



Department: Electrical Engineering

Laboratory of Applied Automation and Industrial Diagnostics

order N°: / 2021

Authorization of thesis defense N° 304/2021

THESIS

With a view to obtaining the degree of DOCTORATE in science

In: Applied Automation and Industrial Diagnostics

Option: Electrotechnics

Presented by

FERKOUS Khaled

Characterization and Evaluation of Solar Radiation for the Ghardaïa site

Supported, on 11/12/2021, before the jury composed of:

Last and first name	Grade	Institution of affiliation	designation
Mr. HAFIFA Ahmed	Professor	University of Djelfa	Président
Mr KOUZOU Abdellah	Professor	University of Djelfa	Supervisor
Mr. CHELLALI Farouk	MCA	University of Djelfa	Co-Supervisor
Mr. MOKRANI Lakhdar	Professor	University of Laghouat	Examiner
Mr. AZOUI Boubakeur	Professor	University of Batna	Examiner
Mr. DRID Said	Professeur	University of Batna	Examiner
Mr. OUAI Atallah	MCA	University of Laghouat	Guest



Département : Génie Electrique

Laboratoire d'Automatique Appliquée et Diagnostic Industriel

N° d'ordre : / 2021

Autorisation de soutenance N° 304/2021

THÈSE

Présentée pour l'obtention du grade de DOCTORAT en sciences

En : Automatique Appliquée et Diagnostics Industriel

Option : Electrotechnique

Présentée par

Mr. FERKOUS Khaled

Caractérisation et Evaluation du Rayonnement Solaire pour le site de Ghardaïa

Soutenue publiquement, le 11 /12 /2021, devant le jury composé de :

Nom et Prénom	Grade	Etablissement de rattachement	Désignation
Mr. HAFAIFA Ahmed	Professeur	Université de Djelfa	Président
Mr KOUZOU Abdellah	Professeur	Université de Djelfa	Directeur de thèse
Mr. CHELLALI Farouk	MCA	Université de Djelfa	Co Directeur de thèse
Mr. MOKRANI Lakhdar	Professeur	Université de Laghouat	Examineur
Mr. AZOUI Boubakeur	Professeur	Université de Batna	Examineur
Mr. DRID Said	Professeur	University de Batna	Examineur
Mr. OUAI Atallah	MCA	Université de Laghouat	Invité

Université de Djelfa, 2021

Dédicaces

A la mémoire de ma cher mère, Sans toi Mama, tout cela n'aurait pas connu le jour.

A la mémoire de ma cher sœur, toujours été mon modèle de gentillesse et de persévérance

A mon père; que dieu te garde en bonne santé et longue vie.

A ma chère épouse et nos adorables enfants :

Qu'ils sachent simplement qu'ils sont au fond de mon cœur

A chaque instant et en tout lieu.

Remerciement

Avant d'attaquer la phase de remerciements, je voudrais dire à quel point il m'a été difficile d'entreprendre une thèse en étant salarié, de reprendre mes études à trente ans et surtout à quel point je suis content d'avoir pu la mener à son terme.

En tout premier lieu, je remercie Allah le tout-puissant et miséricordieux, qui m'a donné la force et la patience d'accomplir ce modeste travail.

Je voudrais remercier mes directeurs de thèses. J'ai beaucoup appris à leur contact : ils m'ont permis de progresser dans de nombreux domaines tant scientifiques que rédactionnels ou organisationnels. Donc, un grand merci à Monsieur Abdellah Kouzou, Monsieur Farouk Chellali.

Je souhaite aussi faire part de ma gratitude aux membres du jury. Merci à M. Ahmed Hafaifa d'avoir accepté d'être rapporteur de cette thèse. Je tiens aussi à remercier M. Mokrani Lakhdar (Université de Laghouat), M. Azoui Boubakeur (Université de Batna), M. Drid Said (Université de Batna) et M. Ouai Atallah (Université de Laghouat), d'avoir consenti à être examinateurs dans mon jury de thèse.

Mes remerciements vont aussi à mes collègues de l'université de Ghardaïa en particulier: Tayeb Boulmaiz pour leur bonne humeur et leur assistance.

Outres toutes les personnes que je viens de présenter et qui m'ont aidées directement ou indirectement durant cette thèse, il y a trois autres personnes que je tiens tout particulièrement à remercier. Il s'agit tout d'abord, de mes deux enfants *Abd Elmouaiz* et *Abd Elmatine*. Je pense qu'il n'a pas toujours été facile pour eux de voir leur papa « trop souvent devant son ordinateur ». Il en est de même pour mon épouse : pendant toutes les périodes où j'étais mobilisé par la thèse, je ne pouvais pas être très disponible à la maison, je me rends bien compte que je ne suis pas le seul à avoir fait des sacrifices pour que cette thèse soit menée à bien. Merci aussi pour l'aide apportée durant les phases de rédaction.

Résumé

Dans cette thèse, des modèles hybrides utilisant l'algorithme de Régression de Processus Gaussienne (GPR) avec la décomposition en ondelettes W-GPR ont été proposés pour prédire le rayonnement solaire journalier dans la ville de Ghardaïa (Algérie). Le problème est examiné avec des données météorologiques (variables exogènes) et des données du rayonnement solaire au temps précédant le jour prédit (variables endogènes) comme entrées dans le processus d'estimation du modèle optimal. À cette fin, des séries de données journalières pendant 3 ans (2013-2015) ont été utilisées dans l'apprentissage du modèle tandis que les données de 2016 ont été utilisées pour le tester. Les résultats ont montré l'efficacité du modèle hybride, en particulier WPD-GPR, par rapport au modèle GPR classique. Le modèle a donné d'excellents résultats lors de l'utilisation d'entrées endogènes, en termes d'erreur quadratique moyenne, d'erreur quadratique moyenne relative, d'erreur absolue moyenne et coefficient de détermination.

Mots clé : *Rayonnement solaire ; Comportement aléatoire ; Comportement cyclique ; Prédiction ; Régression de Processus Gaussienne; ondelettes ; Modèle hybride.*

Abstract

In this study, hybrid models using Gaussian Process Regression (GPR) algorithm and Wavelet Decomposition W-GPR have been proposed to predict daily solar radiation in Ghardaia city (Algeria). The problem is examined with meteorological data (exogenous variables) and delayed solar radiation data (endogenous variables) as inputs for the estimation process of optimal model. For this purpose, 3 years data series (2013-2015) have been used in the model training while data of 2016 were used to test the model. The results showed the hybrid model efficiency, especially WPD-GPR when comparing to the classical GPR model. The model showed excellent results when using endogenous inputs, in terms of Root Mean Square Error, relative Root Mean Square Error, Mean Absolute Error and determination coefficient.

Key Words : *Solar radiation ; Radom behavior; Cyclical behavior; Forecasting ; Gaussian Process Regression; wavelets ; Hybrid model.*

ملخص

في هذه الأطروحة تم اقتراح نماذج هجينة باستخدام خوارزمية انحدار العملية الغاوسية GPR مع التحلل التويجي W للتنبؤ بالإشعاع الشمسي اليومي في مدينة غرداية، وتم فحص المشكلة ببيانات الأرصاد الجوية (المتغيرات الخارجية) وبيانات الإشعاع الشمسي في وقت ما قبل اليوم المتوقع (المتغيرات الداخلية) كمدخلات، تم استخدام سلسلة بيانات مدتها 3 سنوات (2013-2015) في تدريب النموذج بينما تم استخدام بيانات عام 2016 للتحقق من صحة النموذج. أظهرت النتائج كفاءة النموذج الهجين، خاصة WPD-GPR مقارنة بنموذج GPR الكلاسيكي، أعطى النموذج نتائج ممتازة عند استخدام الإشعاع الشمسي كمتغير وحيد في سلسلة المدخلات، من حيث جذر متوسط الخطأ التربيعي، والجذر النسبي لمتوسط الخطأ التربيعي ومتوسط الخطأ المطلق. ومعامل التحديد.

الكلمات المفتاحية: الإشعاع الشمسي؛ سلوك عشوائي؛ سلوك دوري؛ تنبؤ؛ انحدار العملية الغاوسية؛ موجات؛ نموذج هجين.

Nomenclatures

λ	longitude	(°)
φ	latitude	(°)
δ	déclinaison solaire	(°)
n_j	numéro de jour de l'année	-
ω	angle horaire	(°)
h	Hauteur angulaire	(°)
θ_z	angle zénithal	(°)
d	Durée astronomique du jour	Heurs
a	Azimut	(°)
r_0	distance moyenne terre-soleil	1UA=150 millions Km
r	distance actuelle terre-soleil	UA
I_0	Constante solaire	W/m ²
I_{SC}	Constante solaire corrigé	W/m ²
T_{min}	la température minimale de l'air	°C
T_{max}	la température maximale de l'air	°C
T_{moy}	la température moyenne de l'air.	°C
RH_{min}	l'humidité relative minimale.	%
RH_{max}	l'humidité relative maximale	%
RH_{moy}	l'humidité relative moyenne.	%
S_d	la durée d'insolation moyenne journalière	Heurs
S_0	la durée d'insolation maximale	Heurs
K	Indice de clarté	-
TSV	temps solaire vrai	heure
TL	Temps solaire local	heure
TU	Temps universel	heure
ΔH	Décalage horaire	heure
TSM	Temps solaire moyen	heure
ET	Equation du temps	min
β_0	angle du jour	(°)
I_h	éclairage sur un plan horizontal	W/m ²

H_0	Irradiation solaire hors atmosphère sur un plan horizontal	$Wh. m^{-2}jour^{-1}$
H	irradiation solaire reçue sur un plan horizontal	$Wh. m^{-2}jour^{-1}$
G_h	rayonnement global sur une surface horizontale	W/m^2
G_c	rayonnement global par ciel clair	W/m^2
I	rayonnement direct	W/m^2
D	rayonnement diffus	W/m^2
$H_{n,obs}$	Valeur observées	$Mj. m^{-2}jour^{-1}$
$\bar{H}_{n,obs}$	Valeur observées moyenne	$Mj. m^{-2}jour^{-1}$
$H_{n,pred}$	Valeurs prédites	$Mj. m^{-2}jour^{-1}$
$\bar{H}_{n,pred}$	Valeurs prédites et moyenne.	$Mj. m^{-2}jour^{-1}$
r	Coefficient de corrélation	-
R^2	Coefficient de détermination	%
MSE	Erreur quadratique moyenne	$Mj. m^{-2}jour^{-1}$
$RMSE$	Racine de l'erreur moyenne quadratique	$Mj. m^{-2}jour^{-1}$
$rRMSE$	Erreur relative l'erreur moyenne quadratique	$Mj. m^{-2}jour^{-1}$
GSR	Rayonnement solaire globale (Global Solar Radiation)	$Mj. m^{-2}jour^{-1}$

Abréviation

Terme	Anglais	Français
<i>ABC</i>	Artificial Bee Colony	colonie d'abeilles artificielles
<i>ANN</i>	Artificial Neural Network	Réseau neuronal artificiel
<i>ANFIS</i>	Adaptive Neural Fuzzy Inference Systems	Systèmes d'inférence floue neuronale adaptative
<i>AR</i>	Autoregressive	Autorégressif
<i>ARMA</i>	Autoregressive Moving Average	Moyenne mobile autorégressive
<i>ARIMA</i>	Autoregressive Integrated Moving Average	Moyenne mobile intégrée autorégressive
<i>ARX</i>	Average Autoregressive exogenous	Moyenne Autorégressive exogène
<i>ARPEGE</i>	Small Scale Large Scale Research Action	Action de Recherche Petite Echelle Grande Echelle
<i>AROME</i>	Application of Research to Operations at MESoscale	<i>Application de la recherche aux opérations à MESoscale</i>
<i>AI</i>	Artificial Intelligence	intelligence artificielle
<i>BC</i>	Bristow Campbell	Bristow Campbell
<i>BiLSTM</i>	Bidirectional Long Short-Term Memory	Mémoire à long court terme bidirectionnelle
<i>CLSTM</i>	Convolutional Long Short-Term Memory	mémoire convolutive à long court terme
<i>CNN</i>	Convolutional Neural Network	mémoire convolutive à long court terme
<i>CFA</i>	Cascade Forecasting Architecture	Architecture de prévision en cascade
<i>DL</i>	Deep learning	L'apprentissage en profondeur
<i>DWTs</i>	Wavelet decompositions	Décompositions ondelette
<i>ECMWF</i>	European Centre for Medium-Range Weather Forecasts	<i>Centre européen de prévisions météorologiques à moyen terme</i>
<i>EEMD</i>	Ensemble Empirical Mode Decomposition	Décomposition en mode empirique d'ensemble
<i>EML</i>	Extreme Learning Machine	Machine d'apprentissage extrême
<i>ESSS</i>	Exponential Smoothing State Space	espace d'état de lissage exponentiel
<i>FFA</i>	Fire-Fly Algorithm	algorithme de mouche de feu
<i>FR</i>	Fuzzy Regression	régression floue
<i>GFS</i>	Global Forecast System	Système mondial de prévision
<i>GPR</i>	Gaussian process regression	Régression de Processus Gaussienne
<i>GRU</i>	gated recurrent units	unités récurrentes fermées
<i>k-NN</i>	k-Nearest Neighbor	k-voisin le plus proche
<i>KRR</i>	Kernel Ridge Regression	Régression de la crête du noyau
<i>LS</i>	Least Squares	moindres carrés
<i>LSTM</i>	Long Short-Term Memory	Mémoire longue à court terme
<i>MEA</i>	Mind Evolutionary Algorithm	algorithme évolutionnaire de l'esprit
<i>ML</i>	Machine Learning	apprentissage automatique

<i>MLP</i>	Multilayer Perceptron	perceptron multicouche
<i>MLR</i>	Multi-Linear Regression	régression multilinéaire
<i>NAR</i>	Nonlinear Autoregressive	autorégressif non linéaire
<i>NDFD</i>	National Digital Forecast Database	Base de données nationale de prévisions numériques
<i>NWP</i>	Numerical Weather Prediction	Prévision météorologique numérique
<i>ONM</i>	Weather center	Office National de la Météorologie
<i>PFA</i>	Parallel Forecasting Architecture	Architecture de prévision parallèle
<i>PSO</i>	Particle Swarm Optimization	optimisation de l'essaim de particules
<i>RBF</i>	Radial Basis Function	fonction de base radiale
<i>RBNN</i>	Radial Basis Neural Network	réseau de neurones à base radiale
<i>SOM</i>	Self-Organizing Maps	cartes auto-organisées
<i>SPSO</i>	self-Segulated Particle Swarm Optimization	optimisation d'essaim de particules autorégulée
<i>SVM</i>	Support Vector Machines	Soutenir les machines vectorielles
<i>TSI</i>	Total Sky Imager	Imageur du ciel total
<i>URAER</i>	Renewable Energies Applied Research Unit	<i>Unité de Recherche Appliquée en Energies Renouvelables</i>
<i>WD</i>	Wavelet Decomposition	décomposition ondelettes
<i>WRF</i>	Weather Research and Forecasting	Recherche et prévisions météorologiques
<i>WPD</i>	Wavelet Packet Decomposition	décomposition de paquets d'ondelettes
<i>WT</i>	Wavelet Transformation	Transformation en ondelettes

Table des Figures

Figure (1- 1) : Structure du Soleil.	6
Figure (1- 2) :Distribution spectrale de l'éclairement solaire hors atmosphère de dans les 32 intervalles spectraux et leur contribution correspondante relative.	7
Figure (1- 4) : Les coordonnées terrestres d'un lieu donné.....	8
Figure (1- 5): Mouvement et rotation de la terre.....	9
Figure (1- 6): Angle horaire ω du soleil.	10
Figure (1- 7): Mouvement de la Terre autour du Soleil.	13
Figure (1- 8): Composantes solaires.....	15
Figure (1- 9): Héliographe à fibre optique.	17
Figure (1- 10): Héliographe Campbell-Stokes.	18
Figure (1- 11): Schéma d'un pyranomètre (à gauche), pyranomètre type Eppley (à droite).	19
Figure (1- 12): Pyréliomètre (mesure du rayonnement direct).	19
Figure (1- 13): Carte d'Afrique et Moyen Orient de l'irradiation globale annuel.	20
Figure (1- 14): Irradiation globale horizontale et Répartition des stations météorologiques.....	21
Figure (2- 1) : Dispositif Total Sky Imager (TSI).	27
Figure (2-2): Etapes de mise en œuvre de modèles NWP en 2D.	28
Figure (2- 3): Vue de la terre découpée en une multitude de petites zones.	28
Figure (2- 4): Représentation schématique du neurone artificiel.	34
Figure (2- 5): Analyse d' étude bibliographique.	45
Figure (3- 1) : Processus de modélisation et de prévision.....	48
Figure (3- 2): Processus de décomposition en ondelettes.	50
Figure (3- 3): Processus de décomposition par paquets d'ondelettes	50
Figure (3- 4): Organigramme du modèle proposé W – GPR.	51
Figure (3- 5): la zone d'étude.....	52
Figure (3- 6): Unité de recherche appliquée en énergies renouvelables (URAER) Ghardaïa.	53
Figure (3- 7): Les capteurs météorologiques installée sur le toit de l'URAER (Ghardaïa).....	54
Figure (3- 8): Le cycle climatologique du GSR quotidien pour la ville de Ghardaia	55
Figure (3- 9): Les statistiques d'entrée pour la ville de Ghardaia.....	57
Figure (3- 10) : l'irradiation solaire globale hors atmosphère au site de Ghardaïa.	57
Figure (3- 11): DWT des entrées du modèle W – GPR.	59
Figure (4- 1) : l'évolution du rayonnement global journalière (Ghardaïa)	63

Figure (4- 2) : l'évolution du rayonnement global journalière normalisé (Ghardaïa).	64
Figure (4- 3) : Nuages de points de la valeur de régression de l'énergie solaire rayonnement par rapport à la mesure, avec en entrée les différentes combinaisons pour le modèle W-GPR.....	67
Figure (4- 4) : L'erreur de prédiction dans la période de test.	68
Figure (4- 5): Rayonnement global mesuré par rapport au meilleur estimé W-GPR modèle M ₉ . 68	
Figure (4- 6): dispersion de la valeur prévue du rayonnement solaire par rapport à la valeur mesurée, avec différentes combinaisons d'entrées à l'aide du modèle W-GPR.	70
Figure (4- 7): Rayonnement global mesuré par rapport au meilleur estimé W-GPR modèle M ₉ . 71	
Figure (4- 8): dispersion de H mesuré et estimé avec un modèle uni-varié pour les meilleurs modèles.....	73
Figure (4- 9): Valeurs mesurées par rapport aux valeurs estimées pour WP-GPR.....	73
Figure (4- 10) : dispersion de H mesuré et estimé avec un modèle GPR pour les multi-horizon. 74	
Figure (4- 11) : dispersion de H mesuré et estimé avec un modèle W-C-GPR pour les multi-horizon.....	74
Figure (4- 12): dispersion de H mesuré et estimé avec un modèle WP-GPR pour les multi-horizon.....	75
Figure (4- 13) : distribution de fréquence de l'erreur de prédiction (Pe).....	76
Figure (4- 14): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour multi ondelette mère.....	76
Figure (4- 15): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour paquet ondelette.	77
Figure (4- 16): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour le modèle de référence.	77

Liste des Tableaux

Tableau (1- 1): Consistance du programme de développement des EnR.	22
Tableau (2- 1) : Les principaux modèles météorologiques	29
Tableau (2- 2) : Revue bibliographique	40
Tableau (3- 1) : Variable objective et les statistiques d'entrée pour la ville de Ghardaïa.	56
Tableau (3- 2): Effet du type d'ondelette sur la précision du modèle.	58
Tableau (4- 1): Effet de la décomposition sur la précision des modèles régressives	66
Tableau (4- 2) : Effet de la décomposition sur la précision des modèles prédictives exogènes. ..	69
Tableau (4- 3) : Comparaison des performances globales des modèles	71
Tableau (4- 4) : Effet de la nature de décomposition sur la précision des modèles prédictives uni varié.	72
Tableau (4- 5) : Effet de la décomposition sur la précision des modèles prédictives multi- horizon.....	75
Tableau (4- 6) : Comparaison des performances du modèle développé avec les récentes études	78

Sommaire

Nomenclatures.....	I
Abréviation.....	III
Table des Figures	V
Liste des Tableaux.....	VII
Introduction Générale.....	1
Chapitre 1: Généralités sur le Gisement Solaire.....	4
1.1. Introduction	5
1.2. Rayonnement solaire	5
1.2.1 Nature du rayonnement solaire.....	5
1.2.2 Propagation des ondes électromagnétiques	6
1.3. Repérage du soleil dans le ciel	7
1.3.1 Les coordonnées géographiques.....	8
1.3.2 Coordonnées horaires	9
1.3.3 Coordonnées horizontales	10
1.3.4 Les cinq temps.....	11
1.4. Le rayonnement extra-terrestre.....	12
1.4.1 Distance terre – soleil	12
1.4.2 Constante solaire	13
1.4.3 Irradiation solaire hors atmosphère	14
1.5. Les Composantes du rayonnement solaire au sol.....	15
1.5.1 Rayonnement solaire direct	15
1.5.2 Rayonnement diffus	16
1.5.3 Rayonnement global.....	16
1.5.4 Indice de clarté	16
1.6. Mesure du rayonnement solaire.....	16
1.6.1 L'héliographe	17
1.6.2 Pyranomètre.....	18
1.6.3 Pyrhéliomètre	19
1.7. Le Gisement solaire Algérien.....	20
1.7.1 Gisement solaire	20
1.7.2 Gisement solaire en Algérie	21
1.7.3 Le Programme de développement des énergies renouvelables en Algérie.....	22
1.8. Conclusion.....	23

	Chapitre 2 : Classification des Modèles Prédictives de Rayonnement Solaire	24
2.1	Introduction	25
2.2	Séries temporelles.....	25
2.3	La Prévision de l'éclairement solaire	26
2.3.1	Modèles météorologiques.....	26
a)	<i>Imagerie du ciel ou « Sky Imaging »</i>	26
b)	<i>Modèles basés sur les données satellites</i>	27
c)	<i>Les Modèles Numériques de Prévision Météorologiques NWP</i>	27
2.3.2	Modèles empiriques et semi empiriques	30
a)	<i>Modèles empiriques</i>	30
b)	<i>Semi empiriques</i>	30
2.3.3	Modèles de persistance.....	30
2.3.4	Modèles linéaires.....	31
	<i>Modèle Autorégressif Intégrée Moyenne Mobile ARIMA</i>	32
2.3.5	Modèles non-linéaires	32
a)	L'Apprentissage automatique « Machine Learning »	32
b)	L'apprentissage profond « Deep Learning »	38
2.3.6	Les Méthodes hybrides.....	38
2.3.7	Revue bibliographique	39
2.4	Conclusion.....	46
	Chapitre 3 : Méthodologie de Prédiction	47
3.1	Introduction	48
3.2	Modèle de prédiction.....	48
3.2.1	Principe de fonctionnement de la décomposition ondelette:	49
3.2.2	Décomposition ondelettes en paquets	50
3.2.3	Ondelette mère	51
3.3	Prédiction	51
3.4	Région d'étude et données météorologiques.....	52
3.4.1	Aperçu sur l'unité de recherche appliquée en énergies renouvelables (URAER).....	53
3.4.2	Dispositifs expérimentaux	54
3.5	Préparation des données	55
3.6	Le choix de l'ondelette mère.....	58
3.7	Évaluation des performances.....	59
3.8	Conclusion.....	61

Chapitre 4 : Résultats et Discussions	62
4.1. Introduction	63
4.2. Méthodologie de construction des modèles GPR.....	63
4.3. Régression du rayonnement global journalier.....	65
4.4. Prévission du rayonnement global journalier.....	69
4.4.1. Utilisation de variables exogènes	69
4.4.2. Utilisation de variables endogènes	72
4.5. Prévission multi-horizon.....	74
4.6. Résultats des prévisions par rapport aux études précédentes	78
4.7. Synthèse des simulations.....	79
4.8. Conclusion.....	80
Conclusion Générale et Perspectives	81
Bibliographie	85
Publications en revue et conférences	99

Introduction Générale

Introduction Générale

Il est clair que l'Algérie, par sa nouvelle politique énergétique tend à promouvoir le développement des énergies renouvelables, notamment l'énergie solaire, du fait de sa situation géographique qui dispose l'un des gisements solaires les plus élevés au monde.

Mais l'exploitation de ce gisement d'énergie solaire, soulève certains défis techniques en raison de son caractère intermittent et aléatoire, où son intégration dans les réseaux d'exploitation (électrique ou thermiques) pose des problèmes pour le maintien de l'équilibre production-consommation. Par conséquent, une utilisation efficace de cette énergie solaire nécessite des prévisionnelles fiables. L'enjeu actuel des chercheurs est de développer des modèles prédictifs qui permettent d'atteindre de bonnes performances en réduisant significativement le taux d'erreur par rapport aux différentes échelles de temps (minute, horaire, journalière ou mensuelle).

En effet, la prédiction du comportement ou de la réponse de tout phénomène, que ce soit par des techniques statistiques ou d'autres techniques d'apprentissage (empiriques, stochastiques,), nécessite un ensemble de variables d'entrée dans les modèles ou ce que l'on appelle des entrées. Il a été remarqué que la majorité des modèles proposés dans la littérature dans le contexte de la prévision de l'énergie solaire sont principalement basés sur des réseaux neuronaux artificiels et utilisent plusieurs variables d'entrée (durée d'ensoleillement, humidité, vitesse du vent, nébulosité, précipitations, température, ...), ce qui n'est pas toujours évident en raison de l'indisponibilité des différents dispositifs nécessaires pour mesurer ces variables climatiques dans un site donné.

L'objectif des travaux présentés dans cette thèse est l'amélioration des performances des modèles prédictifs de l'énergie solaire en n'exploitant que quelques variables simples mesurables et disponibles sur site, comme la température. Pour cela, nous proposons un modèle hybride basé sur la combinaison d'une méthode d'apprentissage automatique avec un algorithme de transformation en ondelettes (W), qui est récemment appliqué dans le domaine de la météorologie et dans le solaire en particulier.

La présente thèse présente une contribution au développement de modèles prédictifs de l'irradiation solaire globale journalière à un pas de temps d'un jour en utilisant la technique W-GPR. En effet, pour prouver l'efficacité de ces modèles, une étude comparative basée sur les performances est menée entre les modèles utilisant l'ARN que nous avons développés dans cette thèse et les modèles déjà cités dans la littérature.

Dans la présente thèse, la région qui a été choisie pour l'étude et d'application de nos modèles prédictifs développés, est Ghardaïa (sud de l'Algérie), car elle est considérée comme une plateforme expérimentale pour les applications solaires, en raison de son potentiel solaire élevé, donc favorable aux applications solaires (photovoltaïques ou thermiques).

Ce manuscrit s'organise en 4 chapitres comme suit :

Dans le premier chapitre, la première partie est réservée à la brève présentation de quelques concepts de base de l'énergie solaire. Dans la deuxième partie nous présentons les définitions de quelques grandeurs solaires telles que : Les grandeurs astronomiques, les grandeurs géographiques, le rayonnement hors atmosphère, le rayonnement direct, diffus et global, et les appareils de mesure d'irradiance solaire. Ce chapitre est terminé par la présentation du programme de développement des énergies renouvelables en Algérie

Le deuxième chapitre est consacré à la présentation des différentes méthodes qui sont utilisées dans le cadre de la prévision du rayonnement solaire avec la description des algorithmes associés et le principe général de leurs utilisations.

Le troisième chapitre focus principalement sur le modèle de prédiction proposé dans le cadre de ce projet. C'est un modèle hybride basé sur la combinaison entre une méthode d'apprentissage automatique avec un algorithme de la transformée en ondelette (W). Nous présentons dans ce chapitre la théorie liée à cette méthode, ainsi qu'une description compréhensible des différentes parties du modèle proposé.

Le quatrième chapitre a pour but d'exposer les résultats obtenus après avoir appliqué ces modèles proposés sur les données réelles collectées sur site. Il est divisé en quatre sections relatives à des conditions expérimentales différentes. La dernière partie du chapitre présente les conclusions tirées afin de mettre en évidence les points forts et les points faibles des différents modèles en fonction des situations dans lesquelles ils sont utilisés.

Enfin, dans la conclusion générale nous présentons une synthèse des résultats de nos expérimentations qui mette en évidence les apports de notre travail. Aussi, la proposition de nouvelles perspectives de recherche qui puissent être une continuation de la présente thèse.

Chapitre 1: **Généralités sur le Gisement Solaire**

1.1. Introduction

L'énergie solaire est la plus dominante de toutes les énergies renouvelables elle est considérée comme l'une des énergies les plus faciles à exploiter. Comme la plupart des énergies douces, elle donne à l'utilisateur la possibilité de subvenir sans intermédiaires à une partie de ses besoins. La connaissance de la position du soleil dans le ciel à tout instant et à tout lieu est nécessaire pour l'étude de l'énergie interceptée. Les heures du lever et du coucher ainsi que la trajectoire du soleil dans le ciel au cours d'une journée permettent d'évaluer certaines grandeurs telles que la durée maximale d'insolation et l'irradiation globale. Dans ce chapitre nous allons définir certaines grandeurs solaires à savoir :

- Les grandeurs astronomiques,
- Les grandeurs géographiques,
- Le rayonnement hors atmosphère,
- Le rayonnement direct, diffus et global,
- Les appareils de mesure d'éclairements solaire,
- Le programme de développement des énergies renouvelables en Algérie.

1.2. Rayonnement solaire

Le soleil émet en permanence, dans toutes les directions de l'espace, des rayonnements électromagnétiques composés de « grains » de lumière appelés photons. Ces rayonnements se propagent à la vitesse de la lumière C ; il lui faut donc, en moyenne, 499 secondes, soit 8 minutes et 19 secondes, pour atteindre notre atmosphère (Bessemoulin and Oliviéri 2000). La terre capte dans sa haute atmosphère une énergie d'environ 1367 W/m^2 , relativement indépendante du lieu où l'on est sur la terre. Ces 1367 W/m^2 vont être absorbés partiellement par l'atmosphère. Pour que la terre capte cette énergie, les rayons lumineux doivent être perpendiculaire à la surface de l'atmosphère et ne dépend pas pratiquement que de l'épaisseur de l'atmosphère traversée (de l'ozone, de la vapeur d'eau, du CO_2 ...), et donc essentiellement de l'altitude et du lieu où l'on est.

1.2.1 Nature du rayonnement solaire

Le Soleil (Figure 1-1) émet une énergie d'environ de $3.8 \cdot 10^{20} \text{ MW}$; elle est provenue de réactions thermonucléaires qui s'y produisent. Elles transforment à chaque seconde environ 700 millions de tonnes d'hydrogène en 695 millions de tonnes d'hélium et 5 millions de tonnes d'énergie sous forme de rayons gamma. L'énergie générée dans le noyau du soleil doit être transférée vers la surface ensuite pour la rayonner dans l'espace. Le soleil émet une énergie électromagnétique sous forme de photons qui sont des particules de lumière. Près d'un tiers de cette énergie incidente sur la

terre est réfléchi, mais le reste est absorbé et par la suite, retransmis à l'espace lointain en termes de rayonnement infrarouge (Bacher, Madsen et al. 2009). Le rayonnement solaire se réfère à l'énergie provenant du Soleil dans la gamme de longueurs d'onde 0,3-3 μm ; elle constitue la principale source d'énergie pour le système global Terre-atmosphère.

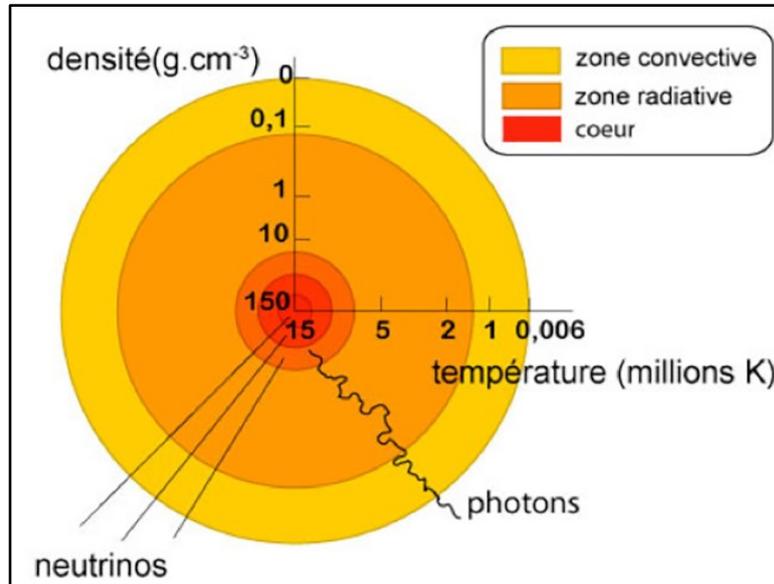


Figure (1- 1) : Structure du Soleil (Kemmoku, Orita et al. 1999).

1.2.2 Propagation des ondes électromagnétiques

Le rayonnement solaire se propage à la vitesse de la lumière; il lui faut donc, en moyenne, 499 secondes, soit 8 minutes et 19 secondes, pour atteindre notre atmosphère. La théorie corpusculaire de Max Planck³ prévoit que tout rayonnement de fréquence f peut être considéré comme un flux de photons dont l'énergie élémentaire est directement proportionnelle à cette fréquence ($E = hf$). De ce fait, ce sont les rayonnements de courte longueur d'onde (ou de haute fréquence) qui sont les plus énergétiques (Bessemoulin and Oliviéri 2000).

Notre œil perçoit une partie seulement du rayonnement solaire, celle située dans le domaine dit visible, dont les longueurs d'onde sont comprises entre 0,40 et 0,70 μm (certains auteurs placent la limite du visible à 0,77 μm pour que les contributions énergétiques du visible et du proche infrarouge soient égales). Le soleil émet cependant dans une large gamme de longueurs d'onde, allant des rayons gamma (longueurs d'onde inférieures à 10-12 m) aux grandes ondes radioélectriques (de longueur d'onde atteignant 1000 mètres), en passant par les rayons X, le rayonnement ultraviolet, le rayonnement visible, le rayonnement infrarouge et le rayonnement hyperfréquences.

La plus grande partie de l'énergie solaire est cependant rayonnée dans les domaines ultraviolet, visible et proche infrarouge : 99,2 % de l'énergie solaire hors atmosphère se trouve entre 0,2 μm et 4 μm . Au sol, par suite de l'absorption du rayonnement solaire par la vapeur d'eau, le spectre est limité vers le haut à 2,5 μm environ (Figure 1-2).

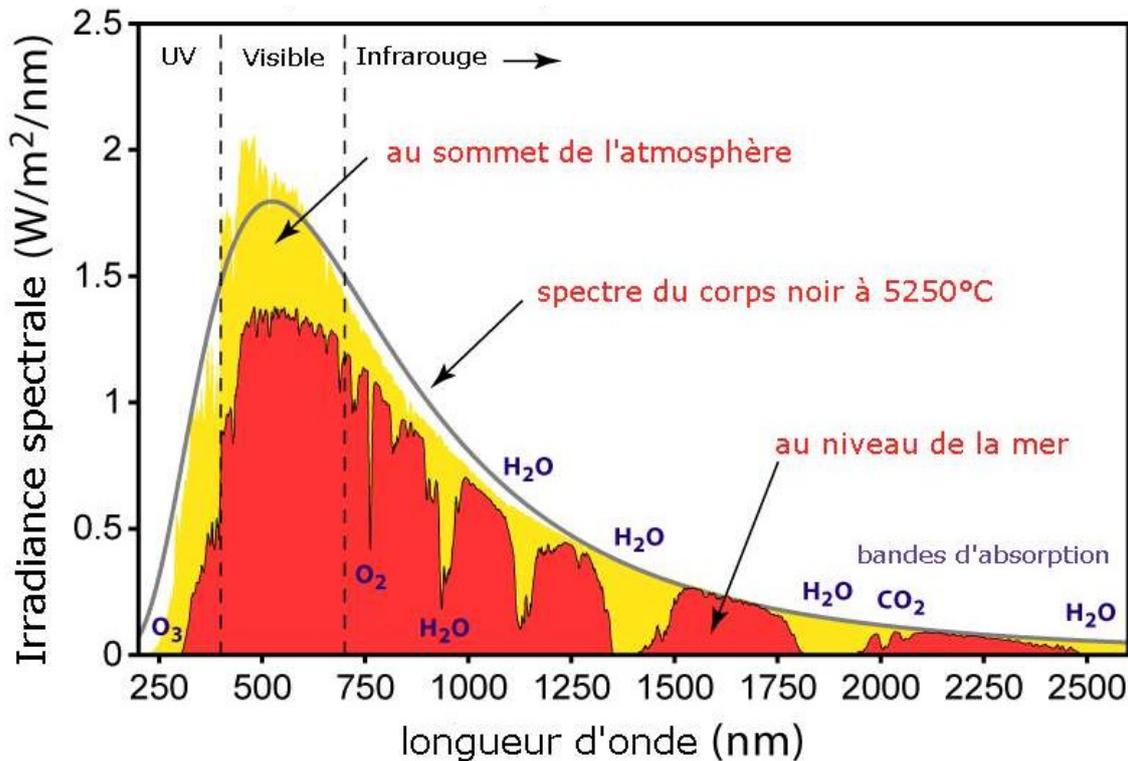


Figure (1- 2) :Distribution spectrale de l'éclairement solaire hors atmosphère de (Gueymard 2004)

1.3. Repérage du soleil dans le ciel

La valeur d'éclairement en un point du sol à un instant donné dépend de la position du soleil, ainsi que l'état optique de l'atmosphère, c'est pour cela il convient de formuler des définitions et des éléments essentiels pour la bonne compréhension du rayonnement solaire par le biais des méthodes de calcul du bilan de ce rayonnement en un point de la surface terrestre.

La terre subit deux types de déplacement aux répercussions totalement différents. Le premier est lié au mouvement de révolution de la terre autour du soleil de périodicité annuelle, qui permet de comprendre le phénomène des saisons. Le second mouvement est lié à la rotation de la Terre sur elle-même autour de l'axe des pôles de périodicité de 24 heures, cette dernière est à l'origine de la succession des jours et des nuits. Il est bien sûr possible de déterminer de façon précise la position du soleil en fonction du temps et de la position de l'observateur sur la terre.

1.3.1 Les coordonnées géographiques

Tout point de la sphère terrestre peut être repéré par deux coordonnées, appelées coordonnées terrestres, à savoir : sa latitude " φ ", qui est positive dans l'hémisphère nord, elle est négative dans l'hémisphère sud, et sa longitude " λ " positive à l'ouest, négative à l'est (voir Figure (1-3) Le méridien origine, servant à la mesure de la longitude, est celui de Greenwich.

- La longitude λ

La longitude d'un lieu donné est l'angle formé par le méridien de ce lieu avec le méridien d'origine (méridien de Greenwich), elle est comptée de 0° à 180° , positivement vers l'est et négativement vers l'ouest.

- La latitude φ

La latitude " φ " permet de localiser la distance angulaire d'un point arbitraire par rapport à l'équateur (Figure 1-3). Elle change de 0° à l'équateur à 90° au pôle Nord, positivement vers le pôle Nord et négativement vers le pôle Sud (Bahraoui-Buret and Khtira 1984).

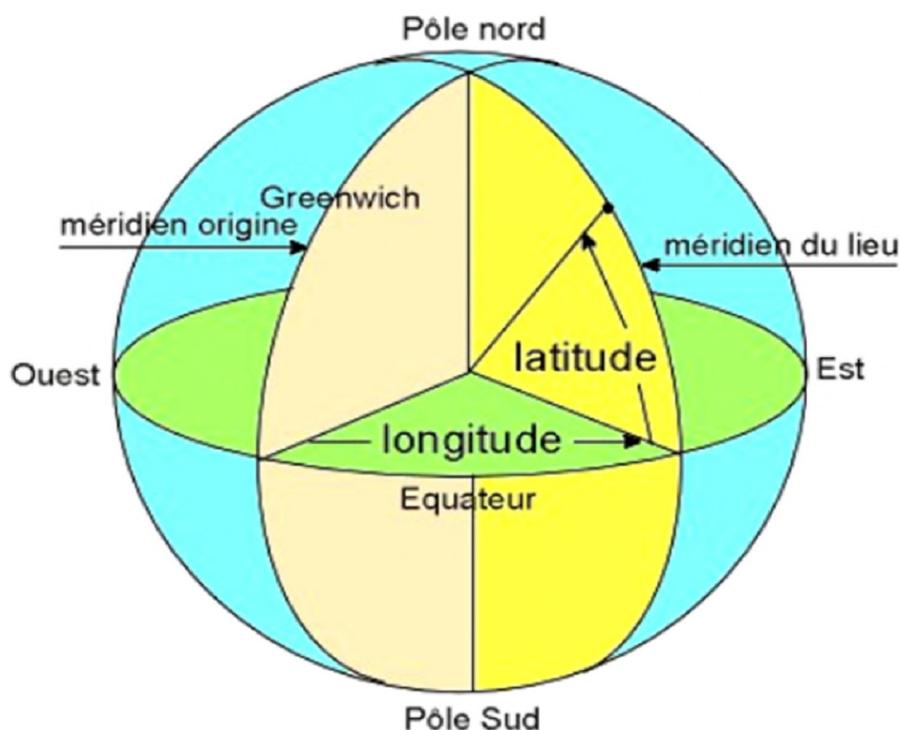


Figure (1- 3) : Les coordonnées terrestres d'un lieu donné (Oudrane 2018).

1.3.2 Coordonnées horaires

- La déclinaison solaire δ

La déclinaison solaire est l'angle que fait la direction du soleil avec sa projection sur le plan équatorial. Elle varie entre $+23^{\circ}27'$ au solstice d'été (le 21 Juin) et $-23^{\circ}27'$ au solstice d'hiver (le 21 Décembre) (Figure 1-4). Plusieurs chercheurs ont proposé des formules permettant de calculer la déclinaison, l'équation de Cooper est l'une de ces formules (Iqbal 2012) elle est donnée par :

$$\delta = 23.45 \sin\left(\frac{360}{365}(n_j + 284)\right) \quad (\text{Degrée}) \quad (1.1)$$

n_j est le numéro de jour de l'année, variant de 1 à 365. (Pour le 1^{er} Janvier, $n_j = 1$ et pour le 31 Décembre, $n_j = 365$).

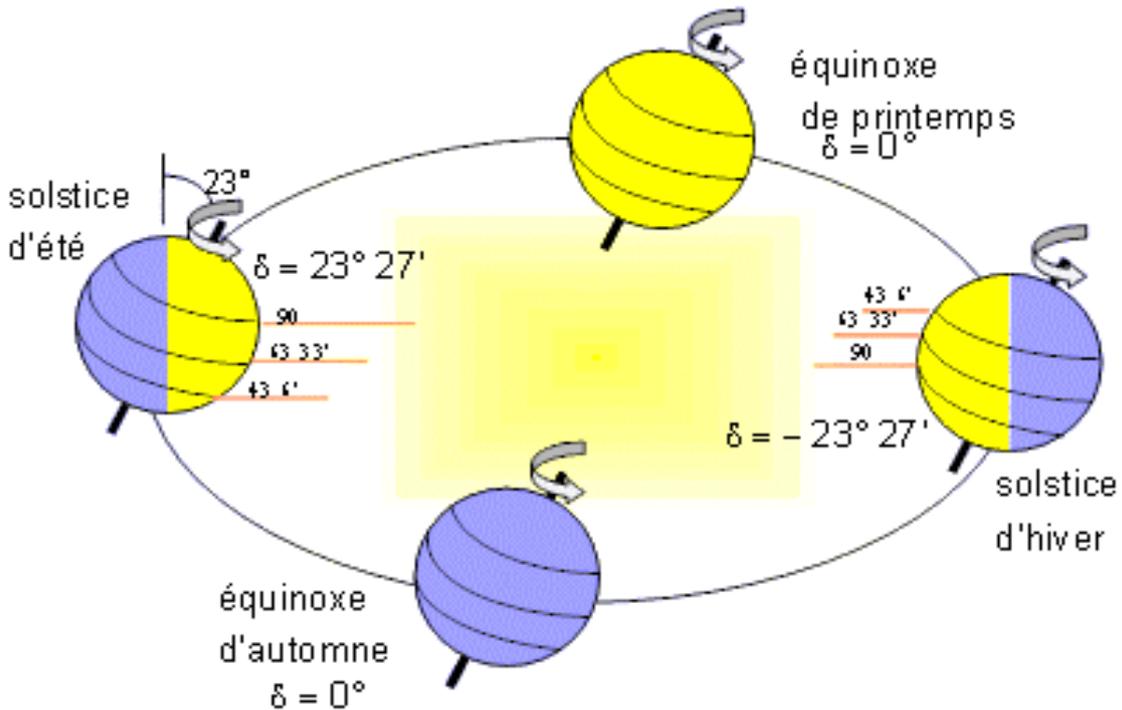


Figure (1- 4): Mouvement et rotation de la terre (Kalogirou 2013) (Badescu 2014).

- L'angle horaire ω

L'angle horaire, comme c'est mentionné dans la Figure (1-5), se mesure à partir du midi solaire, il est positif s'il est avant midi et négatif s'il est après midi (ω vaut 0° à midi, -90° à 18 heures et 90° à 6 heures, en temps solaire vrai, chaque heure le décale de 15° , positifs le matin et négatifs l'après-midi).

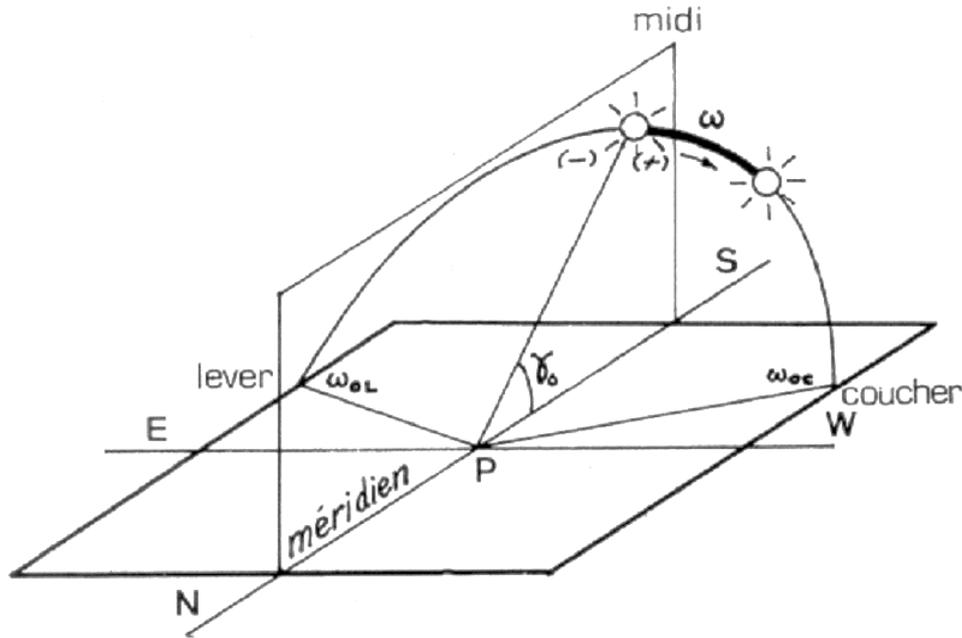


Figure (1- 5): Angle horaire ω du soleil.

Autrement dit, C'est la mesure de l'arc de trajectoire solaire compris entre le soleil et le plan méridien du lieu ça valeur peut être donnée par la formule suivante:

$$\omega = 15(12 - TSV) \quad (\text{Degrée}) \tag{1.2}$$

TSV est le temps solaire vrai exprimé en heures.

1.3.3 Coordonnées horizontales

- Hauteur angulaire

C'est l'angle h formé par le plan horizontal au lieu d'observation et la direction du soleil. Elle est liée à l'angle entre les rayons du soleil et la verticale nommé l'angle zénithal (θ_z), donnée par la relation suivante :

$$\theta_z + h = \frac{\pi}{2} = 90^\circ \tag{1.3}$$

L'expression mathématique de la hauteur du soleil est donnée par :

$$\sin(h) = \cos(\varphi) \cos(\delta) \cos(\omega) + \sin(\varphi) \sin(\delta) \tag{1.4}$$

φ : la latitude du lieu,

δ : la déclinaison du soleil et ω : l'angle horaire

A partir de la hauteur h , on peut déduire les heures de lever et de coucher de soleil. En prenant $h=0$, on peut calculé ω_s donnée par la formule suivante (Duffie and Sons 1991):

$$\omega_s = \cos^{-1}(-\tan(\varphi) \tan(\delta)) \tag{1.5}$$

- **Durée astronomique du jour**

La durée astronomique du jour s'obtient facilement en utilisant la relation ci-après :

$$d = \frac{2}{15} \omega_s = \frac{2}{15} \cos^{-1}(-\tan(\varphi) \tan(\delta)) \quad (1.6)$$

- **Azimut**

L'azimut du soleil est l'angle compris entre la projection de la direction du soleil sur le plan horizontal et la direction sud (Figure 1-6).

$$a = \frac{\cos(\delta) \sin(\omega)}{\cos(h)} \quad (1.7)$$

Il est nul à midi TSV et maximal au lever et au coucher du soleil.

1.3.4 Les cinq temps

- **Temps universel**

C'est le temps solaire moyen du méridien de Greenwich GMT (Greenwich Mean Time) qui est le méridien central du fuseau horaire.

- **Temps solaire local (TL)**

Le temps légal (ou local) est le temps officiel de l'Etat, il diffère par rapport au temps mondial de Greenwich par un décalage exprimé en heures.

$$TL = TU + \Delta H \quad (1.8)$$

ΔH étant le décalage horaire entre le méridien de Greenwich et l'Etat considéré,

- **Temps solaire moyen**

La rotation de la terre autour d'elle-même introduit la notion du temps solaire moyen ou TSM. On le définit comme étant le temps qui sépare en moyenne deux passages successifs par le méridien du lieu, une rotation complète de la terre autour d'elle-même prend 24 heures. La rotation de la terre autour d'elle-même introduit la notion du temps solaire moyen ou TSM. On le définit (Kazemzadeh, Amjadian et al.) :

$$TSM = TU + \frac{\lambda}{15} \quad (1.9)$$

- Equation du temps

C'est une équation qui tient compte de la variation de la vitesse de rotation de la terre, Nous reprenons l'expression proposée par (Duffie and Beckman 2013):

$$ET = 9.87 \sin(2\beta_0) - 7.53 \cos(\beta_0) - 1.5 \sin(\beta_0), \quad (\text{Minute}) \quad (1.10)$$

L'angle β_0 est défini en fonction du numéro du jour de l'année :

$$\beta_0 = \frac{360}{365} (n_j - 81) \quad (1.11)$$

- Temps solaire vrai

C'est le temps solaire local corrigé de l'équation du temps, c'est une donnée astronomique universelle liée à l'excentricité de l'orbite de la terre autour du soleil :

$$TSV = TSM + ET \quad (1.12)$$

En général, pour convertir le temps standard local 'TL' au temps solaire vrai TSV, on utilise l'expression suivante :

$$TSV = TL - \Delta H + \frac{ET + 4\lambda}{60} \quad (1.13)$$

ΔH : est le décalage horaire par rapport au méridien de Greenwich. (Égale 1 pour l'Algérie).

TL : est le temps légal ou temps local standard, donné par une montre.

λ : Longitude du lieu.

1.4. Le rayonnement extra-terrestre

Le rayonnement à l'entrée de l'atmosphère habituellement nommé « extra-terrestre » ou « hors atmosphère ». Ce rayonnement ne dépend d'aucun paramètre météorologique, mais il est fonction de quelques paramètres astronomiques et géographiques.

1.4.1 Distance terre – soleil

La terre tourne autour du Soleil sur une orbite elliptique, faisant un tour complet en un an (365.25 jours). L'équinoxe est la position de la terre sur son orbite au moment où la durée du jour est égale à celle de la nuit. Cela se produit le 20-21 mars (équinoxe de printemps) et 22-23 septembre (équinoxe d'automne) de chaque année. Le solstice est le point sur l'orbite de la terre quand la journée est la plus longue de l'année (solstice d'été, 20-21 juin) ou elle est la plus courte (solstice d'hiver, 21-22 décembre) (Figure 1-6),

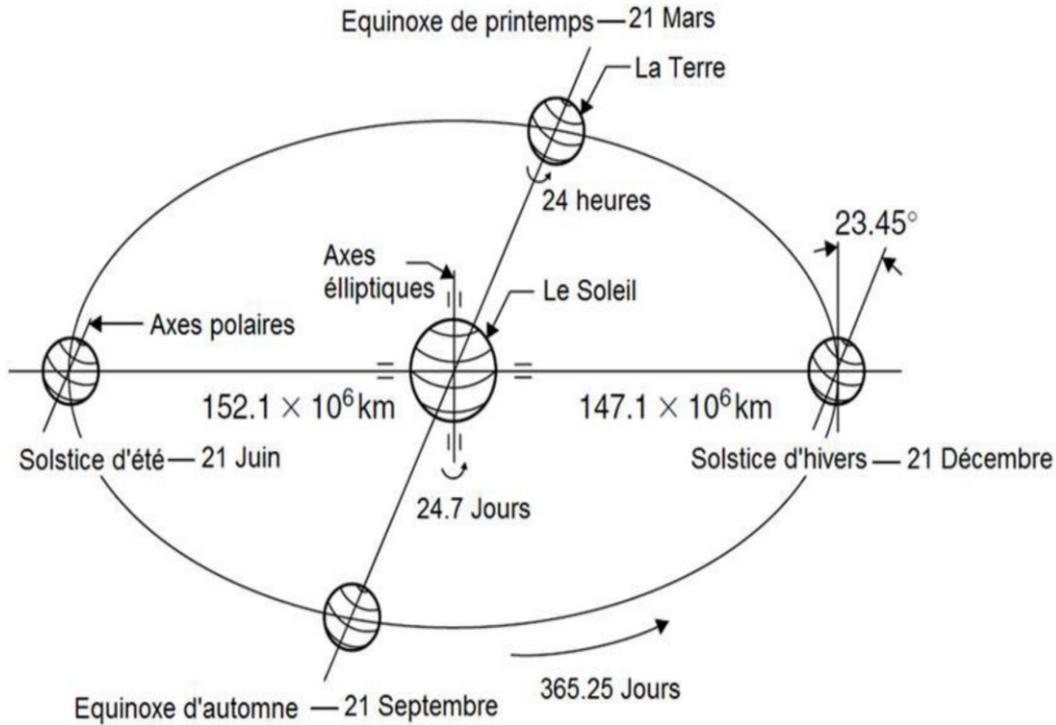


Figure (1- 6): Mouvement de la Terre autour du Soleil (Kalogirou 2013).

la distance Terre-Soleil est donnée par la formule de Garg (Garg 1982):

$$E_0 = \left(\frac{r_0}{r}\right)^2 = 1 + 0.033 \cos\left[\frac{2\pi(n_j)}{365}\right] \tag{1.14}$$

Avec :

r_0 : la distance moyenne entre la terre et le soleil, noté 1UA=150 millions Km.

r : la distance actuelle entre la terre et le soleil.

1.4.2 Constante solaire

La constante solaire notée I_0 exprime la quantité d'énergie solaire que recevrait une surface de $1 m^2$ située à une distance de 1 UA et exposée perpendiculairement aux rayons du Soleil, en l'absence de l'atmosphère. Pour la terre, c'est donc la densité de l'énergie au sommet de l'atmosphère. La première valeur moyenne estimée de la constante solaire était $1353 Wm^{-2}$ (réf), cette valeur a été mise à jour en 1977 à $1377 Wm^{-2}$ (Iqbal 2012) et plus tard l'Organisation Météorologique Mondiale (OMM) a adopté une valeur de $1367 W.m^{-2}$ (Dambreville 2014). La dernière valeur de la constante solaire est de l'ordre de $1366.1 Wm^{-2}.m^{-2}$ (Iqbal 2012). Pour le jour n , La correction de la constante solaire est obtenue à l'aide de l'équation suivante :

$$I_{sc}(n_j) = I_0 \cdot E_0 \tag{1.15}$$

1.4.3 Irradiation solaire hors atmosphère

➤ Flux solaire d'un plan horizontal

Pour un site donné, à une heure donnée, l'éclairement sur un plan horizontal hors atmosphère, I_h s'exprime par la relation suivante :

$$I_h = I_{SC} \cdot \sin h \quad (1.16)$$

h : la hauteur solaire ;

I_{SC} : la constante solaire corrigée.

➤ Irradiation solaire pour un plan horizontal

• Quotidienne

L'irradiation globale horaire sur une surface horizontale, G_0 , est obtenue à l'aide de la formule suivante :

$$H_0(h, n_j) = \int_{t_1}^{t_2} I_{SC}(n_j) \sin(h(TSV)) dt \quad (1.17)$$

On remplace $\sin(h)$ par sa valeur, et en intégrant, on obtient :

$$H_0(h, n_j) = \frac{I_{SC}(n_j)}{15} [\sin(\varphi) \sin(\delta)(\omega_2 - \omega_1) + \cos(\varphi) \cos(\delta)(\sin(\omega_2) - \sin(\omega_1))] \quad (1.18)$$

δ et I_{SC} sont la déclinaison solaire et la constante solaire corrigée respectivement, ω_1 et ω_2 désignent les angles horaires des deux temps t_1 et t_2 .

• Journalière

L'irradiation globale journalière sur une surface horizontale $H_0(n_j)$, s'obtient en intégrant la relation (1.17) du lever au coucher du soleil :

$$H_0(n_j) = \int_{\omega_l}^{\omega_c} I_{SC}(n_j) \sin(h) \frac{dt}{d\omega} d\omega \quad (1.19)$$

ω étant l'angle horaire et $\left(\frac{dt}{d\omega} = \frac{12}{\pi}\right)$, on obtient :

$$H_0(n_j) = \frac{24}{\pi} I_{SC} \left(\frac{\pi}{180} \omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s) \right) \quad (1.20)$$

ω_s : l'angle de lever s'exprime en degré, I_{SC} en (W/m^2) et G_0 en $(Wh/m^2 \text{ jour})$

➤ Irradiation solaire pour un plan vertical

Pour une surface unitaire placée hors atmosphère et normale au rayonnement solaire, l'irradiation solaire H_n quotidienne est :

$$H_n = I_{SC} \cdot d \quad (1.21)$$

Où D est la durée astronomique du jour elle est exprimé en heure.

1.5. Les Composantes du rayonnement solaire au sol

Le rayonnement solaire appelé également rayonnement électromagnétique émis par le soleil est grandement perturbé par l'atmosphère (Figure (1-7)). Ce qui permet au sol de recevoir que les composants les plus importants et les plus actifs du rayonnement solaire total qui sont le rayonnement direct et le rayonnement diffus.

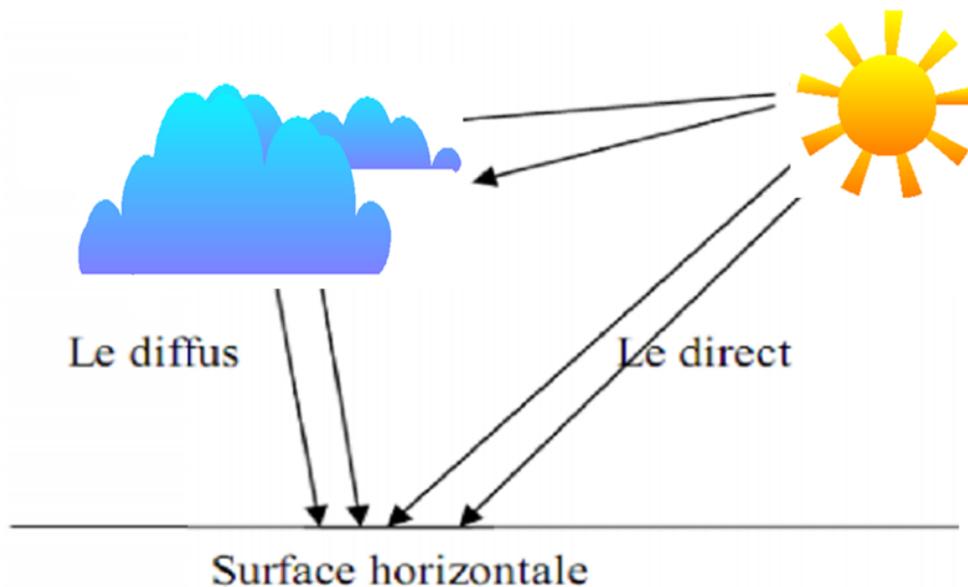


Figure (1- 7): Composantes solaires (Günther, Janotte et al. 2011)

1.5.1 Rayonnement solaire direct

Le rayonnement direct est reçu directement du soleil, c'est un flux uniforme de rayons parallèles entre eux et de puissance incidente I (W/m^2). C'est le flux des photons qui n'ont pas interagi avec les constituants de l'atmosphère et ont conservé une direction commune et leurs énergies propres.

1.5.2 Rayonnement diffus

Parmi les photons qui interagissent avec la couche d'atmosphère, certains sont absorbés et d'autres subissent un simple changement de direction (diffusion). Il s'agit donc de la répartition d'un faisceau parallèle en une multitude de faisceaux partant dans toutes les directions. Pour un élément plan considéré, la composante diffusée D (W/m^2), provenant de toutes les directions, est la plus difficile des composantes à calculer.

1.5.3 Rayonnement global

Le rayonnement global est simplement la somme des composantes directes et diffusées. On distingue deux types de données d'ensoleillement :

- *Rayonnement instantané* : c'est le rayonnement en fonction de l'heure de la journée
- *Rayonnement cumulé* : correspond au cumul du rayonnement global par jour.

1.5.4 Indice de clarté

Le rapport entre le rayonnement au sol et le rayonnement extraterrestre est appelé indice de clarté. Les valeurs de ce dernier varient selon les endroits et les saisons. Cet indice est donné par la formule :

$$K = \frac{H}{H_0} \quad (1.22)$$

Ou :

H : irradiation solaire reçue sur un plan horizontal ($Wh. m^{-2} jour^{-1}$)

H_0 : Irradiation solaire hors atmosphère sur un plan horizontal ($Wh. m^{-2} jour^{-1}$).

1.6. Mesure du rayonnement solaire

Pour assurer la performance des projets solaires, les données de rayonnement solaire doivent être fiables et exactes. Le principe classique des mesures d'éclairements est l'effet thermoélectrique ce principe est similaire à un corps noir qui reçoit le rayonnement solaire, l'augmentation de sa température est mesurée par une série de couples thermoélectriques ; on enregistre donc une force électromotrice. Une mesure précise est toujours délicate d'autant plus que l'appareil est situé à l'extérieur. Une variété de capteurs de mesure du rayonnement global et diffus est disponible chez un certain nombre de fabricants différents, associés à différentes implications en termes de précision et de coût. On distingue deux principales catégories de technologie de mesure l'héliographe et le pyranomètre (Iqbal 2012).

1.6.1 L'héliographe

C'est un instrument météorologique utilisé pour mesurer la valeur journalière de la durée d'ensoleillement en un point de la surface de la Terre, il existe actuellement des enregistreurs électroniques (utilisant des photodiodes) comme c'est illustré dans la Figure (1-8), où une fibre optique émet régulièrement un signal qui engendre une impulsion dès que l'éclairement reçu par le capteur dépasse 120 W.m^{-2} . Cette dernière est définie comme la somme des intervalles de temps pour lesquels le rayonnement solaire direct dépasse le seuil de 120 W.m^{-2} (Paulescu, Paulescu et al. 2012). Même si les informations fournies ne sont pas très utiles du point de vue des prévisions météorologiques, elles s'avèrent pertinentes en matière de climatologie. Pour obtenir des mesures plus proches à la réalité possible, il faut veiller à installer l'héliographe dans un endroit où celui-ci ne sera pas perturbé par l'ombre des objets (immeuble, etc.). On distingue plusieurs types d'héliographe.



Figure (1- 8): Héliographe à fibre optique.

Héliographe de Campbell-Stokes

L'héliographe de Campbell-Stokes a été le premier du genre. Il a été inventé au milieu du XIX^e siècle. Il est constitué d'une sphère de verre destinée à focaliser les rayons solaires sur un papier sensible qui va alors se décolorer ou brûler. Ce papier « imprimé d'une échelle de temps » est positionné sur un support concave, à l'arrière de la sphère. À la fin d'une journée, il suffit de sommer les intervalles de temps durant lesquels le rayonnement solaire a laissé des traces sur le papier pour en déduire la durée d'ensoleillement (Figure (1-9)).



Figure (1- 9): Héliographe Campbell-Stokes (Paulescu, Paulescu et al. 2012).

Héliographes modernes à cellules photovoltaïques

Il existe également des héliographes à cellules photovoltaïques. Dans ce type d'héliographes, ce sont les tensions électriques générées qui permettent de remonter aux valeurs de l'éclairement. De nos jours, on utilise plutôt des instruments dits « dynamiques », par opposition aux instruments classiques dits « statiques ». Dans les héliographes dynamiques tous les centièmes d'heure, une fibre optique en rotation sur elle-même émet un signal proportionnel à l'éclairement reçu par un capteur.

1.6.2 Pyranomètre

Les pyranomètres mesurent le rayonnement global (direct + diffus) de toute l'hémisphère céleste dans la bande de longueur d'onde 0.3 à 3 μm .

Le pyranomètre d'Eppley est une thermopile adaptée à cet usage. La surface réceptrice comporte deux anneaux concentriques en argent ; l'anneau intérieur est recouvert de noir, l'anneau extérieur recouvert de blanc. La différence de température, mesurée entre les deux anneaux par des thermocouples en contact thermique avec les surfaces intérieures des anneaux et qui sont isolés électriquement, peut être enregistrée à raison d'une lecture par heure sous forme d'une tension de sortie de l'ordre du mV (en fait $10\mu\text{V} / \text{W}/\text{m}^2$). Le pourcentage de diffus intercepté par l'anneau d'ombre varie au cours de l'année avec sa position et les conditions atmosphériques (Garcia, Frigerio et al. 2014).

Pyranomètre d'Eppley :

Le pyranomètre d'Eppley mesure le rayonnement global (direct + diffus) de tout un hémisphère dans la bande de longueur d'onde 0.3 à 3 μ m. Il comporte une surface réceptrice formée de deux anneaux concentriques en argent ; l'anneau intérieur est recouvert de noir, l'anneau extérieur recouvert de blanc. La différence de température est mesurée entre les deux anneaux par des thermocouples en contact thermique avec les surfaces intérieures des anneaux, mais isolés électriquement (Figure (1-10)).

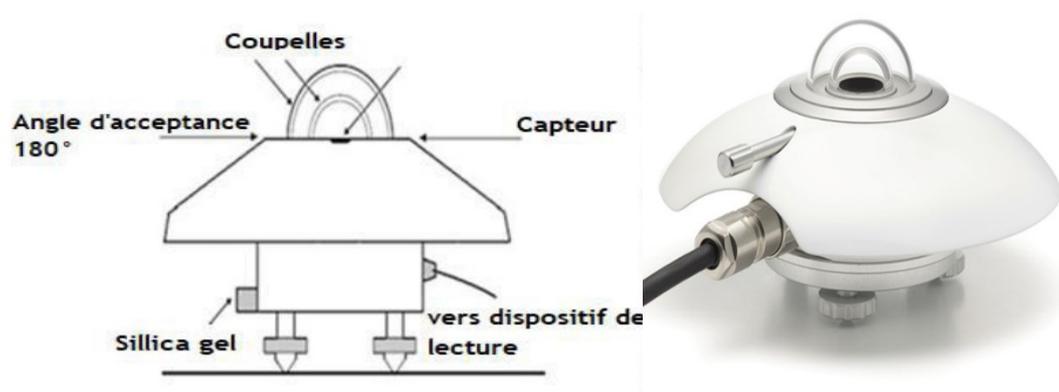


Figure (1- 10): Schéma d'un pyranomètre (à gauche), pyranomètre type Eppley (à droite) (Paulescu, Paulescu et al. 2012).

1.6.3 Pyrhéliomètre

Un pyrhéliomètre se compose d'un élément de détection de rayonnement enfermé dans un boîtier (tube de collimation) qui comporte une petite ouverture à travers laquelle seuls les rayons solaires directs entrent. Le rayonnement réfléchi d'un nuage ou d'une particule dans l'air ne passe pas par cette petite ouverture et via son tube de collimation au détecteur (Figure (1-11)). Pour effectuer des mesures toute la journée, un pyrhéliomètre doit être pointé directement vers le soleil à l'aide d'un dispositif de suivi solaire ou "Tracker".



Figure (1- 11): Pyrhéliomètre (Jarraud 2008).

1.7. Le Gisement solaire Algérien

1.7.1 Gisement solaire

Le gisement solaire est un ensemble de données décrivant l'évolution du rayonnement solaire disponible au cours d'une période donnée. Il est utilisé pour simuler le fonctionnement d'un système énergétique solaire et faire un dimensionnement le plus exact possible compte tenu de la demande à satisfaire. De par sa situation géographique, l'Algérie possède un potentiel solaire le plus important parmi les pays de la région Nord-Africains et Moyen-Orient (Figure (1-12)).

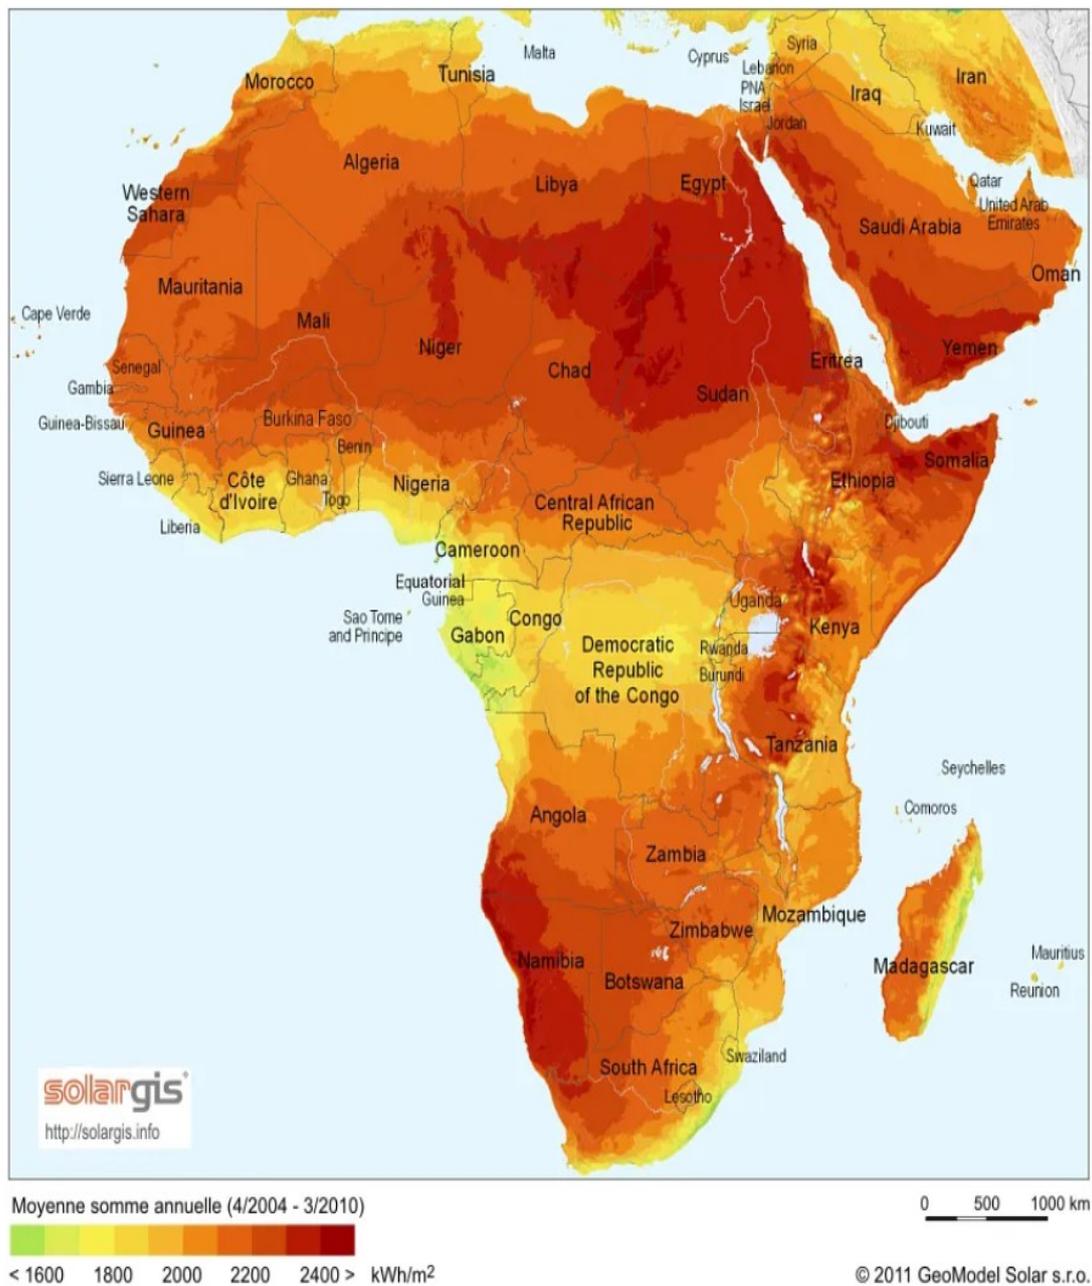


Figure (1- 12): Carte d'Afrique et Moyen Orient de l'irradiation globale annuel (Harsarapama, Aryani et al. 2020).

1.7.2 Gisement solaire en Algérie

L'Algérie dispose d'un des gisements solaires les plus importants du monde. La durée d'insolation sur la quasi-totalité du territoire national dépasse les 2000 heures annuellement et atteint les 3900 heures (hauts plateaux et sahara). L'énergie reçue quotidiennement sur une surface horizontale de 1 m² est de l'ordre de 5 kWh sur la majeure partie du territoire national, soit près de 1700 kWh/m²/an au Nord et 2263 kWh/m²/an au sud du pays. La Figure (1-13) résume le potentiel solaire en Algérie.

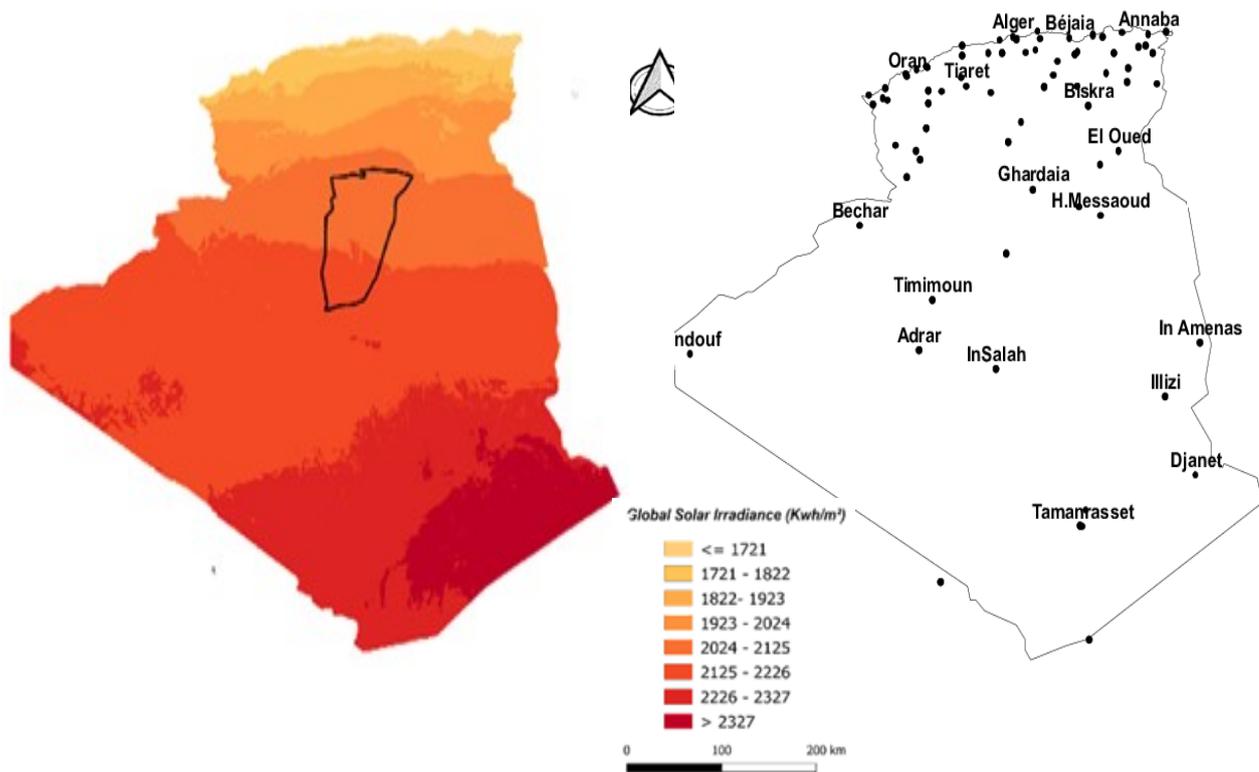


Figure (1- 13): Irradiation globale horizontale et Répartition des stations météorologiques (Algérie)

En effet, sur les cinquante-six stations qui mesurent la durée d'insolation, seules huit d'entre elles assurent la mesure des composantes globale et diffuse du rayonnement solaire reçu sur plan horizontal. Ainsi, des modèles ou des techniques de reconstitution du rayonnement solaire à partir de la durée d'insolation ou d'autres paramètres météorologiques sont utilisés.

1.7.3 Le Programme de développement des énergies renouvelables en Algérie

L'Algérie s'engage dans une nouvelle ère énergétique durable. Le programme des énergies renouvelables actualisé consiste à installer une puissance d'origine renouvelable de l'ordre de 22.000 MW à l'horizon 2030 pour le marché national, avec le maintien de l'option de l'exportation comme objectif stratégique, si les conditions du marché le permettent. A travers ce programme d'énergies renouvelables, l'Algérie compte se positionner comme un acteur majeur dans la production de l'électricité à partir des filières photovoltaïque et éolienne en intégrant la biomasse, la cogénération, la géothermie et au-delà de 2021, le solaire thermique. Ces filières énergétiques seront les moteurs d'un développement économique durable à même d'impulser un nouveau modèle de croissance économique. 37 % de la capacité installée d'ici 2030 et 27 % de la production d'électricité destinée à la consommation nationale, seront d'origine renouvelable.

Selon le site du ministère de l'énergie, le potentiel national en énergies renouvelables étant fortement dominé par le solaire, l'Algérie considère cette énergie comme une opportunité et un levier de développement économique, notamment à travers l'implantation d'industries créatrices de richesse et d'emplois. La stratégie de l'Algérie en la matière vise à développer une véritable industrie des EnR associée à un programme de formation et de capitalisation des connaissances, qui permettra à terme, d'employer le génie local algérien, notamment en matière d'engineering et de management de projets. Le programme EnR, pour les besoins d'électricité du marché national, permettra la création de plusieurs milliers d'emplois directs et indirects. La consistance du programme en énergie renouvelables à réaliser pour le marché national sur la période 2015-2030 est de 22 000 MW, Tableau (1-1) indiqué la répartition par filière.

Tableau (1- 1): Consistance du programme de développement des EnR.

	2015-2020 [MW]	2021-2030 [MW]	Totale [MW]
Photovoltaïque	3000	10575	13575
Eolien	1010	4000	5010
CSP (solaire thermique)	-	2000	2000
Cogénération	150	250	400
Biomasse	360	640	1000
Géothermie	05	10	15
Total	4525	17475	22000

Pour les installations raccordées au réseau, le soutien de l'Etat s'effectue à travers le mécanisme du tarif d'achat garanti (feed-in tarif) : Ce système garantit aux producteurs d'énergie renouvelable de bénéficier de tarifs leur octroyant une rentabilité raisonnable de leur investissement sur une durée d'éligibilité de 20 ans pour le solaire et l'éolien et 15 ans pour la cogénération.

Pour atteindre les objectifs fixés dans ce programme, tous les moyens pédagogiques et matériels doivent être fournis aux chercheurs dans le domaine des énergies renouvelables. Le plus important d'entre eux est peut-être de fournir une base de données climatologique aux chercheurs. *Malheureusement*, le réseau de mesures radiométriques que compte le pays, est peu dense relativement à la superficie du territoire. Effectivement, seules sept stations météorologiques sur la soixantaine que compte le réseau de l'Office National de la Météorologie (*ONM*) assurent la mesure des composantes diffuses et globales du rayonnement solaire reçu sur le plan horizontal et peu de stations assurent l'enregistrement de la composante directe. A cet effet, nous avons choisi d'étudier durant cette thèse, un site dont les données sont disponibles à notre disposition.

1.8. Conclusion

Dans ce chapitre, nous avons pu établir les connaissances de base sur le rayonnement solaire, source principale de tous systèmes de conversion de l'énergie solaire, dès son émission par le soleil jusqu'à sa pénétration sur la surface terrestre. On a pu présenter des notions importantes sur le gisement solaire comme les coordonnées terrestres et horaires. Nous avons vu que le rayonnement solaire global est composé de deux composantes distinctes : l'une et dépend de la distance séparant le point de mesure et le soleil, et l'autre est stochastique dépend de l'état du ciel (atténuations atmosphériques), puis, on a cité quelques types de capteurs de rayonnement utilisés avant de terminer par la présentation du gisement solaire Algérien.

**Chapitre 2 : Classification des
Modèles Prédicatives de
Rayonnement Solaire**

2.1 Introduction

Ce chapitre présente les différentes méthodes qui sont utilisées dans le cadre de la prévision du rayonnement solaire. Nous détaillerons les modèles utilisés pour réaliser cette étude. Il existe plusieurs façons de réaliser la prévision de la ressource solaire. Le choix de l'une ou l'autre méthode dépend de l'horizon de prévision et des besoins de l'utilisateur. En effet, tous les modèles n'ont pas la même précision en fonction du type de prévision souhaité, du lieu, de l'horizon temporel, ou encore du type et voire du nombre de données disponibles (Reikard 2009). Les 3 grandes familles de modèles prédictifs sont réparties en fonction des horizons de prévision :

- Le très court terme, dont l'horizon est compris entre quelques minutes et une heure.
- Le court terme, dont l'horizon de prévision s'étend de 1 heure à 6 heures.
- Le moyen terme, de 1 jour à 1 semaine.

Nous allons dans cette section présenter les différentes manières de réaliser la prévision de l'éclairement solaire. Nous entrerons ensuite dans le détail des techniques qui nous intéressent.

2.2 Séries temporelles

Une série temporelle est une succession d'observations (ou de mesures) au cours du temps représentant un phénomène. Elle est définie mathématiquement comme un ensemble de vecteurs $x(t)$, $t = 0, 1, 2, \dots$ où t représente la mesure du temps. Les variables $x(t)$ sont traitées comme variables aléatoires. Le pas de temps des observations est considéré constant, et la modalité d'acquisition des signaux doit être identique tout au long de la période d'observation. Pour utiliser le formalisme des séries temporelles dans la prédiction du rayonnement solaire, il est nécessaire, au préalable, de poser certaines définitions. Ainsi,

x_t : est la valeur courante en t de la chronique $x(t)$ (t : le temps, est compris entre 1 et n , n : le nombre total d'observations).

h : est le nombre de points ou de valeurs à prédire de la série temporelle.

Horizon de la prédiction : ce terme représente l'historique de la prédiction de la série temporelle de $(n+1)$ à $(n+h)$, porte le nom d'horizon 1, jusqu'à l'horizon h . Pour un horizon 1 (cas le plus simple), le formalisme général de la prédiction sera représenté par l'équation 2.1

$$x_{t+1} = f_n(x_t, x_{t-1}, \dots, x_{t-p+1}) + \epsilon(t+1) \quad (2.1)$$

où ϵ représente l'erreur entre la prédiction et la mesure, f_n le modèle à estimer et t le paramètre temporel qui prend les $(n-p)$ valeurs suivantes : $n, n-1, \dots, p+1, p$. Où n est le nombre d'observations et p le nombre de paramètres du modèle (on suppose que $n \gg p$).

Il existe de nombreux modèles de prédiction de rayonnement solaire basés sur le formalisme des Séries Temporelles. Il est possible de les rassembler en quatre grands groupes ([Brockwell and Davis 2009](#)) ([Hamilton and Susmel 1994](#)) :

- Modèles de persistance. Ils ont été définis pour fixer les limites de performances de modèles plus élaborés.
- Modèles linéaires, un modèle particulier ARMA avec une forme récursive issue de la prévision des puissances éoliennes a notamment été adapté à la problématique solaire.
- Modèles non-linéaires (les réseaux de neurones). Il, est divisé en deux sous-groupes, « Machine Learning » tel que les processus gaussiens ([Wang, Yu et al.](#)) et les supports de vecteur machine (SVM). « Deep Learning » tel que Long Short Memory (LSTM), Convolutional Neural Network (CNN).

2.3 La Prédiction de l'éclairement solaire

2.3.1 Modèles météorologiques

Les techniques basées sur l'imagerie du ciel et les données satellitaires utilisent soit des images provenant de dispositifs d'imagerie du ciel (caméras pointées vers le ciel), soit des images provenant des satellites. A partir de ces « photographies », ces techniques peuvent prévoir le mouvement des nuages dans un futur proche, et à partir de ces informations couplées à l'utilisation d'algorithmes spécifiques, prévoir le rayonnement solaire.

a) Imagerie du ciel ou « Sky Imaging »

La technique consiste à l'utilisation des images du ciel provenant d'acquisitions terrestres (lentilles grand angle). Cette catégorie de méthodes de prédiction solaire prédit le mouvement du nuage et ses effets sur le rayonnement solaire d'un lieu géographique spécifique. Cette classe peut faire des prédictions temporelles (instantanées) allant jusqu'à 15 à 30 min. Le Total Sky Imager (TSI) est représenté sur la Figure (2-1) composé d'un miroir hémisphérique convexe avec une caméra au-dessus. Le miroir contient une bande d'ombre de suivi du soleil pour protéger la caméra des reflets du soleil. Ce dispositif se distingue par la facilité de mise en œuvre et résolution temporelle pour la prévision du rayonnement solaire à très court terme ([Rudd 2011](#)).



Figure (2- 1) : Dispositif Total Sky Imager (TSI).

b) Modèles basés sur les données satellites

les modèles basés sur les données satellites peuvent être classés en deux catégories, modèles physiques et modèles statistiques (Noia, Ratto et al. 1993).

- Les modèles physiques sont basés sur l'utilisation de modèles de transfert radioactif qui nécessitent une mesure précise et complète de la morphologie atmosphérique ainsi qu'un étalonnage soigneux des appareils de mesures satellitaires. A l'inverse, ils ne nécessitent pas de mesures in situ de données au sol.
- Les modèles satellitaires statistiques s'appuient sur des régressions statistiques simples entre les mesures réalisées par satellite et au sol. Contrairement aux modèles physiques, ces modèles sont beaucoup plus simples, ne reposent pas sur la mesure précise de la composition de l'atmosphère, mais ils nécessitent de disposer de données mesurées au sol. Le modèle de Perez, développé en 2002 (Perez, Ineichen et al. 2002) est le plus utilisé pour estimer le rayonnement solaire à partir d'images satellites.

c) Les Modèles Numériques de Prévision Météorologiques NWP

Un modèle NWP (Numerical Weather Prediction) est un programme informatique qui simule le mouvement atmosphérique dans l'espace et dans le temps des nuages et particules, l'atmosphère est représentée par une grille 3D. Plus l'espacement de la grille est fin, plus la simulation élaborée est complexe, mais le temps d'obtention des résultats est plus long, ce qui peut être un frein. Il convient donc de faire un choix judicieux entre taille du maillage, complexité des modèles et durée d'exécution du programme. La simulation faite avec ce type de modèle génère l'état futur de l'atmosphère dans chaque voxel (pixel en 3D), à partir de son état initial (Guerbette,

Mahfouf et al. 2016). D'abord un domaine est défini, il est ensuite spatialement discrétisé suivant la résolution désirée. Enfin, le NWP prévoit l'ensemble des variables météorologiques usuelles en résolvant les équations du mouvement et les lois de la thermodynamique. La Figure (2-2) présente les étapes de mise en œuvre des modèles NWP.

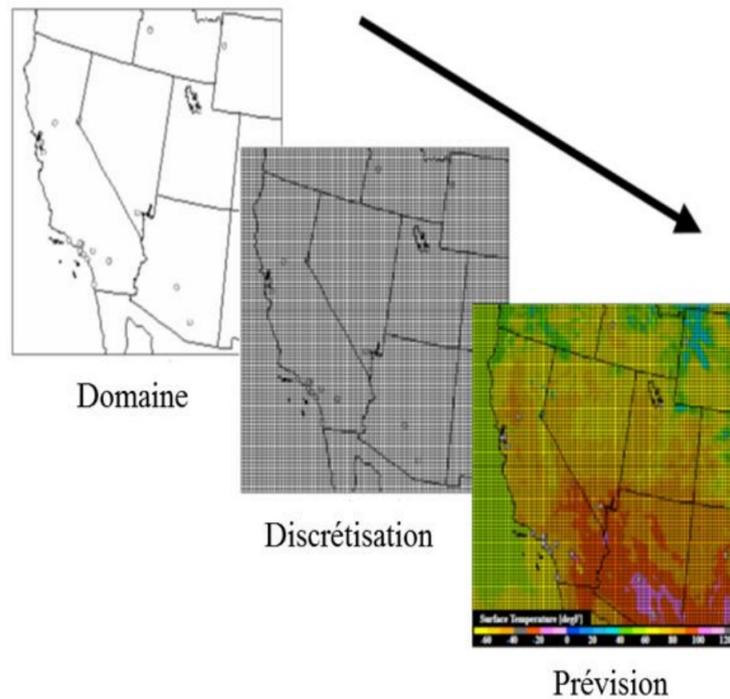


Figure (2-2): Etapes de mise en œuvre de modèles NWP en 2D.

Dans la Figure (2-3), un exemple de discrétisation 3D de la terre est présenté :

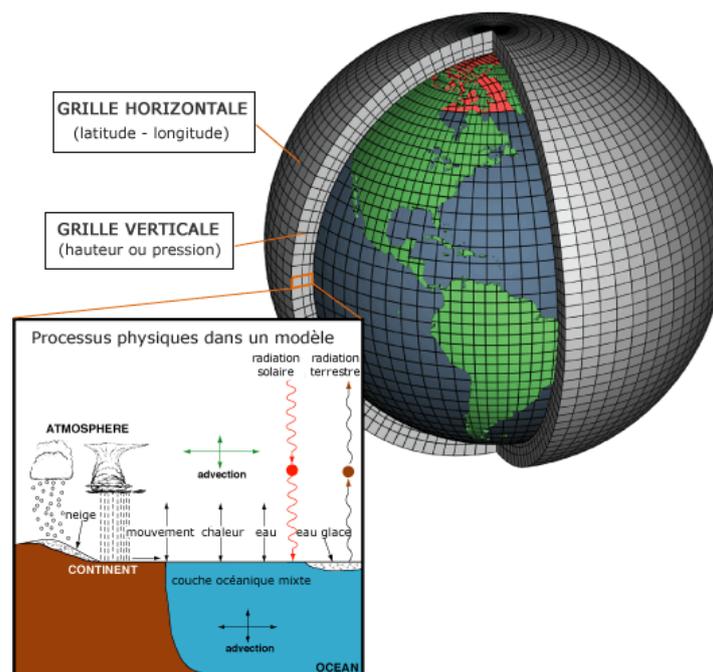


Figure (2- 3): Vue de la terre découpée en une multitude de petites zones. Notons ici la grille horizontale et la grille verticale. (Source : <https://www.meteocontact.fr>)

Tableau (2- 1) : Les principaux modèles météorologiques

Modèle	Abréviation	locale	Résolution	Initialisation	Accessible gratuitement	L'échéance de la prévision
Global Forecast System	<i>GFS</i>	(américain)	27 km jusqu'à 192 h 70 km de 192 h à 384 h	quatre fois par jour : 00 h, 06 h, 12 h et 18 h	Oui	16 jours
European Centre for Medium-Range Weather Forecasts	<i>ECMWF</i>	Européen	0,25 ° x 0,25 ° lat	deux fois par jour à 00 h et 12 h	Non	10 jours
Weather Research and Forecasting	<i>WRF</i>	États-Unis	horizontale entre 2 et 15 km	quatre fois par jour à 00 h, 06 h, 12 h et 18 h	Oui	36 heures
Action de Recherche Petite Echelle Grande Echelle	<i>ARPEGE</i>	Monde	selon les zones géographiques	quatre fois par jour à 00 h, 06 h, 12 h et 18 h	Non	4 jours
Application of Research to Operations at MESoscale	<i>AROME</i>	français	0,025° (env. 2,5 km) et 0,01° (env 1,3km)	quatre fois par jour : 00 h, 06 h, 12 h et 18 h	libre	36 heures

2.3.2 Modèles empiriques et semi empiriques

a) Modèles empiriques

Les modèles empiriques sont des modèles basés sur des observations expérimentales ; on peut distinguer plusieurs sortes de ces modèles (modèles basés sur la durée d'insolation, basés sur la température, etc.). Le premier modèle estimant le rayonnement global est celui proposé par (Angstrom 1924); il a établi une relation régressive simple entre le rapport du rayonnement global sur une surface horizontale (Yang, Kurtz et al.) et le rayonnement global par ciel clair (G_c), en fonction du rapport entre la durée d'insolation moyenne journalière (S_d) et la durée d'insolation maximale (S_0). Parmi les travaux utilisés ces modèle, on peut citer les travaux de (Ferkous et al. 2018). Donc pour un lieu donné, nous avons la relation suivante :

$$\frac{G_h}{G_c} = a + b \left(\frac{S_d}{S_0} \right) \quad (2.2)$$

Où : a et b sont des constants linéaires du modèle d'Angstrom.

b) Semi empiriques

Les modèles semi empiriques utilisent des relations mathématiques en fonction de la masse d'air pour calculer les effets des constituants de l'atmosphère (intégrés sur tout le spectre) sur l'atténuation du rayonnement direct et la création du rayonnement diffus (Ferkous et al. 2020).

2.3.3 Modèles de persistance

C'est un modèle de référence trivial particulièrement pour la prévision à court terme. En effet, le modèle de persistance est souvent une technique imprécise pour plus d'une heure avant la prévision. La persistance suppose que le rayonnement solaire à chaque temps $t+1$ est mieux prédit par sa valeur au temps t :

$$\hat{x}_{t+1} = x_t \quad (2.3)$$

Un modèle de persistance à partir de l'indice de clarté est défini dans (Inman, Pedro et al. 2013) smart persistance :

$$k_{t+\Delta t} = k_t = \frac{I_t}{I_t^{clr}} \quad (2.4)$$

Avec I_t^{clr} le rayonnement solaire défini selon un modèle ciel clair (Kasten 1996), (Ineichen 2008), (Mueller, Dagestad et al. 2004). La prévision à partir du modèle de persistance devient :

$$I_{t+\Delta t}^{pers} = k_t I_{t+\Delta t}^{clr} \quad (2.5)$$

2.3.4 Modèles linéaires

a) *Modèle Autorégressif à Moyenne Mobile (ARMA)*

Dans les années 1970, ([Box and Jenkins 1976](#)) ont décrit la méthodologie de l'analyse des séries temporelles et ils ont ainsi développé la famille de modèles constitués par les modèles auto régressifs à moyenne mobile. Il s'agit d'une approche statistique de l'analyse des séries temporelles. Une des combinaisons de modèle auto régressif (AR) avec un modèle de moyenne mobile (MA) permet le développement du modèle ARMA. Ce modèle, utilisé pour la prévision de séries temporelles stationnaires, est utilisé dans de nombreux domaines et plus particulièrement dans le domaine de la prévision du rayonnement solaire, il s'agit d'un modèle linéaire.

On définit les modèles AR et MA, respectivement d'ordre p et q , pour une série temporelle $x(t)$ et $t \in \mathbb{Z}$ par :

$AR(p)$:

$$x(t) = \sum_{i=1}^p \varphi(i) \cdot x(t-i) + \varepsilon(t) \quad (2.6)$$

$MA(q)$:

$$x(t) = \sum_{i=1}^q \theta(i) \cdot \varepsilon(t-i) \quad (2.7)$$

La combinaison des deux modèles devient alors $ARMA(p, q)$:

$$x(t) = \varepsilon(t) + \sum_{i=1}^p \varphi(i) \cdot x(t-i) + \sum_{i=1}^q \theta(i) \cdot \varepsilon(t-i) \quad (2.8)$$

Où $\varphi(i)$ et $\theta(i)$ sont les paramètres du modèle, p et q les ordres et ε le résidu qui est un bruit blanc est bien souvent omise dans la littérature si la série temporelle est stationnaire ([Delignières 2000](#)), ([Doucouré 2015](#)). Le modèle $ARMA$ est donc un modèle basé sur une combinaison de mesures et d'erreurs antérieures pour caractériser une donnée actuelle. La phase d'optimisation de ce modèle détermine les ordres du modèle. Les paramètres du modèle (φ et θ) sont déterminés pendant la phase d'apprentissage ([Fouilloy 2019](#)). Ce modèle est très utilisé dans l'analyse des séries temporelles, il est peu gourmand en ressources et est rapide à mettre en œuvre.

b) *Modèle Autorégressif Intégrée Moyenne Mobile ARIMA*

Les modèles *ARIMA* constituent une classe générale de modèles statistiques qui peuvent être convertis en processus stationnaire, tout en utilisant "la différenciation". Donc, les modèles *ARIMA* sont une généralisation des modèles *ARMA*. Ils comprennent une composante autorégressive (*AR*), une composante moyenne mobile (*MA*), et un terme de différenciation (*d*) ; il est désigné couramment par *ARIMA* (*p*, *d*, *q*) et donné par l'expression mathématique suivante :

$$X(t) = (1 - B)^d x(t) \quad (2.9)$$

$$X(t) = \sum_{i=1}^p \varphi(i) \cdot X(t - i) + \sum_{i=1}^q \theta(i) \cdot \varepsilon(t - i) \quad (2.10)$$

Où *B* est un opérateur de retard, les coefficients d'ajustement $\varphi(i)$ et $\theta(i)$ sont estimés en utilisant la procédure de minimisation (Box, Jenkins et al. 2015).

Il existe une multitude d'évolutions de ce type de modèle telles que ARMAX, SARMA, SARIM, Le lecteur intéressé peut se référer à l'ouvrage de Box et Jenkins sur l'analyse des séries temporelles (Box and Jenkins 1976).

2.3.5 Modèles non-linéaires

L'Intelligence Artificielle (AI) reproduit les quatre capacités cognitives humaines (Figur (2-5)) : percevoir, comprendre, agir, apprendre. Elle se décline essentiellement en deux domaines : l'apprentissage machine ou « Machine Learning » et l'apprentissage profond « Deep Learning ». En plus de ces deux techniques, plusieurs concepts tournent autour pour former ce que l'on appelle les domaines de l'AI qui regroupent de nombreux processus et diverses applications.

a) L'Apprentissage automatique « Machine Learning »

L'apprentissage automatique est un domaine qui fait partie de l'informatique, il est classé dans la famille des méthodes d'intelligence artificielle. L'utilisation de l'apprentissage automatique est aujourd'hui largement répandue dans de nombreux domaines. Ce type d'approche permet, de manière avantageuse, de résoudre des problèmes qui sont impossible à représenter par des algorithmes explicites. Les modèles d'apprentissage automatique sont en capacité de trouver des relations entre les entrées et les sorties même si la représentation est impossible, cela les rendent particulièrement adaptés aux tâches de prévisions. Les quatre types d'apprentissage du Machine Learning :

- L'apprentissage supervisé (supervised learning), est le plus populaire pour l'apprentissage automatique car plus facile à comprendre et plus simple à mettre en œuvre. Avec des données sous forme d'exemples avec des étiquettes, l'algorithme d'apprentissage est alimenté d'exemples de paires exemple-étiquette, ce qui permet à l'algorithme de prédire l'étiquette pour chaque exemple et de lui indiquer s'il a prédit la bonne réponse ou non. Au fil du temps, l'algorithme apprendra à approximer la nature exacte de la relation entre les exemples et leurs étiquettes. Une fois pleinement formé, l'algorithme d'apprentissage supervisé sera capable d'observer un nouvel exemple jamais vu auparavant et de prédire une bonne étiquette pour celui-ci.
- L'apprentissage non-supervisé (unsupervised learning), le système est formé avec des données non étiquetées et sans donner les bonnes réponses. C'est très instructif lorsque nous ne savons pas ce que nous cherchons dans les données traitées.
- L'apprentissage semi-supervisé (semi-supervised learning), qui consiste à fournir de nombreux exemples au système, ainsi que la bonne réponse pour certains d'entre eux. Ce type d'apprentissage utilise les données non-annotées pour compléter l'apprentissage supervisé.
- L'apprentissage par renforcement (reinforcement learning), il est né du mariage de la psychologie expérimentale ([Greenspan and Baars 2005](#)) et les neurosciences computationnelles ([IMPULSIONS and CYR 2016](#)). Les méthodes algorithmiques de l'apprentissage par renforcement reposent sur des principes simples issus de l'étude de la cognition humaine ou animale pour permettre de faire à des agents automatisés des tâches dans un cadre de programmation générique. Le système s'améliore à force de punitions et de récompenses.
- *Réseau de Neurones Artificiels*

Les réseaux de neurones artificiels (ANN), une technique inspirés du fonctionnement du cerveau humain, permet d'aborder sous des angles nouveaux de problèmes de perception, de mémorisation, d'apprentissage et de raisonnement ([Crone 2005](#)).

Les réseaux de neurones se sont imposés comme des alternatives très prometteuses pour constituer un modèle mathématique capable d'approximer des relations entre les variables. Contrairement aux méthodes traditionnelles, les réseaux de neurones sont réalisés sans faire aucune hypothèse sur la répartition des variables, et sans imposer aucune forme particulière aux données. Ils sont largement employés avec succès pour la prévision dans divers domaines ([Bishop 1995](#)), ([Touzet 1992](#)). Ces réseaux de neurones ont été considérés comme des outils utiles pour les problèmes de

classification et de régression. Leur objectif était de comprendre les propriétés du système nerveux à partir des composants élémentaires.

Principes généraux

Un neurone est une unité de calcul. Elle peut comporter 1 ou plusieurs entrées et 1 sortie calculée grâce à différentes caractéristiques :

- Des entrées (X ou E), la sortie applique le même fonctionnement ;
- Chacune des entrées à un poids (W) accordé à chacune des entrées et permettant de modifier l'importance de certaines par rapport aux autres ;
- Une fonction d'agrégation, qui permet de calculer une unique valeur à partir des entrées et des poids correspondants ;
- Un seuil (ou biais), permettant d'indiquer quand le neurone doit agir ;
- Une fonction d'activation, qui associe à chaque valeur agrégée une unique valeur de sortie dépendant du seuil.

Le résultat du calcul du neurone n'est autre que la somme des produits de toutes les entrées et des poids, le tout passé par un "filtre" que l'on appelle fonction d'activation (sortie). Le neurone formel peut donc se résumer sous la forme suivante la Figure (2-4):

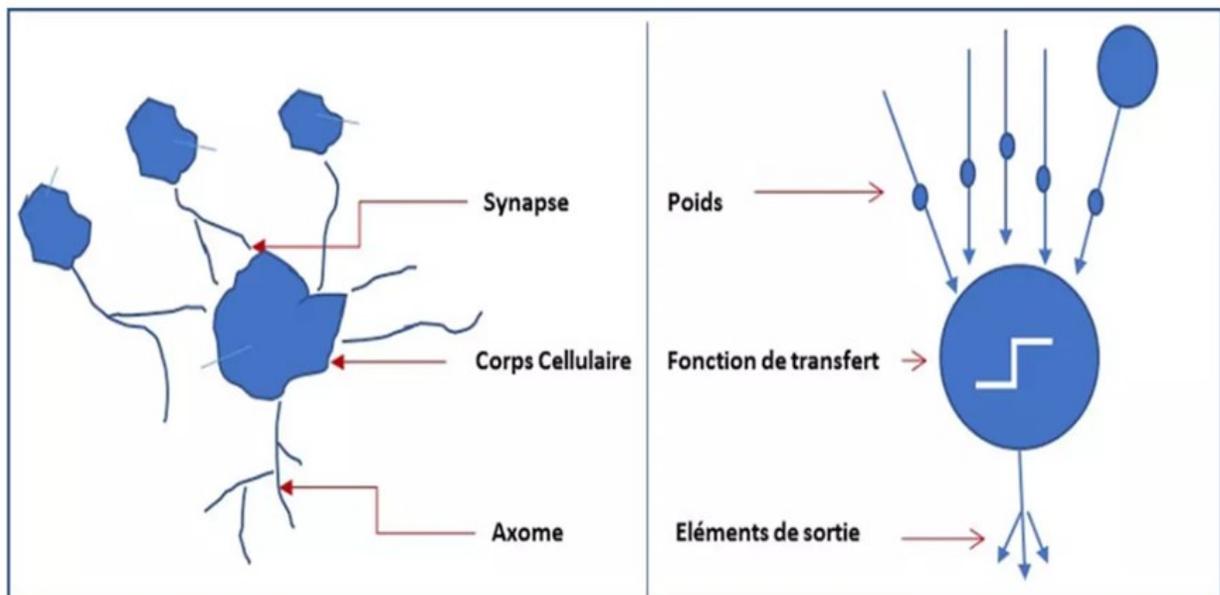


Figure (2- 4): Représentation schématique du neurone artificiel (Touzet 1992).

- *Les Régression de Processus Gaussienne*

En anglais « Gaussian process regression (GPR) » sont connus depuis longtemps en statistiques, mais il ne sont utilisés que depuis peu en Machine Learning (Neal 2012), développée assez récent (Rasmussen and Williams 2006) : un réseau de neurones place une probabilité a priori sur l'espace de fonctions, et lorsque la couche cachée est infinie, il s'agit d'un GPR. Ce type de modèles est, en réalité, une généralisation d'une distribution gaussienne (ou normale) multivariée. Il s'agit de modèles non linéaires. Avant d'expliquer le principe des processus gaussiens, il est important de définir le cadre d'étude lié à la statistique Bayésienne

La statistique Bayésienne

La statistique Bayésienne est une théorie fournit aux chercheurs un outil pour mettre à jour leurs précédentes estimations en présence de nouvelles données, basées sur la probabilité conditionnelle (la probabilité qu'un certain événement ait lieu, étant donné l'occurrence d'un autre événement). Le théorème de Bayes est décrit par l'équation (2.12).

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad (2.12)$$

De plus $P(A)$ peut-être écrite comme une marginalisation suivant l'équation (2.13)

$$P(A) = \sum_i P(A|B_i)P(B_i) \quad (2.13)$$

avec $\{B_i\}$ une partition de l'ensemble des possibles de B. On peut alors définir le théorème de Bayes par l'équation (2.14)

$$P(B|A) = \frac{P(A|B)P(B)}{\sum_i P(A|B_i)P(B_i)} \quad (2.14)$$

L'inférence Bayésienne

L'inférence Bayésienne facilite l'apprentissage supervisé dans le cadre bayésien. L'inférence signifie littéralement : une conclusion donnée sur la base de l'évidence, la première tâche dans l'apprentissage supervisé est d'approximer $P(A|B)$ avec le modèle approprié (Tipping 2003). Autrement dit, il faut mettre en place des modèles paramétrés pour définir notre probabilité conditionnelle comme décrit par l'équation (2.15).

$$P(B|A) = f(A, \theta) \quad (2.15)$$

avec θ un vecteur de paramètres, et f notre modèle. Etant donné un ensemble D de N données d'exemples de notre variable, une technique conventionnelle pour entraîner le modèle serait d'utiliser une fonction de perte pour optimiser les paramètres θ . Les prédictions de B sont ainsi faites, étant donné A en évaluant $f(A|\theta)$ avec des paramètres fixés à leurs valeurs optimales.

Pour obtenir une distribution postérieure sur θ , une distribution préalable $p(\theta)$ doit être spécifiée avant d'observer les données. Le besoin d'une distribution a priori est souvent vu comme un inconvénient de l'inférence Bayésienne. Cependant, en excluant toutes les variables sans intérêt, l'approche Bayésienne est capable de préférer des modèles simples qui suffisent à expliquer les données, sans inclure des complexités superflues (Tipping 2003).

L'inférence Bayésienne peut être résumée par l'équation (2.16), calculée par la loi de Bayes

$$P(D|\theta) = \frac{P(D|\theta)P(\theta)}{P(D)} \quad (2.16)$$

Si la donnée D est considérée comme un vecteur d'entrée X et la valeur cible correspondante y , alors l'équation (2.16) peut être reformulée suivant l'équation (2.17).

$$P(\theta|y, X) = \frac{P(y|X, \theta)P(\theta)}{P(y|X)} \quad (2.17)$$

avec :

$P(\theta)$: les connaissances a priori sur les paramètres avant d'observer les données ;

$P(y|X, \theta)$: la vraisemblance d'observer nos résultats ou cibles, en fonction de données d'entrées définies, et une certaine distribution de θ ;

$P(y|X)$: la constante de normalisation.

On pourrait réécrire l'équation (2.18) ainsi :

$$\text{distribution a posteriori} = \frac{\text{vraisemblance} \times \text{connaissance a priori}}{\text{constante de normalisation}} \quad (2.18)$$

Un processus gaussien ou G peut être décrit par le système d'équations (2.19)

$$\begin{aligned} f(x) &\sim GP(m(x), k(x, x')) \\ m(x) &= E[f(x)] \\ k(x, x') &= E[(f(x) - m(x))(f(x') - m(x')))] \end{aligned} \quad (2.19)$$

avec $f(x)$ le processus réel que l'on souhaite modéliser, m la moyenne, k la fonction de covariance ou kernel, E l'espérance mathématique et x et x' deux points différents. (Rasmussen and Williams 2006) ont défini que les processus gaussiens sont une généralisation de la probabilité de distribution gaussienne. Alors que les probabilités de distribution sont utilisées pour décrire des données aléatoires, un processus (stochastique) gouverne les propriétés des fonctions. Au lieu de calculer une distribution complète sur les fonctions pour approximer un processus sous-jacent, nous allons nous limiter à la distribution des propriétés de ces fonctions sur un nombre fini de points.

Prédire à partir des processus gaussiens

Etant donnée un ensemble de points de test, la distribution de probabilité de de la loi jointe entre les données d'entraînement et les sorties de test) est donnée par une loi normale définie par l'équation (2.20).

$$\begin{bmatrix} f \\ f^* \end{bmatrix} \sim \mathcal{N} \left(\begin{bmatrix} m(x) \\ m(x^*) \end{bmatrix}, \begin{bmatrix} K(X, X) & K(X, X^*) \\ K(X^*, X) & K(X^*, X^*) \end{bmatrix} \right) \quad (2.20)$$

S'il y a n données d'entraînements et n^* données tests, alors $K(X, X^*)$ représente la matrice $n \times n^*$ de covariance entre les données d'entraînement X et les données de test X^* . X^* définit le symbole de la loi normale.

- ***Machines à Vecteurs Supports pour la Régression***

Le développement de ces modèles « Support Vector Machine (SVM) » en anglais est directement issu des travaux de *Valdimir Vapnik* dans les années 80 (Vapnik 2013). Ce sont d'un ensemble de techniques d'apprentissage supervisé destinées à traiter des problèmes de discrimination ou de régression, sont des classifieurs linéaires généralisés. Cette méthode a été appliquée avec succès à la prévision de séries temporelles. Le formalisme des SVM est similaire à celui des processus Gaussiens. La formule mathématique des SVM appliquée à la prévision de séries temporelles est (Lauret, Voyant et al. 2015) :

$$\hat{x}(t+h) = \sum_{i=1}^n \alpha_i \cdot k_{rbf}(x_i, x_{test}) + b \quad (2.21)$$

Dans laquelle, x_i est le $i^{\text{ème}}$ vecteur d'entrées pour l'apprentissage et x_{test} le vecteur de test. La fonction de base radiale est donnée par :

$$k_{rbf}(x_p, x_q) = \exp \left[\frac{-(x_p - x_q)^2}{2\sigma^2} \right] \quad (2.22)$$

Le paramètre b (paramètre de biais) est déduit de l'équation précédente, l'hyperparamètre σ également, il définit notamment la complexité du modèle. Concernant les SVR, les coefficients α_i sont liés à la différence de deux multiplicateurs de Lagrange qui sont déduits par la résolution d'un problème de programmation quadratique. Contrairement aux réseaux de neurones artificiels, sujets aux problèmes de minimums locaux, pour les SVR le problème est strictement convexe et ne possède donc qu'une seule et unique solution. En outre, il faut souligner (contrairement aux processus Gaussiens) que tous les modèles d'entraînement ne participent pas à la relation précédente. En effet, un choix pratique d'une fonction de coût (fonction ε de Vapnik) (BACH 2015) dans le problème quadratique, permet d'obtenir une solution particulière construite à partir d'une régression. A noter alors que certains des coefficients α_i seront non-nuls.

b) L'apprentissage profond « Deep Learning »

L'apprentissage profond (DL) branche du machine Learning où la machine est capable d'apprendre par elle-même, basée sur un ensemble d'algorithmes modélisant des abstractions de haut niveau dans des données en utilisant des architectures de modèle particulièrement complexes, sont interconnectés pour traiter et mémoriser des informations, comparer des problèmes ou situations quelconques avec des situations similaires passées et résoudre le problème de la meilleure façon possible.

2.3.6 Les Méthodes hybrides

L'idée d'une méthodologie hybride est introduite pour résoudre les inefficacités induites par l'utilisation d'un seul modèle. (Zhang 2003) confirme qu'un modèle hybride ayant à la fois des capacités de modélisation linéaires et non linéaires pourraient être une bonne alternative pour prédire des données de séries chronologiques. Des hybridations similaires peuvent également être utilisés, chaque technique a des propriétés de calcul qui les rendent aptes à des problèmes particuliers et non pour d'autres. L'utilisation des méthodes hybrides se développe rapidement avec des applications réussies dans de nombreux domaines tels que le contrôle des processus, le diagnostic médical, la simulation cognitive, etc. En ce qui suit, nous donnerons plus de détails sur les modèles hybrides

ondelettes -GP, ondelette-SVM qui ils nous avons utilisés pour la prédiction du rayonnement solaire dans le chapitre suivant.

2.3.7 Revue bibliographique

Pour avoir une idée générale sur les performances des techniques d'apprentissage statistique par rapport à la prédiction de l'Irradiation solaire journalier, une synthèse de quelques résultats est illustrée dans le Tableau (2-2)

Tableau (2- 2) : Revue bibliographique

	Rayonnement Solaire				
	Modèle	Sites	Horizon	Performances	Références
Modèles Météorologiques	NDFD	USA	1h	RMSE=170.2 W/m ²	(Perez, Kivalov et al. 2010)
	Satellite Images- ANN	USA	30 min	RMSE=61.24 W/m ²	(Marquez, Pedro et al. 2013)
	SKY Imager	USA	5 min	nRMSE=24.3% nMAE=14.4%	(Yang, Kurtz et al. 2014)
	Persistence, ECMWF-NWP ECMWF-MOSNN	Italie	j+1	RMSE =96.4 W/m ² MAE= 62.9 W/m ²	Cornaro, Pierro et al. (2015)
	Regression tree - NWP	Italie	1 h	nRMSE= 13%	(Lazzaroni, Ferrari et al. 2015)
	NWP , WRF-SOLAR	USA	1 min	RMSE =15 W/m ²	Jimenez, Hacker et al. (2016)
	WRF	Japan	j+1	RMSE=118.9 W/m ²	(Liu, Shimada et al. 2016)
	ECMWF-ANN+ SAT	Island - Espagne	1 h	RMSE=104.75 W/m ²	(Aguiar, Pereira et al. 2016)
Modèles statistiques	ANN, AR , k-NN, Markov	France	j+1	nRMSE= 21%	(Paoli, Voyant et al. 2010)
	AR, ARMA, ARIMA	Italia	j+1	Pe= 42.7 MJ/m ²	(Ferrari, Lazzaroni et al. 2013)
	ARMA, ARIMA	Turque	1h	MAPE= 7.87%,	(Colak, Yesilbudak et al. 2015)
	ARMA, GARCH	Chine	Mensuel	MAE= 1.025 MJ/m ² RMSE= 1.44 MJ/m ²	(Sun, Yan et al. 2015)

		ARMA, NAR	Algérie	1h	nRMSE= 20.34%	(Benmouiza and Cheknane 2016)
		ARMA, ARIMA	Maroc	Mensuel	RMSE= 0,77 MJ/m ² MAPE = 1,65 %	(Belmahdi, Louzazni et al. 2020)
Modèles Empirique		Empirique	Turque	j+1	R ² = 0.9152	(Ulgen and Hepbasli 2004)
		Empirique (kriging)	Singapore	j+1	nRMSE=24.54%	(Yang, Dong et al. 2014)
		Empirique (kriging)	Espagne	j+1	RMSE=2.651 MJ/m ²	(Rodríguez-Amigo, Díez-Mediavilla et al. 2017)
		Empirique	Algérie	Mensuel	nRMSE=4.6246 % R ² = 0.9770	(Achour, Bouharkat et al. 2017)
		Empirique combiné	Chine	j+1	RMSE= 2.584 MJ/m ²	(Fan, Wang et al. 2018)
Apprentissage Automatique	ML	Regression	Argentine	j+1	RMSE =3.2 MJ/m ²	(Podestá, Núñez et al. 2004)
		ANN, Generalized Regression	Espagne	j+1	MAE=2.33 MJ/m ²	(Moreno, Gilabert et al. 2011)
		ANN, Persistence	USA	j+1	nRMSE=17.7%	(Marquez and Coimbra 2011)
		BC, ANN, k-NN	Espagne	j+1	RMSE= 3.160 MJ/m ² R ² =0.9100	(Moreno, Gilabert et al. 2011)
		ANN, GP, SVM, Persistence	France	1h	nRMSE=19.6%	(Perez, Lorenz et al. 2013)
		EML	Spain	j+1	RMSE=0.692 W/m ²	(Salcedo-Sanz, Casanova-Mateo et al. 2014)
		RF	Australia	j+1	MAPE =38%	(Huang, Troccoli et al. 2014)
		ANN, SVM, k-NN, RF	Chine	j+1	MAPE= 11.8%	(Long, Zhang et al. 2014)

		KELM	Iran	j+1	RMSE= 2.016 MJ/m ² R ² = 0.8203	(Shamshirband, Mohammadi et al. 2015)
		SVM-WT, ANN, GP, ARMA	Iran	j+1	RMSE=1.24 MJ/m ² R ² =0.90	(Mohammadi, Shamshirband et al. 2015)
		tree	USA	j+1		(McCandless, Haupt et al. 2015)
		GEP, ANN, ANFIS, Empirical	Iran	j+1	RMSE=1.850 MJ/m ² R ² =0.9350	(Mehdizadeh, Behmanesh et al. 2016)
		SVM	Algérie	j+1	RMSE = 2.779 MJ/m ² R ² = 0.896	(Belaid and Mellit 2016)
		RBNN, GRNN	Chine	j+1	RMSE = 1.96-3.25 MJ/m ² R ² = 0.959	(Wang, Kisi et al. 2016)
		MLP, RBF, GRNN	Chine	j+1	RMSE= 1.940 R ² =0.8600	(Wang, Kisi et al. 2016)
		ANFIS, Empirique	Chine	j+1	RMSE=2.07 MJ/m ² R ² =0.91	(Wang, Kisi et al. 2017)
		ANFIS, SVM, ANN	Mexique	j+1	RMSE= 2.578 MJ/m ² R ² =0.68	(Quej, Almorox et al. 2017)
		SVR	Algeria	j+1	RMSE=1.59 MJ/m ² R ² =0.974	(Guermoui, Rabehi et al. 2018)
		ANN, MLR	Greece	j+1	RMSE= 3.166 MJ/m ²	(Antonopoulos, Papamichail et al. 2019)

DL					$R^2= 0.884$	
		MEA-ANN, ANN, RF, WNN	Chine	j+1	RMSE=2.814 MJ/m2 $R^2=0.8850$	(Feng, Gong et al. 2019)
		ANN, SVM, DL, k-NN	Turque	j+1	RMSE = 2.157 MJ/m2 $R^2 = 0.9320$	(Ağbulut, Gürel et al. 2021)
		LSTM	Cap-Vert	j+1	RMSE=0.7624 W/m ²	(Brownlee 2018)
		CLSTM, CNN, LSTM	Australie	j+1	rRMSE= 1.15%	(Ghimire, Deo et al. 2019)
		LSTM	Corée du Sud	j+1	nMSE= 10.4 %	(Muhammad, Lee et al. 2019)
		LSTM, GRU	Corée du Sud	j+1	RMSE=0.5333 W/m2	(Aslam, Lee et al. 2020)
		LSTM ,GRU, FFNN, RNN, RF	Corée du Sud	j+1	RMSE=4.7768 MJ/m ²	(Aslam, Lee et al. 2020)
		Sky Images - Deep Learning	France	10 min	MSE=36.6 W/m ² .min RMSE=20.4 W/m ² .min	Quentin.(2021)
Modèles Hybrides		NWP-ARMA	France	j+1	nRMSE=14.9%	(Voyant, Muselli et al. 2012)
		ANN-linear regression	USA	j+1	$R^2=0.9$	(Aggarwal and Saini 2014)
		ESSS-ANN	Japan	j+1	nRMSE= 20.69% $R^2= 0.908$	(Dong, Yang et al. 2014)
		Empirique-BNN	Algeria	j+1	RMSE =1.07 MJ/m ² MAE =0.7 MJ/m ²	(Yacef, Mellit et al. 2014)
		SVM- PSO- SOM	USA - Singapore.	j+1	nRMSE=22%	(Dong, Yang et al. 2015)

SVM-FFA	Nigeria	j+1	RMSE= 1.8661 MJ/m ² R ² = 0.7280	(Olatomiwa, Mekhilef et al. 2015)
ANN-ARX	Iran	j+1	RMSE=1.730 MJ/m ² R ² =0.870	(Shamshirband, Mohammadi et al. 2016)
WD-SVM	Australie	j+1	RMSE=2.317 MJ/m ²	(Deo, Wen et al. 2016)
FRF-SVM	Turque	j+1	RMSE=1.571 MJ/m ²	(Baser and Demirhan 2017)
GPR-PFA- CFA	Algerie	j+1	RMSE= 3.18 MJ/m ²	(Guermoui, Melgani et al. 2018)
EEMD-LS-SVR	Chine	j+1	Std.NRMS= 0.025%	(Sun, Wang et al. 2018)
WRF-KELMAN	Japan	j+1	nRMSE =26.8%	(Che, Chen et al. 2019)
ML- Satellite-	Singapore	j+1	nRMSE = 24.21%	(Yagli, Yang et al. 2020)
ABC-LS-SVM	Algerie	j+1	R ² = 0.977	(Rabehi, Guermoui et al. 2020)
WD-CLSTM WD-CNN-LSTM	Chine	j+1	RMSE =139.133 W/m ² R ² =0.757	(Wang, Yu et al. 2018)
SPSO-DL	Turque	j+1	RMSE= 0.61 MJ/m ² R ² = 0.980	(Kaba, Sargül et al. 2018)
CNN-BiLSTM	Arabie saoudite	j+1	nMAPE=4.25%	(Boubaker, Benghanem et al. 2021)
vanilla LSTM, GRU BiLSTM, CNN-LSTM	Inde	j+1	RMSE= 8.724 MJ/m ² R ² = 0.7334	(Brahma and Wadhvani 2020)

Le Tableau (2-2) montre que :

- Les RNA ont été largement utilisés dans le domaine de la prévision de l'éclairement solaire, ils ont été étudiés dans de nombreuses régions du monde et des chercheurs ont démontré la capacité de ces techniques à réaliser une prévision basée sur l'utilisation des séries temporelles de données météorologiques avec précision.
- Les méthodes basées sur la régression linéaire (ARMA, ARIMA) sont aussi très utilisées, même si elles sont généralement légèrement moins efficaces que les méthodes basées sur les RNA, elles peuvent être probantes dans certains cas.
- La plupart des articles dans la littérature concernent des comparaisons entre différents modèles plus ou moins complexes, les modèles sont comparés entre eux, et souvent hybridés pour observer les améliorations possibles dans leurs performances dues à ces hybridations. On entend par hybridation le fait d'assembler différents modèles pour les utiliser ensemble et observer les effets sur les performances lors des prévisions. Cette méthode est souvent génératrice d'amélioration mais aussi de complexité des modèles.
- D'après la Figure (2-5) notons que, le DL, branche du ML basée sur un ensemble d'algorithmes modélisant des abstractions de haut niveau dans des données en utilisant des architectures de modèle particulièrement complexes, composées de multiples transformations non linéaires, de prendre sa place parmi les modèles plus largement utilisés pour la prévision du rayonnement solaire.

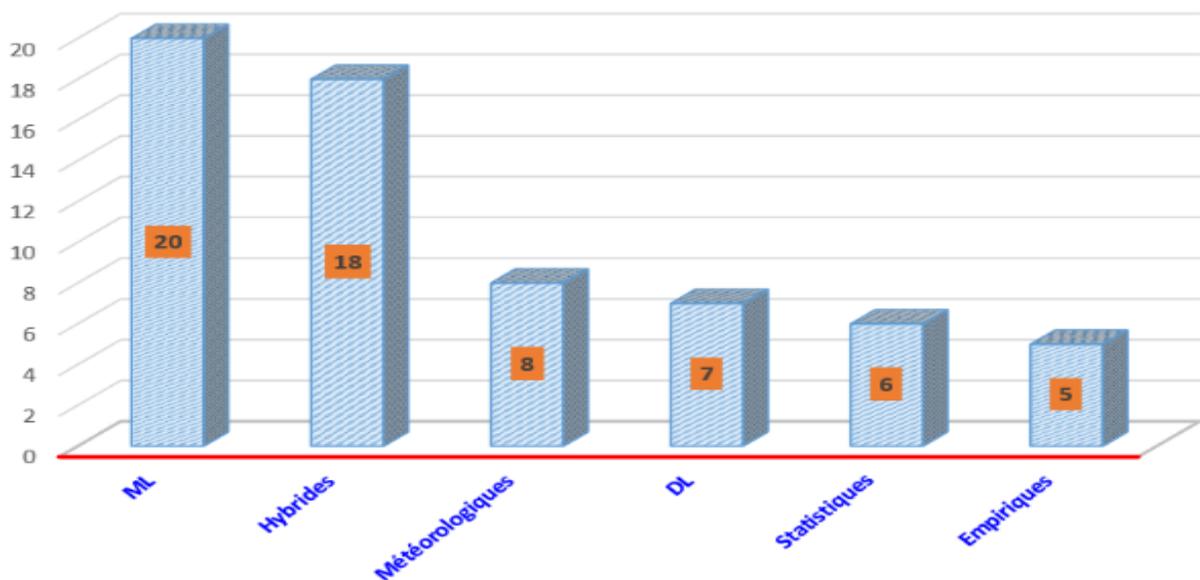


Figure (2- 5): Analyse d'étude bibliographique.

2.4 Conclusion

Dans le présent chapitre, nous avons revu les différentes approches et fondements permettant la prédiction et la prévision du rayonnement solaire. Nous avons constaté qu'il est très difficile de faire un choix clair parmi les méthodes de prédiction existantes dans la littérature. Cependant, pour l'horizon de prédiction à court terme et à très court terme, nous avons quelques méthodes de prédiction qui donnent de très bons résultats. Tous ces modèles choisis à constituent un panel de techniques assez intéressant pour s'attaquer à des problèmes de prévision. Nous pouvons citer :

- Les méthodes dites « classiques » sont généralement les moins complexes (ARMA, ARIMA) ;
- Les méthodes basées sur les fonctions Kernel (Machine Learning) ;
- Les méthodes plus compliquées sont celles dites Ensemble « Deep Learning » ;
- Les méthodes hybrides.

Le chapitre à venir portera sur la performance de l'hybridation des réseaux d'ondelettes et les modèles GP et SVM pour la prédiction du rayonnement solaire.

Chapitre 3 : **Méthodologie de Prédiction**

3.1 Introduction

Ce chapitre aborde la méthode de prédiction qui a été proposée dans le cadre de ce projet et la théorie liée à cette méthode, ainsi qu'une description compréhensible des différentes parties du système. Donc, nous proposons un modèle hybride basé sur la combinaison entre une méthode d'apprentissage automatique avec un algorithme de la transformée en ondelette (WT). Car, d'après les investigations des chercheurs, les méthodes hybrides sont parmi les techniques les plus compétitives pour la prédiction des séries temporelles (Kazemzadeh, Amjadian et al. 2020), (Jaihuni, Basak et al. 2020), (Yan, Shen et al. 2020).

3.2 Modèle de prédiction

Le modèle de prédiction que nous avons adopté pour notre application se présente comme suit : Premièrement, les données recueillies passent par une phase de décomposition à base d'ondelettes. Les résultats de la décomposition sont envoyés à l'algorithme d'entraînement et de prédiction. Enfin, les résultats de la prédiction sont envoyés à l'algorithme d'évaluation du modèle pour choisir le modèle le plus précis. La théorie liée à l'algorithme d'entraînement et de prédiction a été abordée au chapitre 2. La figure (3-1) donne une illustration générale de la structure du système de prédiction.

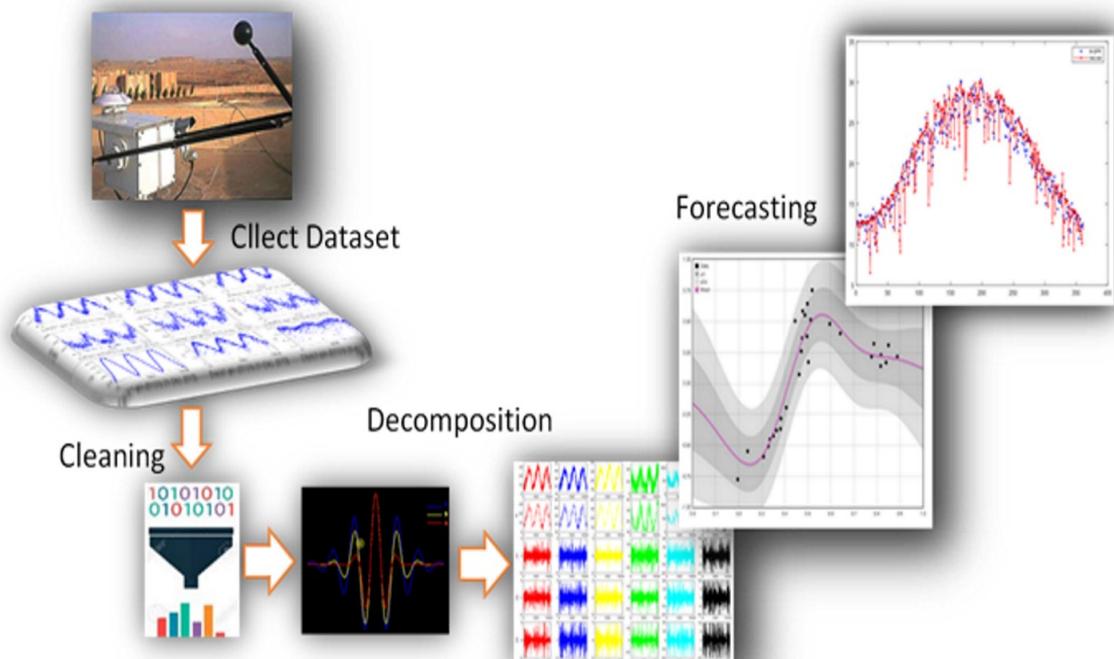


Figure (3- 1) : Processus de modélisation et de prévision.

3.2.1 Principe de fonctionnement de la décomposition ondelette:

La principale motivation pour utiliser la décomposition en ondelettes (WT) est la simple analyse de la série obtenue. Pendant de nombreuses années, la WT (ou transformée en ondelettes) a été mélangée avec des modèles de séries chronologiques comme technique de prétraitement. WT utilise un ensemble de filtres pour décomposer la série chronologique d'origine de manière itérative, de sorte que des modèles de prévision distincts puissent être appliqués à chaque composante. La transformée en ondelettes continue (CWT) d'une fonction $f(t)$ par rapport à l'ondelette mère $\psi(t)$ peut s'écrire par l'intégrale suivante (Addison Paul 2002):

$$F_w(a, \tau) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{1 - \tau}{a}\right) dt \quad (3-1)$$

Où

(*) représente l'opération de la conjugaison complexe, $\tau \in \mathbb{R}$ est la valeur de translation, $a \in \mathbb{R}^{+*}$ est le coefficient de mise à l'échelle.

Contrairement à la transformation de Fourier, la CWT a été discrétisée et est connue sous le nom de transformée en ondelettes discrète (DWT). L'approche est une implémentation de la transformée en ondelettes par la mise à l'échelle et la translation des ondelettes en temps discret. Dans ce cas, les ondelettes sont données par :

$$\psi_{n,k}(t) = |a_0^n|^{-\frac{1}{2}} \psi\left(\frac{1 - k\tau_0 a_0^n}{a_0^n}\right) \quad (3-2)$$

où

n et k sont des entiers ($a = a_0^n$)

$\tau = k\tau_0 a_0^n$

Plus de détails sur la transformée en ondelettes peuvent être trouvés dans la littérature (Heil 1993), (Mallat 1989),

Le principal avantage de l'utilisation de la méthode des ondelettes est sa robustesse, car elle n'inclut aucune hypothèse paramétrique ou procédure de test potentiellement défectueuse. Un autre avantage de la méthode par ondelettes est que la décomposition du signal permet d'étudier indépendamment le comportement du signal à différentes échelles de temps. Les résultats décomposés par WD de la série chronologique de rayonnement solaire sont illustrés à la figure (3-2).

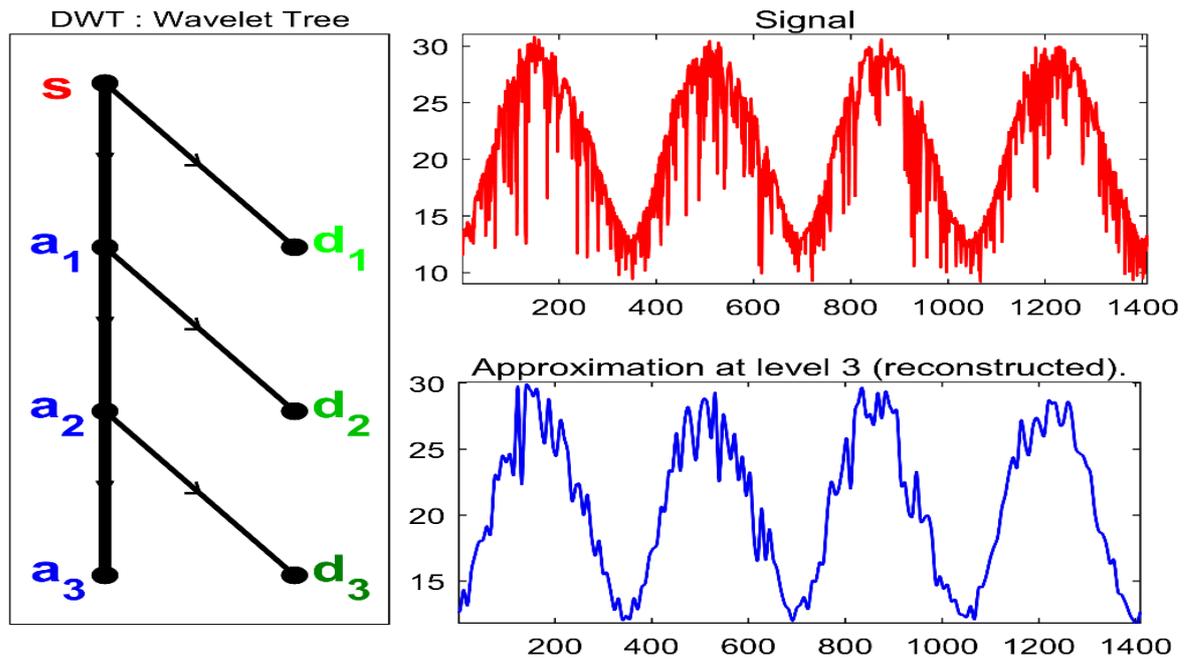


Figure (3- 2): Processus de décomposition en ondelettes.

3.2.2 Décomposition ondelettes en paquets

La décomposition par paquets d'ondelettes (WPD) est une transformation en ondelettes spéciale. Différent du WT, le WPD gère à la fois les composants approximatifs et détaillés dans le processus de décomposition (Zhou, Zhou et al. 2006), comme le montre la figure (3-3).

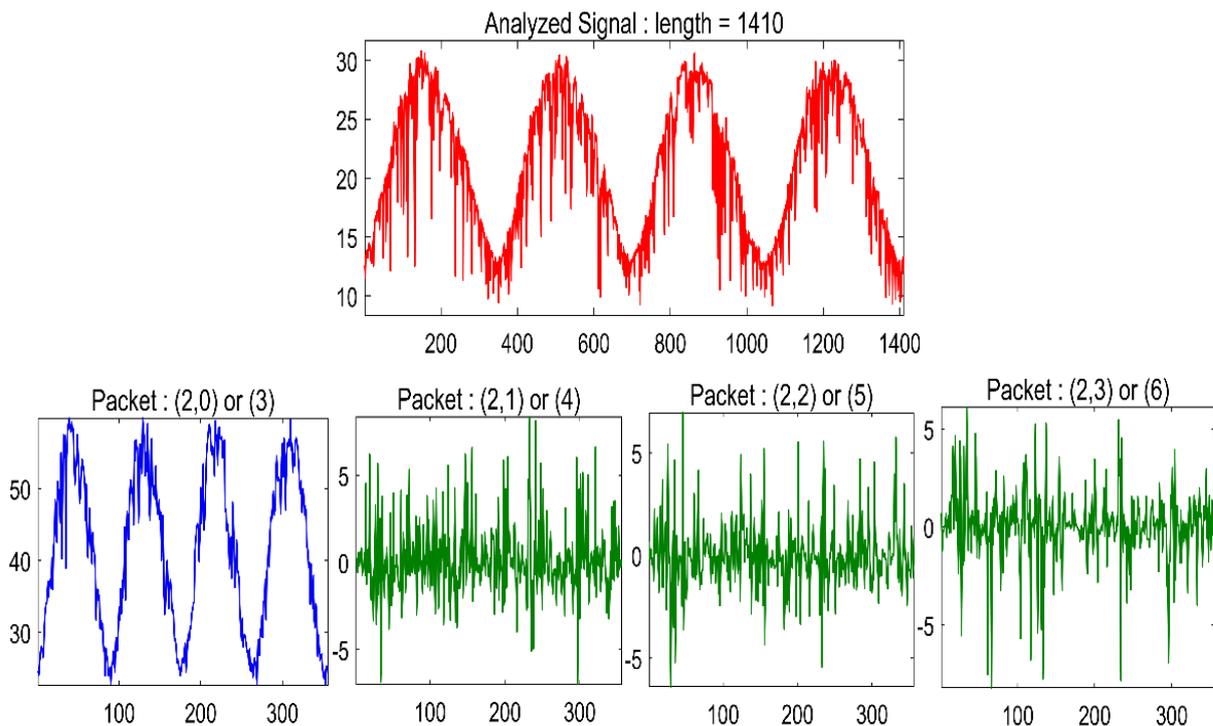


Figure (3- 3): Processus de décomposition par paquets d'ondelettes

3.2.3 Ondelette mère

Une ondelette mère est une fonction de base qui peut être traduite et dilatée, et qui permet de suivre le plan temps-fréquence afin d'analyser un signal. (Ngui, Leong et al. 2013).

3.3 Prédiction

La décomposition est appliquée aux données de séries temporelles utilisées pour la prédiction GP, les séries chronologiques des variables prédictives ont été décomposées en sous-séries d'approximation (basse fréquence) et en sous-séries détaillées (D) (haute fréquence). Dans l'étape suivante, l'approximation et les sous-séries détaillées ont été utilisées dans la matrice d'entrée pour le modèle ondelettes – GPR. La sortie du modèle ondelettes-GP développé présente le rayonnement solaire prédit à la fin du processus de simulation. Par conséquent, les modèles hybrides combinant ondelette et GPR peuvent être classés comme W-GPR (GPR utilisant des ondelettes), WPD-GPR (GPR utilisant des paquets d'ondelettes). Le modèle (W, WPD) -GP est représenté dans l'organigramme de la figure (3-4). La marge d'erreur entre la sortie cible et la sortie prévue est ensuite calculée à l'aide des indicateurs statistiques. RMSE, nRMSE, MSE et R^2 sont utilisés pour l'évaluation des performances du (WD, WPD) -GP développé.

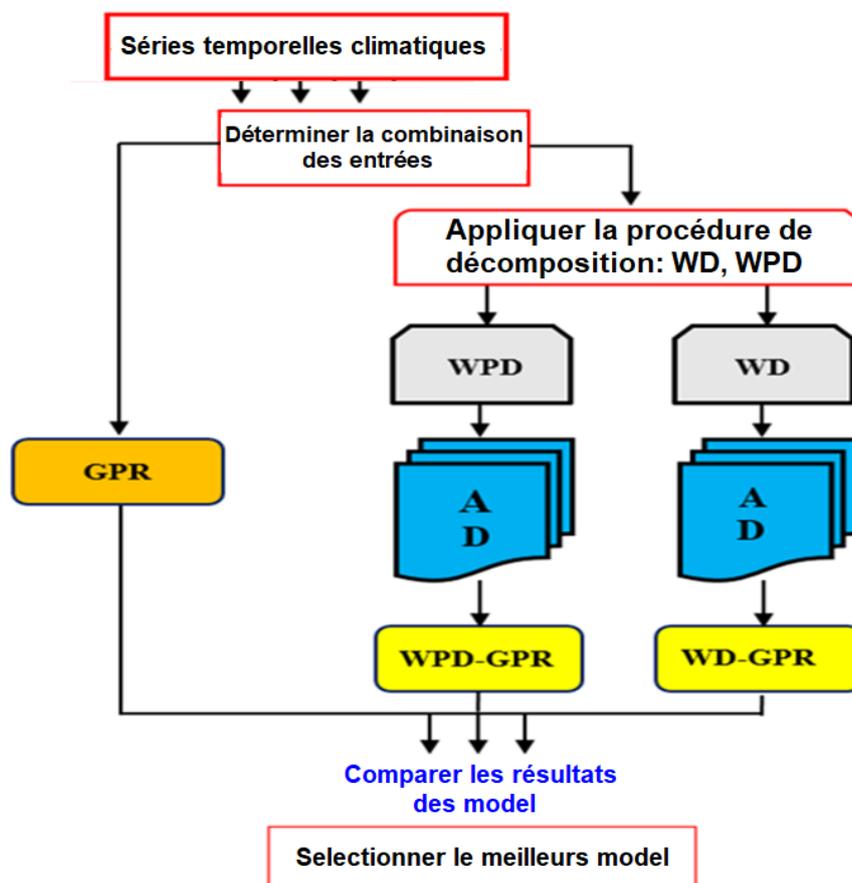


Figure (3- 4): Organigramme du modèle proposé W – GPR.

3.4 Région d'étude et données météorologiques

La zone d'étude couvre la province de Ghardaia ($32,2^{\circ}$ - $32,82^{\circ}$ N, $3,7^{\circ}$ et $4,5^{\circ}$ E), située dans la région désertique d'Algérie, à une altitude de 450 m. Les précipitations au cours de l'année sont faibles à Ghardaia; elle est classée comme un climat désertique BWh (ou désert chaud, selon la classification de Köppen-Geiger). Les précipitations moyennes à Ghardaia sont de 68 mm / an alors que la température moyenne annuelle est de $21,0^{\circ}$ C. La ville a un grand potentiel solaire tout au long de l'année en raison de sa situation géographique (le rayonnement solaire quotidien moyen reçu est d'environ 6000 Wh/m^2 sur une surface horizontale, comme indiqué sur la figure (3-5)).

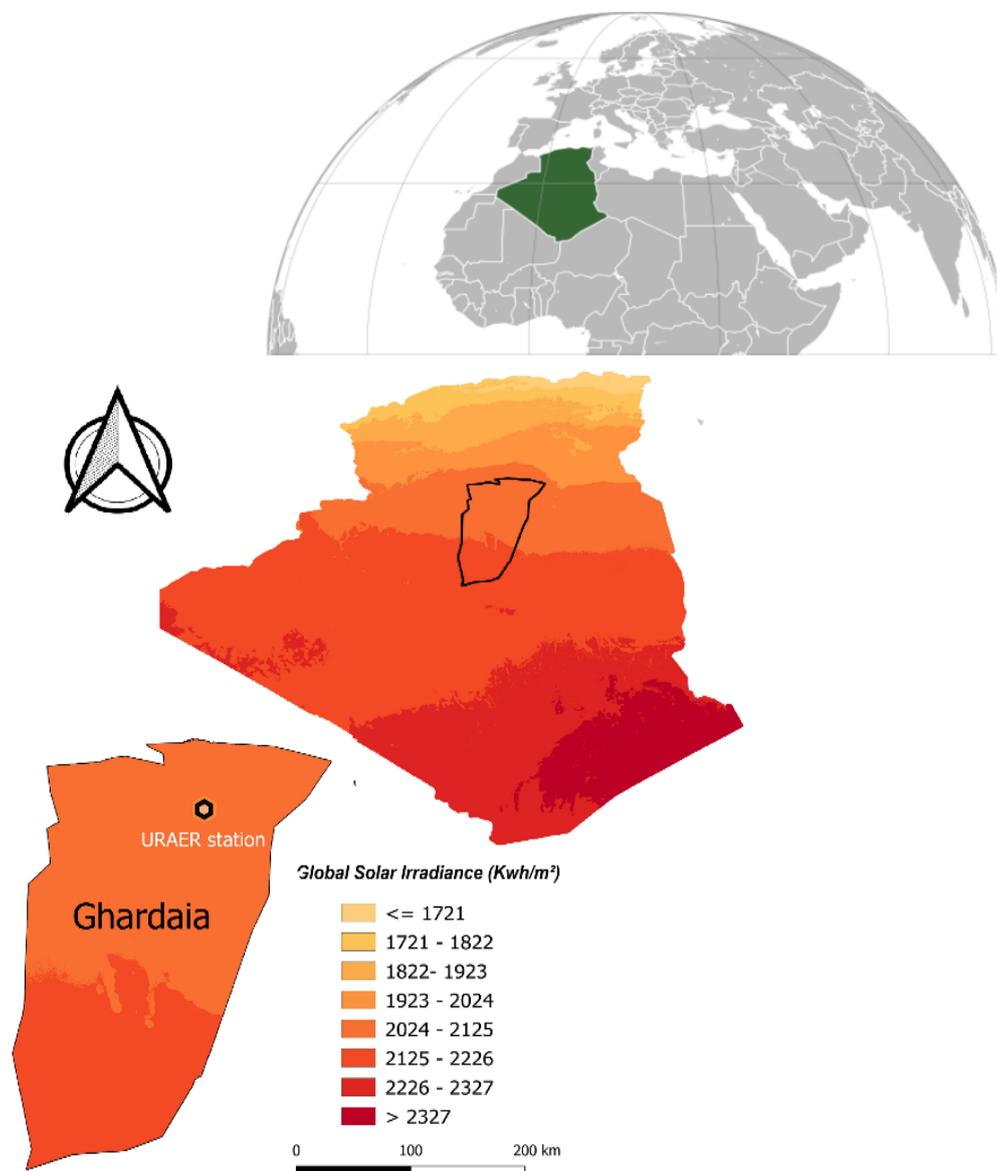


Figure (3- 5): la zone d'étude

3.4.1 Aperçu sur l'unité de recherche appliquée en énergies renouvelables (URAER)

URAER a été inaugurée en 1999, appartient au Centre de Développement des Energies Renouvelables (CDER), et est située à 1 kilomètre de l'aéroport de Ghardaïa (figure (3-6)). L'URAER est une plateforme expérimentale dédiée aux différentes activités liées aux énergies renouvelables. Elle comporte deux divisions assurant la gestion des différentes activités. Ces divisions sont :

- La division Mini Centrales Solaires.
- La division Application des Energies Renouvelables dans les Milieux Arides et Semi Arides.

Chaque division dispose d'équipes de recherche travaillant au développement des différentes applications liées aux énergies renouvelables. Elles assurent également l'encadrement des étudiants universitaires master et doctorat qui veulent finaliser leurs travaux de fin d'études.



Figure (3- 6): Unité de recherche appliquée en énergies renouvelables (URAER) Ghardaïa.

Le choix de ce site est porté sur la disponibilité des données radiométriques recherchées. En fait, l'ensemble des données de rayonnement solaire utilisées dans cette thèse ont été acquies par une station de mesure radiométrique localisée au niveau de URAER. Cette station est de haute précision et est utilisée pour la mesure des trois composantes radiométriques. Elle est capable de suivre quotidiennement la trajectoire du soleil du lever au coucher, grâce à un système de poursuite.

3.4.2 Dispositifs expérimentaux

Les capteurs météorologiques inclus dans cette station, servent à mesurer les paramètres suivants : la température de l'air, l'humidité atmosphérique, la vitesse et la direction du vent, la pression atmosphérique, la température de rosée et la pluviométrie. Ces instruments sont reliés à une acquisition de données du type Campbell Scientific, modèle RS232 pour le stockage et la collecte des données radiométriques (figure (3-7)). Ces mesures sont programmées à un pas de mesure d'une minute et de dix minutes.



Figure (3- 7): Les capteurs météorologiques installée sur le toit de l'URAER (Ghardaïa).

Concernant la station CIMEL, en plus des paramètres météorologiques précédents, elle mesure aussi le rayonnement global reçu sur un plan horizontal à l'aide du Pyranomètres CE-180. Une acquisition de données du type Campbell Scientific, modèle RS232 est utilisée pour la collecte et pour le stockage des données à des intervalles de 10 min pour chaque paramètre (les compteurs sont analysés à intervalles de 10 secondes et des valeurs moyennes à intervalles de 10 minutes sont calculées et stockées (figure (3-8))).

3.5 Préparation des données

Les ensembles de données contiennent la température minimale de l'air (T_{\min}), la température maximale de l'air (T_{\max}), la température moyenne de l'air (T_{moy}), l'humidité relative minimale (RH_{\min}), l'humidité relative maximale (RH_{\max}) et l'humidité relative moyenne (RH_{moy}), y compris le solaire quotidien total sur une surface horizontale. Les données ont été mesurées et enregistrées à l'unité de recherche pour la période de 4 ans du 1er janvier 2013 au 31 décembre 2016.

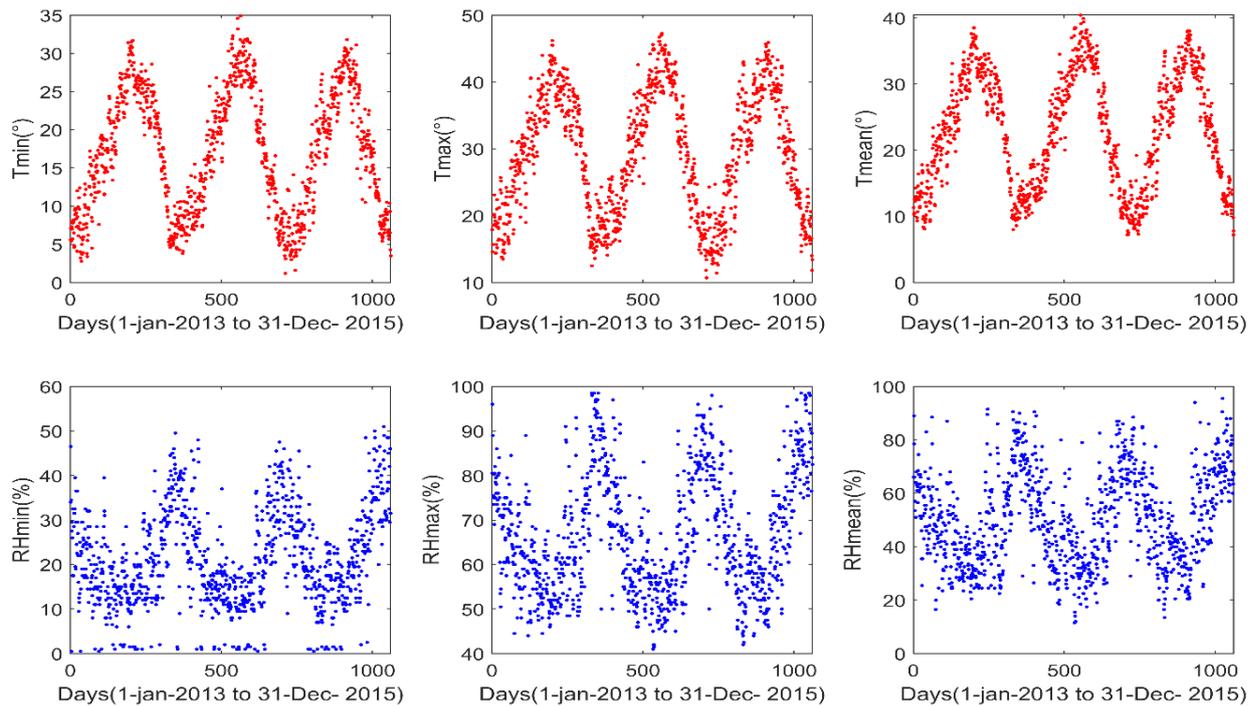


Figure (3- 8): Le cycle climatologique du GSR quotidien pour la ville de Ghardaia variables prédictives pour la période d'étude du 1er janvier 2013 au 31 décembre 2015 (obtenu de URAER).

La figure (3-8), présente les variables utilisées comme entrées (T_{\min} , T_{\max} , T_{moy} , H_0 et le rayonnement solaire hors atmosphère) après le raffinement, la valeur la plus faible du rayonnement solaire est enregistrée au cours du mois de décembre et la valeur la plus élevée est enregistrée au mois de juillet. En termes d'humidité relative, c'est l'opposé du rayonnement solaire, où la valeur la plus élevée est enregistrée au cours du mois de décembre et la valeur la plus basse au mois de juillet.

La précision des modèles est grandement affectée par la qualité des données utilisées. Il est préférable d'effectuer la procédure de nettoyage des données pour améliorer la qualité des données en les filtrant de toute erreur ou doute. Diverses techniques ont été suggérées dans la littérature pour améliorer la qualité des données en filtrant les erreurs. Dans cette étude, la stratégie suivante a été adoptée:

- Afin d'identifier les valeurs de rayonnement solaire quotidiennes inexactes, l'indice de clarté K est défini comme le rayonnement de surface divisé par le rayonnement extraterrestre (équation (1)) et calculé pour chaque jour spécifique, toutes les valeurs de H doivent être inférieures à H_0 , ce qui signifie que K est un nombre sans dimension compris entre 0 et 1.
- (ii) Dans ce travail, les valeurs qui sont en dehors de la plage de $0,015 < K < 1$ ont été supprimées (Yadav and Behera 2014). Un mois est supprimé de l'ensemble de données si les valeurs incorrectes sont > 5 jours dans de ce mois; si le nombre est < 5 , les valeurs sont remplacées par des valeurs correctes basées sur l'interpolation (Deo, Wen et al. 2016). Sur l'ensemble de données de 1500 jours utilisé dans cette étude, nous avons trouvé 12 jours qui étaient en dehors de la plage acceptable.

Les données de température minimale et les données d'humidité minimale, moyenne et maximale sont positivement biaisées avec les facteurs d'asymétrie moyens de 0,02, 0,37, 0,24 et 0,43, respectivement, tandis que les données de température maximale, moyenne et le rayonnement solaire extraterrestre, le rayonnement solaire incident quotidien sont négatifs asymétrique avec des facteurs d'asymétrie moyens de $-0,04$, $-0,02$, $-0,24$ et $-0,15$. Le tableau (3-1) résume les statistiques descriptives de la série chronologique d'entrée pour les quatre ans. Comme prévu, toutes les données peuvent être considérées comme gaussiennes dans leurs comportements distributionnels, statistiquement, deux mesures numériques de forme (asymétrie et excès d'aplatissement (excess kurtosis)) peuvent être utilisées pour tester la normalité. Pour l'aplatissement, la règle générale est que si le nombre est supérieur à +1, la distribution atteint un sommet. Si l'asymétrie n'est pas proche de zéro, alors l'ensemble de données n'a pas de distribution gaussienne (George and Mallery 1999).

Tableau (3-1) : Variable objective et les statistiques d'entrée pour la ville de Ghardaïa.

<i>Variables</i>	T_{\min}	T_{\max}	T_{moy}	RH_{\min}	RH_{\max}	RH_{moy}	H
<i>Min</i>	01.2	10.70	7.20	00.50	41.00	11.50	03.49
<i>Max</i>	34.90	47.30	40.40	51.00	98.50	95.50	30.81
<i>Moy</i>	17.07	29.25	22.91	21.32	91.47	50.10	20.59
<i>Std</i>	07.98	9.13	8.62	10.77	13.45	17.60	06.05
<i>Asymétrie</i>	00.02	-0.04	-0.02	00.37	00.43	00.24	-0.15
<i>Kurtosis</i>	01.79	01.78	01.74	02.62	02.24	02.19	01.88

La corrélation entre H et ses prédicteurs est représentée par la droite de régression qui est incluse dans la figure (3-9), notant que le degré de corrélation entre T_{max} et H est élevé avec la plus grande valeur de la corrélation $r = 0,70$.

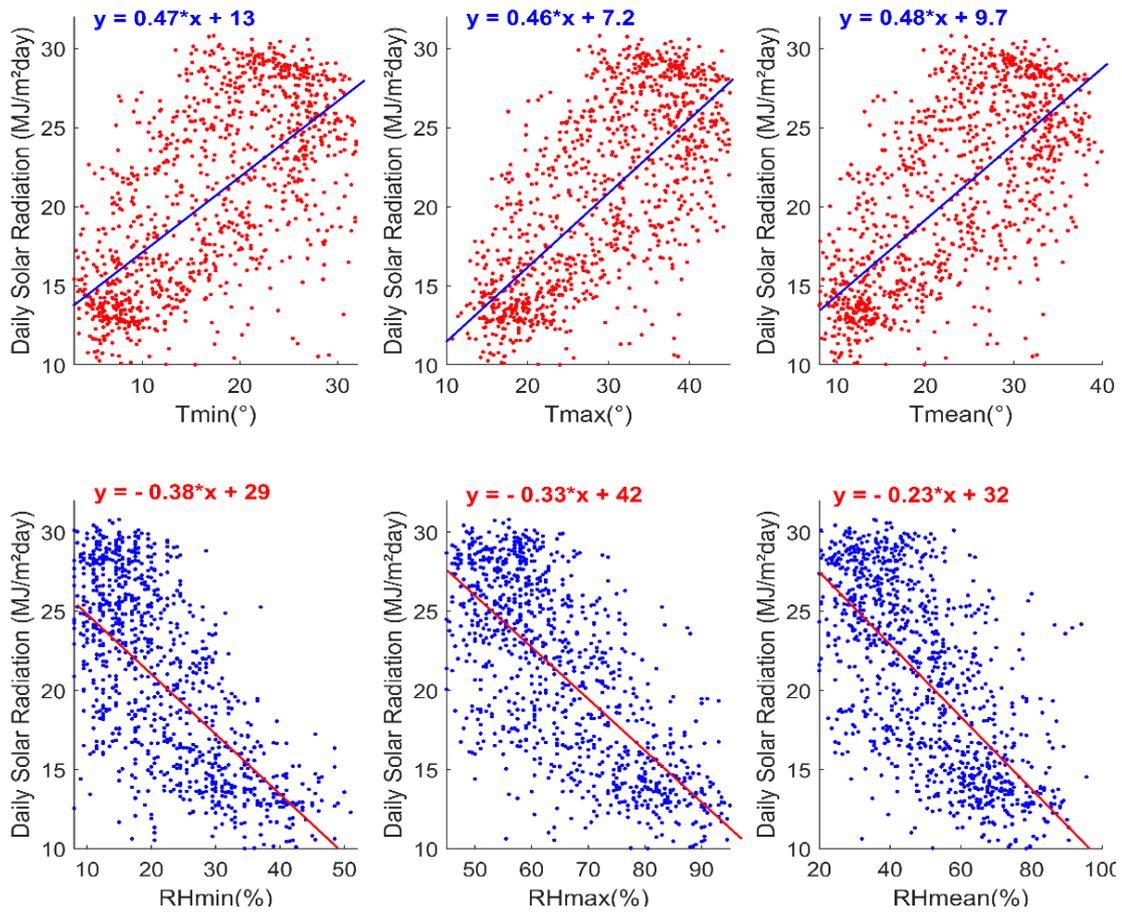


Figure (3- 9): Les statistiques d'entrée pour la ville de Ghardaia.

La figure (3-10) représente l'évolution de l'irradiation solaire globale journalière hors atmosphère pour Ghardaïa ($\varphi=32.23'N$)

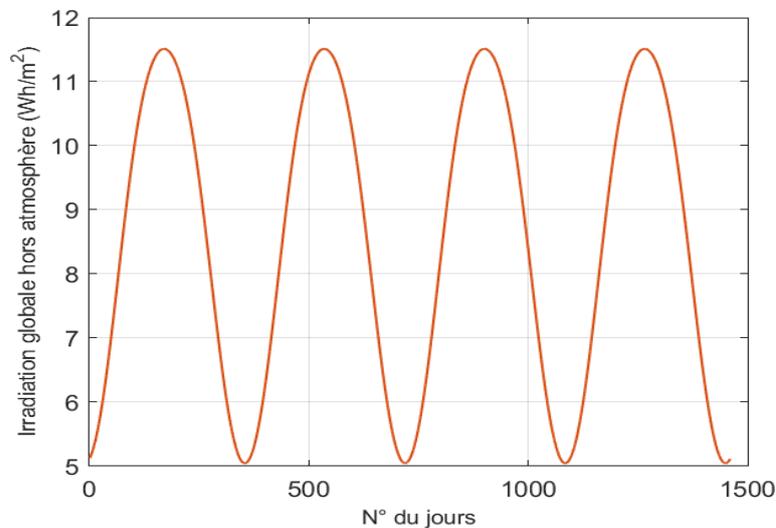


Figure (3- 10) : l'irradiation solaire globale hors atmosphère G_0 au site de Ghardaïa.

3.6 Le choix de l'ondelette mère

Certains travaux utilisent la sous-série entière d'ondelettes [(Nourani, Komasi et al. 2009), (Wang, Yu et al. 2018), (Adamowski and Sun 2010)], tandis que d'autres travaux suppriment la composante détaillée et conservent les sous-séries restantes sous forme de bruit basé sur le coefficient de corrélation [(Rajae, Mirbagheri et al. 2010), (Kisi and Cimen 2011)]. Dans l'approche proposée, nous considérons chaque signal décomposé en ondelettes dans sa forme originale pour capturer leurs attributs aléatoires et leur structure physique; sur cette base, nous insérons la sous-chaîne entière dans le modèle W-GPR.

Le choix de l'ondelette mère est l'un des plus importants facteurs affectant la précision des modèles de prédiction (Rafiee, Tse et al. 2009). Il existe de nombreuses familles d'ondelettes utilisables (famille Daubechies « db », famille Symlets « sym », famille « Haar » et Coiflets « coif », famille Fejer-Korovkin « fk », approximation discrète de la famille Meyer « dmey »). L'application d'un niveau de décomposition plus élevé peut ralentir le processus d'apprentissage, et dans certains cas, réduire la précision des modèles. Dans ce travail, après plusieurs expériences, des ondelettes ont été choisies (db1, db4, db8, sym2, sym4, sym8, coif1, coif3, dmey3). Selon le tableau (3-2), l'ondelette coiflet d'ordre 3 (abrégée coif3) est sélectionnée comme ondelette mère (RMSE = 2,419 MJ / m².jour).

Tableau (3- 2): Effet du type d'ondelette sur la précision du modèle.

	db4	db8	sym2	Sym8	coif1	coif3	coif5	dmey
R²	0.907	0.912	0.910	0.916	0.920	0.921	0.908	0.920
MSE	6.887	6.496	8.548	6.241	5.940	5.852	18.219	5.912
RMSE	2.624	2.548	2.923	2.498	2.437	2.419	4.268	2.431
rRMSE	12.82	12.44	14.27	12.19	11.89	11.81	2.083	11.80

Pour déterminer le niveau de décomposition, nous avons utilisé l'équation (3-3) ;(Wang and Ding 2003) (Seo, Kim et al. 2015).

$$L = \text{Int}[\log N] \quad (3- 3)$$

où :

L est le niveau de décomposition, N est le nombre d'ensembles de données de séries chronologiques. La figure (3-11) montre les signaux de décomposition $DWTs = A3 + D3 + D2 + D1$ des sept variables d'entrée en utilisant des ondelettes de type coif3 avec trois niveaux de

décompositions détaillées et un niveau d'approximation, où le niveau approximatif a la fréquence la plus basse.

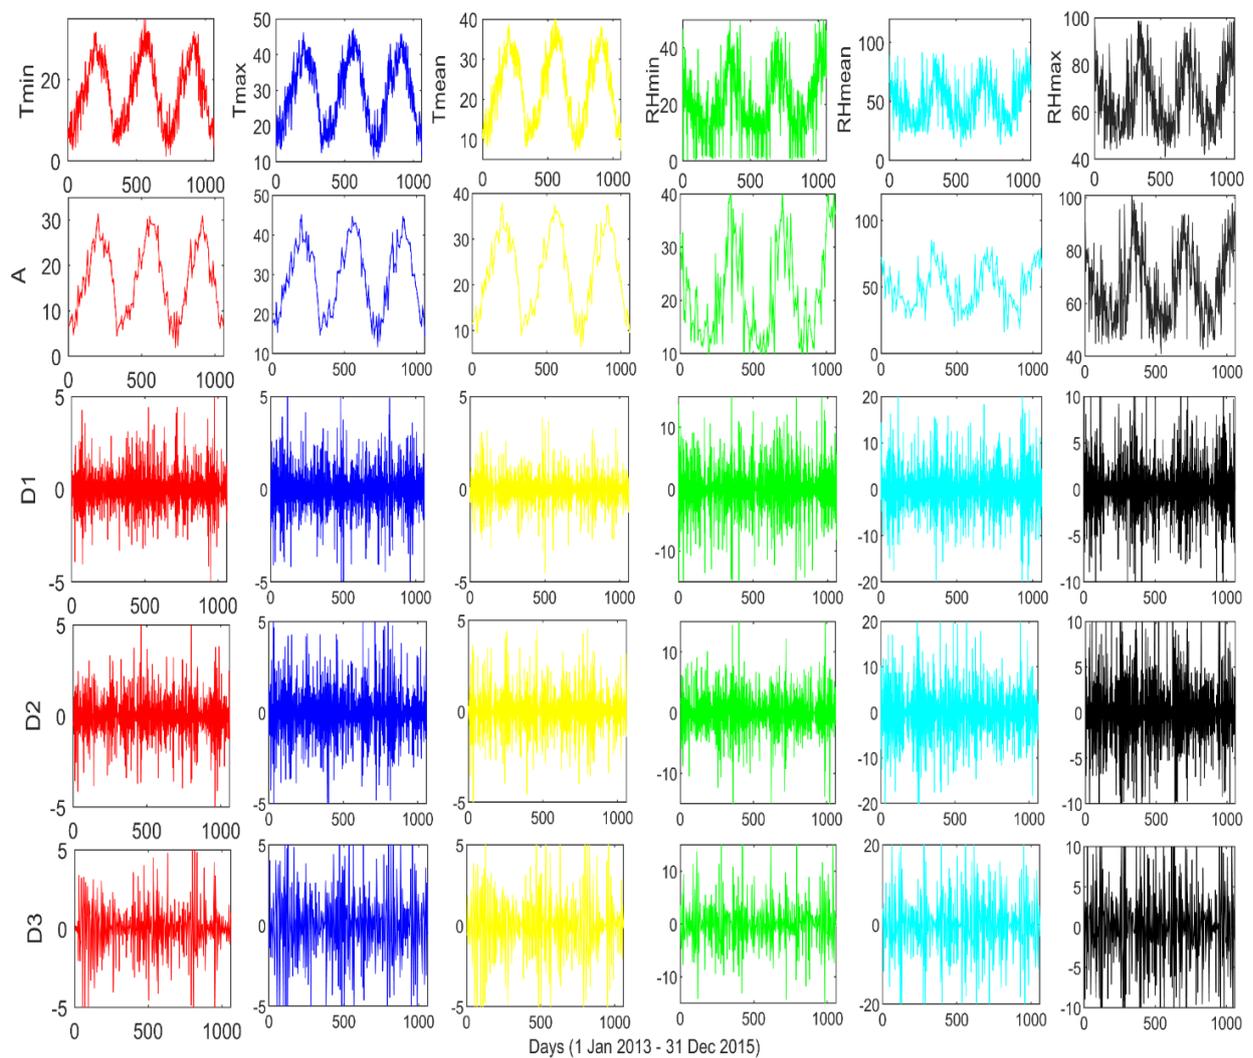


Figure (3- 11): DWT des entrées du modèle $W - GPR$ du.

3.7 Évaluation des performances

Pour évaluer le succès de ce modèle, quatre statistiques différentes des mesures ont été adoptées, fréquemment utilisées dans la littérature. Ces mesures sont le coefficient de détermination (R^2), l'erreur absolue moyenne (MSE), l'erreur absolue moyenne quadratique (RMSE) et l'erreur quadratique moyenne normalisée (rRMSE). Les performances des modèles proposés ($W - GPR$) sont testées sur la base des mesures statistiques suivantes pour N nombre de points de données:

- *Coefficient de détermination (R^2)*

Le coefficient de détermination (R^2 , soit le carré du coefficient de corrélation linéaire r) est un indicateur qui permet de juger de la qualité d'une régression linéaire simple. Il mesure l'adéquation

entre le modèle et les données observées (Ce coefficient varie entre 0 et 1, soit entre un pouvoir de prédiction faible et un pouvoir de prédiction fort).

$$R^2 = \frac{(\sum_{n=1}^N (H_{n,Obs} - \bar{H}_{n,Obs}) (H_{n,Pred} - \bar{H}_{n,Pred}))^2}{\sum_{n=1}^N (H_{n,Obs} - \bar{H}_{n,Obs})^2 \sum_{n=1}^N (H_{n,Pred} - \bar{H}_{n,Pred})^2} \quad (3-4)$$

ou:

$H_{n,obs}, \bar{H}_{n,obs}$ Valeur observées et moyenne des observations respectivement.

$H_{n,pred}, \bar{H}_{n,pred}$: Valeurs prédites et moyenne des prédictions respectivement.

- *Erreur quadratique moyenne (MSE)*

L'erreur quadratique moyenne est une grandeur permettant de comparer des estimateurs entre eux, qu'ils soient biaisés ou sans biais. Elle est définie de la manière suivante :

$$MSE = \frac{1}{N} \sum_{n=1}^{n=N} (H_{n,Pred} - H_{n,Obs})^2 \quad (3-5)$$

- *Racine de l'erreur quadratique moyenne (RMSE)*

Le RMSE représente la différence entre les valeurs prédites estimées par le modèle et les valeurs mesurées. En fait, RMSE identifie la précision du modèle calculée par ([Rabehi, Guermoui et al. 2020](#))

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (H_{n,Obs} - H_{n,Pred})^2}{N}} \quad (3-6)$$

- *erreur quadratique moyenne relative (rRMSE)*

Le rRMSE est calculé en divisant le RMSE par la moyenne des données mesurées comme suit ([Khelifi, Guermoui et al. 2020](#)) :

$$rRMSE = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N (H_{n,Obs} - H_{n,Pred})^2}}{\frac{1}{N} \sum_{n=1}^N (H_{n,Obs})^2} \times 100 \quad (3-7)$$

Selon ([Ertekin and Yaldiz 2000](#)) la performance du modèle en considérant rRMSE est définie comme:

$rRMSE < 10\%$, la performance est **excellente**.

$10\% < rRMSE < 20\%$, la performance est **bonne**.

$20\% < rRMSE < 30\%$, la performance est **correcte**.

$rRMSE > 30\%$, la performance est **médiocre**.

3.8 Conclusion

Dans ce chapitre, nous avons posé les fondements de notre approche de prédiction de séries temporelles avec ondelette- GPR. Nous avons axé notre travail sur trois grands thèmes :

- Comprendre le principe de base des transformées d'ondelette ainsi que l'ondelette en paquets et ses propriétés fondamentales.
- Une description de la base de données utilisée est présentée, et la sélection des variables d'entrée avec une méthode basée sur le coefficient de corrélation entre les entrées choisies et la sortie (rayonnement solaire) ;
- L'utilisation d'une nouvelle grandeur (indice de clarté 'k') pour filtrée la base de données.

Par la suite, une description du réseau de mesure radiométriques algérien a été illustrée. Pour notre étude, le choix s'est focalisé sur le site de Ghardaïa (URAER) à cause de la disponibilité des données. Une caractérisation de ce site de point de vue radiométrique a été présentée.

En outre, les outils statistiques permettant l'évaluation des performances des prédicteurs ont été aussi synthétisés. Nous aborderons dans le prochain chapitre, les résultats des simulations effectuées lors de cette thèse.

Chapitre 4 : **Résultats et Discussions**

4.1. Introduction

Le présent chapitre a pour but d'exposer les résultats obtenus après avoir appliqué ces modèles sur les données collectées. Il est divisé en quatre sections relatives à des conditions expérimentales différentes. Les conclusions les plus objectives possibles sont dressées afin de mettre en lumière les points forts et les points faibles des différents modèles suivant les situations dans lesquelles ils ont été utilisés.

- La première section de ce chapitre concerne le développement des modèles de régression, pour la prévision du rayonnement journalière horizontal. Ces modèles sont validés et comparés.
- Comme nous l'avons vu dans le Chapitre 3 (Partie 3), la prévision est de plus en plus demandée par les gestionnaires de réseaux électriques.
- La troisième section de ce chapitre traitera de la prévision.
- Enfin la quatrième section présentera les travaux et expérimentations menés

4.2. Méthodologie de construction des modèles GPR

Les étapes classiques de prévision sont principalement réalisées en deux phases: une phase d'apprentissage et une phase de validation (Figure 4-1).

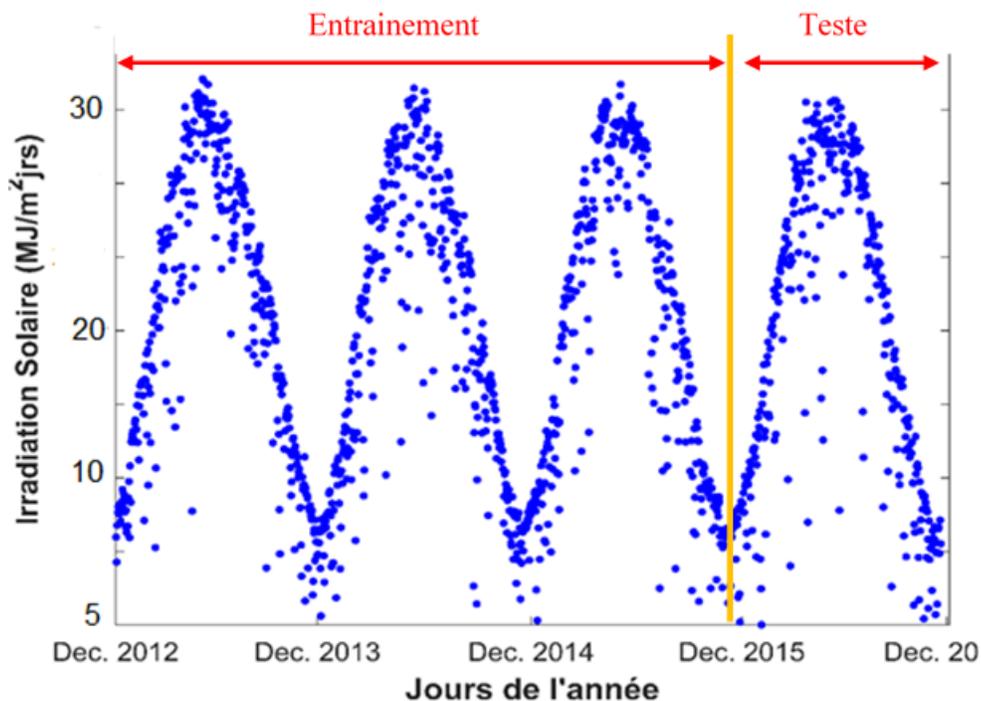


Figure (4- 1) : l'évolution du rayonnement global journalière (Ghardaïa)

L'estimateur reçoit en entrée les données d'apprentissage utilisées pour générer un modèle. Par la suite, il reçoit des données de test qui serviront à prédire de nouvelles valeurs sur la base du modèle généré précédemment. Une fois le processus terminé, les données de test et les résultats de prévision sont comparés afin d'estimer le taux d'erreur. Trois ans de données (2013 et 2015) ont été choisis pour la phase d'apprentissage, et une année (2016) a été utilisée pour la phase de test.

En fait, nous avons travaillé sur les données de quatre ans (2013 et 2016) pour l'établissement des modèles. Figure 4-1 montre l'évolution du rayonnement global journalier pour le site d'étude. On peut noter que le comportement du rayonnement global ressemble à celui des signaux périodiques bruité. Le bruit résultant de la couverture nuageuse, est plus important durant les mois d'hiver. On peut le constater, l'irradiation solaire mesurées est comprise entre 10 MJ/m²j et 30 MJ/m²j.

Normalisation standard des données (normalisation z-score)

La normalisation z-score les rapprocherait toutes de la distribution normale standard. La distribution résultante a une moyenne de 0 et un écart-type de 1. En utilisant la formule suivante (N est le nombre d'observation) :

$$X_{normalisé} = \frac{X - \mu(x_i)_{i=1...N}}{\varepsilon(x_i)_{i=1...N}} \quad \mu = moy(x_i), \quad \varepsilon = std(x_i)$$

Figure (4-2) montre l'évolution du rayonnement global journalière pour notre site (Ghardaïa). On peut noter que le comportement du rayonnement global ressemble à celui des signaux périodiques bruité

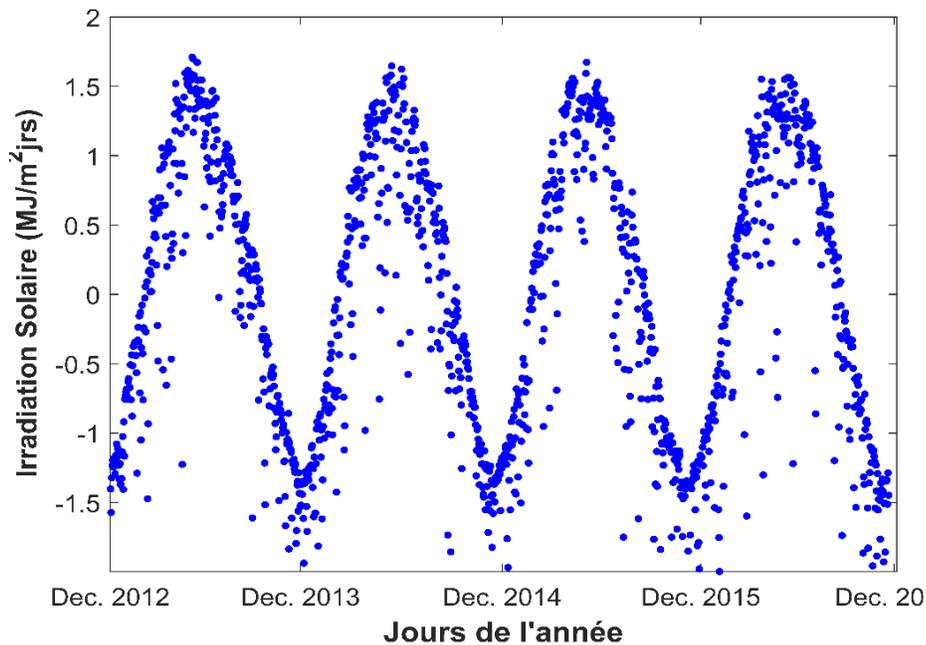


Figure (4- 2) : l'évolution du rayonnement global journalière normalisé (Ghardaïa).

4.3. Régression du rayonnement global journalier

Dans cette section, les données météorologiques sont utilisées pour prédire le rayonnement solaire quotidien pour le même jour, le rayonnement solaire extraterrestre H_0 a été utilisé comme variable prédictive principale, puis les combinaisons d'entrée ont été divisées en trois groupes. Le premier groupe dépend de la température de l'air comme deuxième variable prédictive.

$$W - GPR1 : \begin{cases} M_1 = [H_0, T_{max}] \\ M_2 = [H_0, T_{max}, T_{min}] \\ M_3 = [H_0, T_{max}, T_{min}, T_{moy}] \end{cases}$$

Le deuxième groupe dépend de l'humidité relative comme deuxième variable prédictive.

$$W - GPR2 : \begin{cases} M_4 = [H_0, RH_{moy}] \\ M_5 = [H_0, RH_{moy}, RH_{min}] \\ M_6 = [H_0, RH_{moy}, RH_{min}, RH_{max}] \end{cases}$$

La troisième comporte toutes les variables prédictives:

$$W - GPR3 : \begin{cases} M_7 = [H_0, T_{max}, RH_{moy}, T_{min}, RH_{min}] \\ M_8 = [H_0, T_{max}, RH_{moy}, T_{min}, RH_{min}, T_{moy}] \\ M_9 = [H_0, T_{max}, RH_{moy}, T_{min}, RH_{min}, RH_{max}] \\ M_{10} = [Toutes les variables] \end{cases}$$

Le Tableau (4- 1) résume les résultats des performances des 10 modèles développés pour le cas de régression, un examen attentif du tableau 4-1 montre que la meilleure performance qui peut être obtenue pour le premier groupe (W-GPR1) est celle avec comme entrées le T_{max} et T_{min} (M_2). Avec cette combinaison, on a pu obtenir un $R^2 = 0,95$ et un $rRMSE = 11,76 \%$, alors que si on inclut toutes les variables liées à la température, on obtient un $R^2 = 0,95$ et un $rRMSE = 12,10 \%$ (M_3).

Pour le deuxième groupe (W-GPR2) les performances sont meilleures en utilisant M_4 avec un $R^2 = 0,94$ et un $rRMSE = 12,59\%$ par rapport à l'inclusion de toutes les variables de l'humidité relative, qui ont donné un $R^2 = 0,94$, $rRMSE = 12,80\%$ (M_5).

Enfin, dans le W-GPR3 où on a combiné les variables de la température et de l'humidité relative, les meilleures performances qu'on a pu obtenir sont celle du modèle M_9 avec un $R^2 = 0,96$ et un $rRMSE = 11,21 \%$.

Tableau (4- 1): Effet de la décomposition sur la précision des modèles régressives

Combinaisons d'entrées		W-GPR					GPR				
		R ²	MAE	MSE	RMSE	rRMSE	R ²	MAE	MSE	RMSE	rRMSE
W-GPR1	M ₁ [H ₀ , T _{max}]	0.94	1.24	7.16	2.18	12.40	0.94	1.4	7.91	2.4	13.69
	M ₂ [H ₀ , T _{max} , T _{min}]	0.95	1.06	5.81	1.93	11.76	0.94	1.29	7.00	2.23	12.87
	M ₃ [H ₀ , T _{max} , T _{min} , T _{mean}]	0.95	1.11	6.17	2.00	12.10	0.94	1.31	7.22	2.27	13.06
W-GPR2	M ₄ [H ₀ , RH _{mean}]	0.94	1.20	6.50	2.10	12.59	0.94	1.34	7.13	2.26	12.99
	M ₅ [H ₀ , RH _{mean} ,RH _{min}]	0.94	1.20	6.93	2.14	12.80	0.94	1.35	7.07	2.25	12.93
	M ₆ [H ₀ , RH _{mean} ,RH _{min} , RH _{max}]	0.94	1.19	6.58	2.11	12.66	0.94	1.3	6.79	2.2	12.68
W-GPR3	M ₇ [H ₀ , T _{max} ,RH _{mean} , T _{min} , RH _{min}]	0.95	1.07	5.51	1.91	11.67	0.95	1.25	6.80	2.2	12.69
	M ₈ [H ₀ , T _{max} ,RH _{mean} , T _{min} , RH _{min} , T _{mean}]	0.95	1.09	5.89	1.94	11.84	0.95	1.26	6.84	2.21	12.73
	M ₉ [H ₀ , T _{max} ,RH _{mean} , T _{min} , RH _{min} , RH _{max}]	0.96	1.02	5.25	1.81	11.26	0.95	1.22	6.38	2.12	12.31
	M ₁₀ [Toutes les variables]	0.96	1.04	5.38	1.84	11.34	0.95	1.24	6.61	2.16	12.52

Le nuage de points de la valeur prédite $H_{n,pred}$ et de la $H_{n,obs}$ mesurée est illustré à la figure (4-3), le modèle M_9 est considéré comme la combinaison optimale ($rRMSE = 11.26\%$).

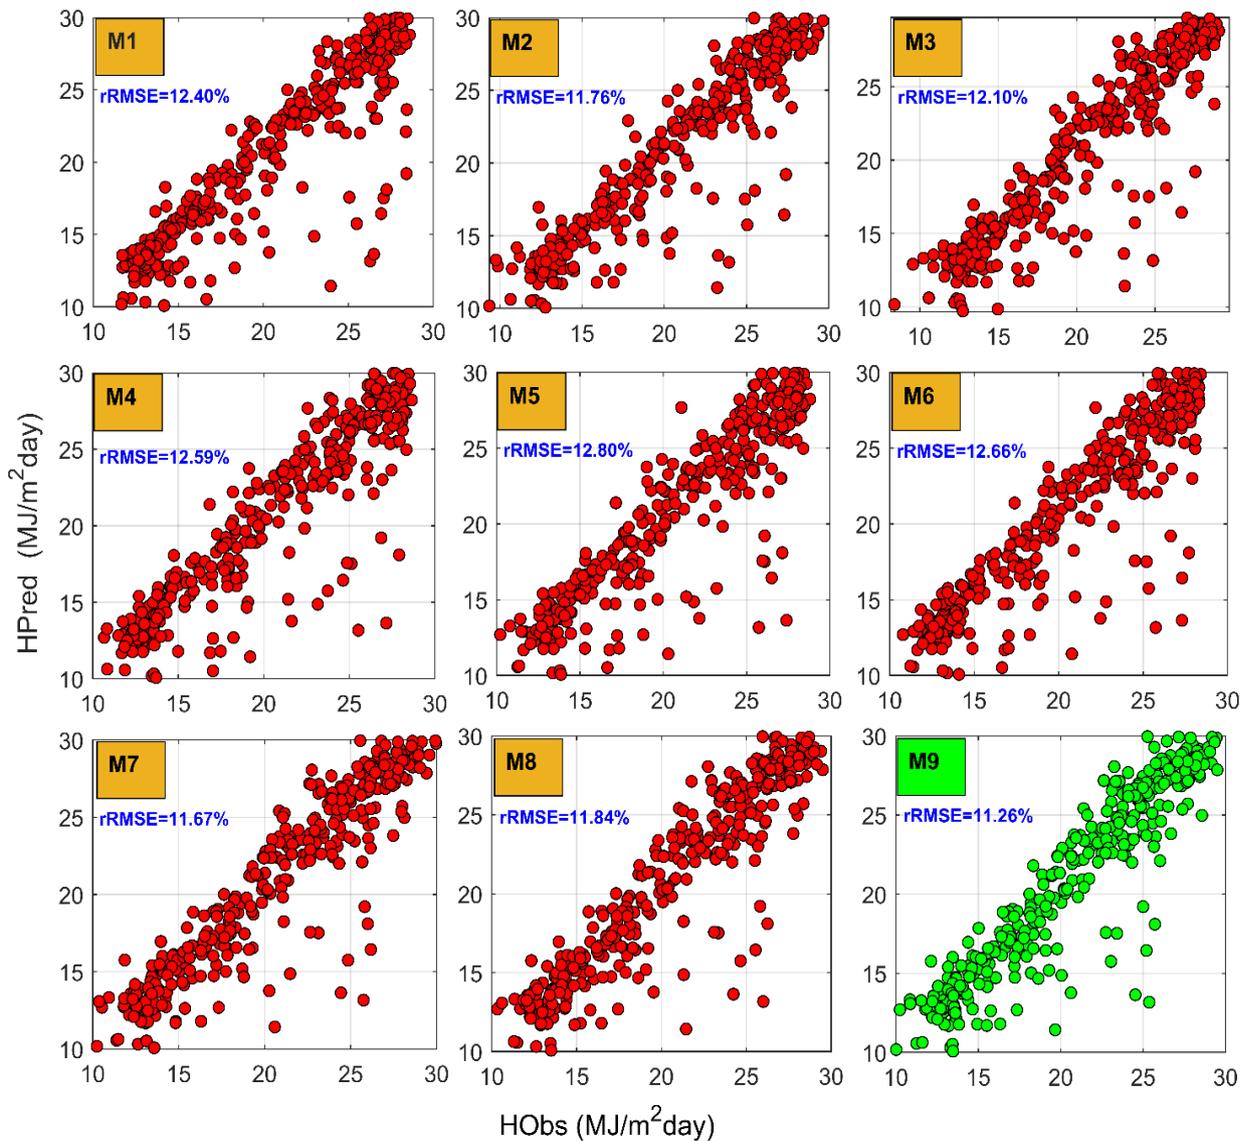


Figure (4- 3) : Nuages de points de la valeur de régression de l'énergie solaire rayonnement par rapport à la mesure, avec en entrée les différentes combinaisons pour le modèle W-GPR.

Les performances atteintes avec l'utilisation de la combinaison des variables d'entrée (W-GPR3) avec le modèle hybride ondelette-GPR montre la fiabilité de ce dernier avec un coefficient de corrélation de 0,96, alors qu'il est égale à 0,95 pour le modèle sans la transformation ondelette (GPR3). C'est le même constat que si on compare avec le rRMSE qui est égale à 11,21 % pour le modèle hybrid et 12,52 % pour le modèle classique. La Figure (4- 4): représente la variation de l'erreur de prévision (P_e) au cours de l'année. Elle montre que le modèle GPR sur-estime le H par rapport au modèle W-GPR (K. Ferkous et al 2021).

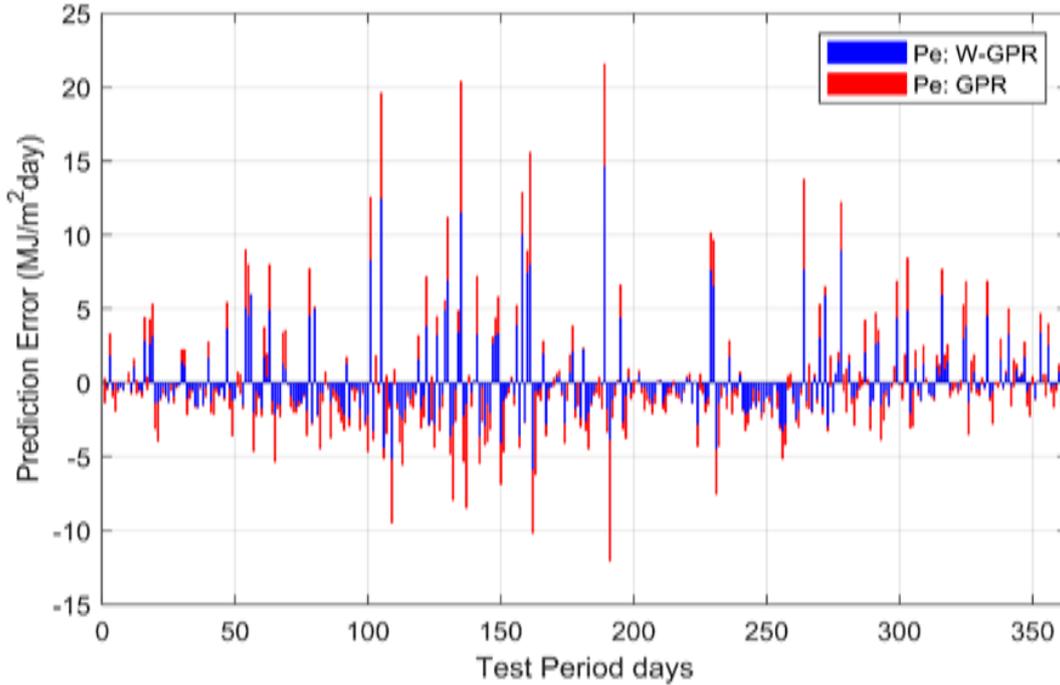


Figure (4- 4) : L'erreur de prédiction dans la période de test.

Une comparaison des valeurs du rayonnement solaire global journalier prédite par le modèle hybride W-GPR et ses valeurs mesurées, est menée. Les résultats sont reportés en Figure (4-4) et Figure (4-5). De ces figures, on peut le voir que le modèle M_9 a montré son efficacité pour la prédiction du rayonnement global et ses sorties sont en accord avec les valeurs observées, à l'exception de quelques jours où les conditions de ciel réduisent considérablement l'énergie du rayonnement solaire.

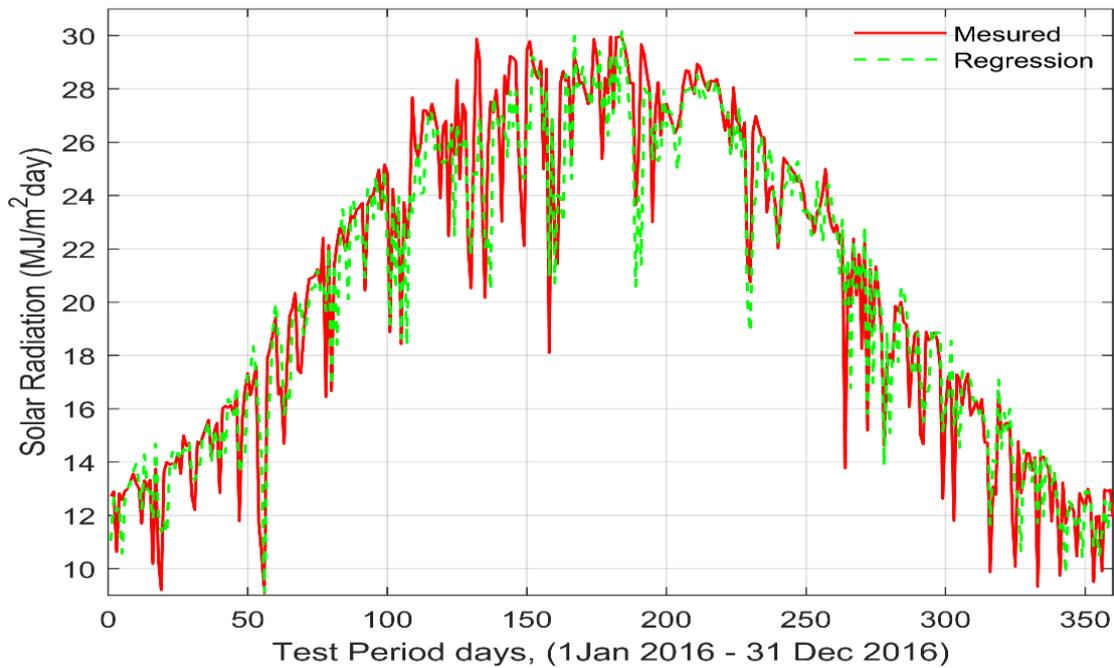


Figure (4- 5): Rayonnement global mesuré par rapport au meilleur estimé W-GPR modèle M_9 .

Les résultats ont montré l'effet significatif de la combinaison utilisée sur la précision des modèles W-GPR, où la combinaison H_0 , T_{\min} , T_{\max} , RH_{\min} , RH_{\max} , RH_{mean} offre une grande précision par rapport aux autres modèles W-GPR proposés. Pour démontrer la précision du modèle W-GPR, ses prédictions sont comparées au modèle classique (GPR). Les résultats ont montré une amélioration significative des performances du modèle W-GPR apparaissant dans les indices statistiques $R^2 = 0,960$, $MAE=1,02 \text{ MJ/m}^2\text{jour}$, $MSE=5,25 \text{ MJ/m}^2\text{jour}$, $RMSE= 1,81 \text{ MJ/m}^2\text{jour}$, $rRMSE= 11,26\%$.

4.4. Prédiction du rayonnement global journalier

4.4.1. Utilisation de variables exogènes

Dans cette section, les données météorologiques sont utilisées pour prédire le rayonnement solaire quotidien pour le jour suivant. Le rayonnement solaire extraterrestre H_0 a été utilisé comme variable prédictive principale, puis les combinaisons d'entrée sont les même que celles présentés dans la section précédente.

Le Tableau (4- 2) résume les résultats des performances des 9 modèles développés pour le cas exogène.

Tableau (4- 2) : Effet de la décomposition sur la précision des modèles prédictives exogènes.

	<i>G1</i>			<i>G2</i>			<i>G3</i>		
	M_1	M_2	M_3	M_4	M_5	M_6	M_7	M_8	M_9
	GPR								
R²	88.4	90	89.5	89.7	89.7	90.1	91.4	91.2	90.6
MSE	8.413	7.500	7.725	7.635	7.576	7.293	7.304	7.345	6.887
RMSE	2.900	2.739	2.779	2.763	2.752	2.701	2.703	2.710	2.624
rRMSE	14.19	13.37	13.56	13.49	13.43	13.18	13.19	13.23	12.81
	W-GPR								
R²	91.35	90.83	90.19	89.77	89.98	91.46	91.52	92.32	92.2
MSE	7.76	6.41	6.77	7.30	7.53	7.38	6.31	6.49	5.85
RMSE	2.78	2.53	2.60	2.70	2.74	2.71	2.513	2.548	2.41
rRMSE	13.60	12.36	12.70	13.19	13.40	13.26	12.27	12.44	11.81
	(WP-GPR)								
R²	90,61	91.22	91.14	90.57	90.75	92.28	92.30	92.38	92.39
MSE	6.77	6.25	6.26	6.81	6.68	5.71	5.69	5.63	5.62
RMSE	2.60	2.50	2.50	2.61	2.58	2.39	2.38	2.37	2.36
rRMSE	12.67	12.21	12.23	12.69	12.59	11.66	11.63	11.59	11.58

La valeur idéale du coefficient de détermination (R^2) est égale à un, ce qui signifie une correspondance parfaite entre les valeurs prédites et mesurées. Le nuage de points de la valeur prédite $H_{n,pred}$ et de la $H_{n,obs}$ mesurée est illustré à la figure (4-6), le modèle considéré comme la combinaison optimale ($R^2 = 0,92$).

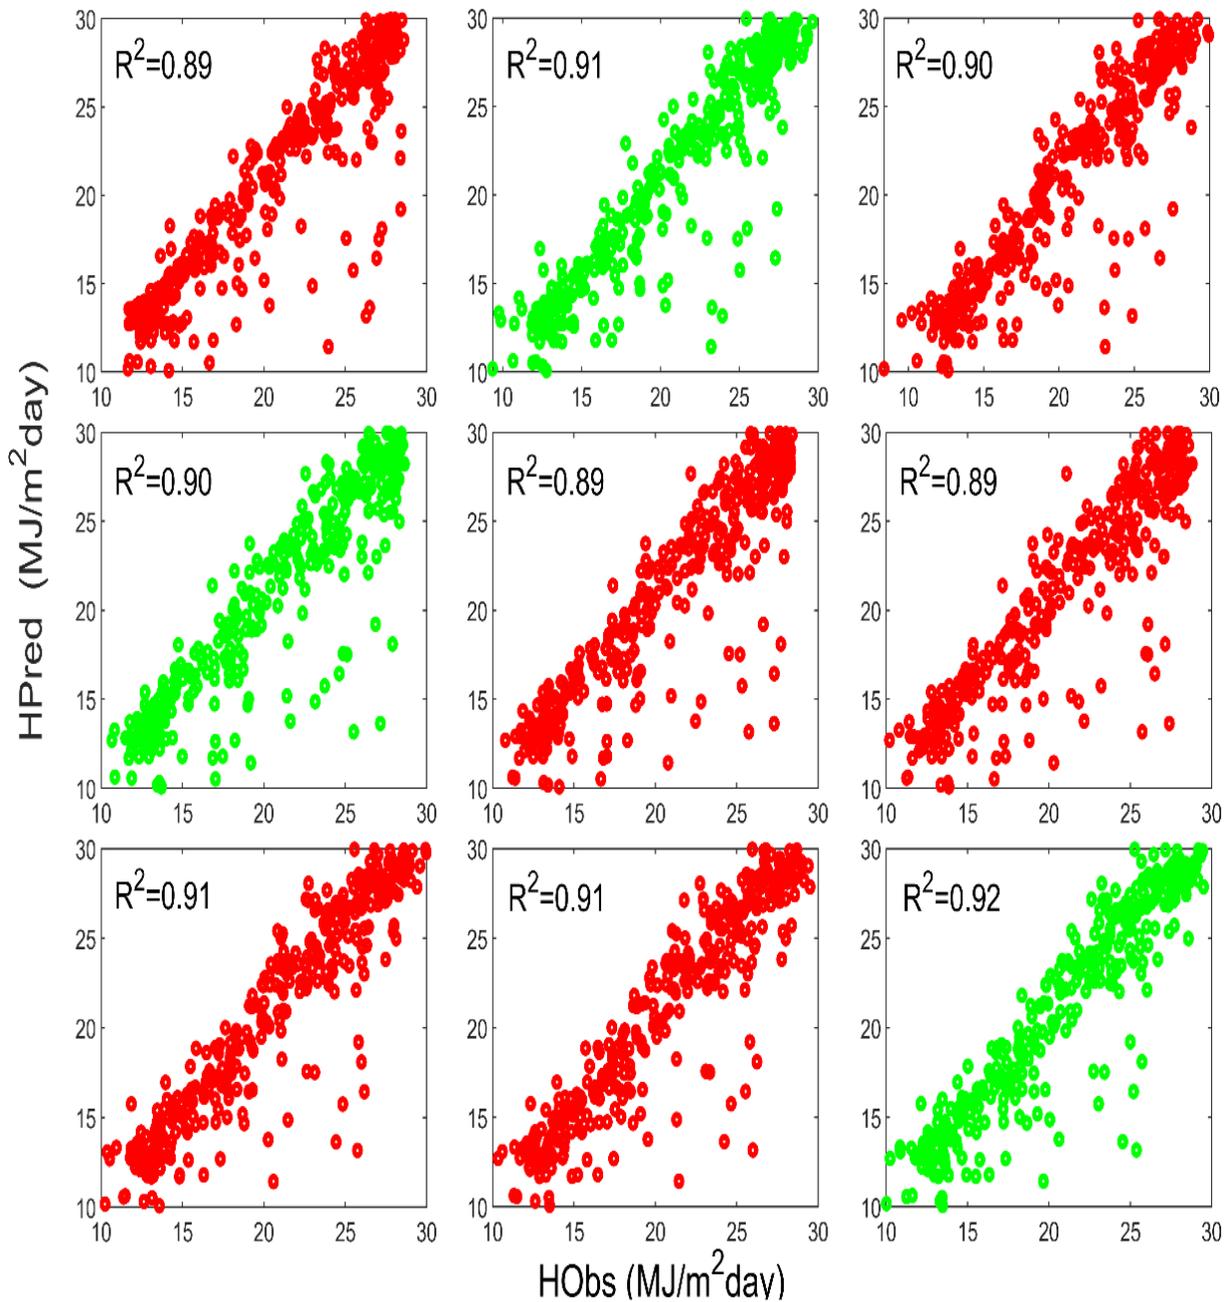


Figure (4- 6): dispersion de la valeur prévue du rayonnement solaire par rapport à la valeur mesurée, avec différentes combinaisons d'entrées à l'aide du modèle W-GPR.

De la figure (4-7), on peut le voir que le modèle M_9 a montré son efficacité pour la prédiction du rayonnement global et ses sorties sont en accord avec les valeurs observées, à

l'exception de quelques jours où les conditions de ciel réduisent considérablement l'énergie du rayonnement solaire

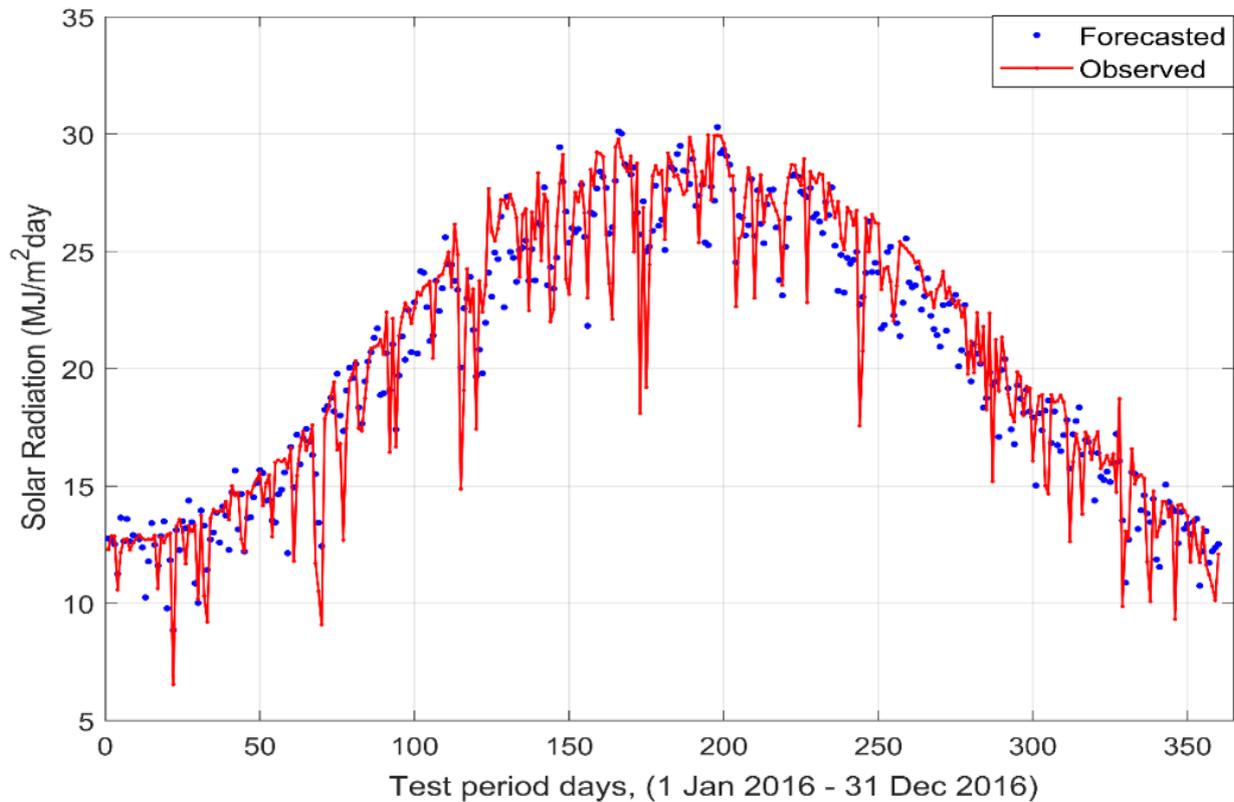


Figure (4- 7): Rayonnement global mesuré par rapport au meilleur estimé W-GPR modèle M_9 .

Afin de comparer les résultats de notre étude, certains modèles bien établis, notamment le modèle SVM est testés de la même manière. À partir du tableau (4-3), l'excellente prévisibilité du modèle W-GPR est démontrée par sa supériorité sur les modèle W-SVM (rRMSE = 11,81%).

Tableau (4- 3) : Comparaison des performances globales des modèles

Modèle	R^2	RMSE (MJ/m ² Day)	rRMSE (%)
SVM	0.831	4.510	15.30
GPR	0,906	2.624	12.81
W – SVM	0.898	2.883	13.47
W – GPR	0,923	2.36	11.81

4.4.2. Utilisation de variables endogènes

Nous avons vu dans le paragraphe précédent que les prédictions de rayonnement global réalisées en utilisant, en entrée du W-GPR, des données de nature exogènes à la nature de la sortie, ne permettent pas d'obtenir de bons résultats. Dans cette section, on va tester l'utilisation d'entrées de natures identiques et voir les performances qu'on peut atteindre. Nous avons proposé l'utilisation de modèles uni variés qui utilisent (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5} , H_{t-6} , H_{t-7} , H_{t-8} , H_{t-9}). Le Tableau (4- 4) résume les résultats des performances des modèles développés pour le cas uni-varié.

m1= W-GPR (H_{t-1})

m2= W-GPR (H_{t-1} , H_{t-2})

m3= W-GPR (H_{t-1} , H_{t-2} , H_{t-3})

m4= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4})

m5= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5})

m6= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5} , H_{t-6})

m7= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5} , H_{t-6} , H_{t-7})

m8= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5} , H_{t-6} , H_{t-7} , H_{t-8})

m9= W-GPR (H_{t-1} , H_{t-2} , H_{t-3} , H_{t-4} , H_{t-5} , H_{t-6} , H_{t-7} , H_{t-8} , H_{t-9})

Tableau (4- 4) : Effet de la nature de décomposition sur la précision des modèles prédictives uni varié.

		GPR								
		m1	m2	m3	m4	m5	m6	m7	m8	m9
R²	94.35	94.24	93.70	93.55	93.98	93.67	93.71	93.60	93.36	
MSE	3.87	3.94	4.29	4.37	4.06	4.28	4.24	4.33	4.48	
RMSE	1.96	1.98	2.07	2.09	2.01	2.06	2.06	2.08	1.11	
rRMSE	9.53	9.60	10.04	10.12	9.70	9.97	9.93	10.04	10.22	
		W-GPR								
R²	96.27	98.62	98.90	98.99	99.00	98.98	98.93	98.88	98.87	
MSE	2.58	0.96	0.77	0.71	0.70	0.71	0.75	0.78	0.79	
RMSE	1.60	0.98	0.88	0.84	0.83	0.85	0.86	0.88	0.89	
rRMSE	7.78	4.72	4.24	4.05	4.02	4.05	4.15	4.16	4.24	
		WP-GPR								
R²	96.81	99.49	99.47	99.54	99.51	99.48	99.50	99.44	99.37	
MSE	2.21	0.37	0.38	0.34	0.36	0.39	0.37	0.41	0.46	
RMSE	1.49	0.61	0.62	0.58	0.60	0.62	0.61	0.64	0.68	
rRMSE	7.19	2.93	2.99	2.83	2.90	2.99	2.94	3.08	3.27	

Le modèle WP-GPR avec m_4 est considéré comme la combinaison optimale, peut voir que la dispersion entre les valeurs mesurées et estimées est faible pour GPR (94,35%), alors que la dispersion est forte dans le cas WP-GPR (99,54%), Les résultats sont représentés par les diagrammes de dispersion (scatter-diagrams) reportés en Figure (4-8).

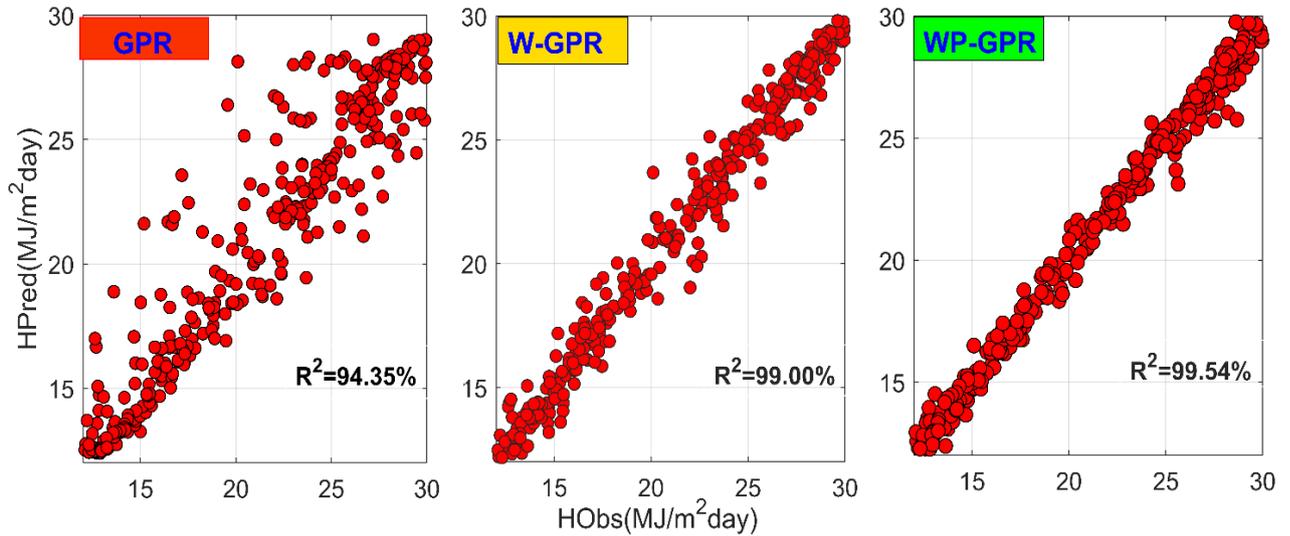


Figure (4- 8): dispersion de H mesuré et estimé avec un modèle uni-varié pour les meilleurs modèles.

D'après le tableau 4-4 et la figure (4-9), la comparaison entre le modèle classique et le modèle WP-GPR montre que l'utilisation de la transformée en ondelettes paquet augmente la précision du modèle dans les prévisions.

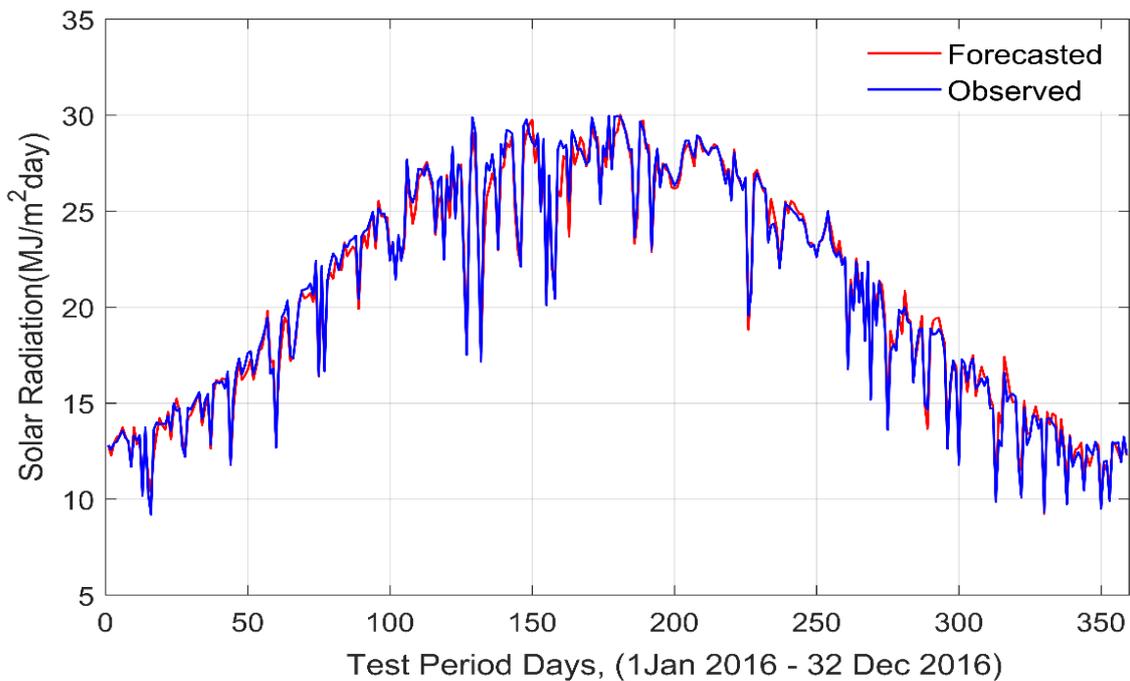


Figure (4- 9): Valeurs mesurées par rapport aux valeurs estimées pour WP-GPR.

4.5. Prédiction multi-horizon

Dans cette section nous avons tester différentes mères ondelettes sur trois horizons différents. Les diagrammes de dispersion des valeurs GSR prévues par rapport aux valeurs observées lors de la période de validation sont présentés sur la figure (4-10).

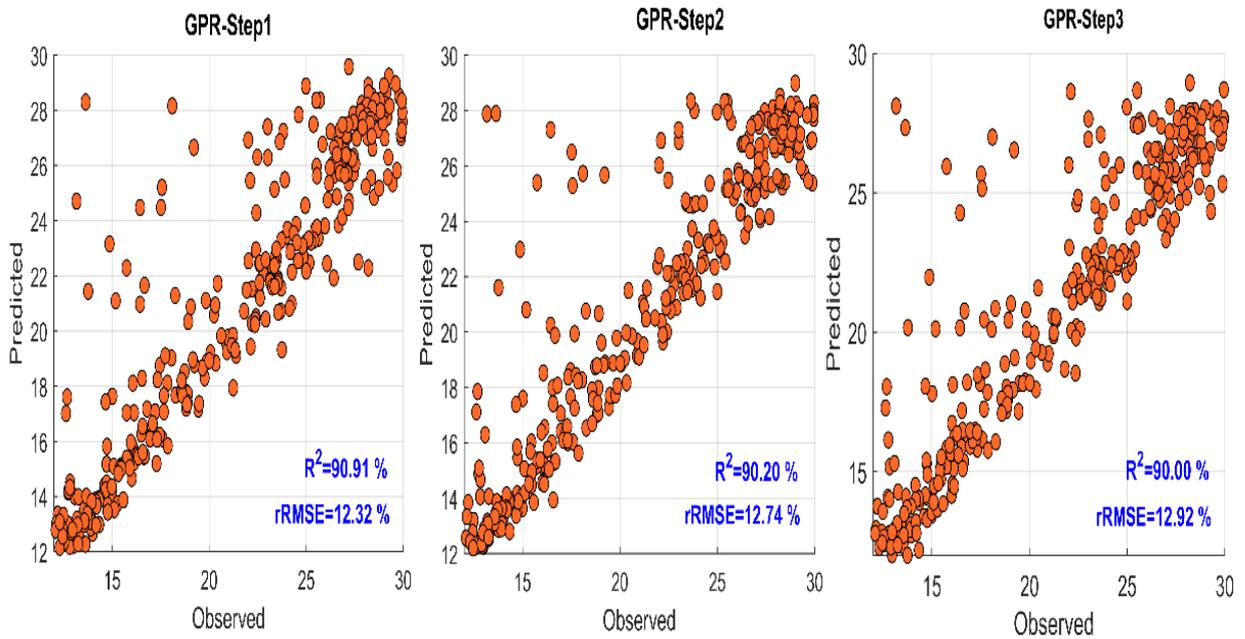


Figure (4- 10) : dispersion de H mesuré et estimé avec un modèle GPR pour les multi-horizon

Pour le modèle GPR, d’après la Figure (4-11) ont constaté une augmentation de 0.6 % en terme de rRMSE entre le premier et le dernier pas.

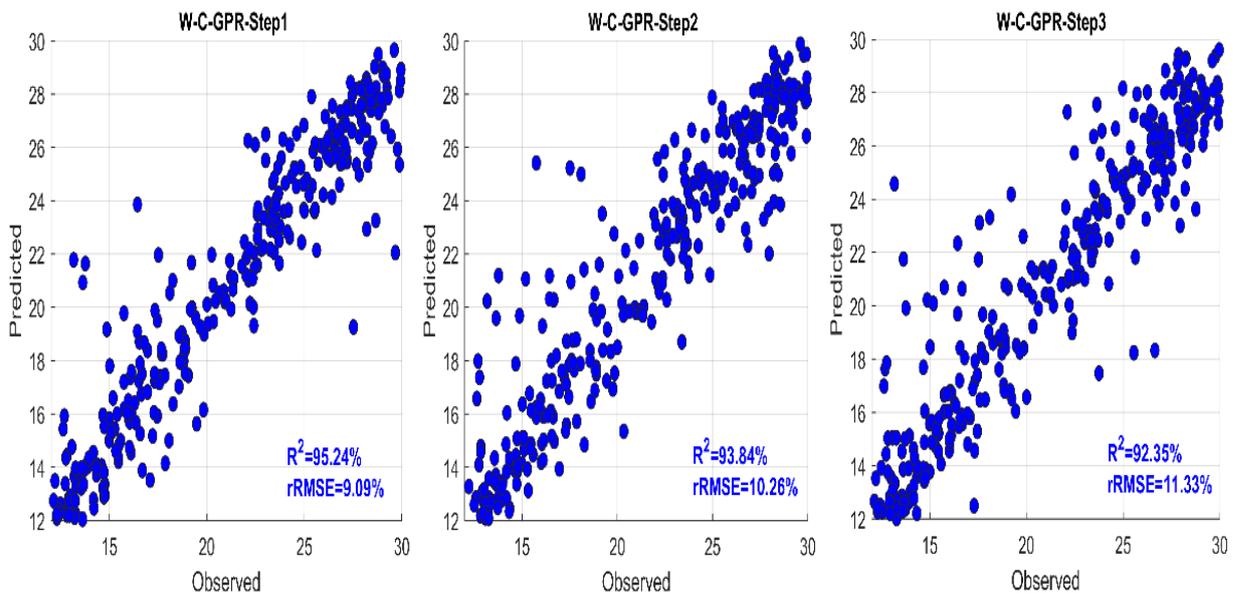


Figure (4- 11) : dispersion de H mesuré et estimé avec un modèle W-C-GPR pour les multi-horizon

Pour le modèle ondelette (coiflet ondelette mère)-GPR, d'après la Figure (4-12) ont constaté une augmentation de 2.24 % en terme de rRMSE entre le premier et le dernier pas.

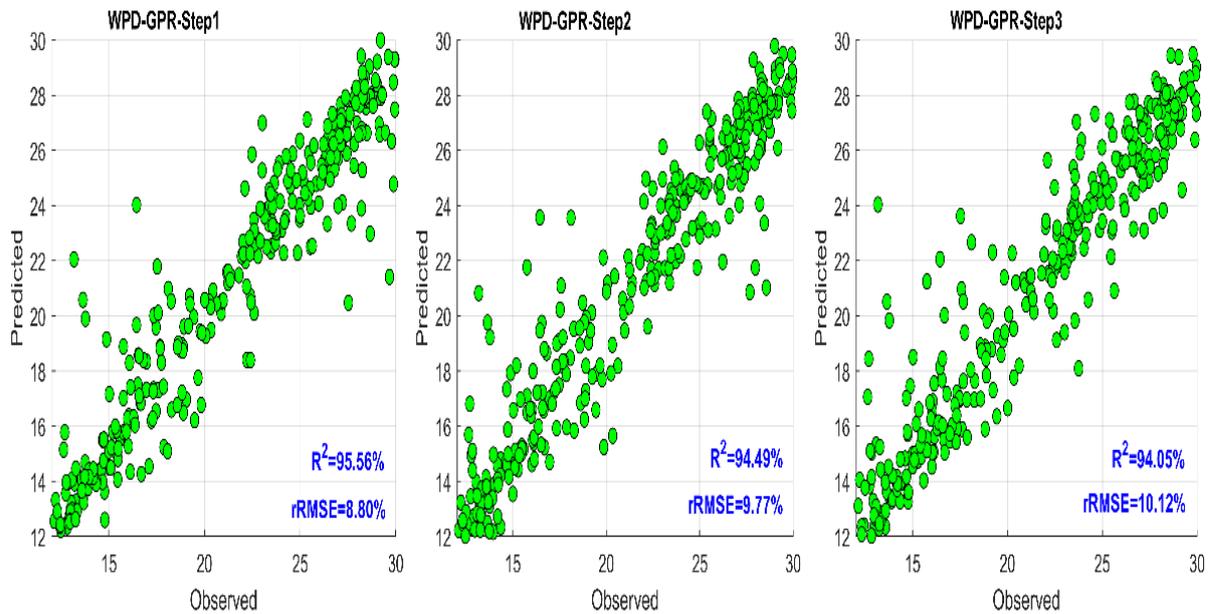


Figure (4- 12): dispersion de H mesuré et estimé avec un modèle WP-GPR pour les multi-horizon.

D'après les résultats des différents types d'ondelettes mères nous avons constaté que le modèle WPD-GPR permet d'obtenir la plus haute précision en termes de R²=95,56 % et de rRMSE=8,80 % par rapport au WC-GPR (R² =95,24 % et rRMSE =9,09 %) et W-GPR (R²=90,91 % et rRMSE=12,32 %) en 1^{er} pas. Pour les 2^{ème} et 3^{ème} pas, c'est avec le même modèle qu'on obtient les meilleures performances avec un R²=94,49 % et rRMSE=9,77 % par rapport au WC-GPR (R² =93,84 % et rRMSE =10,26 %) et W-GPR (R²=90,20 % et rRMSE=12,74 %) en 2^{ème} pas, et un R²=94,05 % et rRMSE=10,12 % par rapport au WC-GPR (R² =92,35 % et rRMSE =11,33 %) et W-GPR (R²=90,00 % et rRMSE=12,92 %) en 3^{ème} pas.

Tableau (4- 5) : Effet de la décomposition sur la précision des modèles prédictives multi- horizon.

Indexes	1-step	2-step	3-step	1-step	2-step	3-step	1-step	2-step	3-step
	<i>GPR</i>			<i>WPD-GPR</i>			<i>W-GPR</i>		
R²	90.91	90.20	90.00	95.56	94.49	94.05	95.24	93.84	92.35
MSE	6.40	6.86	7.00	3.23	3.99	4.30	3.45	4.42	5.40
RMSE	2.53	2.61	2.64	1.80	1.99	2.07	1.85	2.10	2.32
rRMSE	12.32	12.74	12.92	8.80	9.77	10.12	9.09	10.26	11.33

Le Tableau (4- 5) résume les résultats des performances des modèles développés pour chaque étape. La figure (4-13) élabore une vue de prévision en termes de distribution de l'erreur de prédiction (P_e) dans les modèles hybride proposés. La plus grande plage d'erreur P_e obtenue par le modèle WP-GPR dans la prédiction du GSR est présente aux valeurs les plus bass

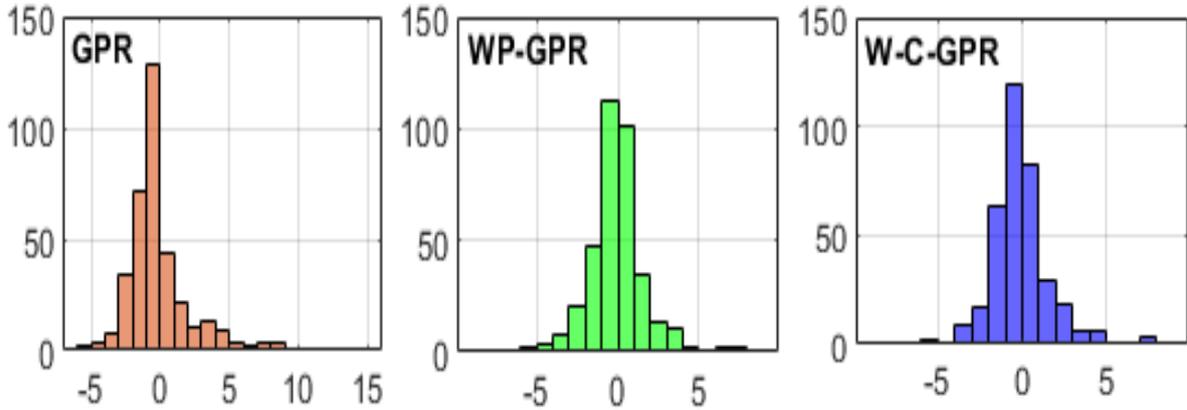


Figure (4- 13) : distribution de fréquence de l'erreur de prédiction (P_e)

Une comparaison des valeurs du rayonnement solaire global journalier prédite par les modèle hybride et ses valeurs mesurées, est menée. Les résultats sont reportés dans les Figures 4- (14,15,16).

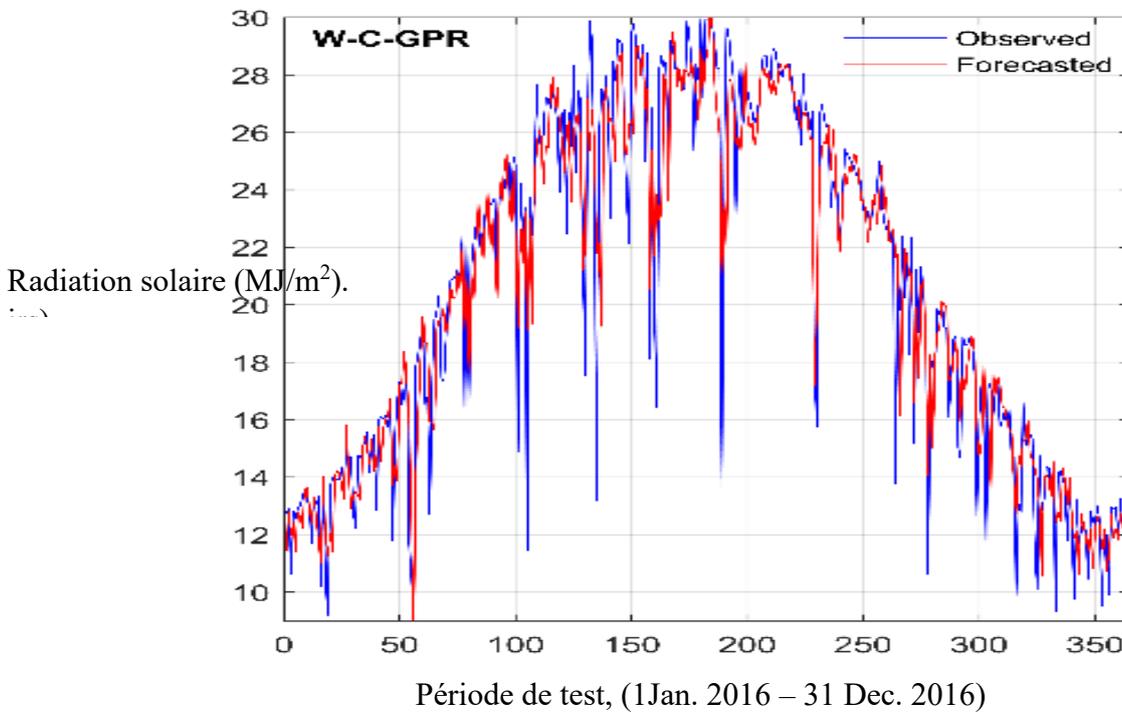


Figure (4- 14): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour multi ondelette mère.

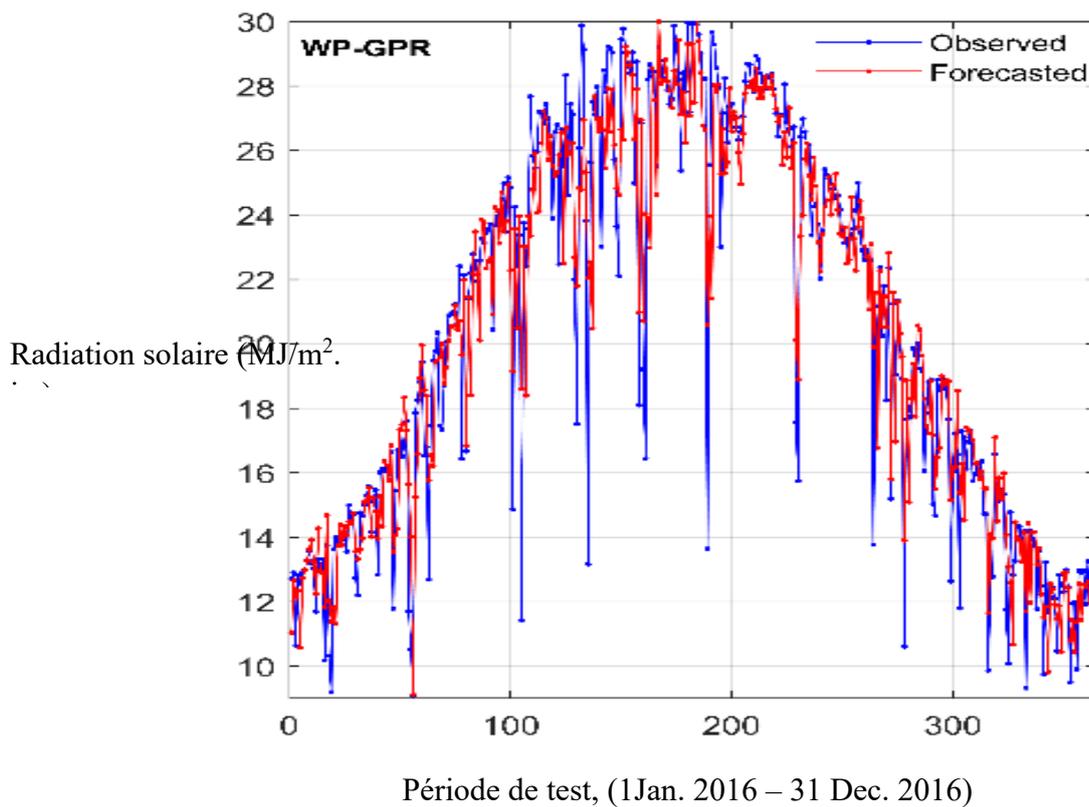


Figure (4- 15): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour paquet ondelette.

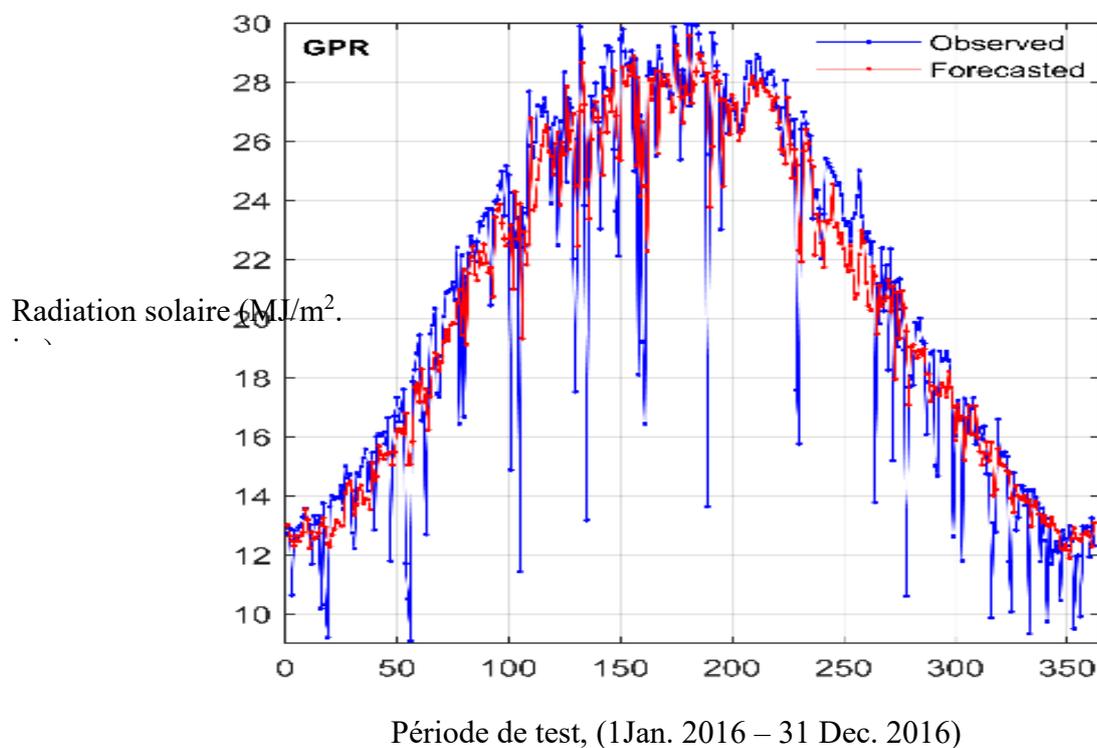


Figure (4- 16): Valeurs mesurées Rayonnement solaire quotidien par rapport aux valeurs estimées pour le modèle de référence.

4.6. Résultats des prévisions par rapport aux études précédentes

Le tableau (4-6) montre une comparaison statistique entre les résultats de l'étude actuelle et ceux des études précédentes. Les résultats ont été comparés à ceux d'études utilisant des algorithmes de la même classe.

Tableau (4- 6) : Comparaison des performances du modèle développé avec les récentes études

<i>Ref.</i>	<i>Prediction models</i>	<i>Best model</i>	<i>Evaluation metrics</i>		
			R^2	RMSE	rRMSE
Ağbulut, Gürel et al. (2021)	ANN, SVM, DL, k-NNA	ANN	0.932	2.15	14.10
Deo, Wen et al. (2016)	W-SVM	W-SVM	0.928	2.317	12.57
Feng, Gong et al. (2019)	MEA- ANN, ANN, RF, W-ANN	MEA-ANN	0.885	2.81	19.60
Quej, Almorox et al. (2017)	ANFIS,SVM,ANN	SVM	0.689	2.57	-
Mohammadi, Shamshirband et al. (2015)	SVR	SVR	0.914	2.00	9.03
Aji, Wakamori et al. (2018)	SVR	SVR	0.983	-	21.90
Mehdizadeh, Behmanesh et al. (2016)	GEP, ANN, ANFIS, Empirical	ANN	0.935	1.850	-
<i>Etude actuelle</i>	GPR, W-GPR, WP-GPR	WP-GPR	0,923	0.36	11.58

DL: Deep learning, MEA: Mind Evolutionary Algorithm, RF: Random Forests, GEP: Gene Expression Programming

Selon le tableau 6, Ağbulut, Gürel et al. (2021) a étudié les données GSR journalière, les auteurs ont trouvé la valeur la plus élevée de R^2 égale à 0,932 % dans leur étude. Cette valeur est la meilleure du tableau 4-6. D'autre part, la valeur rRMSE a été calculée à 14,10 % dans cette étude. Cette valeur est la deuxième valeur la plus mauvaise parmi les études montrées dans le tableau 4-6. Cela rend difficile la détermination de l'algorithme de prédiction le plus efficace, Cependant, on peut noter que le modèle proposé est supérieur au reste des modèles.

4.7. Synthèse des simulations

Dans cette section nous avons rassemblé les différents résultats obtenus au cours des simulations. Ces résultats nous ont permis de confronter nos simulations avec les mesures du rayonnement global journalière.

- Parmi les combinaisons proposées, la combinaison du neuvième modèle consistant en une fusion entre la température et l'humidité a surpassé toutes les combinaisons proposées.
- Les meilleurs modèles parmi ceux que nous avons mis en œuvre sont les modèles hybrides. Les valeurs de l'indice rRMSE varie entre 11.2% pour (M₉) et 12.8% pour (M₅).
- Nous avons pu dégager les types d'ondelette mère les plus adéquates. Il s'avère que la décomposition type (coif) donne une meilleure performance par rapport aux autres ondelette mère (K. Ferkous et *al.* 2021-a).
- En comparant les résultats obtenus par le modèle proposé avec les résultats obtenus à l'aide de l'un des modèles les plus utilisés dans la littérature qui est le modèle SVM, on a pu voir que le modèle W-GPR surpasse à la fois le modèle seul SVM mais aussi le modèle hybride W-SVM
- Nous avons également pu conclure que la décomposition paquet ondelette donne une meilleure performance que lorsqu'on utilise les ondelettes standards, et ceci a été remarqué pour tous les modèles prédictifs utilisés.
- Les modèles endogènes donnent des résultats très proches de ceux mesurés, ce qui confirme la supériorité de tels modèles par rapport à l'utilisation des modèles exogènes.
- Les modèles GPR et WPD-GPR gardent une bonne performance dans la prédiction du rayonnement solaire sur toutes les horizons utilisés (t+1, t+2 et t+ 3) (K. Ferkous et *al.* 2021-b).

4.8. Conclusion

Le modèle conventionnel basé sur la méthodologie de GPR a été utilisé et a permis la prédiction de la série temporelle de l'irradiation globale journalier à partir de celle des données météorologiques (variables exogènes) et des données du rayonnement solaire au temps précédant le jour prédit (variables endogènes) comme entrées. Les performances sont telles que le coefficient de corrélation est de 0.90 et le rRMSE est de 13.37% à partir des données météorologiques (variables exogènes), et le coefficient de corrélation est de 0.94 et le rRMSE est de 9.35% à partir des données du rayonnement solaire au temps précédant le jour prédit (variables endogènes) comme entrées. Ces performances ont amélioré par l'introduction d'algorithme de décomposition Ondelette (W) pour décomposer les données d'entrées. Par conséquent le rRMSE s'améliore de 11.81% et le coefficient de corrélation est de 92.3% à partir des variables exogènes, le rRMSE s'améliore de 4.02% et le coefficient de corrélation est de 99.00% à partir des variables endogènes. Le modèle hybride WP_GPR proposé a apporté une loue amélioration à la prédiction de l'irradiation globale journalier in situ. Les performances sont telles que le coefficient de corrélation est de 99.54% et le rRMSE est de 2.83% à partir des variables endogènes comme entrées.

Conclusion Générale et Perspectives

Conclusion Générale

L'intégration d'énergies renouvelables intermittentes à un réseau électrique est très délicate, et particulièrement dans les pays qui ont un énorme gisement d'énergie solaire comme l'Algérie. Une possibilité en vue de cette intégration réside dans la caractérisation des différentes ressources. Cette étude s'inscrit donc dans la recherche de prédicteurs de la ressource solaire afin de quantifier l'énergie disponible pour en faciliter la gestion au sein d'un réseau. Dans cette thèse, deux différentes approches sont utilisées pour la prédiction de l'irradiation solaire globale dans un site caractérisé par un climat aride (Ghardaïa) et favorable aux installations solaires.

La première approche consiste à utiliser le modèle conventionnelle basé sur la méthodologie de Gaussian process regression (GPR) a permis la prédiction de la série temporelle d'irradiation solaire journalière à partir de celle des paramètre d'entrée mesurables qui est la température (T_{\max} , T_{\min} , T_{moy}) et l'humidité relative (RH_{\max} , RH_{\min} , RH_{moy}), avec un autre paramètre calculable à partir de formules théoriques, l'irradiation solaire globale hors atmosphère (extraterrestre) H_0 , dites variables exogènes et des données du rayonnement solaire au temps précédant le jour prédit (variables endogènes) in situ. Les resultats de performances sont telles que le coefficient de corrélation est de 0.90 et le rRMSE est de 13.37% quand utilisant des entrées exogènes et 0.94 et le coefficient de corrélation est de 0.94 et le rRMSE est de 9.53% pour les entrées endogènes. Le modèle (GPR) a permis d'améliorer légèrement les performances de la prédiction par rapport au modèle SVM. Le rRMSE s'améliore de 2% et une amélioration du 0.07% pour le coefficient de corrélation

La deuxième approche consiste à appliquer un modèle hybride en associant deux techniques complètement différentes, l'une basée sur le principe de décomposition ondelette (W) et l'autre sur l'apprentissage statistique (GPR) afin de prédire à un pas de temps d'une journée l'irradiation solaire globale journalière in situ. A travers cette étude, nous avons essayé d'utiliser la combinaison appropriée de données climatiques comme variables d'entrée exogène après les avoir décomposée à l'aide de plusieurs algorithmes de décomposition. Le modèle W-GPR a donné de meilleurs résultats que le modèle conventionnelle GPR, Surtout lors de l'utilisation des données du rayonnement solaire au temps précédant le jour prédit (variables endogènes), Le rRMSE atteint 4.02 % et le coefficient de corrélation atteint 99.00 %.

Enfin, on a comparé statistiquement les résultats de l'étude actuelle et ceux des études précédentes utilisant des algorithmes de la même classe, nous avons conclu qu'aucun algorithme unique n'offre les meilleures performances, mais cela varie d'une région à l'autre. Cependant, le modèle hybride WP-GPR, lorsqu'il utilise des entrées endogènes, a prouvé son efficacité et sa supériorité sur les autres modèles (rRMSE diminué de 1.19 %, R^2 augmenté de 0.54%).

Le modèle hybride W-GPR proposé a apporté une loure amélioration à la prédiction d'irradiation globale journalier in situ, Cependant il n'existe pas un seul algorithme offrant les meilleures performances, mais il varie d'une région à l'autre. De plus, les performances d'un même algorithme peuvent être très élevées pour une région et faibles pour une autre. Cela rend difficile la détermination de l'algorithme de prédiction le plus efficace. Mais, cette technique hybride pourrait être une solution pour la ville de Ghardaïa.

Perspectives

La réalisation de ces travaux de thèse a révélé des perspectives d'amélioration auxquelles il semble judicieux de s'intéresser.

- La première perspective qui vient à l'esprit est de nous essayerons d'adapter ces modèles WD-GPR développés à d'autres sites avoisinant tout en utilisant les mêmes entrées.
- Prédire le rayonnement global à l'échelle horaire, voire même à un horizon très court (horizon 10 ou 5 minutes), car ces deux horizons seront intéressés par un gestionnaire de réseau électrique.
- L'hybridation de GPR avec l'algorithme de la décomposition donne de bons résultats. Cependant, le mixage effectué doit pouvoir être amélioré notamment par l'utilisation des autres algorithmes de décomposition comme les algorithmes CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) et VMD (variational mode decomposition), etc.

D'autres améliorations, encore plus évoluées sont envisageables, on peut citer :

- L'utilisation des SIG (Système d'Information Géographique) dans les prédictions afin de réellement prendre en compte le relief et ainsi mieux quantifier le masque solaire, les zones géographiquement équivalentes, etc.
- L'utilisation d'images satellites de rayonnement global. Chaque pixel donne les informations relatives à une zone géographique précise. Une carte de $N \times N$ pixels donne simultanément N^2 mesures à l'instant t . Si l'on génère les cartes périodiquement, cela signifie que l'on peut transposer ces cartes en N^2 séries temporelles de rayonnement global. Il devient ainsi possible d'utiliser tout ce qui a été montré dans ce manuscrit (prédiction à horizon).
- L'apprentissage profond (DL) branche du machine Learning où la machine est capable d'apprendre par elle-même, Aux vues de nos recherches, la possibilité de réellement mixer les modèles en utilisant les concepts précédents et les modèles (DL) apparaît, elle aussi, comme une piste d'expérimentation intéressante.

Bibliographie

Bibliographie

Achour, L., Bouharkat, M., Assas, O. and Behar, O., Hybrid model for estimating monthly global solar radiation for the Southern of Algeria: (Case study: Tamanrasset, Algeria), *J. Energy*, Vol. **135**, no., pp. 526-539, (2017).

Adamowski, J. and Sun, K., Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds, *J. Journal of Hydrology*, Vol. **390**, no. 1, pp. 85-91, (2010).

Addison Paul, S. The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance, Institute of Physics Publishing (2002).

Ağbulut, Ü., Gürel, A. E. and Biçen, Y., Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison, *J. Renewable Sustainable Energy Reviews*, Vol. **135**, no., pp. 110114, (2021).

Aggarwal, S. K. and Saini, L. M., Solar energy prediction using linear and non-linear regularization models: A study on AMS (American Meteorological Society) 2013–14 Solar Energy Prediction Contest, *J. Energy*, Vol. **78**, no., pp. 247-256, (2014).

Aguiar, L. M., Pereira, B., Lauret, P., Díaz, F. and David, M., Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting, *J. Renewable Energy*, Vol. **97**, no., pp. 599-610, (2016).

Aji, P., Wakamori, K. and Mineno, H. Highly accurate daily solar radiation forecasting using SW-SVR for hybrid power plant in Indonesia. *2018 4th International Conference on Nano Electronics Research and Education (ICNERE), IEEE*. Vol. no., pp. 1-5, (2018).

Angstrom, A., J Quarterly Solar and terrestrial radiation. Report to the international commission for solar research on actinometric investigations of solar and atmospheric radiation, *J. Journal of the Royal Meteorological Society*, Vol. **50**, no. 210, pp. 121-126, (1924).

Antonopoulos, V. Z., Papamichail, D. M., Aschonitis, V. G. and Antonopoulos, A. V., Solar radiation estimation methods using ANN and empirical models, *J. Computers and Electronics in Agriculture*, Vol. **160**, no., pp. 160-167, (2019).

- Aslam, M., Lee, J.-M., Kim, H.-S., Lee, S.-J. and Hong, S., Deep Learning Models for Long-Term Solar Radiation Forecasting Considering Microgrid Installation: A Comparative Study, *J. Energies*, Vol. **13**, no. 1, pp., (2020).
- BACH, S. A. E. F., Apprentissage Statistique M2 Probabilités et Statistiques, Université Paris-Sud Cours 1: Théorie de l'apprentissage statistique: de Vapnik à la localisation (1/2), (2015).
- Bacher, P., Madsen, H. and Nielsen, H. A., Online short-term solar power forecasting, *J. Solar energy*, Vol. **83**, no. 10, pp. 1772-1783, (2009).
- Badescu, V.. Modeling solar radiation at the earth's surface, Springer (2014).
- Bahraoui-Buret, J. and Khtira, A., Etude du rayonnement solaire à Rabat, *J. Revue Internationale d'héliotechnique*, 2ème semestre, Vol. no., pp. 7-11, (1984).
- Baser, F. and Demirhan, H., A fuzzy regression with support vector machine approach to the estimation of horizontal global solar radiation, *J. Energy*, Vol. **123**, no., pp. 229-240, (2017).
- Belaid, S. and Mellit, A., Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate, *J. Energy Conversion and Management*, Vol. **118**, no., pp. 105-118, (2016).
- Belmahdi, B., Louzazni, M. and Bouardi, A. E., One month-ahead forecasting of mean daily global solar radiation using time series models, *J. Optik*, Vol. **219**, no., pp. 165207, (2020).
- Benmouiza, K. and Cheknane, A., Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models, *J. Theoretical and Applied Climatology*, Vol. **124**, no. 3, pp. 945-958, (2016).
- Bessemoulin, P., Oliviéri, J., 2000. Le rayonnement solaire et sa composante ultraviolette. La Météorologie, 8e série 31, 42–59. (2000).
- Bishop, C. M. Neural networks for pattern recognition, Oxford university press (1995).
- Boubaker, S., Benghanem, M., Mellit, A., Lefza, A., Kahouli, O. and Kolsi, L., Deep Neural Networks for Predicting Solar Radiation at Hail Region, Saudi Arabia, *J. IEEE Access*, Vol. **9**, no., pp. 36719-36729, (2021).

- Box, G. E., Jenkins, G. M., Reinsel, G. C. and Ljung, G. M. Time series analysis: forecasting and control, John Wiley & Sons (2015).
- Box, G. E. and Jenkins, G. M. J. C. H.-D., Time series analysis: Forecasting and control San Francisco, *J.* Vol. no., pp., (1976).
- Brahma, B. and Wadhvani, R., Solar Irradiance Forecasting Based on Deep Learning Methodologies and Multi-Site Data, *J. Symmetry*, Vol. **12**, no. 11, pp., (2020).
- Brockwell, P. J. and Davis, R. A. Time series: theory and methods, Springer science & business media (2009).
- Brownlee, J. Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in Python, Machine Learning Mastery (2018).
- Che, Y., Chen, L., Zheng, J., Yuan, L. and Xiao, F., A Novel Hybrid Model of WRF and Clearness Index-Based Kalman Filter for Day-Ahead Solar Radiation Forecasting, *J.* Vol. **9**, no. 19, pp. 3967, (2019).
- Colak, I., Yesilbudak, M., Genc, N. and Bayindir, R. Multi-period Prediction of Solar Radiation Using ARMA and ARIMA Models. *2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*. Vol. no., pp. 1045-1049, (2015).
- Cornaro, C., Pierro, M. and Bucci, F., Master optimization process based on neural networks ensemble for 24-h solar irradiance forecast, *J. Solar energy*, Vol. **111**, no., pp. 297-312, (2015).
- Crone, S. F., Stepwise selection of artificial neural network models for time series prediction, *J. J Journal of Intelligent Systems*, Vol. **14**, no. 2-3, pp. 99-122, (2005).
- Dambreville, R. Pr evision du rayonnement solaire global par t el ed etection pour la gestion de la production d' nergie photovolta ique, Universit  de Grenoble (2014).
- D Didier Delignieres, S eries temporelles – Mod es ARIMA. S minaire EA "Sport – Performance – Sant " Mars 2000. (2000).
- Deo, R. C., Wen, X. and Qi, F., A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset, *J. Applied Energy*, Vol. **168**, no., pp. 568-593, (2016).

Dong, Z., Yang, D., Reindl, T. and Walsh, W. M., Satellite image analysis and a hybrid ESSS/ANN model to forecast solar irradiance in the tropics, *J. Energy Conversion and Management*, Vol. **79**, no., pp. 66-73, (2014).

Dong, Z., Yang, D., Reindl, T. and Walsh, W. M., A novel hybrid approach based on self-organizing maps, support vector regression and particle swarm optimization to forecast solar irradiance, *J. Energy*, Vol. **82**, no., pp. 570-577, (2015).

Doucouré, B. Proposition, intégration dans un système de gestion de réseau intelligent et validation expérimentale d'une méthode de prédiction pour un système d'énergies renouvelables, these doctorat, Université du Québec à Trois-Rivières (2015).

Duffie, J. A. and Beckman, W. A. Solar engineering of thermal processes, John Wiley & Sons (2013).

Duffie, J. A. and Sons, I., WA, Solar Engineering of Thermal Processes, *J. John Wiley*, Vol. no., pp. 250-330, (1991).

Ertekin, C. and Yaldiz, O., Comparison of some existing models for estimating global solar radiation for Antalya (Turkey), *J. Energy Conversion Management*, Vol. **41**, no. 4, pp. 311-330, (2000).

Fan, J., Wang, X., Wu, L., Zhang, F., Bai, H., Lu, X. and Xiang, Y., New combined models for estimating daily global solar radiation based on sunshine duration in humid regions: A case study in South China, *J. Energy Conversion and Management*, Vol. **156**, no., pp. 618-625, (2018).

Feng, Y., Gong, D., Zhang, Q., Jiang, S., Zhao, L. and Cui, N., Evaluation of temperature-based machine learning and empirical models for predicting daily global solar radiation, *J. Energy Conversion and Management*, Vol. **198**, no., pp. 111780, (2019).

Feng, Y., Gong, D., Zhang, Q., Jiang, S., Zhao, L. and Cui, N., Evaluation of temperature-based machine learning and empirical models for predicting daily global solar radiation, *J. Energy Conversion Management*, Vol. **198**, no., pp. 111780, (2019).

Khaled Ferkous, Farouk Chellali, Abdalah Kouzou, Belgacem Bekkar, Wavelet-Gaussian Process Regression Model For Forecasting Daily Solar Radiation In The Saharan Climate, *Clean Energy*, Volume 5, Issue 2, June 2021, Pages 316–328, <https://doi.org/10.1093/ce/zkab012>.

Khaled Ferkous, Farouk Chellali, Abdalah Kouzou, Belgacem Bekkar, Wavelet-Gaussian Process Regression Model For Regression Daily Solar Radiation In Ghardaia, Algeria. *Instrumentation, Mesures, Métrologies* . Apr 2021, Vol. 20 Issue 2, p113-119. 7p.

Ferrari, S., Lazzaroni, M., Piuri, V., Cristaldi, L. and Faifer, M. Statistical models approach for solar radiation prediction. *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. Vol. no., pp. 1734-1739, (2013).

Fouilloy, A. Comparaison de méthodes d'apprentissage automatique de prévision de la ressource solaire pour une application à une gestion optimisée des réseaux intelligents, Université de CORSE-Pascal PAOLI (2019).

Garcia, C., Frigerio, S., Daehne, A., Corsini, A. and Sterlacchini, S. The Relevance of Early-Warning Systems and Evacuations Plans for Risk Management, in *Mountain Risks: From Prediction to Management and Governance*, Springer pp. 341-364.2014.

Garg, H. P. *Treatise on solar energy*, John Wiley & Sons (1982).

George, D. and Mallery, P. *SPSS for Windows Step by Step: A Simple Guide and Reference*, Allyn and Bacon (1999)..

Ghimire, S., Deo, R. C., Raj, N. and Mi, J., Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms, *J. Applied Energy*, Vol. **253**, no., pp. 113541, (2019).

Greenspan, R. J. and Baars, B. J., Consciousness eclipsed: Jacques Loeb, Ivan P. Pavlov, and the rise of reductionistic biology after 1900, *J. Consciousness and Cognition*, Vol. **14**, no. 1, pp. 219-230, (2005).

Guerbette, J., Mahfouf, J.-F. and Plu, M., Towards the assimilation of all-sky microwave radiances from the SAPHIR humidity sounder in a limited area NWP model over tropical regions, *J. Tellus A: Dynamic Meteorology and Oceanography*, Vol. **68**, no. 1, pp. 28620, (2016).

Guermoui, M., Melgani, F. and Danilo, C., Multi-step ahead forecasting of daily global and direct solar radiation: A review and case study of Ghardaia region, *J. Journal of Cleaner Production*, Vol. **201**, no., pp. 716-734, (2018).

Guermoui, M., Rabehi, A., Gairaa, K. and Benkaciali, S., Support vector regression methodology for estimating global solar radiation in Algeria, *J. The European Physical Journal Plus*, Vol. **133**, no. 1, pp. 22, (2018).

Gueymard, C. A., The sun's total and spectral irradiance for solar energy applications and solar radiation models, *J. Solar energy*, Vol. **76**, no. 4, pp. 423-453, (2004).

Günther, M., Janotte, N., Mezrhab, A., Pottler, K., Schillings, C., Wilbert, S. and Wolferstätter, F., Solar radiation, *J. Advanced CSP Teaching Materials, Enermena*, Vol. no., pp. 22-23, (2011).

Hamilton, J. D. and Susmel, R., Autoregressive conditional heteroskedasticity and changes in regime, *J. Journal of Econometrics*, Vol. **64**, no. 1, pp. 307-333, (1994).

Harsarapama, A. P., Aryani, D. R. and Rachmansyah, D., Open-Source Satellite-Derived Solar Resource Databases Comparison and Validation for Indonesia, *J. Journal of Renewable Energy*, Vol. **2020**, no., pp., (2020).

Heil, C., Ten lectures on wavelets (ingrid daubechies), *J. J SIAM Review*, Vol. **35**, no. 4, pp. 666-669, (1993).

Huang, J., Troccoli, A. and Coppin, P., An analytical comparison of four approaches to modelling the daily variability of solar irradiance using meteorological records, *J. Renewable Energy*, Vol. **72**, no., pp. 195-202, (2014).

Cyr A, Intelligence artificielle et robotique bio-inspirée: Modélisation de fonctions d'apprentissage par réseaux de neurones à impulsions. PhD thesis, Université du Québec à Montréal, Montréal, PQ, Canada, (2016).

Ineichen, P., A broadband simplified version of the Solis clear sky model, *J. Solar energy*, Vol. **82**, no. 8, pp. 758-762, (2008).

Inman, R. H., Pedro, H. T. C. and Coimbra, C. F. M., Solar forecasting methods for renewable energy integration, *J. Progress in Energy and Combustion Science*, Vol. **39**, no. 6, pp. 535-576, (2013).

Iqbal, M. Introduction to solar radiation. New York: Academic Press. (1983).

Jaihuni, M., Basak, J. K., Khan, F., Okyere, F. G., Arulmozhi, E., Bhujel, A., Park, J., Hyun, L. D. and Kim, H. T., A Partially Amended Hybrid Bi-GRU—ARIMA Model (PAHM) for

Predicting Solar Irradiance in Short and Very-Short Terms, *J. Energies*, Vol. **13**, no. 2, pp. 435, (2020).

Jarraud, M., Guide to meteorological instruments and methods of observation (WMO-No. 8), *J. World Meteorological Organisation: Geneva, Switzerland*, Vol. **29**, no., pp., (2008).

Jimenez, P. A., Hacker, J. P., Dudhia, J., Haupt, S. E., Ruiz-Arias, J. A., Gueymard, C. A., Thompson, G., Eidhammer, T. and Deng, A., WRF-Solar: Description and clear-sky assessment of an augmented NWP model for solar power prediction, *J. Bulletin of the American Meteorological Society*, Vol. **97**, no. 7, pp. 1249-1264, (2016).

Kaba, K., Sarıgül, M., Avcı, M. and Kandırmaz, H. M., Estimation of daily global solar radiation using deep learning model, *J. Energy*, Vol. **162**, no., pp. 126-135, (2018).

Kalogirou, S. A. (2013). Solar energy engineering: processes and systems, Academic Press.

Kasten, F., The linke turbidity factor based on improved values of the integral Rayleigh optical thickness, *J. Solar energy*, Vol. **56**, no. 3, pp. 239-244, (1996).

Kato, S., Ackerman, T. P., Mather, J. H. and Clothiaux, E. E., The k-distribution method and correlated-k approximation for a shortwave radiative transfer model, *J. Journal of Quantitative Spectroscopy Radiative Transfer*, Vol. **62**, no. 1, pp. 109-121, (1999).

Kazemzadeh, M.-R., Amjadian, A. and Amraee, T., A hybrid data mining driven algorithm for long term electric peak load and energy demand forecasting, *J. J Energy Conversion Management*, Vol. **204**, no., pp. 117948, (2020).

Kemmoku, Y., Orita, S., Nakagawa, S. and Sakakibara, T., Daily insolation forecasting using a multi-stage neural network, *J. Solar energy*, Vol. **66**, no. 3, pp. 193-199, (1999).

Khelifi, R., Guermoui, M., Rabehi, A. and Lalmi, D., Multi-step-ahead forecasting of daily solar radiation components in the Saharan climate, *J. International Journal of Ambient Energy*, Vol. **41**, no. 6, pp. 707-715, (2020).

Kisi, O. and Cimen, M., A wavelet-support vector machine conjunction model for monthly streamflow forecasting, *J. Journal of Hydrology*, Vol. **399**, no. 1, pp. 132-140, (2011).

Lauret, P., Voyant, C., Soubdhan, T., David, M. and Poggi, P., A benchmarking of machine learning techniques for solar radiation forecasting in an insular context, *J. Solar energy*, Vol. **112**, no., pp. 446-457, (2015).

- Lazzaroni, M., Ferrari, S., Piuri, V., Salman, A., Cristaldi, L. and Faifer, M., Models for solar radiation prediction based on different measurement sites, *J. Measurement*, Vol. **63**, no., pp. 346-363, (2015).
- Liu, Y., Shimada, S., Yoshino, J., Kobayashi, T., Miwa, Y. and Furuta, K., Ensemble forecasting of solar irradiance by applying a mesoscale meteorological model, *J. Solar energy*, Vol. **136**, no., pp. 597-605, (2016).
- Long, H., Zhang, Z. and Su, Y., Analysis of daily solar power prediction with data-driven approaches, *J. Applied Energy*, Vol. **126**, no., pp. 29-37, (2014).
- Mallat, S. G., Multifrequency channel decompositions of images and wavelet models, *J. J IEEE Transactions on Acoustics, Speech, Signal Processing*, Vol. **37**, no. 12, pp. 2091-2110, (1989).
- Marquez, R. and Coimbra, C. F. M., Forecasting of global and direct solar irradiance using stochastic learning methods, ground experiments and the NWS database, *J. Solar energy*, Vol. **85**, no. 5, pp. 746-756, (2011).
- Marquez, R., Pedro, H. T. and Coimbra, C. F., Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to ANNs, *J. J Solar Energy*, Vol. **92**, no., pp. 176-188, (2013).
- McCandless, T. C., Haupt, S. E. and Young, G. S., A model tree approach to forecasting solar irradiance variability, *J. Solar energy*, Vol. **120**, no., pp. 514-524, (2015).
- Mehdizadeh, S., Behmanesh, J. and Khalili, K., Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation, *J. Journal of Atmospheric Solar-Terrestrial Physics*, Vol. **146**, no., pp. 215-227, (2016).
- Mohammadi, K., Shamshirband, S., Tong, C. W., Arif, M., Petković, D. and Ch, S., A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation, *J. Energy Conversion and Management*, Vol. **92**, no., pp. 162-171, (2015).
- Mohammadi, K., Shamshirband, S., Tong, C. W., Arif, M., Petković, D. and Ch, S., A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation, *J. Energy Conversion Management*, Vol. **92**, no., pp. 162-171, (2015).

- Moreno, A., Gilabert, M. A. and Martínez, B., Mapping daily global solar irradiation over Spain: A comparative study of selected approaches, *J. Solar energy*, Vol. **85**, no. 9, pp. 2072-2084, (2011).
- Mueller, R. W., Dagestad, K. F., Ineichen, P., Schroedter-Homscheidt, M., Cros, S., Dumortier, D., Kuhlemann, R., Olseth, J. A., Piernavieja, G., Reise, C., Wald, L. and Heinemann, D., Rethinking satellite-based solar irradiance modelling: The SOLIS clear-sky module, *J. Remote Sensing of Environment*, Vol. **91**, no. 2, pp. 160-174, (2004).
- Muhammad, A., Lee, J. M., Hong, S. W., Lee, S. J. and Lee, E. H. Deep Learning Application in Power System with a Case Study on Solar Irradiation Forecasting. *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*. Vol. no., pp. 275-279, (2019).
- Neal, R. M. Bayesian learning for neural networks, Springer Science & Business Media (2012).
- Ngui, W. K., Leong, M. S., Hee, L. M. and Abdelrhman, A. M. Wavelet analysis: mother wavelet selection methods. *Applied mechanics and materials, Trans Tech Publ.* Vol. **393**, no., pp. 953-958, (2013).
- Noia, M., Ratto, C. F. and Festa, R., Solar irradiance estimation from geostationary satellite data: I. Statistical models, *J. Solar energy*, Vol. **51**, no. 6, pp. 449-456, (1993).
- Nourani, V., Komasi, M. and Mano, A., A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling, *J. Water Resources Management*, Vol. **23**, no. 14, pp. 2877, (2009).
- Olatomiwa, L., Mekhilef, S., Shamshirband, S., Mohammadi, K., Petković, D. and Sudheer, C., A support vector machine–firefly algorithm-based model for global solar radiation prediction, *J. Solar energy*, Vol. **115**, no., pp. 632-644, (2015).
- Oudrane, A. Contribution à la modélisation et au développement des systèmes de chauffage solaire à usage individuel, Ecole Nationale Polytechnique d'Oran Maurice Audin (2018).
- Paletta, Q., Arbod, G. and Lasenby, J., Benchmarking of Deep Learning Irradiance Forecasting Models from Sky Images--an in-depth Analysis, *J. arXiv preprint arXiv:.00721*, Vol. no., pp., (2021).

Paoli, C., Voyant, C., Muselli, M. and Nivet, M.-L., Forecasting of preprocessed daily solar radiation time series using neural networks, *J. Solar energy*, Vol. **84**, no. 12, pp. 2146-2160, (2010).

Paulescu, M., Paulescu, E., Gravila, P. and Badescu, Weather modeling and forecasting of PV systems operation, Springer Science & Business Media V. (2012).

Perez, R., Ineichen, P., Moore, K., Kmiecik, M., Chain, C., George, R. and Vignola, F., A new operational model for satellite-derived irradiances: description and validation, *J. Solar energy*, Vol. **73**, no. 5, pp. 307-317, (2002).

Perez, R., Kivalov, S., Schlemmer, J., Hemker, K., Renné, D. and Hoff, T. E., Validation of short and medium term operational solar radiation forecasts in the US, *J. Solar energy*, Vol. **84**, no. 12, pp. 2161-2172, (2010).

Perez, R., Lorenz, E., Pelland, S., Beauharnois, M., Van Knowe, G., Hemker, K., Heinemann, D., Remund, J., Müller, S. C., Traunmüller, W., Steinmayer, G., Pozo, D., Ruiz-Arias, J. A., Lara-Fanego, V., Ramirez-Santigosa, L., Gaston-Romero, M. and Pomares, L. M., Comparison of numerical weather prediction solar irradiance forecasts in the US, Canada and Europe, *J. Solar energy*, Vol. **94**, no., pp. 305-326, (2013).

Podestá, G. P., Núñez, L., Villanueva, C. A. and Skansi, M. a. A., Estimating daily solar radiation in the Argentine Pampas, *J. Agricultural and Forest Meteorology*, Vol. **123**, no. 1, pp. 41-53, (2004).

Quej, V. H., Almorox, J., Arnaldo, J. A. and Saito, L., ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment, *J. Journal of Atmospheric and Solar-Terrestrial Physics*, Vol. **155**, no., pp. 62-70, (2017).

Quej, V. H., Almorox, J., Arnaldo, J. A. and Saito, L., ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment, *J. Journal of Atmospheric Solar-Terrestrial Physics*, Vol. **155**, no., pp. 62-70, (2017).

Rabehi, A., Guermoui, M., Khelifi, R. and Mekhalfi, M. L., Decomposing global solar radiation into its diffuse and direct normal radiation, *J. International Journal of Ambient Energy*, Vol. **41**, no. 7, pp. 738-743, (2020).

Rabehi, A., Guermoui, M. and Lalmi, D., Hybrid models for global solar radiation prediction: a case study, *J. International Journal of Ambient Energy*, Vol. **41**, no. 1, pp. 31-40, (2020).

Rafiee, J., Tse, P. W., Harifi, A. and Sadeghi, M. H., A novel technique for selecting mother wavelet function using an intelligent fault diagnosis system, *J. Expert Systems with Applications*, Vol. **36**, no. 3, 1, pp. 4862-4875, (2009).

Rajaei, T., Mirbagheri, S. A., Nourani, V. and Alikhani, A., Prediction of daily suspended sediment load using wavelet and neurofuzzy combined model, *J. International Journal of Environmental Science & Technology*, Vol. **7**, no. 1, pp. 93-110, (2010).

Rasmussen, C. and Williams, C. Gaussian processes for machine learning (Vol. 38, pp. 715–719), Cambridge, MA, USA: The MIT Press (2006).

Reikard, G. J. S. E., Predicting solar radiation at high resolutions: A comparison of time series forecasts, *J. Vol. 83*, no. 3, pp. 342-349, (2009).

Rodríguez-Amigo, M. C., Díez-Mediavilla, M., González-Peña, D., Pérez-Burgos, A. and Alonso-Tristán, C., Mathematical interpolation methods for spatial estimation of global horizontal irradiation in Castilla-León, Spain: A case study, *J. Solar energy*, Vol. **151**, no., pp. 14-21, (2017).

Rudd, T. R., Benefits of near-term cloud location forecasting for large solar PV, *California Polytechnic State University, San Luis Obispo*, (2011).

Salcedo-Sanz, S., Casanova-Mateo, C., Pastor-Sánchez, A. and Sánchez-Girón, M., Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization – Extreme Learning Machine approach, *J. Solar energy*, Vol. **105**, no., pp. 91-98, (2014).

Seo, Y., Kim, S., Kisi, O. and Singh, V. P., Daily water level forecasting using wavelet decomposition and artificial intelligence techniques, *J. Journal of Hydrology*, Vol. **520**, no., pp. 224-243, (2015).

Shamshirband, S., Mohammadi, K., Chen, H.-L., Narayana Samy, G., Petković, D. and Ma, C., Daily global solar radiation prediction from air temperatures using kernel extreme learning machine: A case study for Iran, *J. Journal of Atmospheric and Solar-Terrestrial Physics*, Vol. **134**, no., pp. 109-117, (2015).

Shamshirband, S., Mohammadi, K., Piri, J., Petković, D. and Karim, A., Hybrid autoregressive neural network model for estimating global solar radiation in Bandar Abbas, Iran, *J. Environmental Earth Sciences*, Vol. **75**, no. 2, pp. 172, (2016).

- Sun, H., Yan, D., Zhao, N. and Zhou, J., Empirical investigation on modeling solar radiation series with ARMA–GARCH models, *J. Energy Conversion and Management*, Vol. **92**, no., pp. 385-395, (2015).
- Sun, S., Wang, S., Zhang, G. and Zheng, J., A decomposition-clustering-ensemble learning approach for solar radiation forecasting, *J. Solar energy*, Vol. **163**, no., pp. 189-199, (2018).
- Tipping, M. E. Bayesian inference: An introduction to principles and practice in machine learning. *Summer School on Machine Learning, Springer*. Vol. **122** no., pp. 41-62, (2003).
- Touzet, C. 1992. Les reseaux de neurones artificiels-introduction au connexionnisme: cours, exercices et travaux pratiques. EC2. <https://hal-amu.archives-ouvertes.fr/hal-01338010>.
- Ulgen, K. and Hepbasli, A., Solar radiation models. Part 2: Comparison and developing new models, *J. J Energy sources*, Vol. **26**, no. 5, pp. 521-530, (2004).
- Vapnik, V. The nature of statistical learning theory, Springer science & business media (2013).
- Voyant, C., Muselli, M., Paoli, C. and Nivet, M.-L., Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation, *J. Energy*, Vol. **39**, no. 1, pp. 341-355, (2012).
- Wang, F., Yu, Y., Zhang, Z., Li, J., Zhen, Z. and Li, K., Wavelet Decomposition and Convolutional LSTM Networks Based Improved Deep Learning Model for Solar Irradiance Forecasting, *J.* Vol. **8**, no. 8, pp. 1286, (2018).
- Wang, L., Kisi, O., Zounemat-Kermani, M., Salazar, G. A., Zhu, Z. and Gong, W., Solar radiation prediction using different techniques: model evaluation and comparison, *J. Renewable and Sustainable Energy Reviews*, Vol. **61**, no., pp. 384-397, (2016).
- Wang, L., Kisi, O., Zounemat-Kermani, M., Zhu, Z., Gong, W., Niu, Z., Liu, H. and Liu, Z., Prediction of solar radiation in China using different adaptive neuro-fuzzy methods and M5 model tree, *J.* Vol. **37**, no. 3, pp. 1141-1155, (2017).
- Wang, W. and Ding, J., Wavelet network model and its application to the prediction of hydrology, *J. Nature and Science*, Vol. **1**, no. 1, pp. 67-71, (2003).

Yacef, R., Mellit, A., Belaid, S. and Şen, Z., New combined models for estimating daily global solar radiation from measured air temperature in semi-arid climates: Application in Ghardaïa, Algeria, *J. Energy Conversion and Management*, Vol. **79**, no., pp. 606-615, (2014).

Yadav, A. P. and Behera, L., Solar Radiation forecasting using neural networks and Wavelet Transform, *J. IFAC Proceedings Volumes*, Vol. **47**, no. 1, pp. 890-896, (2014).

Yagli, G. M., Yang, D., Gandhi, O. and Srinivasan, D., Can we justify producing univariate machine-learning forecasts with satellite-derived solar irradiance?, *J. Applied Energy*, Vol. **259**, no., pp. 114122, (2020).

Yan, K., Shen, H., Wang, L., Zhou, H., Xu, M. and Mo, Y., Short-term solar irradiance forecasting based on a hybrid deep learning methodology, *J. Information*, Vol. **11**, no. 1, pp. 32, (2020).

Yang, D., Dong, Z., Reindl, T., Jirutitijaroen, P. and Walsh, W. M., Solar irradiance forecasting using spatio-temporal empirical kriging and vector autoregressive models with parameter shrinkage, *J. Solar energy*, Vol. **103**, no., pp. 550-562, (2014).

Yang, H., Kurtz, B., Nguyen, D., Urquhart, B., Chow, C. W., Ghonima, M. and Kleissl, J., Solar irradiance forecasting using a ground-based sky imager developed at UC San Diego, *J. J Solar Energy*, Vol. **103**, no., pp. 502-524, (2014).

Zhang, G. P., Time series forecasting using a hybrid ARIMA and neural network model, *J. Neurocomputing*, Vol. **50**, no., pp. 159-175, (2003).

Zhou, X., Zhou, C. and Stewart, B. Comparisons of discrete wavelet transform, wavelet packet transform and stationary wavelet transform in denoising PD measurement data. *Conference record of the 2006 IEEE international symposium on electrical insulation, IEEE*. Vol. no., pp. 237-240, (2006).

Publications en revue et conférences

Publications en revue

Khaled Ferkous, Farouk Chellali, Abdalah Kouzou, Belgacem Bekkar, Wavelet-Gaussian Process Regression Model For Forecasting Daily Solar Radiation In The Saharan Climate, *Clean Energy*, Volume 5, Issue 2, June 2021, Pages 316–328, <https://doi.org/10.1093/ce/zkab012>

Khaled Ferkous, Farouk Chellali, Abdalah Kouzou, Belgacem Bekkar, Wavelet-Gaussian Process Regression Model For Regression Daily Solar Radiation In Ghardaia, Algeria. Instrumentation, *Mesures, Métrologies* . Apr 2021, Vol. 20 Issue 2, p113-119. 7p.

Khaled Ferkous, Farouk Chellali, Abdalah Kouzou, Belgacem Bekkar, Hacene Nacer, Wavelet Packet-Gaussian Process Regression Multivariate And univariate Model For Forecasting Daily Solar Radiation, *International Journal of Energy for a Clean Environment*, DOI: 10.1615/InterJenerCleanEnv.2021037413.

Khaled Ferkous, Amar Bentounsi, Farouk Chellali, Modélisation Et Étude De La GAS A Cage Utilisée Dans La Conversion Éolienne, *ElWahat pour les Recherches et les Etudes* Vol.10 n°1 (2017): 139-151.

Conférences

Khaled Ferkous, Farouk Chellali, Kamel Bouaraour, Kouzou Abdellah, Akermi Faouzi, Belgacem Bekkar, Estimation du rayonnement solaire au sol par deux modèles semi-empirique "Davies & Hay - Lacis & Hansen", *National Conférence on Energy Systems, Environment, Plasma and Materials* 7 -8 Mars 2020, Ghardaïa, Algeria.

Belgacem Bekkar, **Khaled Ferkous**, Ahmed Bahri, H ∞ Mixed Weighted Sensitivity controller for Boost DC-DC Converters, *National Conférence on Energy Systems, Environment, Plasma and Materials* 7 -8 Mars 2020, Ghardaia, Algeria.

Khaled Ferkous, Farouk Chellali, Kouzou Abdellah, Kamel Bouaraour, Akermi Faouzi, Determination of the tilt angle of solar collectors for different site of algeria, *5TH International Conference On Advances In Mechanical Engineering* December 17 - 19, Icam 2019 Istanbul. Turkey.

Khaled Ferkous, Farouk Chellali, Kouzou Abdellah, Comparative models for the optimization of tilt angle to obtain maximum power solar radiation in Algeria., *5th International Seminar on New and Renewable Energies SIENR* 2018 October 24 - 25, 2018 URAER Ghardaia, Algeria.

Khaled Ferkous, Amar Bentounsi, Farouk Chellali, Modélisation et étude de la GAS a cage utilisée dans la conversion éolienne, *International Seminar on the apport of the simulation in technological innovation* 7 - 8 March 2017 Ghardaia, Algeria.