



Full Length Research Paper

Contribution à l'étude d'un modèle de réseau de neurone artificiel de prédiction à court terme : Application sur le site de Dakar

Amy Mbaye¹, Didier Maria Dione², Fatou Ndiaye¹, Mouhamed Cherif Aidara¹, Mamadou Lamine Ndiaye¹

¹Electrical Engineering Department of the Polytechnic High School of Dakar Senegal, Laboratory Head of Water, Energy, Environment, and Industrial Process (LE3PI), BP 5085 Dakar-Fann, Senegal.

²Laboratory Physics (HFML), Department of Physics, Faculty of Sciences and Technology, Cheikh Anta Diop University (UCAD), BP 5005, Dakar-Fann, Senegal.

Received April 2024 – Accepted June 2024



*Corresponding author. amy1.mbaye@ucad.edu.sn

Author(s) agree that this article remain permanently open access under the terms of the Creative Commons Attribution License 4.0 International License.

Résumé:

Ce travail s'inscrit dans le cadre du développement d'outils d'apprentissage automatique performants dans le domaine de l'intégration des énergies intermittentes dans le mix énergétique de la Senelec. Ces énergies intermittentes engendrent beaucoup de problèmes au niveau de la planification pour le maintien de l'équilibre consommation/production. Ces problèmes motivent les besoins de développer des outils fiables d'aides à la décision dans les laboratoires de recherche émergent pour accompagner les entreprises ; soutenir les études, les gestionnaires de réseaux, etc. C'est dans cette optique que nous avons développé un modèle de réseau de neurone artificiel de prédiction du rayonnement solaire à court terme. Ce modèle est appliqué sur le site de Dakar-Sénégal. Les paramètres d'entrées du modèle sont constitués à un instant t de la température de l'air, de l'humidité relative et du rayonnement solaire global. La production attendue au temps $t+T$ est le rayonnement solaire global. Les performances du modèle sont évaluées à l'aide de la racine carrée de l'erreur quadratique moyenne normalisée (NRMSE) et de la racine carrée de l'erreur quadratique moyenne (R2).

La Validation du modèle est réalisée au moyen des données mesurées au sein de l'Ecole Supérieure Polytechnique de Dakar pendant un an. L'impact de différents paramètres tels que les pas d'horizon, les algorithmes d'apprentissages (Levenberg-Marquardt, Gradient Conjugué et Quasi-Newton), des fonctions d'activation (Purelin, Logsig et Tansig) et des paramètres environnementaux (température et humidité relative) ont été évalués.

Les résultats de simulation montrent que les meilleures performances (NRMSE= 0.0098 et R2 =1) sont obtenues avec le modèle de combinaison de variable d'entrées [Ginput] sans impact de la température et de l'humidité relative basé sur l'algorithme de Levenberg-Marquardt « trainlm » et le couple de fonction de transfert [Logsig-Purelin] suivent l'horizon 20 minutes.

Ce modèle pourra contribuer au développement de modèle de réseau de neurone pour aider à la prise de décision à court terme dans la zone de Dakar.

Mots clés: Energies; Solaire; Intermittent; Planification; Centrale; RNA

Cite this article:

Amy Mbaye, Didier Maria Dione, Fatou Ndiaye, Mouhamed Cherif Aidara, Mamadou Lamine Ndiaye. (2024). Contribution à l'étude d'un modèle de réseau de neurone artificiel de prédiction à court terme : Application sur le site de Dakar. Revue RAMReS – Sci. Appl. & de l'Ing., Vol. 6(1), pp. 89-100. ISSN 2630-1164.

1. Introduction

Aujourd'hui, avec l'évolution des mentalités et des nouvelles politiques dictées par le Cop21, on assiste à une croissance considérable de l'exploitation et de

l'installation de centrales solaires et éoliennes à travers le monde, en Afrique et particulièrement au Sénégal. Pour une bonne implantation de ces centrales, le Sénégal dispose en effet, d'un important potentiel favorable à la valorisation de la ressource solaire et du

vent. Par conséquent, la mise en place de différentes centrales solaire photovoltaïque dans la presque totalité des régions du Sénégal et une centrale éolienne dans la région de Thiès de plusieurs Mégawatts constitue des réponses fortes aux orientations du Sénégal à l'issue de la cop21. Ces centrales injectent leur production dans le réseau de la société nationale d'électricité (SENELEC). L'intégration massive de telles sources qualifiées d'intermittentes sur le réseau électrique engendre beaucoup de problèmes au niveau de la planification du maintien de l'équilibre consommation/production. En effet, cette planification s'avère difficile du fait du caractère stochastique de la production issue de sources d'énergie intermittentes. La nature stochastique de cette ressource solaire est caractérisée par des fluctuations très rapides et fréquentes de la ressource solaire que l'on observe durant certaines saisons et dans certains types de climats tropicaux. Ces fluctuations s'expliquent par le fait que la structure des données d'irradiation solaire globale est naturellement composée de plusieurs groupes entre lesquels il existe des dépendances temporelles perceptibles entre ces niveaux de variabilités. Cependant, des difficultés sont observées au niveau de la détection des niveaux de variabilités mais aussi au niveau des calculs de dépendances temporels entre niveaux de variabilités. C'est pourquoi, la maîtrise du caractère aléatoire des sources d'énergies intermittentes telles que le rayonnement solaire au sol et le vent reste un défi à relever [1, 2, 3, 4, 5, 6, 8, 9, 10, 11]. Plusieurs études faites dans la littérature montrent clairement que le stockage et la prédiction sont essentiels. Ils pourront, à terme, permettre de mieux maîtriser et d'exploiter ces énergies à caractère stochastiques dont l'intermittence pénalise lourdement l'utilisation [1, 2, 3, 12, 13, 14]. Néanmoins, l' stockage reste peu développé du fait de sa rareté et de sa cherté dans le marché. Par contre, plusieurs études faites dans la littérature montrent clairement que la nature stochastique de ces fluctuations, motive une bonne caractérisation de la ressource afin de prendre des mesures d'atténuations d'impacts. Par conséquent, pour une bonne caractérisation de la ressource solaire, il est important d'appliquer sur les données une bonne technique de prévision. Une bonne technique capable de détecter, de contrôler et d'analyser correctement les différents niveaux de variabilité du rayonnement solaire lorsque les conditions atmosphériques qui la provoquent se produisent. L'idée d'une telle technique est partie du constat que certains prédictors sont inefficaces dans certains cas et très efficaces dans d'autres cas spécifiques. D'après la littérature, certains auteurs constatent que la plupart des études faites sur la prévision énergétique se concentrent sur des prévisions déterministes, stochastiques et probabilistes qu'ils considèrent parfois relativement immatures [15-24]. Cependant, ces prévisions transmettent des informations relativement simples parfois sur l'état futur possible d'un système. Et, comme une prévision est intrinsèquement erronée, il est important de quantifier ces erreurs beaucoup plus détaillées et pour plus de précisions dans la prise de décision. Traditionnellement, les prises de décisions en

entreprise reposaient sur l'intuition, l'expérience et des modèles prédictifs relativement simples. Par contre, aujourd'hui, avec l'avènement de l'IA, cette dynamique change radicalement. D'après des études récentes qu'on retrouve dans la littérature, l'IA se révèle être un outil précieux. Il faut noter que la modélisation prédictive est une application de l'IA qui a le potentiel de transformer la prise de décision stratégique. En utilisant des techniques d'apprentissage automatique, l'IA peut analyser des données historiques afin d'identifier des tendances et des modèles utilisables pour faire des prédictions. De plus, l'IA a le potentiel de transformer la prise de décision et d'aider chaque entreprise à naviguer avec succès dans un monde de plus en plus complexe et incertain. Par exemple, dans un monde où les problèmes d'intégrations des énergies intermittentes restent un défi à relever, l'IA peut jouer un rôle central en permettant aux dirigeants de prendre des décisions beaucoup plus instruites et basées sur des données. C'est dans cette optique que nous avons développé un modèle de réseau de neurone artificiel de prédiction de rayonnement solaire à court terme. Ce modèle est appliqué sur le site de Dakar au Sénégal. Les paramètres d'entrées du modèle sont : le rayonnement solaire globale, la température et l'humidité relative mesurées sur une année. L'idée derrière cette étude est de contribuer au développement de modèle de réseau de neurone pour aider à la prise de décision à court terme au niveau des centrales solaire PV situés dans la région de Dakar.

2. Méthodes

2.1. Les étapes pour l'implémentation d'un modèle de réseau de neurone artificiel.

Le processus de modélisation d'un modèle PMC (Figure1) consiste à :

Traiter et diviser d'abord aléatoirement la base de données en deux parties : 70% pour l'apprentissage et 30% pour la validation.

Appliquer le modèle de réseau de neurone aux données à différents pas de temps (20, 30, 40, 50 et 60 minutes). Et effectuer des combinaisons de variables d'entrées pendant la phase d'apprentissage afin de choisir celle qui corrèlent bien avec la sortie et qui donne de meilleures performances [26, 30, 31, 32, 33].

Evaluer l'impact des algorithmes d'apprentissages (trainlm, trainscg et trainbfg) sur les performances des combinaisons de modèles [30, 31].

Effectuer une étude de l'impact des couples de fonctions de transfert sur les performances du modèle [29, 30, 31, 32, 33].

Evaluer l'impact de la température et de l'humidité relative sur l'évolution de la sortie du modèle avec le meilleur pas de temps [11, 24, 26, 27, 30, 31, 32, 43].

Enfin tester les performances des différents scénarii et à l'issue de ce processus choisir les modèles qui donnent les meilleures performances.

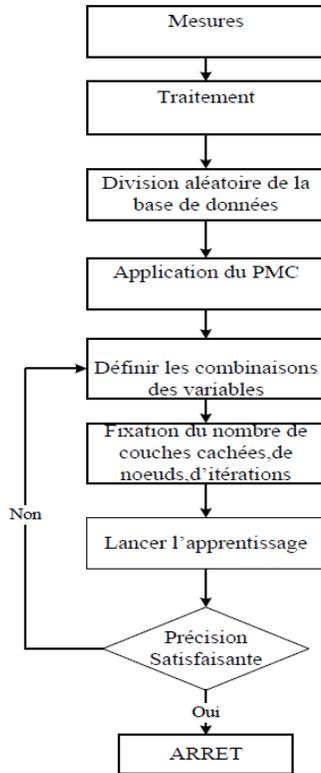


Figure 1 : Processus itératif de la modélisation du modèle

2.2.1. Présentation du site et Données

La zone d'étude est située à l'extrême Ouest de la presqu'île du Cap-Vert, au bord de l'Océan Atlantique, entre la latitude $14^{\circ}75$ N et la longitude -17.33° O avec une altitude moyenne de 16m. Elle couvre une superficie de 550 km². Son climat est de type tropical marqué par l'alternance de deux saisons distinctes : une saison sèche très longue (9mois) et une saison pluvieuse courte (3 mois).

Plusieurs sources de données de stations météorologiques dont celles qui sont installées à l'école supérieure polytechnique (ESP) de l'Université Cheikh Anta Diop (UCAD) de Dakar ont été exploitées. Ces stations mesurent le rayonnement solaire global, direct et diffus, la température ambiante, l'humidité relative, la pluviométrie, la vitesse et la direction du vent.

Nous avons utilisé dans ce travail la radiation solaire globale et des valeurs de la moyenne de la température et de l'humidité relative enregistrées au niveau de stations basées à l'ESP. La longueur de la série s'étend d'une part du 1er Octobre 2016 au 30 Avril 2017 avec un pas de temps horaire ; et d'autre part du 1^{er} Mai 2017 au 30 Septembre 2017 avec un pas de 10 secondes. Une centrale d'acquisition de type datalogger de model CR800 de Campbell Scientific est utilisée.

Par conséquent, la différence de pas de mesure notée est due aux besoins du laboratoire en termes de résolution. Pour harmoniser le traitement des données, nous avons effectué une interpolation cubique, avec le logiciel Matlab afin d'échantillonner avec un pas de mesure à 10 secondes sur le site expérimental. Ensuite

nous avons enlevé les valeurs biaisées. Les résultats obtenus de l'interpolation sont comparés aux données horaires de la Figure2. La courbe horaire (en point bleu) présente un ensoleillement identique aux valeurs mesurées toutes les 10 secondes (courbe verte) ; ce qui valide le modèle cubique utilisé. Il est à noter que, cette approximation peut être utilisée pour déterminer l'ensoleillement à toutes les échelles souhaitées.

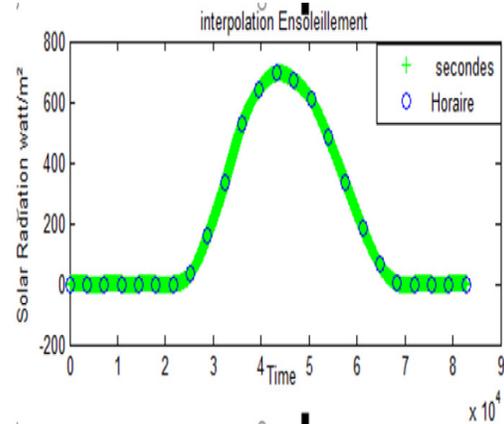


Figure 2 : Interpolation Cubique des données

2.2.2. Le modèle PMC

Dans le domaine météorologique, les lois des paramètres climatiques sont complexes et difficiles à étudier. Pour modéliser ces phénomènes, nous nous sommes particulièrement intéressés à un modèle typique de réseau neuronal connu sous le nom Perceptron Multicouche (PMC) [44, 34, 35, 36]. Dans la littérature, les réseaux de neurones artificiels ont présenté un grand succès dans l'analyse statistique, les traitements de données et la prévision des paramètres environnementaux. Ces différents auteurs ont proposé dans le cadre de leur étude, la prédiction par le biais de réseaux de neurones de type perceptions multicouches (PMC) [4, 5, 11, 45, 28, 29, 37, 38, 39, 40, 41]. Généralement, un modèle de PMC (Figure 3) est généralement composé d'une ou de plusieurs couches d'entrées, d'une ou de plusieurs couches de sortie ainsi que des couches cachées. Les couches cachées sont caractérisées par plusieurs unités non linéaires (les neurones) pour lequel chaque neurone d'une couche est connecté à ceux de la couche suivante. Par conséquent, chaque connexion correspond à un ou des poids et chaque neurone possède une fonction de transfert ou d'activation. Le processus d'apprentissage du modèle consiste à rechercher dans l'espace des paramètres du réseau, « le jeu de poids » optimal qui permet une bonne adéquation avec la cible. En pratique, on définit une fonction erreur qui dépend d'un ensemble de poids. Cet ensemble de poids est noté

$$\Omega = \{w_{ji}^{(1)}, w_{ij}^{(2)}, \theta_j^{(2)}, \theta_i^{(2)}\}$$

L'erreur rend compte de l'écart qui existe entre la sortie du réseau y et la cible t . Dans ce cas, les sorties du réseau sont obtenues par l'Equation (1) :

$$y_i = f^{(2)} \left(\sum_j w_{ij}^{(2)} f^{(1)} \left(\sum_j w_{ji}^{(1)} x_j + \theta_j^{(1)} \right) + \theta_i^{(2)} \right) \quad [\text{Eq. 1}]$$

x_i : valeur du 1^{er} neurone de la couche d'entrée

w_{ij} : poids associés à la connexion entre l'entrée 1 et le neurone caché j

$b = \theta_j^{(1)}$: biais associés au neurone caché j

$\theta_j^{(2)}$: biais associés à la sortie i

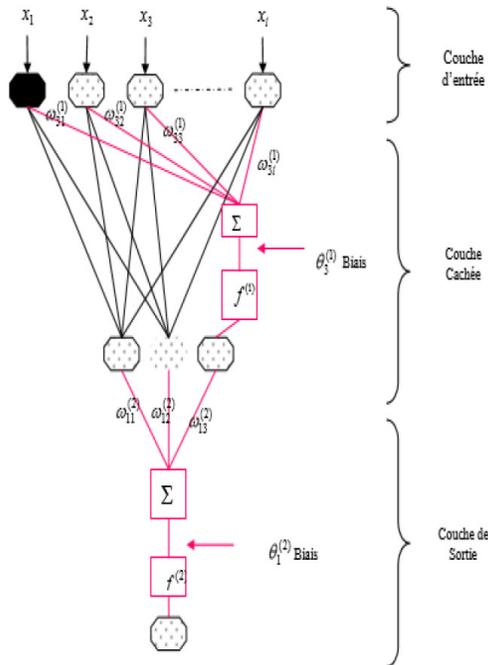


Figure 3 : Schéma d'un modèle PMC

2.2.3. Critères d'élaboration de la base de données

D'après des articles de la littérature, on constate que la tâche clé dans la prédiction des séries chronologiques est la sélection des variables d'entrées [11, 25, 26, 27, 30, 31, 32, 33]. Elle est en fait une étape préalable, car il n'existe pas d'approche systématique à adopter pour les modèles RNA non linéaires. Cependant, rappelons qu'il est nécessaire de tenir compte de certains critères à savoir :

- La parcimonie qui consiste à développer l'architecture RNA la plus simple avec un minimum d'entrées, des couches cachées et des neurones cachés ayant des performances plus élevées.

- Éviter des entrées redondantes (elles contiennent la même information) ; choisir les meilleures variables qui sont bien corrélées avec les variables d'entrées (par exemple l'irradiation solaire pour notre cas d'étude).

En effet, comme on a déjà vu, trop d'entrées peuvent réduire l'efficacité du modèle [30, 32]. Pour pallier à ce problème, nous avons choisi au niveau de la partie résultat la méthode de combinaison des variables parmi tant d'autres existantes dans la littérature avec une

division aléatoire de la base de données en 70% d'apprentissage et 30% pour la validation.

2.2.4. Particularité des trois algorithmes

Nous aborderons dans cette étude les trois algorithmes d'optimisation usuels des RNA qui ont chacun leurs particularités. Il s'agit de l'algorithme Levenberg-Marquardt, la méthode de Newton et celle de la descente du gradient conjugué.

D'abord, la particularité de la méthode de Levenberg-Marquardt « trainlm » est qu'elle est très efficace pour l'entraînement des réseaux de petite et moyenne taille consistant également à la modification des paramètres [29, 30, 31, 33, 42]. Elle est particulièrement astucieuse car elle s'adapte d'elle-même à la forme d'utilisation de l'approximation de la matrice Hessienne (Dérivée seconde de la fonction de coût). Elle assure la meilleure convergence vers un minimum de l'erreur quadratique pour les problèmes d'approximation de fonctions où le nombre de poids du réseau est inférieur à quelques centaines. Le seul défaut de cette méthode est de n'être qu'applicable qu'à un réseau contenant moins d'une centaine de poids à mettre à jour, donc un réseau de neurones qui doit être optimisé pour pouvoir utiliser cette méthode de Convergence.

Pour celle de Newton « trainbfg », il s'agit d'évaluer la matrice Hessienne au point considéré et elle est bien reconnue par son efficacité. Malheureusement, la matrice Hessienne consomme un temps considérable de calcul. De plus, le principal inconvénient réside dans le calcul des dérivées secondes de la fonction qui s'avère être plus souvent coûteux et très difficile à réaliser [42]. Les algorithmes basés sur la méthode de Newton constituent une alternative aux méthodes du gradient conjugué « trainscg » pour atteindre rapidement l'optimisation des paramètres de poids et des biais [42]. Par contre l'algorithme de Levenberg-Marquardt permet de pallier les inconvénients du choix de pas et de nombre d'itérations. Elle choisit automatiquement un compromis entre la direction du gradient et de la direction de Newton. Cette méthode est bien adaptée surtout pour les problèmes de petites dimensions puisque le calcul de la matrice Hessienne est facile. Alors que si le problème présente un grand nombre de variables, il est généralement conseillé de coupler celle-ci avec la méthode du gradient conjugué ou une méthode de Quasi-Newton. Par ailleurs, lorsque l'amélioration relative de la fonction objective devient trop faible, on passe automatiquement à la méthode du gradient conjugué.

2.2.5. Fonction d'activation

Les fonctions d'activation sont une importance capitale dans le fonctionnement d'un réseau de neurone. Elle permet au réseau d'avoir une plus grande flexibilité de calcul qu'un modèle de régression standard. Ces fonctions peuvent être de nature très variée. Le choix de la fonction d'activation est capital pour obtenir un modèle utile en pratique, car il influe sur les propriétés du neurone formel. En réalité, ce qui distingue un neurone formel d'une fonction discriminante linéaire est l'ajout d'une fonction d'activation. Cette fonction

peut être linéaire ou non linéaire. Les fonctions non linéaires les plus utilisées sont la fonction sigmoïde et la fonction logistique. Par contre les fonctions discriminantes linéaires ont une fonction d'activation continue (fonction « Purelin » dans MATLAB). En réalité, plusieurs types de fonctions d'activations existent dans la boîte à outil Matlab Tool books des réseaux de neurones dont les différences résident au niveau des données d'entrées et de sorties.

En particulier, l'utilisation d'une fonction non-linéaire telle que le sigmoïde ou le logistique vient du fait que sa dérivée existe et qu'elle est simple à mettre en œuvre. Elle est représentée par les équations (2) et (3).

$$f^{(1)}(x) = \tanh(x) \quad [\text{Eq. 2}]$$

$$f^{(1)}(x) = \frac{1}{1 + \exp(-x)} \quad [\text{Eq. 3}]$$

Notons que $\tilde{f}(\tilde{x}) = \tanh(\tilde{x})$ est équivalent à

$$f(x) = \frac{1}{1 + e^{-x}}$$
 pour la transformation linéaire

$$x = \frac{x}{2} \text{ sur les entrées et } \tilde{f} = 2f - 1 \text{ sur la sortie.}$$

Ainsi un réseau de neurones dont la fonction d'activation de la couche cachée est la fonction sigmoïde est équivalente à un réseau utilisant la fonction logistique mais ayant des poids et des biais différents [30, 41, 46].

3. Résultats et discussions

3.1. Conception d'un modèle PMC

Les principales caractéristiques de ce modèle, résumés dans le tableau 1 sont :

- Une couche cachée constituée d'un nombre de neurone fixé par l'utilisateur, de trois couches d'entrées (la température, l'humidité relative et l'irradiation solaire globale) et d'une couche de sortie représentant l'irradiation solaire globale.

- Neuf couples de fonction de transfert ont été sélectionnés. Plusieurs études de la littérature montrent que la fonction d'activation de la couche cachée doit être non linéaire (sigmoïde ou logistique) par contre la fonction d'activation de la couche d'entrée et celle de sortie doivent toutes être linéaires (Purelin) [30, 41, 46]. C'est dans ce sens que nous faisons différentes combinaisons entre des couches cachées (Tansig ou Logsig) et la couche de sortie ([Logsig-Purelin] et [Tansig-purelin]).

- L'apprentissage effectué se base sur la méthode de rétropropagation du gradient dont la méthode de minimisation de Levenberg-Marquardt (LM), du gradient conjugué scalaire (GDS) et de la méthode de quasi Newton [42].

- La procédure d'apprentissage est contrôlée par la technique de l'arrêt précoce d'apprentissage afin d'éviter le problème du sur-apprentissage.

Tableau 1.: Caractéristique du type de modèle PMC

Caractéristiques du modèle PMC	Valeurs
Nombre de couches	3
Nombre couches d'entrées	3
Fonction d'activation	Linéaire
Nombre de neurones dans la couche cachée	150
Fonction de transfert	Sigmoïde
Nombre de couches de sortie	1

A l'issue de ce processus, nous avons divisé notre base de données en deux parties : 70% pour l'apprentissage et 30% pour la validation. Alors nous avons appliqué les données sur le modèle de réseau multicouche où l'information se propage dans un seul sens des couches d'entrées vers la couche de sortie (Feed-Forward neural network). Ce réseau a été implémenté sous MATLAB Simulink. Après exécution des différentes étapes du processus nous obtenons un schéma simplifié de ce réseau représenté à la Figure 4.

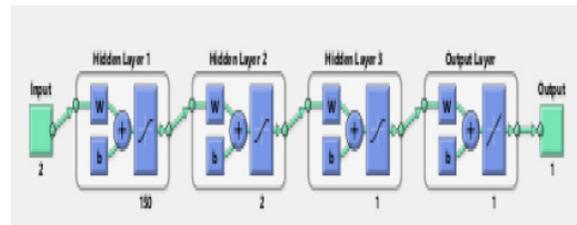


Figure 4 : Modèle d'architecture d'un PM

3.2. Sélection de variables d'entrées avec différents pas de temps

Pour éviter des entrées redondantes, nous allons choisir la méthode de combinaison des variables afin de sélectionner les meilleures variables d'entrées bien corrélées à l'irradiation solaire (la sortie du modèle) [26, 32]. Dans ce cas, nous avons effectué des scénarii de simulations. Elles sont basées sur sept combinaisons possibles de variables d'entrées du modèle PMC à l'instant t pendant la phase de formation pour des pas de temps respectifs de 20, 30, 40,50 60 minutes. Les sept scénarii de simulation de modèle PMC représentés au tableau 2 sont :

- Une combinaison de variables d'entrées [$G_{input}, T_{input}, H_{input}$] avec l'impact de la température et de l'humidité relative sur l'évolution de l'irradiation solaire globale;
- Une combinaison de variables d'entrées [G_{input}, T_{input}] avec l'impact de la température seule sur l'évolution de l'irradiation solaire globale ;
- Une combinaison de variables d'entrées [G_{input}, H_{input}] avec l'impact de l'humidité relative seule sur l'évolution de l'irradiation solaire globale ;
- Une combinaison de variables d'entrées [T_{input}, H_{input}] avec l'impact de l'humidité relative sur l'évolution de la température ;

- Utilisation d'une seule variable d'entrée [H_{input}] sans impact ;
- Utilisation d'une seule variable d'entrée [T_{input}] sans impact ;
- Utilisation d'une seule variable d'entrée [G_{input}] sans impact ;

En sortie à l'instant $t+T$ nous avons l'irradiation solaire globale [G_{output}]. Les performances de chaque scénario de simulation ont été évaluées à l'aide de la racine carrée de l'erreur quadratique moyenne normalisée (NRMSE), le coefficient de détermination (R^2) et le nombre d'itérations pour chaque horizon de temps. Le tableau 2 présente les performances des sept scénarii de tests appliqués sur les données. Les meilleures performances selon le NRMSE sont obtenues avec les quatre schémas faisant intervenir la combinaisons de

variables d'entrées [G_{input}], [G_{input}, H_{input}], [G_{input}, T_{input}], [$G_{input}, T_{input}, H_{input}$]. Leurs valeurs respectivement 0.0098, 0.044, 0.114 et 0.209. Les performances NRMSE obtenues avec les trois combinaisons de modèles de variables d'entrées [T_{input}], [H_{input}] et [T_{input}, H_{input}] sont respectivement 8.957, 9.18 et 13.576. Les résultats montrent de meilleures performances avec des données d'entrées d'irradiation seulement, suivi de celui faisant intervenir la combinaison irradiation-humidité, puis l'autre avec la combinaison irradiation-température et enfin le modèle qui combine l'irradiation, la température et l'humidité. Nous avons constaté que le modèle PMC perd de la performance lorsque l'irradiation solaire globale n'intervient pas dans la combinaison des données d'entrées.

Tableau 2. – Résultats des tests de performances des combinaisons d'entrées

Matrices d'entrées	Epoch	NRMSE	R^2	Pas de temps (minutes)
[$G_{input}, T_{input}, H_{input}$] [G_{output}]	30	0.209	1	20
[G_{input}, T_{input}], [G_{output}]	30	0.114	1	
[G_{input}, H_{input}], [G_{output}]	30	0.044	1	
[H_{input}], [G_{output}]	23	9.180	0.867	
[T_{input}], [G_{output}]	15	8.957	0.855	
[G_{input}], [G_{output}]	29	0.0098	1	
[$G_{input}, T_{input}, H_{input}$] [G_{output}]	30	0.309	0.992	
[G_{input}, T_{input}], [G_{output}]	30	0.247	0.999	
[G_{input}, H_{input}], [G_{output}]	30	0.053	1	
[H_{input}], [G_{output}]	30	9.595	0.856	
[T_{input}], [G_{output}]	14	9.348	0.873	
[G_{input}], [G_{output}]	30	0.0100	1	
[$G_{input}, T_{input}, H_{input}$] [G_{output}]	10	0.398	1	40
[G_{input}, T_{input}], [G_{output}]	30	0.312	1	
[G_{input}, H_{input}], [G_{output}]	30	0.079	1	
[H_{input}], [G_{output}]	30	9.755	0.876	
[T_{input}], [G_{output}]	16	9.668	0.892	
[G_{input}], [G_{output}]	30	0.0101	1	
[$G_{input}, T_{input}, H_{input}$] [G_{output}]	30	0.402	1	50
[G_{input}, T_{input}], [G_{output}]	30	0.312	1	
[G_{input}, H_{input}], [G_{output}]	30	0.079	1	
[H_{input}], [G_{output}]	16	10.27	0.893	
[T_{input}], [G_{output}]	12	9.978	0.915	
[G_{input}], [G_{output}]	30	0.0105	1	
[$G_{input}, T_{input}, H_{input}$] [G_{output}]	14	0.415	1	60
[G_{input}, T_{input}], [G_{output}]	30	0.314	1	
[G_{input}, H_{input}], [G_{output}]	30	0.082	1	
[H_{input}], [G_{output}]	20	10.867	0.882	
[T_{input}], [G_{output}]	24	10.410	0.925	
[G_{input}], [G_{output}]	30	0.0106	1	

3.3. Évaluation de l'impact du pas de temps sur les performances du modèle.

Le modèle PMC avec combinaison de variables d'entrées constituées que de l'irradiation [G_{input}] pour les différents horizons ont un NRMSE en moyenne de 0.01 pour le NRMSE et un coefficient de détermination R^2 de l'ordre de 1. Le nombre d'itérations permettant de conduire à ces résultats est

de 30 (voir tableau2). Au-delà de l'influence de la combinaison des variables d'entrées, les résultats montrent une dégradation de performances avec le temps. En effet, les meilleures performances ont été enregistrées l'horizon de 20 minutes (NRMSE= 0.0098 et $R^2=1$) pour la combinaison [G_{input}] et de 30 minutes (NRMSE= 0.0100 et $R^2=1$) pour la même combinaison.

Les performances enregistrées pour les autres suivent la même tendance.

En somme, l'analyse des résultats de simulation montre une dégradation progressive des performances du PMC avec différentes combinaisons d'entrées lorsque le pas de temps augmente. Pour le passage du pas de temps de 20 minutes à 30 minutes pour les différentes combinaisons des variables d'entrées, les RMSE obtenues sont respectivement :

[Ginput]: NRSME= 0.0098 et 0.0101;

[Ginput, Hinput]: NRSME=0.044 et 0.054;

[Ginput, Tinput]: NRMSE= 0.114 et 0.247;

[Ginput,Tinput,Hinput]:NRMSE= 0.209 et 0.3087.

Les mêmes tendances sont globalement observées pour les autres pas de temps 40, 50 et 60 minutes (tableau 2). L'horizon 20 minutes présente les meilleurs performances (NRMSE =0.0098) quel que soit la combinaison des variables d'entrées.

3.4.Évaluation de l'impact des algorithmes d'apprentissages.

Pour comparer les performances des réseaux de neurones, nous avons testé l'impact des trois algorithmes d'apprentissages à savoir le Levenberg-Marquardt « trainlm », celui du Gradient Conjugué « trainscg » et de Quasi-Newton « trainbfg ». Le test porte sur les quatre combinaisons de modèle pour un horizon 20 minutes.

Les résultats de l'étude de l'impact des trois algorithmes d'apprentissages (trainlm, trainscg et trainbfg) dans le tableau 3 montre que les meilleures performances sont obtenues avec l'algorithme d'apprentissage « trainlm » pour les différents d'architectures de réseaux de neurones. L'architecture [Ginput] donne la meilleure performance par rapport aux autres combinaisons de modèles [Ginput, Hinput],

[Ginput, Tinput] et [Ginput,Tinput, Hinput] (voir tableau3). Son erreur quadratique moyenne normalisée tend vers zéro (NMSE= 0.0098) avec un coefficient de corrélation optimale ($R^2= 1$) obtenu au bout de 29 itérations. Les performances pour les mêmes combinaisons de modèles obtenues avec l'algorithme de descente du gradient conjugué suivent les mêmes tendances. Les meilleures performances ont été également obtenues pour la même combinaison n'utilisant que l'irradiation [Ginput] avec une erreur quadratique moyenne normalisée égale à 0.723 et un coefficient de corrélation optimale ($R^2= 1$) obtenu au bout de 30 itérations. Les performances des combinaisons de modèles [Ginput, Hinput], [Ginput, Tinput], [Ginput, Tinput, Hinput] ont respectivement des NRMSE estimées à 1.458, 1.832 et 2.080. Ces performances ont été également obtenues au bout de 30 itérations. En fin l'algorithme de quasi-Newton les NRMSE sont respectivement égale à 1.361, 1.377, 2.843 et 3.849 pour les combinaisons de variables d'entrées [Ginput], [Ginput, Hinput], [Ginput, Tinput], [Ginput,Tinput, Hinput].Les coefficients de déterminations correspondants (R^2) sont :1, 0.999, 0.998 et 0.998.

En somme, ces résultats montrent que la prédiction du rayonnement solaire global, avec les différents algorithmes d'apprentissages (« trainlm », « trainscg » et « trainbfg ») sont plus sensible aux combinaisons de modèles pour l'horizon temporel 20 minutes. De plus d'après ces trois tests, il est aisé de remarquer que celui qui est plus adapté à notre site d'étude est l'algorithme de Levenberg-Marquardt « trainlm» (NRMSE= 0.0098, $R^2= 1$ et Epoch= 29), suivi celui du Gradient Conjugué « trainscg » (NRMSE= 0.7, $R^2= 1$ et Epoch= 30) et en dernier lieu nous avons l'algorithme Quasi-Newton « trainbfg » (NRMSE= 0.98, $R^2= 1$ et Epoch= 30) avec le [Ginput].

Tableau 2. – Résultats des tests de performances des trois algorithmes d'apprentissages

Matrices d'entrées	Epoch	NRMSE	R^2	Algorithmes d'apprentissages
[Tinput, Ginput, Hinput][Goutput.]	30	0.209	1	Trainlm
[Ginput, Tinput], [Goutput]	30	0.114	1	
[Ginput, Hinput], [Goutput]	30	0.044	1	
[Ginput], [Goutput]	29	0.0098	1	
[Ginput, Tinput, Hinput] [Goutput.]	30	2.080	1	trainscg
[Ginput, Tinput], [Goutput]	30	1.832	0.999	
[Ginput, Hinput], [Goutput]	30	0.1303	0.998	
[Ginput], [Goutput]	30	0.7234	1	
[Tinput, Ginput, Hinput] [Goutput.]	30	2.813	0.998	trainbfg
[Ginput, Tinput], [Goutput]	30	4.017	0.999	
[Ginput, Hinput], [Goutput]	30	1.116	1	
[Ginput], [Goutput]	30	0.987	1	

3.5. Impact des couples de fonction de transfert sur les performances du modèle.

Le tableau 4 présente les performances de quatre combinaisons de modèles sous l'impact des neuf couples de fonctions de transfert via l'algorithme

Levenberg-Marquard. Il s'agit d'évaluer l'impact des neuf couples de fonction de transfert sur les performances des différentes combinaisons de modèles de réseaux de neurones sur un horizon de 20 minutes. Ces performances ont été évaluées grâce à l'erreur quadratique moyenne, le coefficient de corrélation, le

temps de simulation et le nombre d'itération. Les neuf couples de fonctions de transfert évalués sont : [Tansig-Tansig], [Tansig-Logsig], [Tansig-Purelin], [Logsig-Logsig], [Logsig-Tansig], [Logsig-Purelin], [Purelin-Purelin], [Purelin-Logsig] et [Purelin-Tansig].

Tableau 4. - Performances de l'impact des neuf couples de fonctions de transferts

Couples de Fonctions Transferts	Epoch	Temps	NRMSE	R ²	Variables d'entrées
[Logsig-Purelin]	30	00:03:07	0.143	1	[G _{input} , T _{input} , H _{input}] [G _{output}]
[Tansig-Purelin]	30	00:00:24	3.585	0.999	
[Logsig-Logsig]	30	00:02:11	0.080	1	
[Logsig-Tansig]	25	0:00:25	0.356	1	
[Tansig-Tansig]	30	00:04:20	0.058	1	
[Tansig-Logsig]	30	00:03:15	0.176	1	
[Purelin-Purelin]	30	00:02:03	0.144	1	
[Purelin-Logsig]	30	00:03:38	0.025	1	
[Purelin-Tansig]	30	00:03:05	0.025	1	
[Logsig-Purelin]	30	00:01:28	0.117	1	[G _{input} , T _{input}] [G _{output}]
[Tansig-Purelin]	30	00:01:31	0.163	1	
[Logsig-Logsig]	30	00:00:48	0.088	1	
[Logsig-Tansig]	30	00:01:09	1.615	0.999	
[Tansig-Tansig]	30	00:01:18	0.090	1	
[Tansig-Logsig]	30	00:01:38	0.467	0.999	
[Purelin-Purelin]	30	00:01:23	0.118	1	
[Purelin-Logsig]	30	00:01:55	0.025	1	
[Purelin-Tansig]	30	00:01:18	0.011	1	
[Logsig-Purelin]	30	00:01:19	0.1966	1	[G _{input} , H _{input}] [G _{output}]
[Tansig-Purelin]	30	00:00:24	3.585	0.999	
[Logsig-Logsig]	30	0:02:11	0.080	1	
[Logsig-Tansig]	30	00:00:25	0.356	1	
[Tansig-Tansig]	30	00:04:20	0.058	1	
[Tansig-Logsig]	30	00:03:15	0.176	1	
[Purelin-Purelin]	30	00:02:03	0.1441	1	
[Purelin-Logsig]	30	00:02:47	0.375	0.999	
[Purelin-Tansig]	30	00:03:57	0.025	1	
[Logsig-Purelin]	29	00:00:52	0.009	1	[G _{input}] [G _{output}]
[Tansig-Purelin]	30	00:00:21	0.092	1	
[Logsig-Logsig]	30	00:00:53	0.010	1	
[Logsig-Tansig]	30	00:01:40	0.010	1	
[Tansig-Tansig]	21	00:00:15	0.0198	1	
[Tansig-Logsig]	30	00:00:35	0.010	1	
[Purelin-Purelin]	15	00:00:02	1.416	1	
[Purelin-Logsig]	30	00:00:43	0.024	1	
[Purelin-Tansig]	30	00:00:30	0.100	1	

Les meilleures performances (NRMSE= 0.009, R²= 1, t= 00:00:58) sont obtenues avec le couple de fonction de transfert [Logsig-Purelin] et d'une architecture

[G_{input}, G_{output}]. Ensuite vient le couple de fonction de transfert [Logsig-Tansig] (NRMSE=0.010, R²=1, t= 00:00:35s) avec le modèle d'architecture [G_{input},

Goutput]. Les performances NRMSE (0.0103, 0.0104, 0.0198) du modèle de combinaison [Ginput, Goutput] se dégradent sous l'impact de ces différents couples de fonction de transfert [Tansig-Logsig], [Logsig-Logsig], [Tansig-Tansig]. Enfin le modèle d'architecture [Ginput, Goutput] perd de plus en plus ces performances (NRMSE égale à 0.100 ; à 0.024 ou à 1.416) avec les différents couples de fonction de transfert [Purelin-Logsig], [Purelin-Tansig] et [Purelin-Purelin].

En somme, ces résultats (NRMSE=0.009 pour [Logsig-Purelin], NRMSE=0.01 pour [Logsig-Tansig] et NRMSE= 0.02 pour [Purelin-Logsig]) obtenus avec ce modèle d'architecture [Ginput, Goutput] confirment bien que la fonction d'activation de la couche cachée doit être non linéaire (sigmoïde ou logistique). Par contre la fonction d'activation de la couche d'entrée et celle de sortie doivent toutes linéaires (Purelin) [47].

3.6. Impact de la température et de l'humidité relative sur le modèle PMC.

Les résultats d'évaluation des taux d'impact des paramètres exogènes sur l'évolution dynamique de la radiation solaire globale obtenus avec le modèle de PMC sont présentés dans le tableau 5. Il montre les meilleures combinaisons de variables d'entrées de modèle d'architecture [Ginput] sans impact des paramètres exogènes sur l'évolution dynamique de la radiation solaire globale. Ensuite nous avons le modèle

d'architecture [Ginput, Hinput] sous l'impact de l'humidité relative seulement sur l'évolution dynamique de la radiation solaire globale. Par ailleurs nous avons également celui de [Ginput, Tinput] sous l'impact de la température seule sur l'évolution dynamique de la radiation solaire globale. Enfin nous obtenons celui de [Ginput, Tinput, Hinput] sous l'impact simultané de l'humidité relative et de la température sur l'évolution dynamique de la radiation solaire globale selon tous les différents pas de temps de prévisions.

Ces résultats montrent clairement que l'impact est beaucoup plus significatif quand avec la présence simultanée de la température et de l'humidité relative sur l'évolution dynamique de la radiation solaire globale [Ginput, Tinput, Hinput] avec un taux d'impact de 19.99% et une NRMSE= 0.209 pour l'horizon 20 minutes. De plus, nous observons la même tendance pour tous les pas de temps. Par contre l'impact est moins significatif lorsque nous avons la présence dominante de l'humidité relative [Ginput, Hinput] avec un taux d'impact égal à 3.49 % et une NRMSE= 0.044 que lorsque nous somme à une présence dominante de la température [Ginput, Tinput] avec un taux d'impact égale à 10.63 % et une NRMSE= 0.1145 sur l'évolution de la radiation solaire globale. Nous remarquons aussi à travers les résultats que le modèle se livre à une perte de sa performance lorsque la radiation solaire globale n'est pas impliquée dans la combinaison des données d'entrées.

Tableau 5. - : Evaluation du taux d'impact des paramètres exogènes sur les performances des modèles

Pas de temps en minutes	20	30	40	50	60
Taux d'impact_ [Ginput, Tinput, Hinput]	19.99	29.91	38.41	37.28	38.15
Taux d'impact_ [Ginput, Tinput]	10.63	23.45	29.89	28.81	28.52
Taux d'impact_ [Ginput, Hinput]	3.49	4.32	6.82	6.80	6.67
Taux d'impact_ [Ginput]	0	0	0	0	0

3.7. Évolution des données mesurées et celles prédites par le modèle PMC.

La figure 5 présente l'évolution des valeurs observées sur le site d'étude (couleur en vert), des valeurs prédites par le modèle de perception multicouches (courbe en bleu). Les données prédites avec le modèle suivent bien les données mesurées

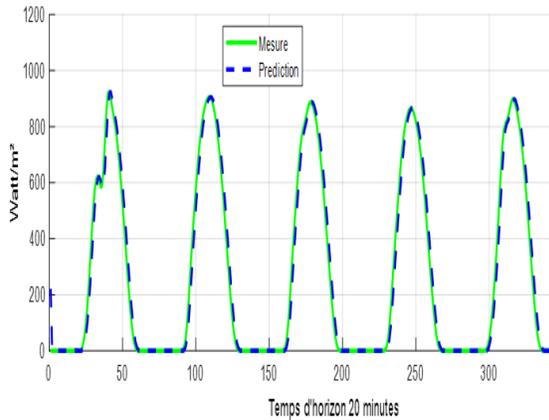


Figure5: Évolution des données mesurées et celles prédites par le PM

3.8. Analyse et Discussion

Ce travail permet de bien confirmer que les performances des modèles RNA dépendent de facteurs divers.

Ils dépendent d'abord du choix de la meilleure combinaison d'entrée (variables météorologiques). En effet, les meilleures performances NRMSE obtenues avec les quatre modèles de combinaisons de variables d'entrées $[G_{input}]$, $[G_{input}, H_{input}]$, $[G_{input}, T_{input}]$, $[G_{input}, T_{input}, H_{input}]$ sont respectivement 0.0098, 0.044, 0.114 et 0.209.

Ils dépendent également du type d'algorithme d'apprentissage car d'après les tests de ces trois algorithmes. Ce constat permet entre autres de remarquer que l'algorithme le plus adapté, pour notre site d'étude en terme de rapidité et de qualité est l'algorithme de Levenberg-Marquardt « trainlm » (NRMSE = 0.0098, $R^2 = 1$ et Epoch = 29), suivi celui du Gradient Conjugué « trainscg » (NRMSE = 0.7, $R^2 = 1$ et Epoch= 30) et en dernier lieu nous avons l'algorithme Quasi-Newton « trainbfg » (NRMSE = 0.98, $R^2 = 1$ et Epoch= 30) avec comme type de modèle PMC de configuration $[G_{input}]$. Les performances du modèle choisi peuvent dépendre du type de couple de fonction de transfert, d'après les résultats de différents tests (NRMSE= 0.009 pour [Logsig-Purelin], NRMSE = 0.01 pour [Logsig-Tansig] et NRMSE= 0.02 pour [Purelin-Logsig]) pour le modèle d'architecture $[G_{input}, G_{output}]$ confirmant bien des conclusion arrêtées dans la littérature. Des auteurs trouvent en effet dans la littérature que la fonction d'activation de la couche cachée doit être non linéaire (sigmoïde ou logistique) et que les fonctions d'activation de la couche d'entrée et celle de sortie doivent toutes linéaires (Purelin) [47].

L'analyse de ces résultats de simulation montre une dégradation progressive des performances de différentes combinaisons d'entrées du modèle PMC lorsque le pas de temps augmente, notamment lorsqu'on passe de 20 à 30 minutes pour les différentes combinaisons de variables d'entrées (voir tableau). Les mêmes tendances sont observées globalement pour les

autres pas de temps 40, 50 et 60. L'horizon 20 minutes présente les meilleurs performances (NRMSE= 0.0098) quel que soit la combinaison des variables d'entrées. Enfin de l'impact des paramètres environnementaux sur l'évolution de la sortie du modèle PMC car ces résultats montrent clairement que l'impact est beaucoup plus significatif lorsqu'on a la présence simultanée de la température et de l'humidité relative à l'entrée sur l'évolution dynamique de la radiation solaire globale $[G_{input}, T_{input}, H_{input}]$ avec un taux d'impact de 19.99% et une NRMSE= 0.209 suivant l'horizon 20 minutes. Par contre l'impact est moins significatif avec la présence dominante de l'humidité relative $[G_{input}, H_{input}]$ pour un taux d'impact égal à 3.49 % et une NRMSE= 0.044 qu'avec présence dominante de la température $[G_{input}, T_{input}]$ pour un taux d'impact égale à 10.63 % et une NRMSE = 0.1145 sur l'évolution de la radiation solaire globale.

4. Conclusion

Dans le cadre de ce travail nous avons testé un modèle de réseau de neurones artificiels de prédiction avec des données mesurées sur le site de Dakar du Sénégal. Ce modèle permettrait de contribuer à l'amélioration des processus de prise de décision à court terme concernant la gestion des centrales solaire PV dans la région de Dakar. Les paramètres d'entrées du modèle sont constitués de la température de l'air, de l'humidité relative et du rayonnement solaire global. La production attendue au temps $t+T$ est le rayonnement solaire global.

Un modèle de perception multicouches basé sur l'étude de l'impact de différents paramètres tels que les pas de temps, les algorithmes d'apprentissages (Levenberg-Marquardt, Gradient Conjugué et Quasi-Newton), les fonctions d'activation (Purelin, Logsig et Tansig) et les paramètres environnementaux (température et humidité relative) est mis au point. Nous avons évalué les performances du modèle via un ensemble de critères de performance tels que la racine carrée de l'erreur quadratique moyenne (NRMSE), et la racine carrée de l'erreur quadratique moyenne (R^2).

Les résultats de la simulation montrent que les meilleures performances (NRMSE= 0.0098 et $R=1$) sont obtenues avec le modèle de combinaison de variable d'entrées $[G_{input}]$ sans impact de la température et de l'humidité relative basé sur l'algorithme de Levenberg-Marquardt « trainlm » et le couple de fonction de transfert [Logsig-Purelin] sur 20 minutes. Ce modèle pourra contribuer au développement de modèle de réseau de neurone pour aider à la prise de décision à court terme dans la zone de Dakar.

REFERENCES

- [1] C.Voyant, «Prediction of time series of global solar radiation and photovoltaic energy production from artificial neural networks», Thesis, University of Corsican-Pascal Paoli doctoral School environment and society, Chapter2, P87 2011).
- [2] S.Monjoly, R.Calif, M.Andre and T.Soubdhan, «Prediction tools for wind power generation: Application to optimize coupling to electricity distribution network», University of the West Indies and Guyana December, (2013).
- [3] M.Diagne, «Gestion intelligente du réseau électrique réunionnais. Prévion de la ressource solaire en milieu insulaire», Energie électrique, Université de la Réunion. Français.fFNNT: 2015 LARE0014ff.fttel-01328719.
- [4] A.Mellit, S.A.Kalogirou, L.Hontoria and S.Shaari, «Artificial intelligence for sizing photovoltaic systems», Renewable and Sustainable Energy Reviews n°13-2, p406-419 (2009).
- [5] A.Mellit, S.A.Kalogirou, «Artificial intelligence techniques for photovoltaic application », Progress in Energy and Combustion Science n°1-1, p52-76, (2008).
- [7] C.V.T.Cabral and al, «Stochastic method for stand-alone photovoltaic system sizing», Solar Energy, 84(9), pp.1628–1636, (2010).
- [8] J.S.G.Ehnberg and M.H.J.Bollen, «Simulation of global solar radiation based on cloud observations», Solar Energy, 78(2), pp.157–162, (2005).
- [9] F.O.Hocaoglu and al, «Stochastic approach for daily solar radiation modeling», Solar Energy, 85(2), pp.278–287, (2011).
- [10] M.Muselli and al, «First order Markov Chain model for generating synthetic-typical days series of global irradiation in order to design photovoltaic stand-alone systems », Energy Conversion and Management, 42(6), pp.675–687, (2001).
- [11] C.Voyant, C.Darras, M.Muselli and al, « Bayesian rules and stochastic models for high accuracy prediction of solar radiation», Applied Energy, Elsevier, (2013). fihal-00862981f.
- [12] G.Vincent, «Présentation EDF-SEI, rencontre prevision insulaire, AIX-EN-Provence», (Octobre 2012).
- [13] C.Monteiro, H.Keko, R.Bessa, V.Miranda, A.Botterud, J.Wang and G.Conzelmann, A quick guide to wind power forecasting: State-of-the-art-2009», Technical Report ANL/DIS-10-2, Argonne National Laboratory, East Lansing, Michigan, (2009).
- [14] A.Botterud, Z.Zhou, J.Wang, J.R.Bessa, H.Keko, J.Mendes, J.Sumaili and V.Miranda, V. (2011). Use of wind power forecasting in operational decisions. Technical Report ANL/DIS-11-8, Argonne National Laboratory, East Lansing, Michigan, (2011).
- [15] P.Lauret, M.H.Diagne, M.David, A.Rodler, M.Muselli, C.Voyant, «A Bayesian model committee approach to forecast global solar radiation», In: World renewable energy forum, W REF2012, including world renewable energy congress XII Colorado renewable energy society (CRES) annual conference, 4354-4359, (2012).
- [16] J.M.Vindel and J.Polo, «Markov processes and Zipf's law in daily solar irradiation at earth's surface », Journal of Atmospheric and Solar Terrestrial Physics, 107, pp.42-47, (2014).
- [17] D.W.Vander Meer, «comment on verification of deterministic solar forecasts: Verification of probabilistic solar forecasts», Sol Energy 2020.http://dx.doi.org/10.1016/j.solener.2020.04.015.
- [18] P.Lauret and al, «Probabilistic Solar Forecasting Using Quantile Regression Models Forecasting», Energies 2017, 10, 1591; doi:10.3390/en 10101591.
- [19] T.Hong and S.Fan, «Probabilistic electric load forecasting: a tutorial review », International Journal of Forecasting, (2016);
- [20] D.W.Vander Meer, J.Widén and J.Munkhammar, «Review on probabilistic forecasting of photovoltaic power and electricity consumption», Renewable and Sustainable Energy Reviews, Volume 81, Part 1, 2018, PP-1484-1512, ISSN 1364-0321, (2018).
- [21] G.P.Zhang and al, «Time Series Forecasting using a hybrid ARIMA and neural network model», Neurocomputing, Volume 50, 2003, Pages 159-175, ISSN 09252312, https://doi.org/10.1016/S0925-2312(01)00702-0.
- [22] A. MBAYE, M.L. NDIAYE, J.Ndong and al, «Impact of meteorological parameters on short-term forecasting: Application to the Dakar site», in Proceedings of the 2019 IEEE 2nd International Conference on Power and Energy Applications 2019 (ICPEA 2019), Singapore, April 2019.
- [23] A.Mbaye, M.L.Ndiaye, D.M.Ndione and al, «ARMA model for short term forecasting of solar potential :Application to a horizontal surface on Dakar site», OAJ Mater Device 4 (1):1–8, (2019).
- [24] Perspective monde, source: Banque mondiale <https://perspective.usherbrooke.ca/bilan/tend/SEN/fr/EG.US.E.ELEC.KH.PC.html>, date de consultation : 26/11/2020.
- [25] I.Shaft, J.Ahmad, S.I.Shah and M.F.Kashif, «Impact de neurones et de couches cachées dans l'architecture du réseau neuronal pour une application de fréquence de temps », Dans Proceedings of the 10th IEEE International Multitopic Conference (INMIC), Islamabad, Pakistan, 23-24 décembre 2006; pp.188-193.
- [26] M. Benganem, «Artificial Intelligence Techniques for Prediction of Solar Radiation Data», International Journal of Renewable Energy Technology, Vol. 3, N°2, pp.189 - 219, (2012).
- [27] Dahmani, G. Notton, R. Dizène and C. Paoli, «État de l'art sur les réseaux de neurones artificiels appliqués à l'estimation du rayonnement solaire », Revue des Energies Renouvelables, Vol. 15 N°4 687- 702, (2012).
- [28] C. Voyant, M. Muselli, C. Paoli and M.L. Nivet, 'Optimization of an Artificial Neural Network Dedicated to the Multivariate Forecasting of Daily Global Radiation' Energy, Vol. 36, N°1, pp. 348-359, 2010.
- [29] A.Sfetsos and A.H.Coonick, «Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques», Solar Energy, vol. 68, no. 2, pp. 169–178, (2000).
- [30] O.Assas and al, «Use of the Artificial Neural Network and Meteorological Data for Predicting Daily Global Solar Radiation in Djelfa, Algeria», International Conference on Composite Materials and Renewable Energy Applications (ICCMREA), 978-1-4799-2516-2/14/\$31.00 ©2014 IEEE.
- [31] M.A.Khan, S.Huque and A.Mohammad, A Neural Network Model for Estimating Global Solar Radiation on Horizontal Surface, 2013 International Conference on Electrical Information and Communication Technology, (EICT), 978-1-4799-2299-4/13/\$31.00 ©2013 IEEE.
- [32] K.Dahmani, G.Notton, C.Voyant and al, «Multilayer Perception approach for estimating 5 minutes and hourly horizontal global irradiation from exogenous meteorological data in locations without solar measurements», Renewable Energy 90:267-282, (2016) ; DOI : 10.1016/j.renene.2016.01.013.
- [33] A.Elamim and al, «Prediction of Time Series of Photovoltaic Energy Production Using Artificial Neural Networks», AI2SD 2018. Advances in Intelligent Systems and Computing, vol.912. Springer, Cham, (2018).
- [34] Jain K, Jianchang M, Mohiuddin KM, Artificial Neural Networks: A tutorial, IEEE Computer 31-44 (29), 1996.

- [35] M.A. Ammar «Mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition batch/continu, Thèse de doctorat de l'I.N.P.-Toulouse-194 p, 2007.
- [36] I. Manssouri, M. Manssouri and B. El Kihel, «Fault Detection by K-NN algorithm and MLP neuronal networks in distillation column » *Journal of information, Intelligence and knowledge*, Vol.3, pp.57-72 2011.
- [37] S.F. Crone, « Stepwise Selection of Artificial Neural Networks Models for Time Series Prediction *Journal of Intelligent System*», Department of Management Science Lancaster University Management School Lancaster, United Kingdom, (2005).
- [38] L. Hontoria, J. Riesco, P. Zufiria and J. Aguilera, «Improved Generation of Hourly Solar Radiation Artificial Series using Neural Networks», In *Proceeding of Engineering Applications of Neural Networks*, EANN'99, Warsaw, Poland, 1999.
- [39] L. Hontoria, J. Aguilera and P. Zufiria, «Generation of Hourly Irradiation Synthetic Series using the Neural Network Multilayer Perceptron», *Solar Energy*, Vol. 72, N°5, pp. 441 - 446, 2002.
- [40] S.F. Crone, «Stepwise Selection of Artificial Neural Networks Models for Time Series Prediction *Journal of Intelligent Systems*», Department of Management Science Lancaster University Management School Lancaster, United Kingdom, (2005).
- [41] S. Hwang, I. Basawa and T. Yoon Kim, «Least squares estimation for critical random coefficient first order autoregressive processes», *Statistics & Probability Letters*, n°1 ;76(3), p 310-317, (2006).
- [42] O. Fatih, G. Hocaoglu, N. Omer and M. Kurba, Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward neural networks, *Solar Energy*, pp. 714–726, (2008).
- [43] G. López, F.J. Batlles, J. Tovar-Pescador, Selection of input parameters to model direct solar irradiance by using artificial neural networks, *Energy*, N°30(9), p 1675-1684, (2005).
- [44] H. Badaoui, Abdelaziz Abdallaoui and Samira Chabaa, Etude des effets des algorithmes d'apprentissage et des fonctions de transfert sur la performance des modèles statistiques neuronaux: Application dans le domaine météorologique, *International Journal of Engineering Research and Development* e-ISSN:2278-067X, pISSN:2278800X, www.ijerd.com Volume9, Issue6 (December 2013), PP.15-26.
- [45] A. Mellit and A.M. Pavan, « 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*, Vol. 84, N°5, pp. 807–821, (2010).
- [46] G. Dreyfus, «Les réseaux de neurones», *Mécanique industrielle et matériaux* n°51, (1998).
- [47] Espinoza, M., J.A.K. Suykens, and al, LS-SVM regression with auto correlated errors. *Proc. of the 14th IFAC Symposium on System Identification (SYSID)*, (2006).