

Prediction du rayonnement solaire horaire En utilisant les reseaux de neurone artificiel

D. Benatiallah ^{*1}, A. Benatiallah ¹, K. Bouchouicha ², B. Nasri¹

^{*1}Laboratoire Energie, Environnement et Système d'Information (LEESI)
Faculté des Sciences et de la Technologie Université Ahmed Draïa - Adrar
²Unité de Recherche en Energies Renouvelables en Milieu Saharien (URER.MS)- Adrar

*Corresponding author: djelloulunv@gmail.com ; Tel.: +213 662 11 79 03

ARTICLE INFO

Article History :

Received : 07/04/2019

Accepted : 03/09/2019

Key Words:

Solar energy;
Solar radiation;
Artificial neural network;
SODA.

Mots-clés :

Energie solaire ;
Rayonnement solaire ;
Réseau de neurone artificiel ;
SODA.

ABSTRACT/RESUME

Abstract: Measurements of solar radiation are rare and limited to only a few areas across the Algerian territory, the sizing and optimization of solar energy projects is a fundamental and indispensable need, it requires knowing solar radiation data at a geographic location by using efficient models to estimate them. The present work aims to predict and develop a neural model for estimating global hourly solar irradiation, according to some parameters of solar geometry and astronomical data for the Adrar region. To do this, we used nine models and three activation functions. The data is collected by Adrar's Saharan Renewable Energy Research Unit and the SODA database over a six-year period (2013 - 2018), 80% of the data was used to train the neural network and the rest for validation. We have tried several combinations of the input data, which gives different level of precision and it has been concluded that the logistic Sigmoid function of 15 neurons of the hidden layer with correlation coefficient between the measured and estimated global solar irradiation is 98.25 %, may be preferred to estimate global solar radiation intensities for the study site and for other locations with similar climatic conditions.

Résumé : Les mesures du rayonnement solaire sont rare et limitées à quelques zones seulement à travers le territoire Algérien, le dimensionnement et l'optimisation des projets de l'énergie solaire est un besoin fondamental et indispensable, il nécessite la connaître des données de radiations solaires à une localité géographique d'implantation en utilisant des modèles efficaces pour les estimer. Le présent travail vise à prédire et développer un modèle neuronal pour estimé l'irradiation solaire globale horaire, en fonction de quelques paramètres de la géométrie solaire et les données astronomique pour la région d'Adrar. Pour ce faire, nous avons utilisé neuf modèles et trois fonctions d'activation. Les données sont collectées par l'Unité de Recherche en Energies Renouvelables en Milieu Saharien d'Adrar et la base de données SODA sur une période de six ans (2013 - 2018) ces données ont traité et contrôlé, 80% des données ont été utilisées pour entraîner le réseau et le reste pour la validation. Nous avons essayé plusieurs combinaisons des données d'entrée, qui donne différent niveau de précision et il a été conclu que la fonction Sigmoïde logistique de 15 neurones de la couche cachée, avec coefficient de corrélation entre l'irradiation solaire globale mesuré

et estimée est de 98.25%, peut être préférée pour estimer intensités de rayonnement solaire global pour le site étudié et pour d'autres endroits ayant des conditions climatiques similaires.

I. Introduction

Récemment, la demande en énergie produite à partir du pétrole, du gaz et de l'uranium a augmenté assez rapidement pour pouvoir être utilisée dans le chauffage de l'eau, le refroidissement, la production d'électricité, le séchage, etc. Il a été prouvé que de nombreuses sources naturelles ont été détruites au cours des dernières décennies, notamment des sources de combustibles à base de pétrole et de gaz, en raison du développement rapide des applications industrielles [1]. Dans l'économie mondiale, une communauté de chercheurs en pleine croissance se concentre sur le domaine des énergies renouvelables, notamment le solaire, dans le but de fournir de l'énergie à l'avenir. Par conséquent, les chercheurs se sont concentrés sur diverses formes d'énergie renouvelable pouvant satisfaire la demande mondiale sans nuire à l'environnement. L'énergie solaire est largement disponible presque partout, elle est sûre, propre, gratuite et disponible dans de nombreux domaines, respectueuse de l'environnement et illimitée dans de nombreuses régions du monde, tout en offrant la possibilité économique de répondre aux besoins énergétiques mondiaux [2]. Dans les systèmes à énergie solaire, les données sur le rayonnement solaire sont extrêmement vitales et sont utilisées dans la conception, l'évaluation et l'optimisation des performances de diverses technologies de l'énergie solaire et applications sur le terrain [3]. La région du sud de l'Algérie et notamment Adrar est l'un des sites les plus favorables à l'utilisation de cette énergie avec un flux moyenne qui dépasse le 7 KWh/m²/j (figure 1) et d'enselement de plus des 3500 heures par ans [4].

Le constituant du rayonnement solaire sur les surfaces horizontales et incliné est considéré comme faisant partie intégrante des études sur les performances du système solaire [5]. Cependant, les stations de mesure du rayonnement ne fournissent pas toujours suffisamment de sites géographiques. En règle générale, dans de nombreuses régions du monde, les installations météorologiques permettant d'évaluer le rayonnement solaire sont absentes ou rares. Par conséquent, ils doivent être estimés à l'aide de la modélisation du rayonnement solaire [6], qui nécessite la connaissance du facteur de transmission atmosphérique. De nombreux aspects des approches de modélisation pour l'estimation du rayonnement solaire ont été étudiés au cours des dernières années. Un grand nombre d'articles ont été publiés sur ce sujet, développant différentes

modèles et approches à cette fin et utilisant différentes sources de données [7-17]. De plus, quelques modèles sont formulés sous des formes similaires et liés aux sites quand ils peuvent être validés avec les valeurs réelles mesurées des sites au cours de différentes saisons. Les modèles de l'intelligence artificielle [18-28]. Représenté par l'apprentissage par réseaux de neurone artificielle (RNA), fournissent un mécanisme pour estimée une ou plusieurs sortie de quelque données en entrée, une fonction d'activation utilisé et un certain nombre de couche.

Nous nous intéressons dans cet article en particulier à la modélisation et développement des modèles de l'intelligence artificielle qui permet la prédiction du rayonnement solaire globale par traitement de plusieurs modèles créent par réseaux de neurone artificiel (RNA) pour choisir la meilleure par son prédiction. Dans ce cadre, on a utilisé comme entrée différent paramètre astronomique et météorologique pour estimer l'irradiation solaire globale dans notre région.

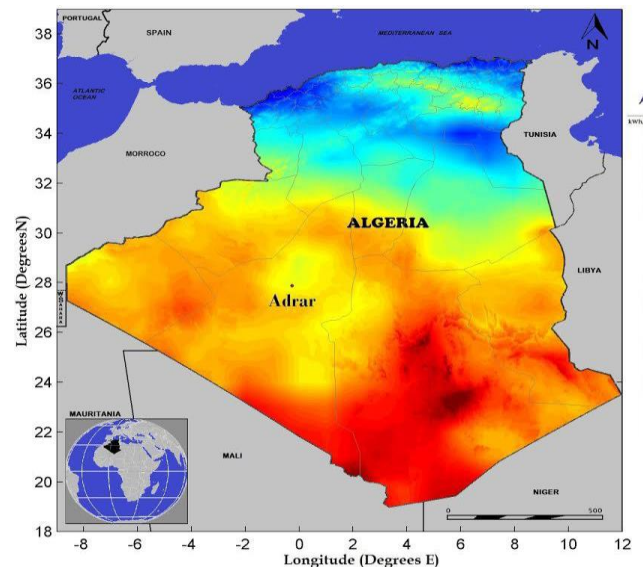


Figure 1. Carte de l'irradiation solaire globale de l'Algérie.

II. Région d'étude

Dans notre étude nous avons choisi le site d'Adrar (lat. 27.88° N, Long. 0.18° W), le choix de ce site s'est porté sur la disponibilité des données radiométriques recherchées par l'appareil de mesure de l'irradiation solaire global (Pyranomètre SOLYS 2) à l'URERMS à Adrar (Figure 2). En effet, Adrar est une ville saharienne située au milieu

du Sahara, cette région connue par des températures diurnes très élevées en été, et des températures basses en hiver [29].

III. Procédure de la construction d'un réseau de neurones artificielle

La procédure de conception d'un réseau de neurone (Figure 3) peut être résumée en cinq étapes :

- La collecte d'une base de données (BDD).
- La séparation de la base de données en deux sous-ensembles (base d'apprentissage et base de validation et test).
- Prétraitement des données.
- Entraînement du réseau de neurones sur les bases d'apprentissage et de validation.
- Mesure des performances du réseau de neurone à base de test.



Figure 2. Station météorologique Neal URERMS -Adrar

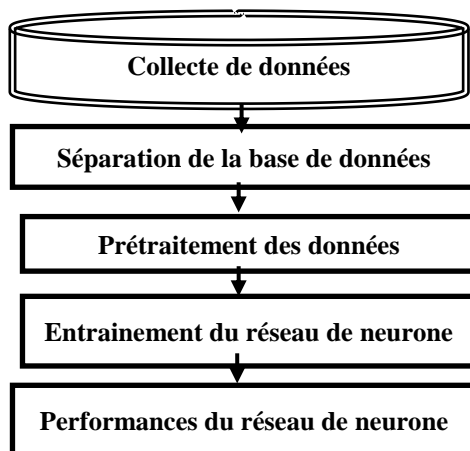


Figure 3. Diagramme de base pour la conception d'un modèle RNA

III.1 Collecte de la base de données

L'objectif de cette étape est de collecter un grand nombre de données et suffisant pour construire une base de données représentative, qu'on doit utiliser à l'apprentissage et au test du réseau de neurones. Cette base de données forme l'entrée de réseau de neurones, et par conséquent c'est elle qui détermine à la fois la taille du réseau, et les performances du système. Pour notre étude, nous avons utilisé les données horaires de six (06) ans (2013 à 2018) de 07h00 jusqu'à 18h00 (Comptant 27844 valeurs) fournies par les données de URERMS d'Adrar (Unité de Recherche en Energies Renouvelables en Milieu Saharien) et la base de données SODA (Simple Ocean Data Assimilation) [30].

Nous avons travaillé avec les paramètres météorologique et astronomique (voir Tableau 2) pour prévoir en sortie le rayonnement solaire global et comme entrées: Température, Humidité, Vitesse du vent, Pression atmosphérique, et en calculer les paramètres : déclinaison horaire, angle de la hauteur solaire du soleil, durée d'insolation du jour, irradiation solaire extraterrestre, par les équations (1-4) respectivement :

$$\delta = 23.45 \sin \frac{360}{365} (j + 284) \quad (1)$$

$$\sin \gamma = \sin \theta \sin \delta + \cos \theta \cos \delta \cos \omega \quad (2)$$

$$S_0 = \left(\frac{2}{15}\right) \omega \quad (3)$$

$$G_0 = \frac{24}{\pi} g_0 \left(\cos(\theta) \cos(\delta) \sin(\omega) + \sin(\theta) \sin(\delta) \frac{\pi}{180} \omega \right) \quad (4)$$

Avec j nombre de jour de l'année (de 1 à 365).

III.2 Séparation de la base de données

Après la collecte des données suffisantes, il faut procéder à la phase de séparation de ces données en deux ensembles, une partie pour effectuer l'apprentissage et l'autre pour la validation, qui permet de contrôler la phase d'apprentissage, tester le réseau obtenu et déterminer ses performances. Nous avons utilisé dans notre étude 80% des données pour l'apprentissage et le reste pour le test et validation.

Après le traitement d'un modèle à l'aide d'une opération d'apprentissage, nous testons le modèle en effectuant des prédictions sur la partie de test. Comme les données dans la partie de test contiennent déjà des valeurs connues pour l'attribut que nous souhaitons prédire, il est facile de déterminer si les prédictions du modèle sont correctes.

III.3 Choix de l'architecteur de réseau de neurone :

Le neurone calcule la somme de ses entrées, cette valeur ensuite passe à travers la fonction d'activation pour produire sa sortie (Fig. 4), l'architecture d'un réseau de neurones est l'organisation des neurones entre eux au sein d'un même réseau. Autrement dit, il s'agit de la façon dont ils ordonnés et connectés [31]. La meilleure méthode est de choisir le nombre de neurones de la couche cachée est de construire plusieurs modèles c'est-à-dire différents neurones dans la couche cachée et de choisir la meilleure architecture pour notre application [32].




Figure 4. Structure d'un neurone artificiel

La structure et l'architecture du réseau de neurones multicouches (MLP) dépend généralement de la base de données qui est constituée de couples entrées et sorties, le choix de nombre de nœuds d'entrées et de sorties sont généralement imposés par la fonction à approximer [33]. Le premier est déterminé par le nombre de variables utilisées en entrée. Dans notre cas, ce nombre est variable. Car on a essayé plusieurs architectures avec différentes variables en entrées (voir tableaux 1-2).

Le nombre de neurones de la couche de sortie est déterminé par le besoin de variable qu'on veut prédire, dans notre étude on va prédire l'irradiation solaire globale, donc on utilise qu'un seul neurone dans la couche de sortie.

Nous avons choisi une démarche qui consiste à considérer d'abord l'architecture la plus simple avec un minimum de neurones dans la couche cachée, puis à la rendre plus complexe et à sélectionner celle qui présente les meilleures performances.

Dans ce cas, nous partons d'une architecture à un (1) neurone dans la couche cachée, et on augmente ce nombre jusqu'à 15, puis on retient l'architecture qui donne le minimum de l'erreur sur la base de test, pour éviter le problème de sur-apprentissage.

III.4 Prétraitement de données

Après la collecte des données, trois procédures de prétraitement et nettoyage des données sont effectuées pour former les RNA plus efficacement. Ces procédures sont: résoudre le problème des données manquantes, normaliser les données et randomiser les données. Les données manquantes sont remplacées par la moyenne des valeurs voisines au cours de la même période. La procédure de normalisation avant de présenter les données d'entrée au réseau est généralement une bonne pratique en appliquant l'équation de normalisation suivante [24] :

$$\text{val_normalisée} = \frac{\text{val_non_normalisée} - \text{val_min}}{\text{val_max} - \text{val_min}} \quad (5)$$

Avec : val-min et val-max : les valeurs minimale et maximale respectivement de variable à normaliser.

Ce prétraitement est important et efficace pour le réseau, et garantissant qu'aucune entrée ne normalise des autres.

III.5 Phase d'apprentissage :

Dans cette phase, les poids sont ajustés afin de rendre les sorties réelles (calculé) proches des sorties cibles (mesurées) du réseau qui sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement afin d'éviter que l'apprentissage ne s'arrête sur un minimum local de la fonction d'erreur.

L'ensemble des données d'apprentissage est donc présenté plusieurs fois au réseau avec différentes valeurs d'initialisation des poids synaptique. Une fois on a choisi l'architecture du réseau de neurone, elle doit subir une phase d'apprentissage. Cette dernière consiste à calculer les pondérations optimales des différentes liaisons, en utilisant la base d'apprentissage [34].

On a choisi dans cette étude l'apprentissage supervisé, en utilisant l'algorithme de Levenberg-Marquadt pour donner des meilleurs résultats, on ce qui concerne la performance de généralisation et la rapidité de convergence. Cet algorithme trouve le minimum par des techniques d'optimisation non linéaire, une mesure de l'écart entre les valeurs prédire et les valeurs mesurés (fonction de coût) [35].

III.6 Phase de test :

Cet étape consiste à tester la performance du modèle développé, à cette phase les données non visibles sont exposées au modèle, il faut toujours procéder à des tests pour estimer sa qualité de généralisation, et ce en lui présentant une base de données différente de celles utilisées pour l'apprentissage (qui représente 20% de la totalité de la base de données).

III.7 Etude des paramètres de construction

L'objectif de notre étude est la validation du réseau de neurone, comme outil de prédiction de

l'irradiation solaire global, par apprentissage supervisé. Nous avons résumé les données utilisées dans le tableau suivant :

Tableau 1. Paramètres utilisés

Variable	Abréviation	Unité	Catégorie	Type	
Température	T _{amb}	°C	Météorologique	Numérique	
Pression atmosphérique	BP	hPa			
Humidité relative	RH	%			
Vitesse du vent	WS	m/s			
Déclinaison	DECL	Degré	Astronomique		
Angle de la hauteur solaire	AngleH	Degré			
Irradiation solaire extraterrestre	G0	Wh/m ²			
Durée d'insolation du jour	Dday	heure			
Numéro de jour de l'année	Jday	-	Numérique (1-365)		
Numéro heure du jour	Hday	-	Numérique (7-18)		

On a testé plusieurs modèles des paramètres d'entrée afin de trouver les combinaisons de variables d'entrée pour trouvé une prédiction efficace. Les entrées utilisées pour ces modèles ont été choisi en se basant sur le calcul du coefficient

de corrélation entre l'irradiation solaire global et chacune des modèles choisi.

Le tableau suivante présente et résume les modèles qui nous avons jugé être le plus intéressant :

Tableau 2. Différents modèles utilisé pour l'entraînement du réseau de neurone

Paramètre d'entré	Variable d'entrée									
	Jday	G0	Dday	Hday	AngleH	DECL	T _{amb}	RH	BP	WS
Modèle 1	X	X	X	X						
Modèle 2	X	X	X	X					X	X
Modèle 3	X	X	X	X		X	X			
Modèle 4	X	X	X	X	X			X		
Modèle 5	X	X	X	X	X	X				
Modèle 6	X	X	X	X	X	X	X			
Modèle 7	X	X	X	X	X	X	X	X		
Modèle 8	X	X	X	X	X	X	X	X	X	
Modèle 9	X	X	X	X	X	X	X	X	X	X

IV. Critères utilisé pour évaluation les performances des modèles

La performance du modèle de rayonnement solaire étudié est également évaluée sur la base des scores statistiques et du coefficient de corrélation proposé par Stone [36] tels que l'erreur de biais moyen (MBE), la racine carrée de l'erreur quadratique moyenne (RMSE), le coefficient de corrélation (R) et moyenne des erreurs absolues (MAPE). Les expressions pour les paramètres

statistiques indiqué et les plus populaire et plus utilisés sont :

- **RMSE** (Root Mean Square Error), la racine carrée de l'erreur quadratique moyenne, RMSE fournit des informations sur la performance à court terme qui est une mesure de la variation des valeurs prédictives autour des données mesurées. Plus le RMSE est bas, plus l'estimation est précise :

$$RMSE = \sqrt{\sum_{i=1}^N (G_c^i - G_m^i)^2 / N} \quad (6)$$

- **MBE** (Mean Bias Error), erreur de biais moyen, MBE est une indication de l'écart moyen des valeurs prédites à partir des données mesurées correspondantes et peut fournir des informations sur la performance à long terme des modèles, plus MBE est basse, donc meilleure prédiction du modèle à long terme. Une valeur MBE positive indique la quantité de surestimation dans l'irradiation solaire directe prédiquée et vice versa.

$$MBE = \sum_{i=1}^N (G_c^i - G_m^i) / N \quad (7)$$

- **MAPE** (Mean Absolute Percentage Error), moyenne des erreurs absolues en pourcentage : MAPE est dans l'ensemble une mesure de la justesse de la prévision. Une valeur inférieure à 10% est considérée comme acceptable.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left(\frac{G_c^i - G_m^i}{G_m^i} \right) \times 100 \quad (8)$$

- **R** (corrélations coefficient) : Le coefficient de corrélation mesure combien les valeurs se rapprochent-elles des valeurs. Clairement, une valeur du coefficient de corrélation plus proche de l'unité implique une meilleure estimation.

$$R = \left[\frac{\sum_{i=1}^N (G_m^i - \overline{G_m})(G_c^i - \overline{G_c})}{\sqrt{\sum_{i=1}^N (G_m^i - \overline{G_m})^2 \sum_{i=1}^N (G_c^i - \overline{G_c})^2}} \right] \quad (9)$$

Avec :

N : Nombre de valeur d'observations

G_m^i : Valeur mesurée du rayonnement global

G_c^i : Valeur calculée du rayonnement global

$\overline{G_m}$: Valeur moyenne de l'irradiation solaire mesurée

$\overline{G_c}$: Valeur moyenne de l'irradiation solaire estimée

Dans notre étude, nous avons utilisé tous les indicateurs cités ci-dessus, pour évaluer la performance de nos modèles.

V. Résultat et discussion :

Les figures suivantes représentent la corrélation ente l'irradiation solaire globale et chacune des modèles (7,8 et 9) d'entrées.


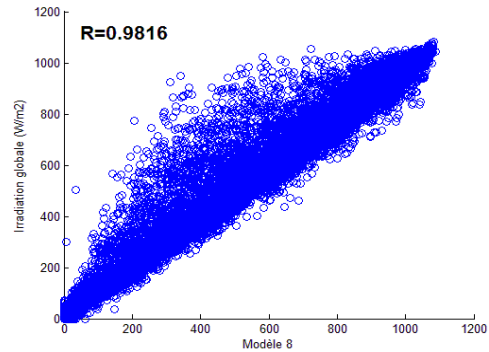



Figure 5. Coefficient de corrélation de modèles 7, 8 et 9

Tableau 3. Différents coefficient de corrélation des modèles utilisé pour l'entraînement du réseau de neurone

Paramètre d'entrer	Coefficient de corrélation	Rang
Modèle 1	0.9769	9
Modèle 2	0.9777	5
Modèle 3	0.9773	7
Modèle 4	0.9804	4
Modèle 5	0.9772	8
Modèle 6	0.9775	6
Modèle 7	0.9814	3
Modèle 8	0.9816	2
Modèle 9	0.9819	1

A partir de ce tableau on a remarqué que les trois modèles d'entrer (7,8 et 9) ont les meilleur résultats parce que le coefficient de corrélation entre les paramètres d'entrer et le rayonnement globale est grand ils sont proche de 1 (entre 0.9814 et 0.9819), donc on va tester uniquement ces trois modèles.

Dans la couche cacher, on peut tester les meilleur trois modèles dans le tableau 3, c.a.d le nombre de paramètre d'entrée sont (7, 8 et 9) paramètres, on va testé chacun par trois fonctions d'activations (linéaire, Sigmoidé logistique et Tangente hyperbolique) un exemple d'interface multicouche (MLP) entraînement de réseau de neurone par la fonction Sigmoidé logistique en annexe, nous changeons le nombre de neurones dans la couche cachée de 1 à 15, on a effectué 1000 apprentissages avec chaque fois une initialisation différente pour

chaque une de ces architectures, puis en sauvegarde la valeur des poids synaptiques qui donne le minimum de RMSE sur la base d'entraînement, les résultats obtenus sont résumé dans le tableau 4, après on va choisi le plus efficace dans chaque modèle.

À partir des calculs on a choisi les meilleurs paramètres d'entrée (tableaux 4) en fonction des indicateurs statistique (la valeur du R proche de 1, plus la valeur absolu du MBE est basse, plus le RMSE est bas, une valeur de MAPE inférieure à 10% acceptable) on résume les résultats de comparaison entre les paramètres d'entrée de modèle linéaire pour chaque nombre des neurones on couche cacher cité aux tableaux 4 et 5.

Tableau 4. Variation des erreurs en fonction du nombre de neurone et paramètre d'entrées dans la couche cachée

Paramètres d'entrées	Nombre de neurone caché	R	RMSE (W/m ²)	MBE (W/m ²)	MAPE (%)
Fonction 1 : Fonction linéaire					
9	7	0,97224	77,1672	-5,1264	11.24
8	10	0,9818	62,0093	-0,3700	7.77
7	15	0,9816	62,1357	-0,1431	7.81
Fonction 2 : Sigmoidé logistique					
9	15	0,9825	61,1410	0,0591	7.60
8	15	0,9822	61,3276	-0,0059	7.66
7	14	0,9820	61,5255	-0,3712	12.98
Fonction 3 : Tangente hyperbolique					
9	13	0,9823	61,0233	-0,0905	7.65
8	15	0,9824	61,5793	-1,1415	7.62
7	15	0,9816	62,1899	-0,4046	7.74

Tableau 5. Résultat du meilleure modèle

Modèle de la fonction	Paramétrée d'entrée	Nombre de neurone caché
Fonction 1	8	10
Fonction 2	9	15
Fonction 3	8	15

D'après les tableaux 4-5 et les graphes de la figure 6, le modèle de la fonction 2 (Sigmoidé logistique) c'est le meilleur par rapport des autres modèles, celui qui donne des indicateurs statistique efficace, pendant le test (R=0,9825, RMSE=61,1410 w/m², MBE=0,0591 w/m², MAPE=7.60) donc on a fixé les paramètres d'entrée à 9 paramètres (le modèle 9).

La comparaison de chaque indicateur statistique de chaque modèle de fonction d'après les graphes de la figure 6, on remarque que le modèle 2 de la

fonction Sigmoidale logistique c'est le meilleure par rapport les autres fonctions, dans la phase de test.

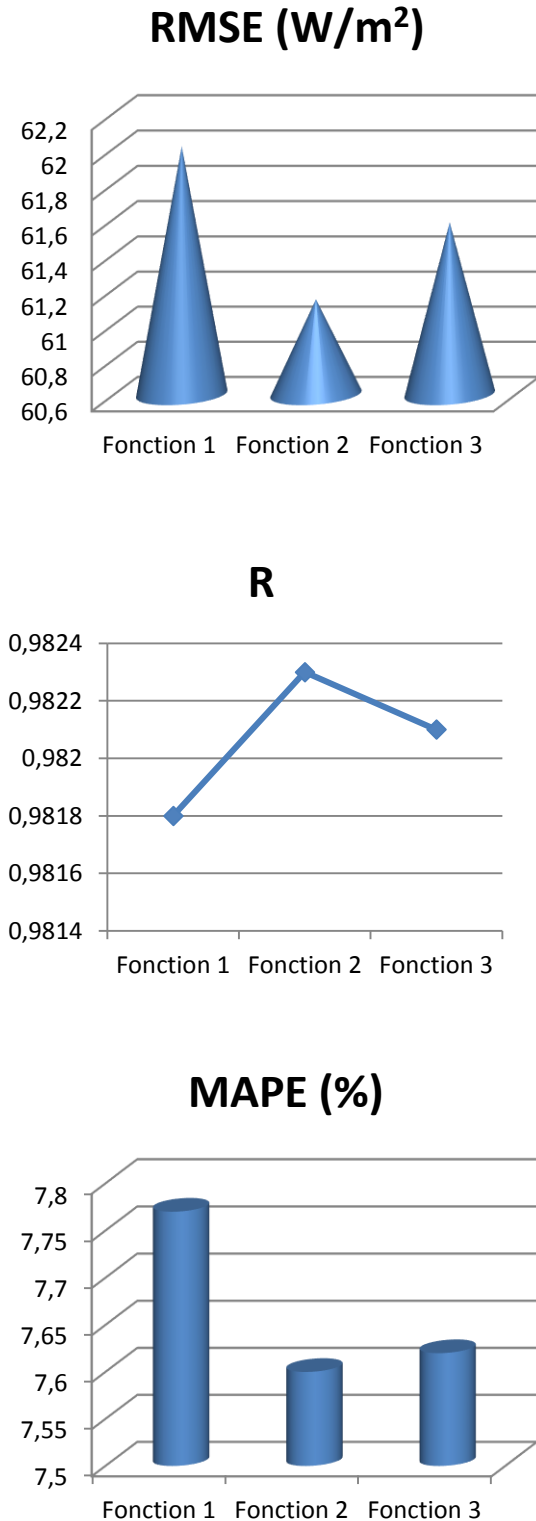


Figure 6. Indicateur RMSE, MAPE et R

VI. Conclusion

Dans le présent article, nous avons examiné la possibilité d'estimer le rayonnement solaire globale horaire à partir de plusieurs modèles en entrant des paramètres astronomique et métrologique en utilisant un réseau de neurones multicouches MLP. Nous avons essayé plusieurs combinaisons des données d'entrée et nous avons constaté que la combinaison de neuf entré (Irradiation solaire extraterrestre, Durée du jour, Température, Pression atmosphérique, Humidité relative, Vitesse du vent, Déclinaison et Hauteur angulaire maximale du soleil, numéro de jour de l'année, numéro heure du jour) avec la fonction Sigmoidale logistique de 15 neurones de la couche cachée est celle qui donne les meilleurs résultats, pour cette combinaison, le coefficient de corrélation entre l'irradiation solaire globale mesuré et celle estimée est de 98.25% pour les données de test. Il a été conclu que ce modèle peut être préféré pour estimer intensités de rayonnement solaire pour le site étudié et pour d'autres endroits ayant des conditions climatiques similaires.

Références

1. Sawin, J. Global Status Report. *Renewables*. REN21 Secretariat, (2013).
2. Shukla, K.; Sudhakar, K.; Rangneker, S. Estimation and Validation of Solar Radiation Incident on Horizontal and Tilted Surface at Bhopal. Madhya Pradesh India. *American-Eurasian Journal of Agriculture & Environnement Sciences* 15 (2015) 129-139.
3. Benatiallah, D.; Benatiallah, A.; Bouchouicha, K. Development and Modeling of a Geographic Information System solar flux in Adrar, Algeria. *International Journal of System Modeling and Simulation* 1 (2016) 15-19.
4. Benatiallah, D.; Benatiallah, A.; Bouchouicha, K. Model for obtaining the daily direct and diffuse solar radiations. *International Journal of Science and Applied Information Technology* 7 (2017) 50-55.
5. Kambezidis, H.D.; Psiloglou, B.E.; Karagiannis, D.; Dumka, U.C.; Kaskaoutis, D.G. Recent improvements of the Meteorological Radiation Model for solar irradiance estimates under all-sky conditions. *Renewable Energy* (2016).
6. Bouchouicha, K.; Bailek, N.; El-Shimy, M. Estimation of Monthly Average Daily Global Solar Radiation Using Meteorological-Based Models in Adrar, Algeria. *Applied Solar Energy* 6 (2018) 448-455.
7. Abdo, T.; El-Shimy, M. Estimating the global solar radiation for solar energy projects-Egypt case study. *International Journal Sustainable Energy* 32 (2013) 682-712.
8. Mesri, M. Numerical methods to calculate solar radiation, validation through a new Graphic User Interface design. *Energy Conversion and Management* 90 (2015) 436-445.
9. Almorox, J.; Benito, M.; Hontoria, C. Estimation of monthly Angström-Prescott equation coefficients from measured daily data in Toledo, Spain. *Renewable Energy* 30 (2005) 931-936.
10. Zaatri, A.; Azzizi, N. Evaluation of some mathematical models of solar radiation received by a ground collector. *World Journal of Engineering* 13 (2016) 376 - 380.
11. Bakirci, K. Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey. *Energy* 34 (2009) 485-501.
12. Lealea, T.; Tchinda, R. Estimation of diffuse solar radiation in the north and far north of Cameroon. *European Scientific Journal* 9 (2013).

13. Namrata, K.; Sharma, S.; Seksen, S. Empirical models for the estimation of global solar radiation with sunshine hours on horizontal surface for Jharkhand (India). *Applied Solar Energy* 52 (2011) 164–172.
14. Mesri-Merad, M.; Rougab, I.; Cheknane, A.; Bachari, N. Estimation du rayonnement solaire au sol par des modèles semi-empiriques. *Revue des Energies Renouvelables* 15 (2012) 451–463.
15. Benatiallah, D.; Benatiallah, A.; Bouchouicha, K.; Nasri B.; Basharat J. A statistical comparative study of clear sky global solar irradiance models under south Algerian climate. *Cinecia e Técnica Vitivincola* 34 (2019) 14-29.
16. Almorox, J.; Bocco, M.; Willington, E. Estimation of daily global solar radiation from measured temperatures at Cañada de Luque, Córdoba, Argentina. *Renewable Energy* 60 (2013) 382–387.
17. Scarpa, F.; Bianco, V.; Tagliafico, L. A clear sky physical based solar radiation decomposition model. *Thermal Science and Engineering Progress* 6 (2018) 323-329.
18. Karoro, A.; Ssenyonga, T.; Mubiru, J. Predicting Global Solar Radiation using an Artificial Neural Network Single-Parameter Model. *Advances in Artificial Neural Systems* 20 (2011).
19. Benganem, M. Artificial Intelligence Techniques for Prediction of Solar Radiation Data: A Review. *International Journal of Renewable Energy Technology* 3 (2012) 189-219.
20. Mohandes, M.; Rehman, S.; Halawani, TO. Estimation of global solar radiation using artificial neural networks. *Renewable Energy* 14 (1998) 179–184.
21. Behrang, MA.; Assareh, E.; Ghanbarzadeh, A.; Noghrehabadi, AR. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. *Solar Energy* 84 (2010) 1468-1480.
22. Miloudi, L.; Acheli, D.; Kesraoui, M.; Application of Artificial Neural Networks for Forecasting Photovoltaic System Parameters. *Applied Solar Energy* 53 (2017) 85–91.
23. Azadeh, A.; Maghsoudi, A.; Sohrabkhani, S. An integrated artificial neural networks approach for predicting global radiation. *Energy Conversion and Management* (2010).
24. Mellit, M.; Pavan, A. A 24-h Forecast of Solar Irradiance Using Artificial Neural Network: Application for Performance Prediction of a Grid-Connected PV Plant at Trieste, Italy. *Solar Energy* 84 (2010) 807–821.
25. Sftos, A.; Coonick, AH. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Solar Energy* 68 (2000) 169- 178.
26. Mohandes, M.; Balghonaim, A.; Kassas, M.; Rehman, S.; Halawani, TO. Use of radial basis functions for estimating monthly mean daily solar radiation. *Solar Energy* 68 (2000).
27. Voyant, C.; Muselli, M.; Paoli, C.; Nivet, M.L. Optimization of an Artificial Neural Network Dedicated to the Multivariate Forecasting of Daily Global Radiation. *Energy* 36 (2010) 348–359.
28. Rehman, S.; Mohandes, M. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy* 63 (2008) 571–576.
29. Benatiallah, D.; Benatiallah, a.; Bouchouicha, K.; Hamouda, M.; Nasri, B. An empirical model for estimating solar radiation in the Algerian Sahara. *American Institute of Physics* (2018); doi: 10.1063/1.5039218.
30. SODA, Site web: www.soda-pro.com/web-services#meteo-data.
31. Hopfield, J. Neural networks and physical systems with emergent collective computational abilities, PNAS proceedings of national academy of sciences of USA April 1, 79(1982) 25-54 <https://doi.org/10.1073/pnas.79.8.2554>
32. Tymvois, F.S.; Jacovides, C.P.; Michaelides, S.C.; Scouteli, C. Comparative study of Angströms and artificial neural networks methodologies in estimating global solar radiation. *Solar Energy* (2005).
33. Ihya, B.; Mechaqrane, A.; Tadili, R.; Bargach, M.N. Estimation de la fraction diffuse a Fès en utilisant les réseaux de neurones artificiels, Congrès International sur les Energies Renouvelables et l'Efficacité Énergétique 20-21 Avril (2011), Fès-Maroc.
34. Tarahi, F. Prédiction de l'irradiation solaire globale pour la région de Tizi-Ouzou par les réseaux de neurones artificiels, mémoire présenté pour l'obtention du diplôme de magister en université Mouloud Mammeri- Tizi-Ouzou, (2011).
35. Dreyfus, G.; Martinez, M.; Samueldies, M. Gordon, M.B.; Badron, F.; Thiria, S.; Hérault, L. réseaux de neurons méthodologie et application. Edition Eyrolles (2002).
36. Stone, R.J. Improved statistical procedure for the evaluation of solar radiation estimation models. *Solar Energy* 51 (1993) 289–91.

Nomenclature

- δ Déclinaison (°)
- γ Angle de la hauteur solaire (°)
- θ Latitude (°)
- ω Angle horaire (°)
- S_0 Durée astronomique du jour (h)
- G_0 Rayonnement solaire extraterrestre (W/m²)
- g_0 Coefficient du rayonnement solaire extraterrestre

Annexe

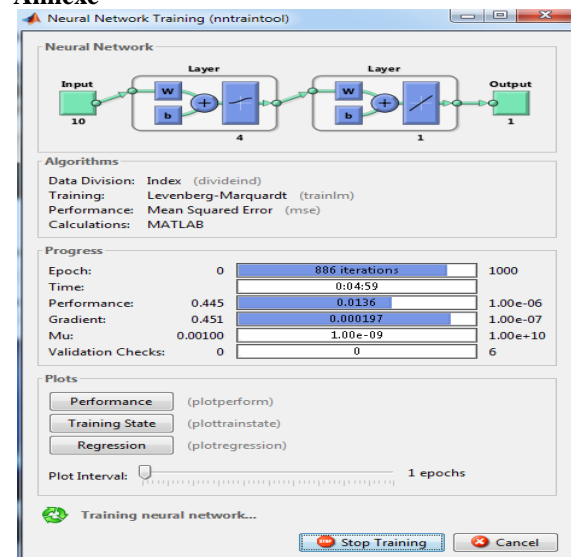


Figure 7. Interface MLP entrainement de réseau de neurone par la fonction Sigmoïde logistique

Please cite this Article as:

Benatiallah D., Benatiallah A., Bouchouicha K., Nasri B., Prediction du rayonnement solaire horaire en utilisant les reseaux de neurone artificiel, *Algerian J. Env. Sc. Technology*, **6:1 (2020) 1236-1245**