

Utilisation des réseaux de neurones artificiels pour la détermination des paramètres électriques de la cellule photovoltaïque

Fayrouz DKHICHI, Benyounes OUKARFI

Laboratoire d'Electronique, Electrotechnique, Automatique & Traitement de l'Information - EEA & TI,
Département Génie Electrique, Faculté de Sciences et Techniques de Mohammeda, Université Hassan II
Casablanca-Mohammeda, Maroc

dkhichi.fayrouz@gmail.com, benyounes.oukarfi@univh2m.ac.ma

Résumé : Dans cette étude nous comparons les performances des algorithmes d'optimisation à descente de gradient (Levenberg-Marquardt, Gauss-Newton et gradient conjugué) dans l'entraînement du réseau de neurones artificiels. Le réseau entraîné permet la détermination des paramètres électriques intrinsèques de la cellule photovoltaïque pour différents valeurs d'irradiance et de température. L'algorithme de Levenberg-Marquardt présente les meilleures performances lors de l'apprentissage du réseau de neurones.

Mots clés : Réseau de neurones artificiels, apprentissage, Algorithme d'optimisation, paramètres électriques, cellule photovoltaïque.

1. Introduction

L'impact de l'éclairement et de la température ainsi que la dégradation des caractéristiques intrinsèques des cellules photovoltaïques (PV), empêchent l'optimisation des performances des panneaux photovoltaïques. Pour étudier l'impact de ces facteurs handicapant, nous avons eu recours aux réseaux de neurones artificiels moyennant l'utilisation d'un modèle électrique à base d'une seule diode (fig. 1).

Ce modèle exprime une relation implicite non linéaire entre la caractéristique [courant (I), tension (V)] produite par la cellule photovoltaïque et ses paramètres électriques internes qui peuvent être identifiés analytiquement ou numériquement [1][2]. L'étude du comportement de la cellule photovoltaïque nécessite l'identification de ses paramètres pour différentes valeurs de température et d'éclairement. Les Réseau de Neurones Artificiels (RNA) paraissent les mieux adaptés pour assurer ce rôle.


Le choix d'utilisation du RNA revient à sa capacité à prédire des résultats à partir de l'exploitation des données acquises. L'information est portée par des poids représentant les valeurs des connexions entre neurones. Le fonctionnement du RNA nécessite son apprentissage par un algorithme d'entraînement, assurant la minimisation de l'erreur générée à la sortie du réseau.

Dans cette étude nous comparons entre trois algorithmes d'optimisation à descente de gradient, permettant l'entraînement du RNA. On distingue deux algorithmes de second ordre (Levenberg-Marquardt et Gauss-Newton) et un troisième du premier ordre (gradient conjugué).

2. La cellule photovoltaïque

2.1 Le modèle équivalent à une seule diode

Dans notre étude, la cellule photovoltaïque est modélisée par un modèle électrique à une seule diode [3].



L'équation mathématique déduite à partir du circuit de la figure 1:

$$I_{PV} = I_{ph} - I_s \left(\exp \left(\frac{V_{PV} + R_s I_{PV}}{n V_{th}} \right) - 1 \right) - \frac{V_{PV} + R_s I_{PV}}{R_{sh}} \quad (1)$$

Figure 1: Circuit électrique équivalent de la cellule photovoltaïque

V_{th} : Tension thermique $V_{th} = \frac{AT}{q}$

T : Température de la cellule en °K

R_s : Résistance série représentant les pertes des différents contacts et connexions.

R_{sh} : Résistance shunt caractérisant le courant de fuite de jonction.

I_{ph} : Photocourant dépendant de l'irradiance et de température.

I_s : Courant de saturation de la diode

A : Constante de Boltzmann qui égale $1.3806503 \cdot 10^{-23}$ J/K

q : Charge électrique de l'électron qui égale $1.60217646 \cdot 10^{-19}$ C

n : Facteur d'idéalité de la diode

2.2 Variation des paramètres électriques d'une cellule photovoltaïque sous éclairnement

Une cellule photovoltaïque éclairée présente une caractéristique $I_{PV}=f(V_{PV})$, pour chaque valeur d'irradiance et de température, en variant la valeur d'une charge R (fig. 2).




Figure 2: Variation de la tension V_{PV} en fonction du courant I_{PV}

Le changement de l'irradiance solaire entre $100W/m^2$ et $1000W/m^2$ et la température cellulaire entre $18^\circ C$ et $65^\circ C$, affecte les valeurs des paramètres électriques internes de la cellule photovoltaïque R_s , R_{sh} , I_{ph} , I_s , et n . En effet, la valeur du courant I_{ph} varie en fonction de l'irradiance (2) et la valeur du courant I_s varie en fonction de la température (3) alors que celles du R_s , R_{sh} et n varient en fonction des deux facteurs environnementaux [4].

$$I_{ph} = \frac{G}{G_{ref}} [I_{ph,ref} + \mu_{sc} (T - T_{ref})] \quad (2) \quad I_s = I_{s,ref} \left(\frac{T}{T_{ref}} \right)^3 \exp \left[\frac{qE_g}{An} \left(\frac{1}{T} - \frac{1}{T_{ref}} \right) \right] \quad (3)$$

Avec :

ref : Indice indiquant la valeur de référence
 μ_{sc} : Coefficient de température du courant de court circuit

E_g : Energie de bande interdite du matériel constituant la cellule photovoltaïque

3. Le réseau de neurones artificiels utilisé

L'identification des cinq paramètres électriques internes de la cellule photovoltaïque pour différentes valeurs de température (T) et d'irradiance (G) est assurée par le réseau, montré dans la figure 3. L'architecture comprend une couche d'entrée, une couche cachée et une couche de sortie.

La couche d'entrée contient deux entrées [T , G], la couche cachée comporte dix neurones cachés et celle de sortie inclut cinq neurones de sortie correspondants aux cinq paramètres R_s , R_{sh} , I_{ph} , I_s , et n , dont on veut prédire les valeurs.




Figure 3: La topologie du RNA utilisée

4. Algorithmes d'entraînement

L'erreur générée par le RNA est connue sous le nom de l'écart quadratique moyen $J_{moy(app)}$, exprimé par l'équation suivante :

$$J_{moy(app)} = \frac{1}{p} \sum_{t=1}^p \sum_{s=1}^v (S_{app}(t, s) - y_{app}(t, s))^2 \quad (4)$$

p : Nombre des exemples {entrée, sortie} t : Indice indiquant le nombre des exemples
v : Nombre des sorties du réseau s : Indice indiquant le nombre des sorties
S : Valeurs cibles du sortie du réseau y : Matrice des valeurs du sortie du réseau, $y = [R_s, R_{sh}, I_{ph}, I_s, n]$

La minimisation de l'écart $J_{moy(app)}$ est assurée par l'ajustement des poids w du RNA en utilisant à chaque fois, un algorithme d'optimisation parmi les trois: Levenberg-Marquardt, Gauss-Newton et gradient conjugué.

4.1 Algorithme de Levenberg-Marquardt (LM) [5] :

Les poids du réseau sont ajustés en utilisant l'équation suivante :

$$w_{k+1} = w_k - \frac{J_k e_k}{J_k' J_k + \lambda I} \quad (5)$$

J : Matrice Jacobéenne de la fonction $J_{moy(app)}$
e : Erreur entre la sortie cible et calculée du réseau
k : Nombre d'itérations I : Matrice identité

Le réglage du pas λ de l'algorithme de Levenberg-Marquardt est fait comme suit :

Si l'écart $J_{moy(app)}$ calculé pour w_{k+1} , diminue, alors:

$$\lambda = \lambda / 10$$

Sinon

$$\lambda = \lambda * 10 \quad \text{et} \quad w_{k+1} = w_k$$

4.2 Algorithme de Gauss-Newton (GN) [6]

Les paramètres du RNA sont modifiés comme suit :

$$w_{k+1} = w_k - \alpha \frac{J_k e_k}{J_k' J_k} \quad (6)$$

α : Le pas trouvé par la méthode de section d'or [7].

4.3 Algorithme de gradient conjugué (GC) [8]

Pour la première itération, la direction de descente de gradient « d » s'exprime comme suit

$$d_{old} = -2 J_k' e_k$$

A partir de la seconde itération :

$$\begin{aligned} \beta &= d_{old}' d_{old} / (J_k' e_k)' J_k' e_k \\ d_{new} &= -2 J_k' e_k + \beta d_{old} \\ w_{k+1} &= w_k + \alpha d_{new} \end{aligned} \quad (7)$$

5. Résultats et discussion

L'écart quadratique moyen obtenu par l'algorithme de LM est le minimum (de l'ordre $3.21 \cdot 10^{-4}$), lorsqu'on le compare avec celui donné par l'algorithme de GN et de GC, qui sont respectivement de l'ordre de $1.02 \cdot 10^{-3}$ et de $2.891 \cdot 10^{-3}$ (fig. 4). Cette meilleure minimisation de l'écart par LM, revient au fait que cet algorithme combine les caractéristiques de l'algorithme de descente de gradient ainsi que celles de l'algorithme de GN. En effet, durant les premières itérations, LM converge comme l'algorithme de descente de gradient pour une grande valeur de λ , en vue de chercher les bonnes valeurs initiales des poids, après il se comporte comme GN pour des faibles valeurs de λ en convergeant rapidement. C'est grâce aux bonnes valeurs initiales des poids

w trouvés durant les premières itérations de convergence de LM, que cet algorithme minimise au maximum possible l'écart $J_{\text{moy}}(\text{app})$.




Figure 4: L'écart quadratique moyen d'apprentissage en fonction des itérations

Les figures 5-9 montrent l'évolution des paramètres R_s , R_{sh} , I_{ph} , I_s et n , en fonction de l'irradiance pour deux valeurs fixes de température (26°C et 45°C) et les figures 10-14 décrivent l'évolution des cinq paramètres électriques en fonction de la température pour deux valeurs fixes de l'irradiance (200W/m² et 400W/m²). On observe que LM donne des courbes plus compatibles aux courbes désirées. En comparant LM avec GN, ce dernier donne des courbes plus ou moins proches à celles souhaitées, alors que GC produit un grand écart, plus important que celui observé à GN.




Figure 5: La résistance série en fonction de l'irradiance




Figure 10: La résistance série en fonction de la température




Figure 6: La résistance shunt en fonction de l'irradiance




Figure 11: La résistance shunt en fonction de la température




Figure 7: Le photocourant en fonction de l'irradiance




Figure 12: Le photocourant en fonction de la température




Figure 8: Le courant de saturation en fonction de l'irradiance




Figure 9 : Le facteur d'idéalité de la diode en fonction de l'irradiance




Figure 13: Le courant de saturation en fonction de température




Figure 14: Le facteur d'idéalité de la diode en fonction de température

6. Conclusion

L'algorithme de Levenberg-Marquardt offre des performances intéressantes dans l'entraînement de réseau de neurones artificiels par rapport à l'algorithme de Gauss-Newton et de gradient conjugué. Il détermine les valeurs des cinq paramètres électriques de la cellule photovoltaïque tellement proches à celles désirées, grâce à sa capacité de minimiser au maximum l'écart quadratique moyen.

Références

- [1] A. Jain, A. Kapoor, Exact analytical solutions of the parameters of real solar cells using Lambert W-function, *Solar Energy Materials & Solar Cells*, Volume 81, Pages 269-277, 2004.
- [2] H. Qin, J. W. Kimball, Parameter Determination of Photovoltaic Cells from Field Testing Data using Particle Swarm Optimization, *IEEE*, 2011.
- [3] T. Ikegami, T. Maezono, F. Nakanishi, Y. Yamagata, K. Ebihara, Estimation of equivalent circuit parameters of PV module and its application to optimal operation of PV system, *Solar Energy Materials & Solar Cells*, Volume 67, Pages 389-395, 2001.
- [4] E. Karatepe, M. Boztepe, M. Colak, Neural network based solar cell model, *Energy Conversion and Management*, Volume 47, Pages 1159-1178, 2006.
- [5] R. Zayani, R. Bouallegue, D. Roviras, Levenberg-Marquardt learning neural network for adaptive predistortion for time-varying HPA with memory in OFDM systems, *16th European Signal Processing Conference (EUSIPCO 2008)*, Pages 25-29, August 2008.
- [6] P.R. Dimmer, O.P.D. Cutteridge, Second derivative Gauss-Newton-based method for solving nonlinear simultaneous equations, *IEEPROC*, Volume 127, No 6, Pages 278-283, december 1980.
- [7] Q. Zuo, X. Yin, J. Zhou, B-J. Kwak, H. K. Chung, Implementation of Golden Section Search Method in SAGE Algorithm, *Proceedings of the 5th European Conference on antennas and propagations (EUCAP) IEEE*, Pages 2028-2032.
- [8] R N. Gong, Wei S. H. Xu, The Conjugate Gradient Method with Neural Network Control, *IEEE*, Pages 82-84, 2010.