fig.3 : le neurone biologique

Quelques années plus tard, en 1949, Hebb propose une formulation du mécanisme d'apprentissage, sous la forme d'une règle de modification des connexions synaptiques (règle de Hebb).

En 1958, c'est le premier réseau de neurones artificiels qui apparaît grâce aux travaux de Rosenblatt, appelé le perceptron. Ce réseau parvient à apprendre à identifier des formes simples et à calculer certaines fonctions logiques. Il constitue donc le premier système artificiel présentant une faculté jusque là réservée aux êtres vivants : la capacité d'apprendre par l'expérience. Mais malheureusement, ce perceptron soulève particulièrement son incapacité à résoudre les problèmes non linéairement séparables, tels que le célèbre problème du XOR (OU exclusif) et il a fallu attendre début des années 80 et le génie de Hopfield pour que l'intérêt pour ce domaine soit de nouveau présent. En effet, Hopfield démontre en 1982 tout l'intérêt d'utiliser des réseaux récurrents (dits "feed-back") pour la compréhension et la modélisation des processus mnésiques. Les réseaux récurrents constituent alors la deuxième grande classe de réseaux de neurones, avec les réseaux type Perceptron (dits "feed-forward").

En parallèle des travaux de Hopfield, Werbos conçoit son algorithme de rétro propagation de l'erreur, qui offre un mécanisme d'apprentissage pour les réseaux multicouches de type Perceptron (appelés MLP pour Multi-layer Perceptron), fournissant ainsi un moyen simple d'entraîner les neurones des couches cachées. Cet algorithme de "back-propagation" ne sera pourtant popularisé qu'en 1986 par Rumelhart.

### B. Le neurone formel

Un neurone formel est une représentation mathématique et informatique du neurone biologique. Les neurones formels sont regroupés en réseaux de neurones. Grâce à des algorithmes d'apprentissage automatique, on peut régler un réseau de neurones pour lui faire accomplir des tâches qui relèvent de l'intelligence artificielle [8].

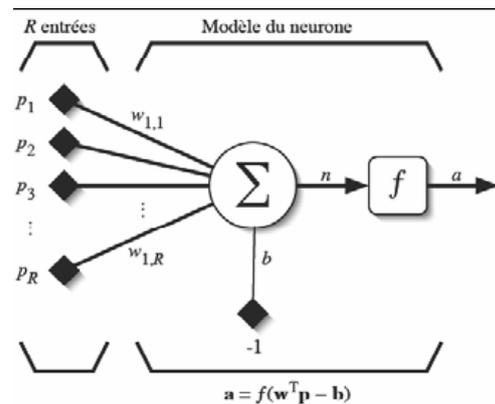


Fig.4 : Representation du neurone

Tel que :

$P_1 ; P_R$  : Les entrées (Dendrites)

$W$  : Les poids du neurone (Synapses : contenant de l'information)

$\Sigma$  : Fonction de sommation.

$f$  : Fonction d'activation.

$a$  : La sortie

$b$  : Biases.

$$n = \sum_{j=1}^R W_{1,j} P_j - b = W_{1,1} P_1 + W_{1,2} P_2 + \dots + W_{1,R} P_R - b \quad \dots (3)$$

Et

$$a = f(n) \quad \dots (4)$$

Parmi les fonctions d'activations  $f$ , on cite les plus utilisées

➤ Une fonction sigmoïdale :

$$f_{sig}(x) = \frac{1}{1 + \exp(-x)} \quad \dots (5)$$

➤ Une fonction tangente hyperbolique :

$$th(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad \dots (6)$$

➤ Une fonction identité

Donc, un neurone formel réalise une somme pondérée suivie d'une non linéarité. Et c'est l'association de tels



## Le 2<sup>ème</sup> Séminaire International sur les Energies Nouvelles et Renouvelables

### The 2<sup>nd</sup> International Seminar on New and Renewable Energies

Unité de Recherche Appliquée en Energies Renouvelables,  
Ghardaïa – Algérie 15, 16 et 17 Octobre 2012



éléments simples sous la forme de réseaux qui permet de réaliser des fonctions plus complexes utiles pour des applications industrielles.

Aujourd'hui le domaine d'application des réseaux recouvre aussi bien la reconnaissance de formes, que le contrôle de processus, la détection de faillites, la segmentation de marchés, la prévision de séries temporelles,.....

#### C. Architecture du réseau de neurone

Le choix d'une architecture adéquate de réseau de neurones est primordiale pour obtenir un système performant ou tout au moins fonctionnel. Or plusieurs aspects sont à considérer lors de la conception dont les plus importants sont :

- le nombre d'entrées et de sorties
- le nombre de couches de neurones
- le nombre de neurones dans chaque couche
- les interconnexions entre les couches (récurrentes ou non récurrentes)
- le choix de la fonction d'activation

En règle général, plus un réseau de neurone a d'entrées et plus la résolution du problème est complexe, plus il faudra de neurones en couche cachée (lin et Lee 1955).

Une technique souvent utilisée consiste à effectuer l'apprentissage d'une première topologie de réseau avec beaucoup de neurones en couche cachée et de diminuer ce nombre jusqu'à ce que les performances commencent à se dégrader. Il est aussi possible de commencer avec une structure simple, pour ensuite la complexifier jusqu'à l'atteinte des performances souhaitées.

#### D. L' apprentissage

Comme le cerveau humain, les réseaux de neurones artificiels peuvent apprendre par expérience. Ainsi suite à l'application séquentielle de plusieurs entrées à apprendre, les algorithmes d'apprentissage modifient la valeur des poids entre les neurones ainsi que la valeur des biais de façon à améliorer la performance du réseau de neurone. En fait, l'ajustement des poids est plus au moins efficace tout dépendamment de la connaissance que nous avons du système à modéliser ou du problème à résoudre. Ainsi, trois grandes classes d'apprentissage existent :

- Apprentissage non supervisé : c lorsqu'il n'y a pas de connaissances a priori des sorties désirées pour des entrées données. L'algorithme d'apprentissage utilisé ajuste les poids de façon à maximiser la qualité de classification des entrées.
- Apprentissage par renforcement : les sorties idéales ne sont pas connus directement, et les poids sont ajustés de

façons plus au moins aléatoire , ensuite la modification est conservée si l'impact est positif ou rejetée sinon.

- Apprentissage supervisé (back propagation) : cet algorithme ne peut être utilisée que lorsque les entrées ainsi que les sorties désirées sont connus. L'ajustement des poids se fait directement à partir de l'erreur, qui est la différence entre la sortie obtenu par le réseau de neurone et celle désirée.

#### E. Application au problème

C'est ce dernier type d'apprentissage basé sur l'algorithme de la rétro propagation qui sera utilisé pour notre réseau de neurone, car nous disposons des entrées ainsi que des sorties désirées que nous avons calculé précédemment (dans la partie une).

Le réseau de neurone utilisé est un réseau multi couche MLP (multi layer perceptron), constitué d'une couche interne contenant 20 neurones, un vecteur d'entrée à deux nœuds et une couche de sortie à 5 neurones suivant les entrées sorties de notre modèle (figure.5).

Pour le vecteur d'entrée, il s'agit de l'éclairement G et de la température T. et le vecteur de sortie contient les valeurs désirées des paramètres électriques du panneau photovoltaïque. Pour un meilleur apprentissage, toutes les données sont normalisées à des valeurs comprises entre 0 et +1.

Le choix du nombre de neurones de la deuxième couche est aléatoire, pour commencer, on prend un nombre important de neurones, ensuite, on diminue jusqu'à atteinte des performances désirées [9].

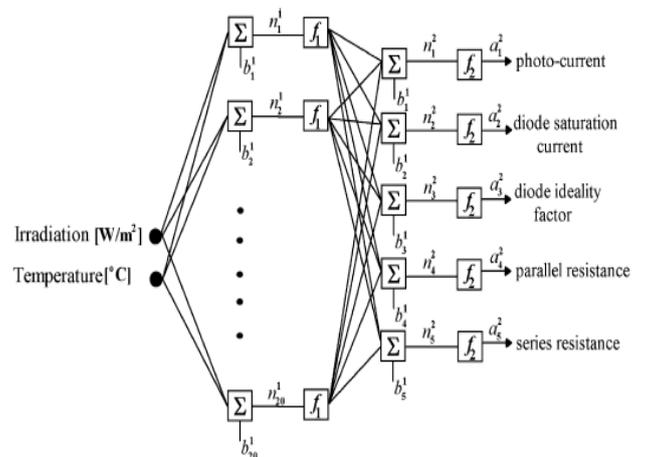


Fig.5 : Architecture du modèle du réseau de neurone



# Le 2<sup>ème</sup> Séminaire International sur les Energies Nouvelles et Renouvelables

## The 2<sup>nd</sup> International Seminar on New and Renewable Energies

Unité de Recherche Appliquée en Energies Renouvelables,  
Ghardaïa – Algérie 15, 16 et 17 Octobre 2012



### 1) L'algorithme (principe de calcul)

Etape1 : initialiser les poids des liens entre les neurones, une valeur entre -1 et 1, déterminée aléatoirement et assigné à chacun des poids.

Etape2 : application d'un vecteur d'entrées-sorties à apprendre.

Etape3 : calcul des sorties du réseau de neurone à partir entrées qui lui sont appliquées et calcul de l'erreur entre ces sorties et les sorties idéales (désirées) à apprendre.

Etape4 : correction des poids des liens entre les neurones de la couche de sortie et de la couche cachée selon l'erreur présente en sortie.

Etape5 : propagation de l'erreur sur la couche précédente et correction des poids des liens entre les neurones de la couche cachée et ceux en entrées.

Etape6 : boucler à la deuxième étape avec un nouveau vecteur d'entrées-sorties tant que les performances du réseau ne sont pas satisfaites.

La rétro propagation est un algorithme de descente du gradient, dans lequel les poids du réseau sont ajustés dans le sens du gradient négatif de la fonction coût, d'où le choix de la fonction de transfert « sigmoïdale » pour sa dérivabilité, que nous emploierons dans la couche interne. La fonction de transfert utilisée dans la couche de sortie est linéaire.

### 2) Principe de la propagation directe

Le calcul s'effectue comme suit :

La somme à l'entrée des neurones de la couche interne est comme suit :

$$S(1, j) = \sum_{i=1}^2 W_{ji} U_{0i} + b_{1j} \quad \dots\dots\dots(7)$$

$W_{ji}$  est le poids de la connexion du  $j$ ème neurone de la couche 1 au  $i$ ème neurone de la couche (1-1),  $b_{1j}$  est le biais des neurones.

$U_{0i}$  est le vecteur d'entrée,  $i=1,2$ .

Les sorties des neurones de la couche interne sont définis comme suit :

$$U(1, j) = f_1(S(1, j)), j = 1 \text{ à } 20 \quad \dots\dots\dots(8)$$

Tel que :

$$f_1(s) = \frac{1}{1 + e^{-2s}} \quad \dots\dots\dots(9)$$

A la couche de sortie, nous avons

$$S(2, j) = \sum_{i=1}^{20} W_{ji} U_{1i} + b_{2j} ; j = 1 \text{ à } 5 \quad \dots\dots\dots(10)$$

La sortie de notre réseau est tel que,  $U(2,j)=S(2,j)$ ,  $j=1$  à 5. Car la fonction de transfert utilisée est une fonction de transfert identité.

### F. Résultats

Nous avons tracé l'évolution de l'erreur en fonction des itérations (figure.6) pour atteindre une précision de  $5.10^{-4}$ , le calcul est très long, mais, on peut optimiser les calculs en se basant sur des algorithmes d'optimisation (tel que l'algorithme de Levenberg-Marquart [10]).

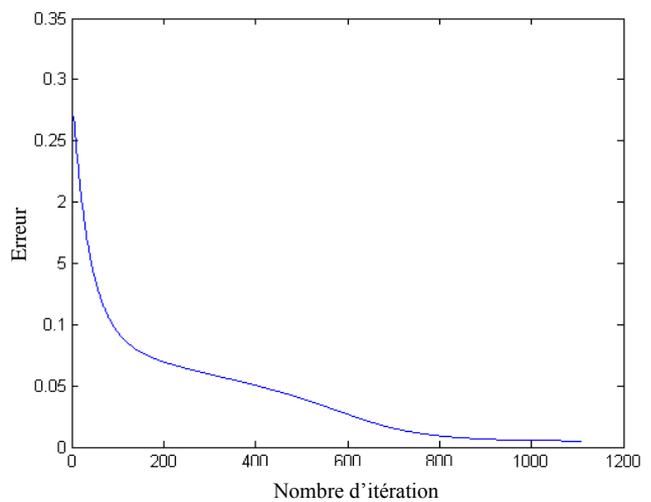


Fig.6 : l'évolution de l'erreur d'apprentissage du réseau de neurone

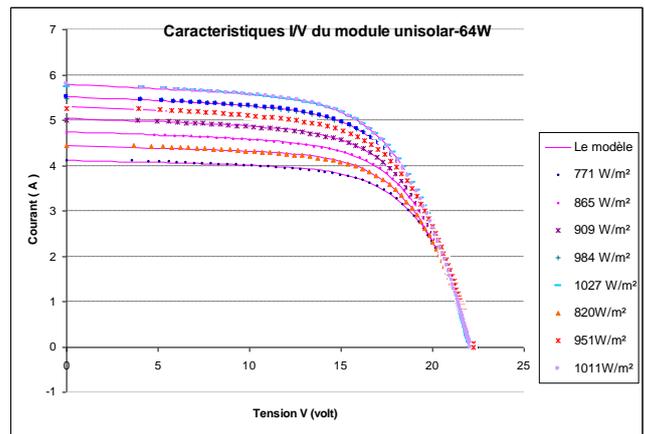


Fig.7 : caractéristiques courant-tensions, du module unisolar 64Wc, via la charge et du modèle entraîné par réseau de neurone.



**Le 2<sup>ème</sup> Séminaire International sur les Energies Nouvelles et  
Renouvelables**  
**The 2<sup>nd</sup> International Seminar on New and Renewable  
Energies**

**Unité de Recherche Appliquée en Energies Renouvelables,  
Ghardaïa – Algérie 15, 16 et 17 Octobre 2012**



Après l'apprentissage de notre réseau de neurones, nous l'avons testé pour d'autres ensembles de données courant-tension ou plus précisément à différents éclairagements et températures que celles exploitées pour l'apprentissage du réseau et les résultats sont montrés sur la figure.7. Nous remarquons une bonne concordance entre les caractéristiques courant-tension mesurées et celles déduites par le modèle du réseau de neurone.

**V. CONCLUSION :**

L'apprentissage des réseaux de neurones, nous a permis de caractériser les modules photovoltaïques, en extrayant ses différents paramètres électriques, en se passant de la résolution des équations non linéaires. Aussi, de pouvoir valider le modèle général à une diode utilisé pour la modélisation des modules photovoltaïques. Les résultats obtenus sont assez satisfaisants. Le réseau ainsi entraîné peut être utilisé pour déterminer les paramètres du module à différents éclairagements et températures.

**RÉFÉRENCE :**

- [1] M. Wolf, G. T. Noel and R. J. Stirn, 'Investigation of the double exponential in the current-voltage characteristics of silicon solar cells' IEEE Trans. Elec. Dev. 24 419-428. (1977).
- [2] Z. Ouennoughi and M. Chegaar, "A simpler method for extracting solar cell parameters using the conductance method". Solid-State Electron., Vol. 43, pp. 1985-1988 (1999).
- [3] M. Chegaar, Z. Ouennoughi et A. Hoffmann. A new method for evaluating illuminated solar cell parameters. Solid-State Electron. 45 (2001) 293–296.
- [4] M. Chegaar, Z. Ouennoughi et F. Guechi. Extracting the parameters of solar cells under illumination. Vacuum vol. 75, 2004, pp. 367-372 A.
- [5] Ali Naci Celik, Nasir Acikgoz, Modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules using four and five parameter models. Applied Energy, vol. 84, pp. 1-15, 2007.
- [6] F. Lasnier et T.G. Ang, Photovoltaic Engineering Handbook. Adam Hilger, Bristol and New York, 1990.
- [7] W. Durisch et J.C. Mayor, Application of a Generalized Current Voltage Model for Solar Cells to outdoor Measurements on a Siemens SM 110- Module. 3rd World Conference on Photovoltaic Energy Conversion. May 11-18-2003, Japan.
- [8] Don R Hush, Bill G Horne, Progress in Supervised Neural Networks. IEEE Signal Processing Magazine, January 1993, pp. 8- 39.
- [9] Adel mellit, Kalogirou SA, Artificial intelligence techniques for photovoltaic applications : Areview. Progress Energy Combust Sci (2008)
- [10] Engin Karatepe, Mutlu Boztepe et Metin Colak, Neural Netwok based solar cell model. Energy conversion and Management 47 (2006) 1159-1178, Elsevier.