République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITE DE MEDEA

Faculté de Technologie

Département du Génie des Procédés et Environnement

Laboratoire de Biomatériaux et Phénomènes de Transport (LBMPT)

THESE DE DOCTORAT

Présentée par :

Siham CHABA MOUNA

En vue de l'obtention du titre de Doctorat en Génie des Procédés.

Option : Génie des Energies Renouvelables.

Thème

Usage des réseaux de neurones pour le calcul des paramètres énergétiques solaires

Soutenue le, Samedi : 17-02-2018, devant le jury composé de :

Mr. L. DEKAR	MCA, université de Médéa, Algérie	Président
Mr. A. OUAGUED	Professeur, université de Chlef, Algérie	Examinateur
Mr. D. HASSANI	MCA, université de Médéa, Algérie	Examinateur
Mr. S. HANINI	Professeur, université de Médéa, Algérie	Directeur de thèse

Dédicace

Je dédie cette thèse à :

Mes très chers et aimables parents.

A mon cher mari et mon petit fils.

A mon frère et mes chères sœurs.

Tous mes amis et collègues.

Tous ceux qui m'ont soutenu et m'ont encouragé.

Chaba Mouna Siham

Remerciements

Je tiens à remercier en premier **ALLAH DJELLA WA ALA** qui m'a donné le courage et la volonté durant mon travail afin qu'il soit une réussite méritée.

Je remercie vivement mon promoteur, Monsieur le Professeur **Salah HANINI** de l'**Université de Médéa** pour sa gentillesse, sa disponibilité, ses qualités humaines et scientifiques, son réel soutien et pour son implication maximale sur tous les plans, durant ces cinq années de travail en commun.

Je tiens à exprimer mes remerciements à mes Co- promoteurs **Mr. LAIDI Maamar** et M^{me}. **KHAOUANE Latifa**, enseignants à l'UYFM, pour leurs aides, leurs accompagnements et leurs éclairages techniques, ainsi qu'un spécial remerciement pour le **Dr. HAMADACHE Mabrouk**, le **Dr. BENKORTBI Othmane** et le **Dr. SI MOUSSA Cherif** pour leurs conseils et leurs aides.

J'adresse mes plus sincères remerciements au **Dr. DEKAR Lyes** de l'**Université de Médéa** pour avoir accepté de présider le jury de cette thèse.

Mes plus vifs remerciements iront également à Messieurs les membres de mon jury de thèse, le **Pr. OUAGUED Abdallah** de l'**Université de Chlef** et le **Dr. HASSANI Djamel** de l'**Université de Médéa** pour avoir bien voulu consacrer une partie de leur temps à examiner et rapporter ce travail.

Résumé : Usage des réseaux de neurones pour le calcul des paramètres énergétiques solaires

L'objectif de la présente étude est de prédire l'irradiation solaire globale reçue sur une surface horizontale (ISGH) en utilisant les réseaux de neurones artificiels(RNA). Ce travail est divisé en deux contributions. Dans la première contribution, une méthodologie pour l'optimisation du réseau de neurones artificiels (RNA) a été réalisée pour modéliser le rayonnement solaire horizontal en utilisant des données satellitaires pendant la période de février 2004 à décembre 2006 pour quatre villes en Algérie, ces villes sont (Adrar, Médéa, Souk-Ahras et Tlemcen) et choisies pour couvrir différents climats. Cette méthodologie est basée sur un axe principal : la sélection de la structure du RNA. Nous nous sommes focalisés surtout sur le choix de : l'algorithme d'apprentissage, la technique de normalisation et l'architecture du réseau. Cela nous a permis d'élaborer un modèle optimal. Les résultats obtenus ont montré un bon accord entre les valeurs prédites et expérimentales, avec un coefficient de régression R dépassant les 90%, à la fin, nous avons développé une interface graphique en langage Matlab® à partir des poids synaptiques et des biais du réseau de neurones optimal élaboré. Cette démarche permet à l'utilisateur d'avoir tous les entrés nécessaires (Jour, Latitude (°), Longitude(°), Température (K), Humidité relative (%), Pression atmosphérique (hpa), Vitesse du vent (m/s), Direction du vent (°)) à l'exécution de ce modèle pour calculer la sortie (Irradiation solaire globale (Wh/m^2)).

La deuxième contribution consiste à développer un modèle de RNA valable pour la prédiction du rayonnement solaire sur la ville de Ghardaïa. La base de données expérimentale a été fournie par l'Unité de Recherche Appliquée pour les Energies Renouvelables (URAER) Ghardaïa– Algérie, pendant l'année 2013. Les résultats obtenus sont très satisfaisants et très précis avec un coefficient de corrélation de 99,72%, une erreur quadratique moyenne (PRMSE) en pourcentage de 4.7%, et une erreur moyenne biaisée (MBE) de 0.02 %. La précision de la prédiction pour la validation interne en termes de (Q_{int}^2), l'erreur quadratique moyenne (PRMSE) et l'erreur moyenne biaisée (MBE) donnent 0,9984, 4,71% et 0,021% pour les trois paramètres respectivement. Tandis que la validation externe (Q_{ext}^2) donnent 0,9977, 5,60% et 0,42% respectivement. Dans le but de comparer la performance du RNSO, un autre modèle a été développé en se basant sur la méthodologie des régressions linéaires multiples (MLR). Les résultats trouvés montrent que le modèle neuronal est plus approprié et robuste pour la prédiction de l'irradiation solaire globale reçue sur une surface horizontale.

Mots clés : réseaux de neurones artificiels, prédiction, l'irradiation solaire globale, la régression linéaire multiple (MLR).

Abstract: Use of neural networks for the calculation of solar energy parameters

The purpose of this study is to predict the global solar radiation received on the horizontal surface (GSR) using artificial neural network (ANN) methodology. This work is divided into two contributions. In the firstly, a methodology for the optimization of the artificial neural network (ANN) has been done to modelise horizontal solar radiation using satellite data during the period of February 2004 to December 2006 for four cities in Algeria, (Adrar, Médéa, Souk-Ahras and Tlemcen) and where selected to cover different climate. This methodology is based on the selection of the ANN structure, focused mainly on the choice of the learning algorithm, the normalization technique and the network architecture. Results show a good agreement between the estimated and the experimental (satellite data) values, with a regression coefficient R greater than 90%, at the end, we developed a graphical interface in Matlab® language based on the synaptic weights and biases of the elaborated optimal neural network. This approach allows the user to have all the inputs (Day, Latitude (°), Longitude (°), Temperature (K), Relative Humidity (%), Atmospheric Pressure (hpa), Wind Speed (m / s), and Wind Direction (°)) needed to run this model to calculate the output *(*global solar irradiation *(*Wh / m2)).

The second contribution is to develop an ANN model for the prediction of horizontal solar radiation in Ghardaia city. The experimental database of GSR during the year of 2013 was provided by the Applied Research Unit for Renewable Energies (URAER) Ghardaia - Algeria. The obtained results are very satisfactory and very accurate with a correlation coefficient of 99.72%, a mean squared error (PRMSE) of 4.7%, and a biased mean error (MBE) of 0.02%.

The prediction accuracy for the internal and the external validation set was estimated by the Q^2_{int}((for training) and Q^2_{ext}((for test) which are equal to 0.9984, 0.9977 for ANN, with a Root Mean Square Error (PRMSE) of 4.71 % and a Mean Bias Error (MBE) of 0.021 % for the internal validation and of 5.60 %, 0.42 % for the external validation, respectively. In order to compare the performance of the best ANN, a Multiple Linear Regression (MLR) model was also developed. Results showed that the best ANN model is a most appropriate and a robust for the prediction of the horizontal solar radiation values in comparison to the MLR model.

Keywords: Artificial neural networks, prediction, global solar irradiation, Multiple Linear Regression (MLR).

الملخص: استخدام الشبكات العصبية لحساب المعلمات للطاقة الشمسية

الهدف من هذه الدراسة هو التنبؤ بشدة الإشعاع الشمسي الكلي الساقط على سطح افقي باستخدام منهجية الشبكات العصبونية الاصطناعية. ينقسم هذا العمل إلى مساهمتين .في المساهمة الأولى، تم استخدام منهجية لتحسين الشبكة العصبية الاصطناعية من أجل تصميم الإشعاع الشمسي الأفقي باستخدام بيانات الأقمار الصناعية خلال الفترة من فبراير 2004 إلى ديسمبر 2006 لأربع مدن في الجزائر، وهذه المدن هي (أدرار، المدية، السوق -أراس وتلمسان)، حيث يتم اختيارها لتغطية مناخ مختلف. تستند هذه المنهجية على محور أساسي : اختيار هيكل الشبكة العصبية الاصطناعية. تم التركيز فيه خاصة على اختيار خوارزمية التعلم، تقنية التطبيع وهندسة الشبكات. وأظهرت النتائج التي تم التوصل إليها وجود توافق جيد بين القيم المقدرة والمقاسة، مع معامل الانحدار R الذي يتجاوز 90٪، في النهاية، قمنا بتطوير واجهة رسومية في لغة MatLab® على أساس الأوزان المتشابكة وتحيزات الشبكة العصبية الاصطناعية الاصطناعية الأمثل .هذا النهج يسمح للمستخدم أن يكون كل المدخلات اللازمة (يوم، خط العرض (°)، خط الطول (°)، درجة الحرارة(K) ، الرطوبة النسبية (٪)، الضغط الجوي)هبا)، سرعة الرياح (م / ث)، اتجاه الرياح (°) لتشغيل هذا النموذج لحساب الإخراج .(الإشعاع الشمسي.(W / m2))

الهدف من المساهمة الثانية هو تطوير نموذج الشبكة العصبية الاصطناعية صالحة للتنبؤ بالإشعاع الشمسي في مدينة غرداية. قاعدة البيانات التجريبية لسنة 2013 تم توفيرها من قبل وحدة الأبحاث التطبيقية للطاقات المتجددة غرداية ـ الجزائر. وكانت النتائج التي تم الحصول عليها مرضية جدا ودقيقة جدا مع معامل ارتباط 99.72٪، جذر متوسط الخطأ المئوي (PRMSE) 4.7٪، و متوسط الخطأ (MBE) 0.02٪. دقة التنبؤ للتحقق الداخلي من صحة النموذج لمرحلة التعلم من حيث (Q_{int}^2)، جذر متوسط الخطأ (PRMSE) و متوسط الخطأ (MBE) تعطي 0.9984، 4.71٪ و0.021٪ للمعلمات الثلاثة على التوالي. في حين أن التحقق من الصحة الخارجية للنموذج لمرحلة الاختبار (Q_{ext}^2) أعطى 0.9977، 5.60٪ و 0.42٪ على التوالي. من أجل مقارنة أداء RNSO، نموذج آخر وضع على أساس منهجية الانحدار الخطي المتعدد (MLR). وأظهرت النتائج أن النموذج العصبي هو الأكثر مناسبة وقوة للتنبؤ بالإشعاع الشمسي العالمي الساقط على سطح أفقي.

الكلمات الجوهرية: الشبكات العصبية الاصطناعية، التنبؤ، الإشعاع الشمسي العالمي، منهجية الانحدار الخطي المتعدد (MLR).

Table des matières

Dédicaces I

Remerciment II

Résumés III

Table des matières VI

Liste des figures X

Liste des tableaux XX

Introduction générale ……. 1

Chapitre I : Irradiation solaire : état de l'art

I.1. Introduction ……. 4

I.2. Le soleil ……... 4

I.2.1. Relation soleil-terre ……. 6

I.3. Irradiation solaire ……. 8

I.3.1. Irradiation Spectrale …… 8

I.3.2. Irradiation d'un corps noir …….. 9

I.4. Position du soleil par rapport à la terre ……. 10

I.4.1. Coordonnées géographiques terrestres …… 10

I.4.2. La trajectoire apparente du soleil……. 11

I.4.2.1. Coordonnées équatoriales ……. 12

I.4.2.2. Coordonnées horizontales ……. 14

I.5. Influence de l'atmosphère sur le rayonnement solaire ……... 15

I.5.1. Atmosphère ……. 15

I.5.2. Masse atmosphérique …….. 17

I.5.3. Absorption atmosphérique …….. 18

I.5.3.1. Absorption dans l'ultraviolet ……. 19

I.5.3.2. Absorption dans le visible ……. 19

I.5.3.3. Absorption dans l'infrarouge ……. 19

I.5.4. Diffusion atmosphérique …….. 20

I.5.5. Distribution spectrale du rayonnement solaire au sol …… 21

I.6. Mesure d'irradiation solaire …… 22
I.6.1. Radiomètres solaires …… 22
A. Pyrhéliomètre…… 22
B. Pyranomètre…….. 23
C. Mesure de la durée d'ensoleillement……. 24
I.6.2. Satellites météorologiques …….. 25
I.7. Conversion énergétique du rayonnement solaire …… 27
I.7.1. Conversion photovoltaïque ……. 27
I.7.1.1. Effet photovoltaïque …….. 28
I.7.1.2. Technologie de fabrication des cellules PV ……. 30
I.7.1.3. Courbe I-V d'un module PV …… 30
I.7.1.4. Systèmes photovoltaïques ……. 32
I.7.2. Conversion thermique ……. 33
I.7.2.1. Utilisation passive ……. 34
I.7.2.2. Utilisation active …… 34
I.8. Potentiel solaire dans le monde …… 36
I.9. Potentiel solaire en Algérie ……. 36
I.10. Conclusion ……..... 39

Chapitre II : Etat de l'art sur la modélisation de l'irradiation solaire

II.1. Introduction …… 40
II.2. Production scientifique mondiale sur la modélisation d'irradiation solaire …….. 41
II.3. Modèles de prédiction …… 42
II.3.1. Modèles empiriques ……... 42
II.3.1.1. Modèles empiriques linéaires …….. 43
II.3.1.2. Modèles empiriques non linéaires …… 44
II.3.2. Modèles de séries temporelles …… 46
A. Modèle ARMA……... 47
B. Modèle ARIMA……. 47
C. Méthodologie de Box-Jenkins…… 48
II.3.3. Modèles simulés ……. 50

II.3.3.1. Modèles de régression linéaire locale (LLR) ……... 51
II.3.3.2. Modèles d'intelligence artificielle (IA) …… 52
A. Modèle réseau de neurones artificiels (RNA) …….. 53
B. Modèle Logique floue (LF) ……. 67
C. Modèles hybrides ……. 70
II.3.4. Modèles optimisés …….. 74
II.3.4.1. Modèles empiriques optimisés ……. 75
II.3.4.2. Modèles simulés optimisés ……... 76
II.4. Performance et évaluation des prédicteurs ……. 77
II.4.1. Coefficient de détermination (R^2) ……. 77
II.4.2. Racine de l'erreur moyenne quadratique (RMSE) ……. 77
II.4.3. Erreur de Biais Moyen (MBE) ……... 78
II.4.4. Erreur moyenne absolue en pourcentage (MAPE) ……. 78
II.5. Conclusion …….. 79

Chapitre III : Modélisation neuronale de l'irradiation solaire globale

- Première contribution -

III.1.1. Introduction ……... 80
III.1.2. Bases de données employées ……. 80
III.1.2.1. Sélection des entrées du modèle neuronal ……. 85
III.1.2.2. Préparation et partage de la base de données……. 86
III.1.2.3. Normalisation des données …… 88
III.1.3. Conception du modèle neuronal ……. 88
III.1.4. Analyse de sensibilité par la méthode des "poids" …… 94
III.1.5. Résultats et discussion …… 96
III.1.5.1. Performances des modèles ……. 96
III.1.5.2. Expressions mathématique des modèles neuronaux optimisés ……. 99
III.1.5.3. Analyse de la sensibilité des entrées par apport à la sortie …… 102
III.1.5.4. Interface de calcul de l'irradiation solaire globale ……. 102
III.1.5. Conclusion ……. 104

- Deuxième contribution-

III.2.1. Introduction ……... 105
III.2.2. Réseaux de neurones artificiels …… 106
III.2.3. Procédure de modélisation …… 108
III.2.3.1. Collecte et division de la base de données ……. 109
III.2.3.2. Modélisation avec les réseaux de neurones ……... 110
III.2.3.3. Modélisation par régression linéaire multiple (MLR) ……. 112
III.2.4. Résultats et discussion …….. 112
III.2.4.1. Réseaux de neurones ……. 112
III.2.4.1.1. Equation du réseau de neurone optimisé …….. 119
III.2.4.1.2. Analyse de sensibilité ……... 119
III.2.4.2. Régression linéaire multiple (MLR) ……. 120
III.2.5. Comparaison ……. 122
III.2.5.1. Comparaison entre le modèle neuronal et la régression linéaire multiple …… 122
III.2.5.2. Comparaison avec différents modèles …….. 123
III.2.6. Programme de calcul d'ISG …….. 125
III.2.7. Conclusion …… 126
Conclusion générale ……. 127
Références bibliographiques ……... 129

N° Figure	Déscription	N° Page
Fig I.1	Structure du soleil …….....	6
Fig I.2	Relation soleil-terre……	7
Fig I.3	Variation du rayonnement solaire extraterrestre avec le temps de l'année …….	7
Fig I.4	Répartition spectrale du rayonnement solaire …….	9
Fig I.5	Loi de Planck affichée pour différentes temperatures……	10
Fig I.6	Coordonnées terrestres ……	11
Fig I.7	Systèmes de coordonnées pour repérer la position apparente du soleil ……	11
Fig I.8	Variation annuelle de l'équation du temps ……	13
Fig I.9	Variation annuelle de la déclinaison solaire ……...	13
Fig I.10	Coordonnées solaires selon le repère horizontal ……	14
Fig I.11	Composantes du rayonnement solaire ……	16
Fig I.12	Définition de la masse d'air ……	18
Fig I.13	Spectre d'absorption du rayonnement solaire au niveau de la mer …….	20
Fig I.14	Processus de transmission, d'absorption, de diffusion et de réflexion dans l'atmosphère (les chiffres sont des pourcentages)……	21
Fig I.15	(a) Schéma d'un pyrhéliomètre. (b) Photo de Hukseflux DR01 ……	23
Fig I.16	(a) Schéma d'un pyranomètre. (b) Pyranomètre de première classe LP PYRA 12 AC équipé d'anneau d'ombre……	24
Fig I.17	(a) Schéma d'héliographe Campbell-Stokes. (b) Photo typique d'héliographe Campbell-Stokes……..	25
Fig I.18	Principe de l'effet photovoltaïque ……..	29
Fig I.19	Cellule photovoltaïque …….....	29
Fig I.20	Caractéristique I-V d'un module photovoltaïque …….....	31
Fig I.21	Effet de l'éclairement (a) et de la température (b) sur les caractéristiques I-V ……..	31
Fig I.22	Systèmes photovoltaïques autonomes connectés à un réseau électrique …….....	33
Fig I.23	Schéma d'un capteure plan …….	35
Fig I.24	Capteurs de concentration ……..	35
Fig I.25	Irradiation solaire globale dans le monde ……..	37
Fig I.26	Présentation des ratios du potentiel solaire …….	37
Fig I.27	Irradiation solaire globale dans l'Algérie ……...	38
Fig I.28	Durée d'insolation en Algérie …….	38
Fig II.1	Evolution du nombre d'articles publiés sur la modélisation d'irradiation solaire …….	41
Fig II.2	Techniques de modélisation d'irradiation solaire ……	42

FigII.3	Méthodologie de Box-Jenkins pour la sélection d'un modèle optimal ……	50
Fig II.4	Correspondance entre le neurone biologique et le neurone artificial ……	54
Fig II.5	Principe du neurone formel ……	55
Fig II.6	Architecture du réseau neuronal de perceptron multicouche MLP ……	56
Fig II.7	Exemple d'un réseau recurrent ……..	57
Fig II.8	Configuration typique d'un réseau RBF …….	58
Fig II.9	Modèle d'un système floue …….	68
Fig II.10	Fonction caractéristique f(σ) et fonction d'appartenance ……	69
Fig II.11	Ensembles et relations floues pour l'estimation de l'irradiation solaire …….	70
Fig II.12	Architecture du modèle ANFIS ……	72
Fig III.1.1	Distribution des différents sites utilisés pour le modèle du réseau de neurone sur la carte géographique algérienne ……	81
Fig III.1.2	Evolution mensuelle de l'irradiation solaire reçue sur un plan horizontal de l'année 2005 pour les quatre stations : (a) Adrar, (b) Médéa, (c) Tlemcen et (d) Souk Ahras……	83
Fig III.1.3	Evolution annuelle de l'irradiation globale reçue sur plan horizontal pour les quatre stations pendant les années 2004 (a), 2005 (b), et 2006 (c) ……	85
Fig III.1.4	Pourcentage de partage de la base de données …….....	87
Fig III.1.5	Organigramme de la méthodologie de calcul du RNSO ……	90
Fig III.1.6	Effet de l'algorithme d'apprentissage sur la performance des réseaux de neurons en termes d'erreur quadratique moyenne ……	91
Fig III.1.7	Effet de la fonction de normalisation sur la performance d'apprentissage du réseau de neurons ……	92
Fig III.1.8	Effet du nombre de neurones de la couche cachée sur la performance d'apprentissage du réseau de neurones :(a) chaque 5 neurones, (b) un neurone ……	93
Fig III.1.9	Effet du nombre de neurones dans les deux couches cachées sur la performance d'apprentissage du réseau de neurons …….....	94
Fig III.1.10	Organigramme de la méthode de "poids" …….....	95
Fig III.1.11	Schéma simplifié de l'architecture du réseau neuronal ……	97
Fig III.1.12	Comparaison entre les valeurs expérimentales et les valeurs prédites pour l'irradiation solaire globale : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test ……...	99
Fig III.1.13	Représentation schématique du RNS optimisé ……	100
Fig III.1.14	Importance relative des variables d'entrées sur la prédiction de l'irradiation solaire…	102
Fig III.1.15	Etapes à suivre pour l'élaboration de l'interface graphique de RNSO par MatLab®…	103

Fig III.1.16	Interface graphique développée pour le calcul l'irradiation solaire ……..	103
Fig III.2.1	Procédure de conception et d'optimisation de l'architecture d'un réseau de neurone artificial ……...	108
Fig III.2.2	Localisation géographique de Ghardaïa, Algérie ……...	109
Fig III.2.3	Réseau de neurones à trois couches …….....	111
Fig III.2.4	Comparaison entre les valeurs expérimentales et prédites pour l'ensemble des données : (a) apprentissage, (b) validation, (c) test et (d) la phase de généralisation……	114
Fig III.2.5	Comparaison entre les valeurs expérimentales et prédites de l'irradiation solaire globale pendant quelques jours, (a) représente deux jours parmi les plus favorable, (b) représente deux jours de la plus défavorable ……	115
Fig III.2.6	Comparaison entre les valeurs expérimentales et calculées de l'irradiation solaire globale pendant toute l'année 2013 ……	116
Fig III.2.7	Traces de résidus pour les données ……	118
Fig III.2.8	Tarte graphique illustrant l'importance relative des variables d'entrée, sur le rayonnement solaire global …….	120
Fig III.2.9	Comparaison entre les valeurs expérimentales et les valeurs prédites par le modèle MLR pour les données : (a) apprentissage, (b) validation, (c) test, et (d) Généralisation	121
Fig III.2.10	Comparaison entre les erreurs des résultats prédits par les modèles RNA et MLR	123
Fig III.2.11	Interface MALAB pour le calcul l'irradiation solaire globale ……..	125

N° Tableau	Description	N° Page
Tab I.1	Quelques chiffres clés du soleil ……	5
Tab I.2	Constante solaire en fonction du nombre d'air masse pour une atmosphère de type méditerranéen……	18
Tab I.3	Albédo typique de différentes surfaces ……	22
Tab II.1	Valeurs des constantes du modèle Angstrom-Prescott ……..	44
Tab II.2	Comportement du ACF et PACF pour le choix du modèle ARMA ……...	49
Tab II.3	Exemples représentatifs de l'utilisation de LLR à la prédiction du rayonnement solaire…..	52
Tab II.4	Exemples représentatifs de l'utilisation de RNA à la prédiction du rayonnement solaire global …….	60
Tab II.5	Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire à des surfaces inclinées …….	63
Tab II.6	Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire à des surfaces quotidien ……	64
Tab. II.7	Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire à court terme	66
Tab III.1.1	Liste des stations météorologiques retenues pour l'étude …….	81
Tab. III.1.2	Minimums et maximums des entrées utilisées ……..	88
Tab. III.1.3	Noms des codes des réseaux et les noms des algorithmes d'apprentissage utilisés lors de la phase de conception du modèle neuronal ……..	91
Tab. III.1.4	Différentes fonctions de normalisation utilisées ……	92
Tab. III.1.5	Structure du réseau de neurones optimisé …….	96
Tab. III.1.6	Poids et biais du RNS optimal ……..	101
Tab. III.2.1	Analyse statistique des entrées et de sortie ……	110
Tab. III.2.2	Paramètres sélectionnés du RNA optimal …….	111
Tab. III.2.3	Structure du modèle RNA optimisé ……..	111
Tab. III.2.4	Analyses statistiques, vecteurs d'accords de validation et la performance du modèle RNA	117
Tab. III.2.5	Coefficients de modèle estimé par analyse de la régression linéaire multiple ……..	122
Tab. III.2.6	Résultats de notre modèle par rapport aux différents modèles similaires …….	125

Introduction générale

Introduction générale

L'épuisement des ressources fossiles, à plus ou moins long terme, la flambée des cours du brut et la lutte contre les émissions de gaz à effet de serre rendent urgentes la maitrise des consommations et la diversification des sources d'énergie, à savoir l'utilisation et le développement des énergies renouvelables.

Le monde évolue et avec lui des caractéristiques comme l'augmentation de la population, de l'activité industrielle et du changement du style de vie. La consommation énergétique mondiale augmente sans cesse depuis 50 ans et rien ne laisse présager un ralentissement de cette croissance, surtout dans les pays émergents. La demande actuelle en énergie peut donc servir de référence et de minorant strict pour évaluer la consommation future. Les ressources énergétiques de la planète se présentent sous deux formes différentes : énergies renouvelables et énergies épuisables.

Pour subvenir aux besoins en énergie de la société actuelle, il est nécessaire de trouver des solutions adaptées et de les diversifier. Actuellement, il y'a principalement deux façons possibles d'agir. La première est de diminuer la consommation des récepteurs d'énergie et augmenter la productivité des centrales énergétiques en améliorant respectivement leur efficacité. Une deuxième démarche consiste à trouver et à développer de nouvelles sources d'énergie.

À l'heure actuelle, la plupart de l'énergie provient de combustibles fossiles tels que le gaz, le charbon et le pétrole. Les combustibles fossiles fournissent plus de 80% de notre énergie primaire. Toutefois, les risques associés à leur utilisation nécessitent une attention immédiate ; les biocarburants, principalement pour le chauffage et la cuisson, contribuent de 10%; et l'énergie nucléaire contribue de 5%. Cela laisse moins de 5% de notre énergie que nous obtenons à partir de l'énergie hydraulique et des autres énergies renouvelables (IEA 2013).

De plus, l'environnement mondial a déjà été touché de façon importante et sur certaines régions, il a été gravement endommagé. Le secteur de l'énergie a un rôle clé à cet égard puisque l'énergie lors de sa production, sa distribution et sa consommation est responsable de la production de substances nocives pour l'environnement. Le dégagement du dioxyde de carbone (CO_2) a été et reste une cause majeure du phénomène d'effet de serre, sans oublier les autres gaz, comme la vapeur (H_2O), les oxydes d'azote (NO_x) et le méthane (CH_4). Ces gaz sont attardés en quantités croissantes dans la basse atmosphère provoquant une augmentation de la température moyenne mondiale de 0.6°C par an (Solomon *et al.*, 2007). Ainsi, les combustibles fossiles sont devenus un acteur principal dans la pollution de l'air, des pluies acides, de la

destruction de la couche d'ozone et du changement climatique mondial. Par conséquent, le monde a besoin d'une énergie propre et abondante.

Une des solutions possibles à ce problème est simplement de consommer moins. Accroître l'efficacité des systèmes actuels est une autre option. L'utilisation des combustibles fossiles devrait également être réduite pour minimiser les émissions de gaz à effet de serre. De plus, l'exploitation de l'énergie solaire semble être l'un des meilleurs moyens pour relever le défi de l'énergie. Compte tenu de son abondance, de sa source gratuite, de sa distribution plus uniforme dans le monde et notamment sa préservation de l'environnement, l'énergie solaire devrait avoir clairement une place privilégiée dans le paysage énergétique.

Cependant, l'énergie solaire produit encore moins de 1% d'électricité dans le monde (IEA, 2013). D'un autre côté, les deux formes primaires de l'énergie solaire que sont la chaleur et la lumière, peuvent être transformées et absorbées par l'environnement par une multitude de façons. Bien que le rayonnement direct puisse être concentré pour produire des températures très élevées, le rayonnement diffus fournit la plupart des "lumière du jour" et, par conséquent, est vital pour les industries de construction. Le rayonnement diffus est également utilisé dans l'analyse du bilan énergétique de l'atmosphère et dans les processus photo-biologique. Ces avantages par rapport aux autres énergies, rendent l'énergie solaire comme un pivot dans tout programme sérieux de développement durable. Par ailleurs, une connaissance précise et détaillée d'irradiation solaire globale disponible sur une région est d'une importance primordiale pour la conception et le développement de systèmes de conversion de l'énergie solaire.

Les données du rayonnement sont insuffisantes dans de nombreux pays. Cette insuffisance se produit de trois façons: couverture spatiale limitée; longueur limitée de l'enregistrement et la prédominance des données pour des surfaces horizontales tandis que les données des surfaces inclinées sont plus appropriées pour les évaluations de l'énergie solaire (Hay, 1979).

Cette situation a incité le développement de procédures de calcul comme la modélisation. La modélisation du rayonnement solaire joue un rôle important. L'irradiation solaire est l'un des paramètres météorologique les plus difficiles à modéliser du fait qu'elle est fonction de plusieurs paramètres géographiques et astronomiques et est tributaire des conditions météorologiques et astronomiques. Il est donc nécessaire de développer des modèles se basant sur les données de stations disponibles, comme le rayonnement extraterrestre, la durée d'ensoleillement, la température moyenne, l'humidité relative, la pression atmosphérique, la vitesse du vent, la précipitation, l'altitude, la latitude, la longitude et la nébulosité.

Au fil du temps, plusieurs méthodes pour estimer le rayonnement solaire sur la surface horizontale ont a été développées, parmi ceux-là, on cite : les modèles expérimentaux (Halawa *et al.,* 2014) et un modèle algorithmique stochastique (Hocaoğlu, 2011). Ces méthodologies ont montré peu de performance lors de la prévision des données sur les rayonnements solaires à long terme. Cependant, pour arriver à surmonter ces problèmes, les recherches actuelles sont orientées vers l'utilisation de techniques basées sur les réseaux de neurones artificiels (Olatomiwa *et al.,* 2015). A ce titre, l'objectif de notre thèse s'inscrit dans cette démarche.

La thèse englobe trois chapitres :

Le premier est un rappel axé sur certaines connaissances de base concernant le soleil, l'irradiation solaire, ses composants, ses variables significatives, les techniques de mesure et les paramètres qui gouvernent l'ensoleillement, les conversions possibles de cette forme d'énergie**,** ainsi que le potentiel solaire dans le monde et notamment en Algérie.

Dans le second chapitre, nous présenterons les différents modèles et méthodes de prédiction. Ainsi, nous présenterons une revue de la littérature concernant les recherches qui ont une relation avec le thème de cette thèse.

Le troisième et dernier chapitre sera consacré quant à lui, à la modélisation neuronale. Il comporte deux contributions : la première traite d'une façon détaillée la méthodologie d'optimisation du modèle neuronal pour la prédiction du rayonnement solaire. Dans la seconde, on discutera et on comparera les modèles du réseau neuronal avec le modèle de régression linéaire multiple (RLM).

En dernier, une conclusion clôturera cette thèse et dans laquelle sont mis en évidence les résultats obtenus ainsi que les perspectives qui peuvent être envisagées dans le futur.

Chapitre I

Irradiation solaire : Etat de l'art

I.1. Introduction

Nous allons commencer ce chapitre en introduisant quelques connaissances de base sur le rayonnement solaire. Nous essayerons de donner un aperçu sur les principales caractéristiques du rayonnement solaire. On discutera sur la définition de base de l'irradiation solaire, sur les effets de l'atmosphère sur la transmission du rayonnement solaire et sur les composants du rayonnement solaire au niveau du sol. Ce chapitre qui couvre également la plupart des méthodes de mesure du rayonnement solaire, comprend une description des capteurs radiométriques et leurs principes de fonctionnement. A la fin, Une brève discussion sur le gisement solaire mondiale et notamment dans l'Algérie est présentée.

I.2. Le soleil

Le soleil est la source fondamentale de presque toute l'énergie sur la terre et est le principal moteur de son système climatique. Le soleil est une immense sphère de plasma (matière ionisée) dont le diamètre atteint 1.39 million de kilomètres, ce qui correspond à une surface totale (Ss) égale à 6.08x1018 m^2. Il est situé à une distance moyenne de 150 millions de kilomètres de la terre. Composé de matière gazeuse, essentiellement d'hydrogène (73.5%) et d'hélium (24.9%), il est le siège de réactions de fusion nucléaire permanentes et sa température de cœur atteint 10^7°K (Daoud, 2013).

L'énergie solaire est le résultat des réactions de fusion nucléaire qui se produisent entre l'hydrogène et l'hélium au centre du soleil. L'énergie peut être divisée en deux catégories : le rayonnement de la matière et le rayonnement électromagnétique. Le rayonnement de la matière comprend les protons et les électrons libérés par le soleil à une vitesse d'environ 500 km/s. Cependant, très peu d'entre eux atteignent la surface de la terre, car la quasi-totalité sont déviés loin par le champ magnétique terrestre. La plupart de l'énergie solaire atteignant la terre est sous la forme d'un rayonnement électromagnétique (Aschwanden, 2006). Ce rayonnement est principalement libéré à la photosphère du soleil, qui a une température d'environ 5776°K. L'énergie de rayonnement E_s peut être calculée par l'équation ci-dessous (Sick & Erge, 1996):

$$E_s = \frac{M_s \pi D_s^2}{\pi (2L_{es})^2} \tag{I.1}$$

M_s est la densité de flux de rayonnement solaire, qui est d'environ $63.5 \cdot 10^6$ W/m^2

D_s est le diamètre du soleil, ce qui représente environ $1.39 \cdot 10^9$ m

L_{es} est la distance entre le soleil et la terre, avec une valeur moyenne d'environ $1.5 \cdot 10^{11}$ m.

Le tableau suivant montre les données caractéristiques principales du soleil :

Tableau I. 1 : Quelques chiffres clés du soleil (Jenkins, 2013)

DONNEES CARACTERISTIQUES	**VALEUR**
Age	$4.6 \cdot 10^9$ ans
Poids	$1.99 \cdot 10^{30}$ Kg
Densité moyenne	1.41 Kg/m^3
Diamètre	$1.392 \cdot 10^9$ m
Surface	$6.088 \cdot 10^{18}$ m^2
Température au centre	$1.6 \cdot 10^7$ °K
Température à la surface	5776 °K
Pression dans le noyau	$4 \cdot 10^{11}$ bar
Rotation des pôles	34 Jours
Rotation de l'équateur	25.4 Jours
Durée de vie (approx. ½ temps de combustion)	5.10^{10} ans
Distribution de la masse	H_2 : 70 % He : 28 % C, N, O, … : 2 %
Consommation de carburant H_2	600 Mt/s
Production d'hélium	596 Mt/s
Différence de masse	4.3 Mt/s

La structure du soleil est schématisée sur la Figure (I.1). On distingue quatre zones particulières ; le noyau, la photosphère, la chromosphère et la couronne. Donc, le rayonnement solaire extraterrestre émis est le résultat composite de plusieurs couches qui émettent et absorbent le rayonnement à différentes longueurs d'onde (Duffie & Beckman, 1980).

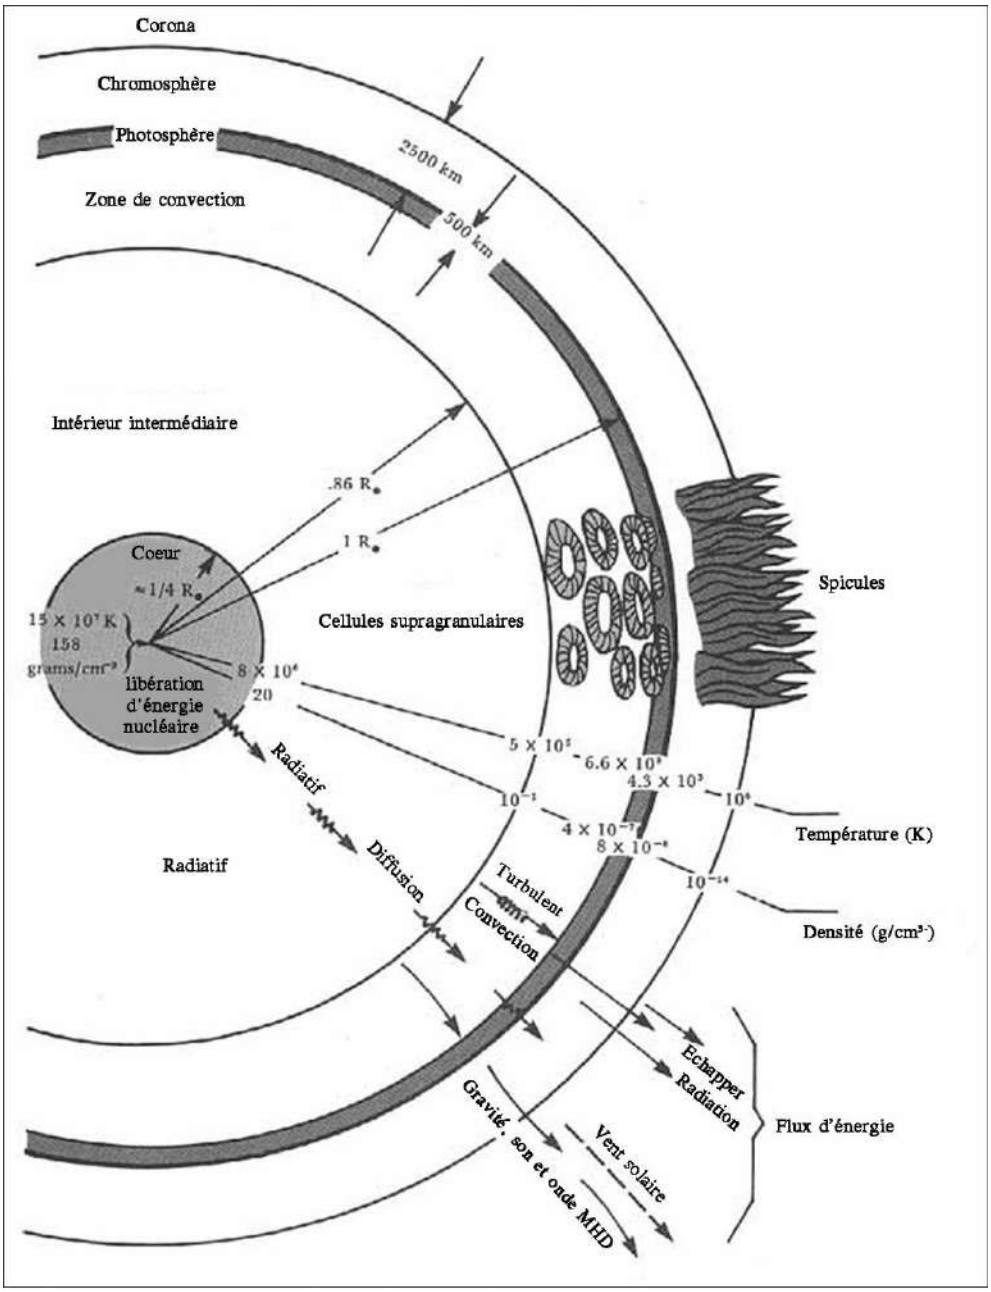


Figure I. 1 : Structure du soleil (Homer, 2011)

I.2.1. Relation soleil-terre

La terre tourne autour du soleil sur une orbite légèrement elliptique. Elle occupe avec le soleil l'un des foyers de l'ellipse. La forme elliptique est presque ronde avec un grand axe de $1.4958 \cdot 10^8$ km, un demi-petit axe de $1.4966 \cdot 10^8$km et une excentricité de 0.0167. Ce qui signifie que le Périhélie, par opposition à l' Aphélie de la terre comparativement au soleil varie de 1,7%(Sick & Erge, 1996). La Figure I**.** 2 représente schématiquement la géométrie de la relation Terre-Soleil.

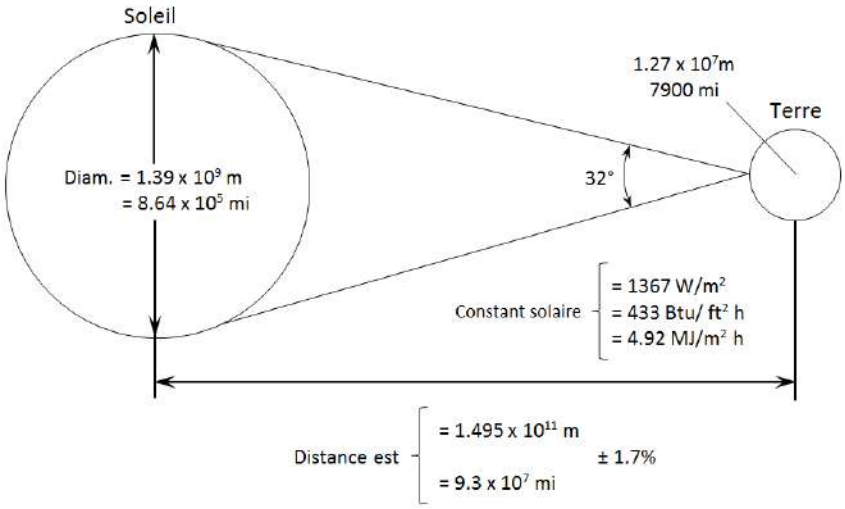


Figure I. 2 : Relation soleil-terre (Duffie & Beckman, 1980)

Par conséquent, la constante solaire, qui est la quantité de rayonnement électromagnétique solaire entrant par unité de surface avant de pénétrer dans l'atmosphère, est calculée pour être d'environ 1367 W/m^2. Cette valeur change à mesure que la distance entre le soleil et la terre varie en un an, d'environ 1320 W/m^2 à 1420 W/m^2 (Fig. 3). Au fil des ans, cette variation diminue à 0,1% en raison de l'activité solaire (Kaltschmitt *et al.,* 2007). On peut obtenir aussi le rayonnement solaire normal extraterrestre en entrant la n^{ème} journée de l'année dans l'équation (I.2) :

$$H_0 = I_0 \left(1 + 0.033 cos \frac{360\, n}{365}\right) \tag{I.2}$$

H_0 : rayonnement solaire normal extraterrestre [W/m^2]

I_0 : constante solaire qui est égale 1367 W/m^2

n : le nombre de jour de l'année

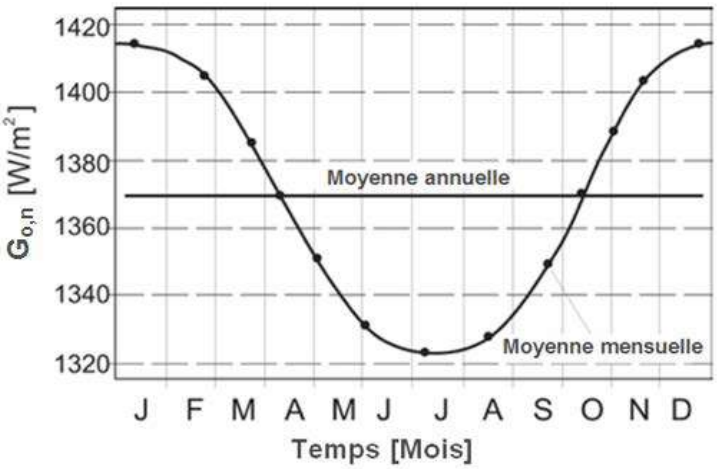


Figure I. 3 : Variation du rayonnement solaire extraterrestre avec le temps de l'année (Fröhlich *et al.*, 1991)

I.3. Irradiation solaire

L'irradiation solaire qui atteint la surface de la terre, appelée irradiation horizontale globale, est toujours inférieure à l'irradiation extraterrestre (H_0). L'irradiation est la quantité d'énergie solaire par unité de surface. Une partie de l'irradiation horizontale globale passe à travers l'atmosphère sans interaction moléculaire visible et arrive directement à partir du faisceau solaire. Elle est donc qualifiée comme irradiation horizontale directe, H_D. L'irradiation horizontale globale restante est dispersée dans l'atmosphère avant d'atteindre finalement la surface de la terre. Ce rayonnement dispersé est appelé irradiation horizontale diffus, H_F.

La relation entre ces trois rayonnements est décrite par Coulson (Coulson 2012)et représentée dans l'Eq. I.3 :

$$H = H_D + H_F \tag{I.3}$$

I.3.1. Irradiation Spectrale

Pour la plupart des dispositifs solaires de conversion d'énergie, la compréhension du spectre est tout aussi importante que de comprendre l'amplitude de l'irradiation. Les dispositifs réagissent différemment à des portions différentes du spectre électromagnétique. Environ 99% du spectre d'émission du soleil sont des radiations à ondes courtes, allant d'environ 300 nm à 3000nm. La bande d'ondes courtes est de plus subdivisée sur le proche infrarouge qui représente 37%, la lumière visible qui représente 44% et l'ultraviolet qui représente 7% du rayonnement solaire.

La Figure I**.** 4 montre les spectres de référence pour les trois types d'irradiation (extraterrestre, globale et directe). La constante solaire, dont nous avons parlé précédemment, est basée sur l'intégrale du spectre extraterrestre. La Figure I**.** 4 montre aussi le spectre terrestre (global) lors de son passage à travers l'atmosphère à 48.19° qui est une approximation moyenne de la longueur de l'atmosphère pendant la journée. Les creux dans les spectres ont lieu en raison de l'absorption de rayonnement par divers gaz dans l'atmosphère.

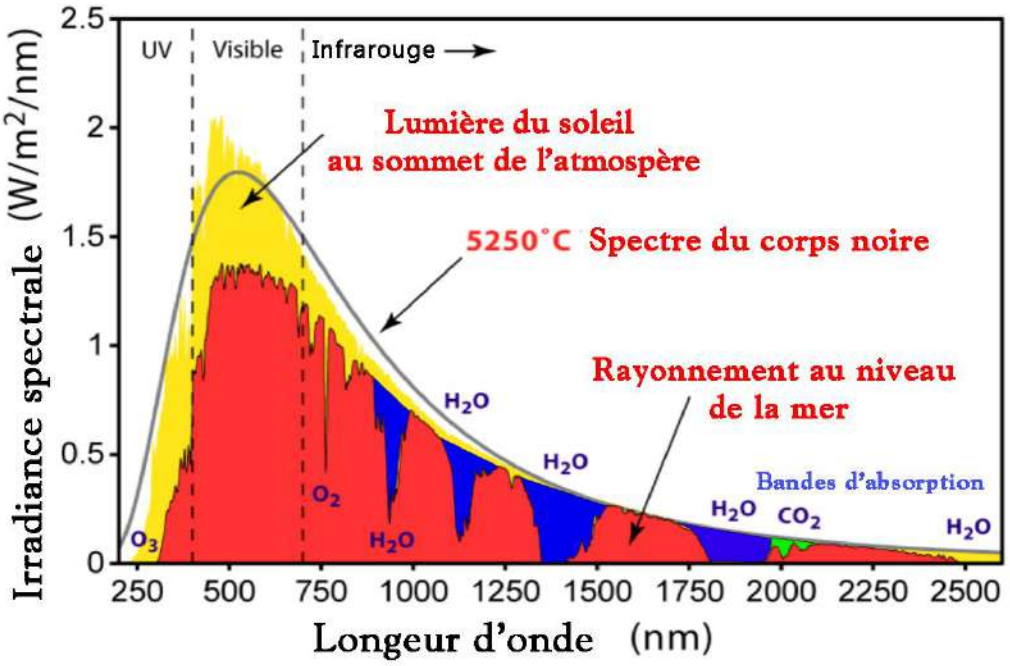


Figure I. 4 : Répartition spectrale du rayonnement solaire (Keller & Costa, 2011;William, 2015)

I.3.2. Irradiation d'un corps noir

L'irradiation du soleil ressemble étroitement à l'irradiation d'un corps noir. Un corps noir est un corps qui absorbe tout le rayonnement entrant et émet un rayonnement maximal possible compte tenu de sa température. Il peut être estimé en utilisant la loi de Stefan-Boltzmann montrée dans l'équation (I.4) (Iqbal 2012) :

$$P = A.\sigma.T^4 \qquad \text{(I.4)}$$

Où

P est la puissance émise par le corps noir en [W],

A est la surface de l'objet en [m^2],

T est la température en [°C]

et σ est la constante de Stefan-Boltzmann ($\sigma = 5{,}6697\times10^{-8}$ W/m².T^4).

L'irradiation solaire est fonction de la longueur d'onde et de la température, ce qui est vrai pour toute surface dont la température est supérieure à zéro. La distribution radiative d'un corps noir a été montrée par Max Planck en 1900 et est représentée sur la Figure I**.** 5. L'axe supérieur est représenté par l'énergie et l'axe inférieur est représenté par la longueur d'onde.

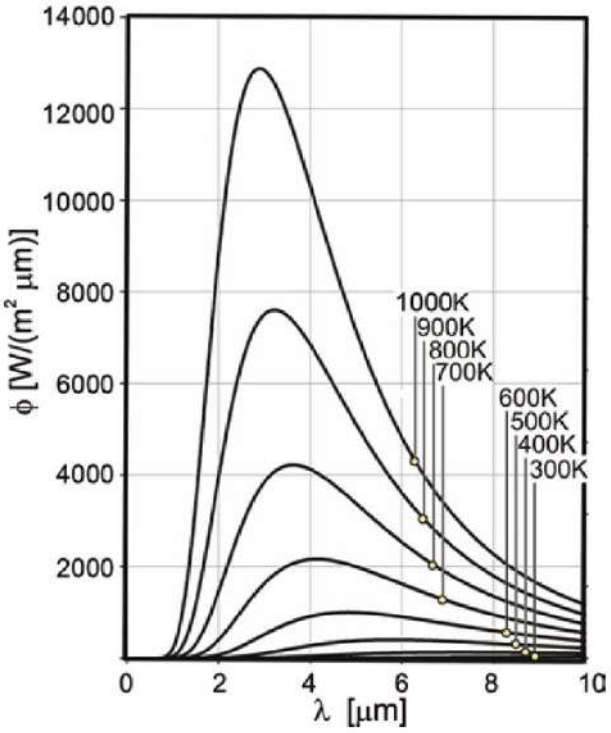


Figure I. 5 : Loi de Planck affichée pour différentes températures (Iqbal, 2012)

I.4. Position du soleil par rapport à la terre

Il est possible de déterminer la position du soleil dans la voûte céleste en fonction du temps et de la position de l'observateur sur la terre.

I.4.1. Coordonnées géographiques terrestres

Pour repérer un site donné à la surface de la terre, on définit les grandeurs suivantes (Fig. 6) :

- **Latitude (θ) :** C'est l'angle θ que fait la verticale du lieu avec le plan équatorial. Elle varie entre 0 et 90°, positivement vers le pôle Nord et négativement vers le pôle sud.
- **Longitude (φ) :** C'est également un angle φ donné par rapport au méridien de Greenwich et le méridien du lieu considéré. Elle est comptée de 0 à 180°, positivement vers l'est et négativement vers l'ouest.
- **Altitude :** L'altitude est l'élévation d'un lieu par rapport au niveau de la mer, mesurée en mètre (m).

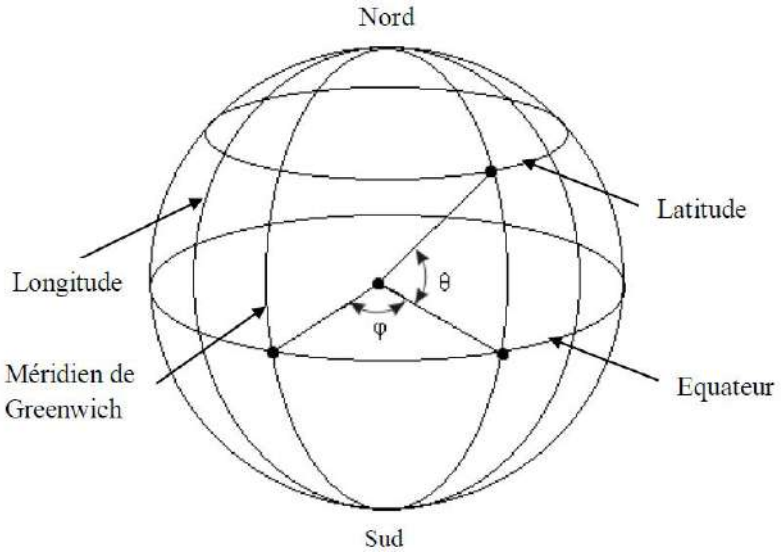


Figure I. 6 : coordonnées terrestres (Meziani, 2012).

I.4.2. La trajectoire apparente du soleil

Pour un lieu donné, la position du soleil est repérée à chaque instant de la journée et de l'année par deux systèmes de coordonnées différents (Bouden, 2008), comme on peut le voir sur la Figure I**.** 7.

- Par rapport au plan équatorial de la terre (repère équatorial).
- Par rapport au plan horizontal du lieu (repère horizontal).

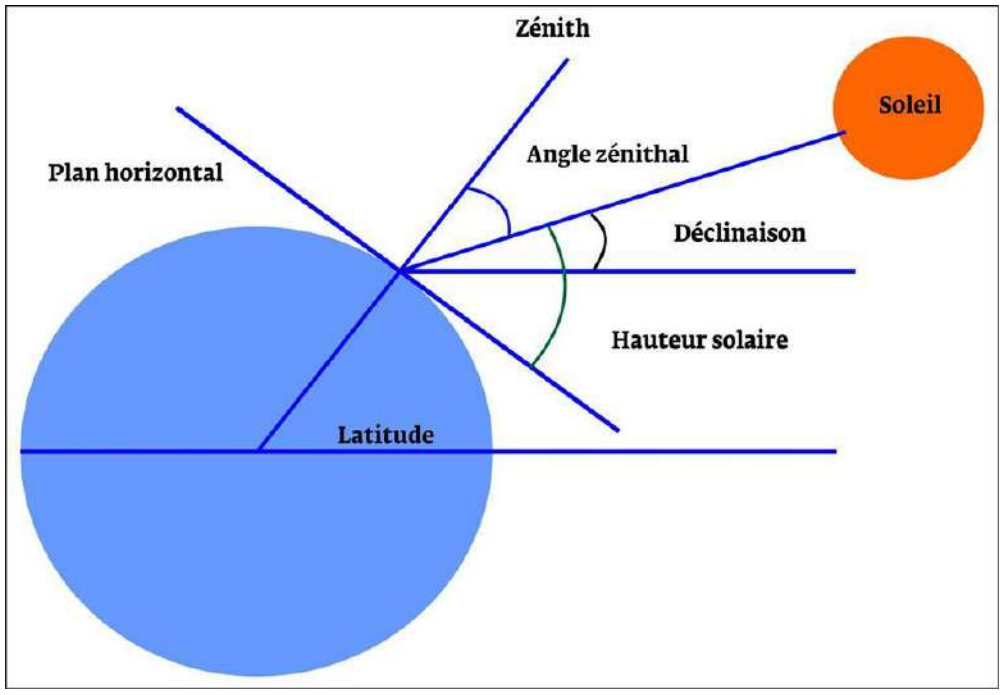


Figure I. 7 : Systèmes de coordonnées pour repérer la position apparente du soleil (Thomas, 2014).

I.4.2.1. Coordonnées équatoriales

- *Angle d'incidence*

Il y a un ensemble de relations utiles entre ces angles. L'équation reliant l'angle d'incidence sur une surface aux autres angles est (Duffie& Beckman, 1980):

$$\cos\theta = sin\delta\ sin\Phi\ cos\beta - sin\delta\ cos\Phi\ sin\beta\ cos\gamma + cos\delta\ cos\Phi\ cos\beta\ cos\omega$$
$$+cos\delta\ sin\Phi\ sin\beta\ cos\gamma\ cos\omega + cos\delta\ sin\beta\ sin\gamma\ sin\omega \quad \text{(I.5)}$$

- *Angle horaire*

L'angle horaire ω comme tous les autres angles est calculée en degrés :

$$\omega = \frac{360}{24}(12 - TSV) \quad \text{(I.6)}$$

Où *TSV* est le temps solaire vrai.

Le temps solaire vrai peut être déduit à partir de la relation :

$$TSV = TU + ET + 4\varepsilon\,|\varphi_r - \varphi| \quad \text{(I.7)}$$

φ_r est la longitude de référence etφ la Longitude locale

ε= +1 ; pour φà l'Est de $\varphi_r$$\varepsilon$= −1 ; pour φ à l'Ouest de φ_r

ET est l'équation du temps (minute) donnée par la relation (I.8) (due à la variation de la vitesse de la Terre autour du Soleil) et elle est illustrée sur la Figure I**.** 7 :

$$ET = 9.87\sin(2\gamma) - 7.53\cos(\gamma) - 1.5\,sin(\gamma) \quad \text{(I.8)}$$

Où γ en radian.

TU est le temps universel qui est le temps solaire moyen mesuré à partir de Greenwich (GMT) avec minuit comme origine.

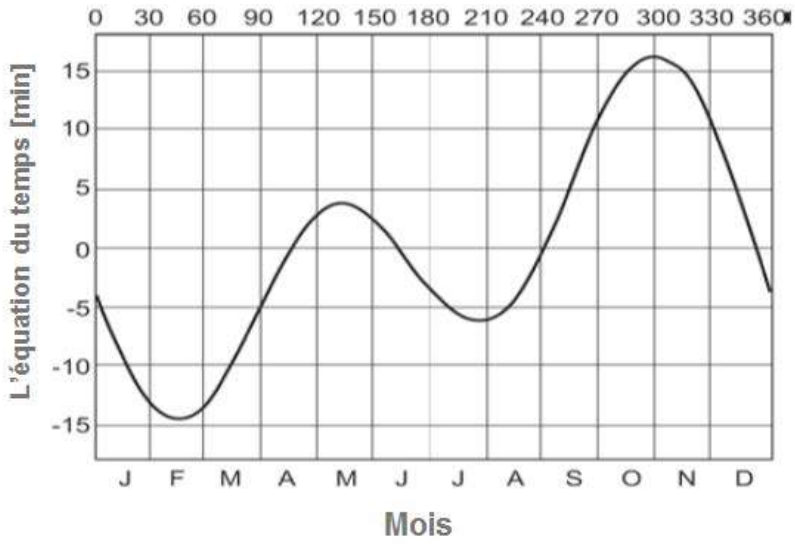


Figure I. 8 : Variation annuelle de l'équation du temps (Iqbal, 2012;William, 2015)

- *Déclinaison*

Plusieurs expressions ont été développées pour évaluer la déclinaison, la plus simple étant celle utilisée par Cooper (Cooper, 1969):

$$\delta = 23.45\ sin\left(360\ \frac{284+n}{365}\right) \qquad \text{(I.9)}$$

La variation de la déclinaison du soleil au cours de l'année est représentée sur la Figure I**.** 9.

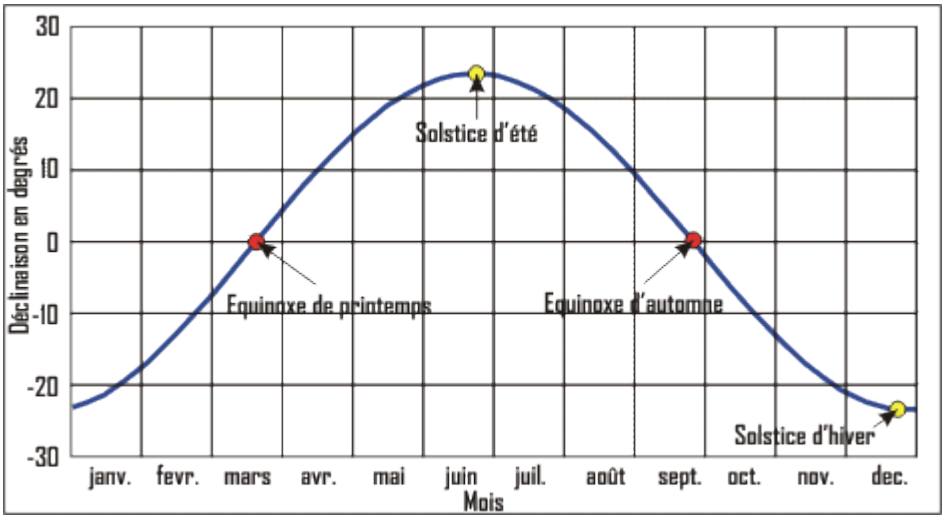


Figure I. 9 : Variation annuelle de la déclinaison solaire (Duffie & Beckman, 1980)

I.4.2.2. Coordonnées horizontales

- *Hauteur du soleil*

La hauteur du soleil (h) varie à chaque instant de la journée et de l'année selon la relation suivante (Duffie & Beckman, 1980; Benkaciali, 2014):

$$\sin(h) = cos(\delta)cos(\Phi)cos(\omega) + sin(\Phi)sin(\delta) \quad \text{(I.10)}$$

- *Azimuth* γ_s

Il se compte de 0° à 360° à partir du sud dans le sens rétrograde. La relation qui donne l'azimuth est donnée ci-dessous (Iqbal, 2012):

$$cos\gamma_s = (\sin h \sin \Phi - \sin \delta)/\cos h \cos \Phi \quad \text{(I.11)}$$

- *Angle zénithal* θ_z

L'angle θ_z est complémentaire de h(Iqbal 2012):

$$\cos(\theta_z) = sin(\Phi)sin(\delta) + cos(\delta)cos(\Phi)cos(\omega) \quad \text{(I.12)}$$

La Figure I**.** 10 montre les différentes coordonnées solaires. En tant que base, on suppose que la superficie de l'emplacement terrestre est horizontale et la direction d'irradiation solaire directe est choisie de manière arbitraire.

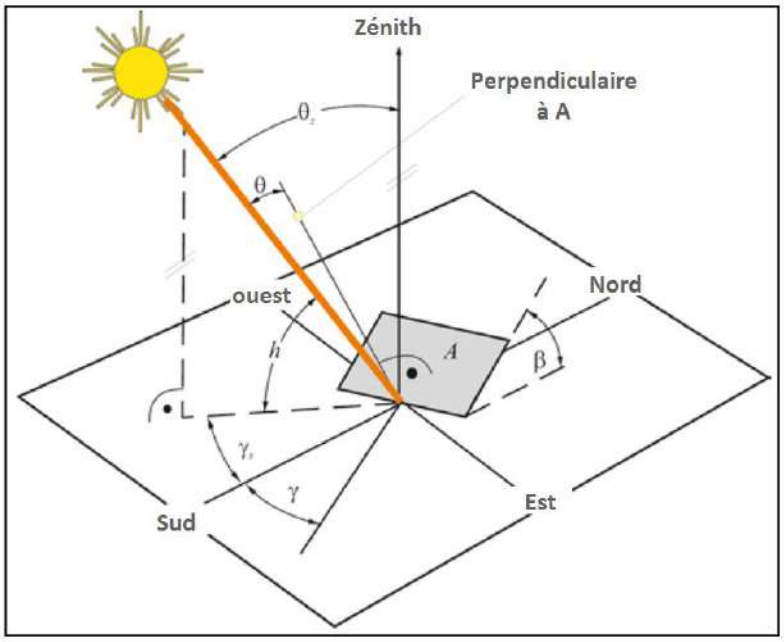


Figure I. 10 : Coordonnées solaires selon le repère horizontal (Paulescu *et al.* 2012;Thomas ,2014)

On définit :

- θ est l'angle entre la direction de la lumière et la normale d'une surface orientée de manière arbitraire A,
- θ_z est l'angle zénithal, défini comme étant l'angle entre le soleil et la normale au plan horizontal sur lequel est située la surface A,
- Φ est latitude, l'angle que fait la verticale du lieu avec le plan équatorial. Si $\theta > 0$, le site se trouve dans l'hémisphère nord, sinon le site est dans l'hémisphère sud,
- φ est longitude, l'angle qui est formé par le méridien de Greenwich et le méridien du lieu considéré. La longitude est comprise entre -180 (vers l'ouest) et +180 (vers l'est),
- h est l'angle d'élévation du soleil. Dans ce qui suit, on applique : $h + \theta_z = 90°$,
- δ est la déclinaison de la terre, définie comme l'angle entre le pic du soleil et l'équateur, et varie entre -23.5° et + 23,5°,
- γ est l'angle d'azimuth de la surface normale de A. Il décrit la différence de la projection horizontale à la surface normale du sud,
- γ_s est l'angle d'azimuth de la direction de rayonnement. Il indique l'écart de la projection horizontale de la direction d'irradiation du sud,
- ω est l'angle horaire, (dans les cas simples 1h=15° ; le matin $\omega<0$ et l'après-midi $\omega> 0$).

I.5. Influence de l'atmosphère sur le rayonnement solaire

I.5.1. Atmosphère

L'atmosphère est composée de différentes couches superposées les unes sur les autres. Depuis le sol, on distingue notamment la troposphère, puis la stratosphère, la mésosphère, suivie de la thermosphère.

L'atmosphère terrestre est composée essentiellement d'azote et d'oxygène. L'air propre et sec est composé de 78 % d'azote, de 21 % d'oxygène, de 1 % d'argon, et de 0,33 % de dioxyde de carbone. On rajoute à cela la vapeur d'eau et les aérosols. Les aérosols sont des particules soit d'origine naturelle, telles que le sable, la suie, les cristaux de glace, ou les poussières volcaniques, soit d'origines artificielles telles que celles produites par l'industrie, l'automobile ou le chauffage.

Ainsi l'atmosphère se décompose en trois groupes : les molécules d'air sec et les gaz permanents, le contenu en eau, et les aérosols. Le rayonnement terrestre en traversant l'atmosphère est donc atténué par chacun de ces groupes.

Lors de son passage dans l'atmosphère terrestre, le rayonnement solaire est considérablement atténué, il n'est donc pas aussi évident de déterminer la valeur du rayonnement solaire à la surface de la Terre que de connaître celle atteignant une surface horizontale au sommet de l'atmosphère. En effet, le rayonnement solaire piégé par notre planète est en partie "utilisé" lors de transformations photochimiques dans les hautes couches atmosphériques (ozone), en partie absorbé par les gaz atmosphériques (vapeur d'eau, oxygène, gaz carbonique, ...), diffusé par les molécules (azote et oxygène) ou diffracté par les gouttelettes nuageuses et les aérosols (Fig. 11).

Le rayonnement direct comme son nom l'indique est le rayonnement solaire reçu directement du soleil à n'importe quel point sur la Terre sans aucune perturbation. Le rayonnement réfléchi, quant à lui, est principalement renvoyé par la surface réceptrice, cette composante étant plus importante dans les régions montagneuses.

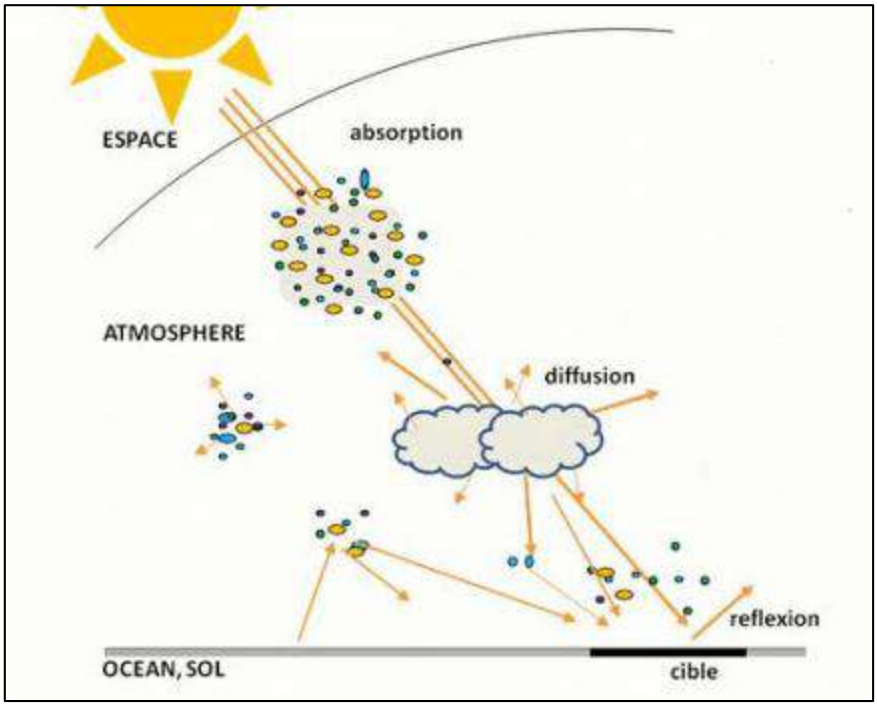


Figure I. 11 : Composantes du rayonnement solaire (Oumbe, 2009).

Le rayonnement solaire qui se fait disperser en passant par l'atmosphère de la terre est appelé rayonnement diffus et il comprend à la fois le rayonnement solaire réfléchi par les nuages et le rayonnement solaire réfléchi par la Terre. La quantité de rayonnement solaire atteignant n'importe quel point de la surface de la Terre dépend de la position de ce point, du moment de l'année, de la diffusion atmosphérique, de la couche des nuages et de la forme et la réflectivité de la surface réceptrice.

I.5.2. Masse atmosphérique

L'intensité d'absorption et de diffusion que subit le rayonnement solaire à la traversée de l'atmosphère est liée à la quantité de molécules rencontrées par ce rayonnement. La loi de transmission est donnée par la relation suivante :

$$Q = Q_0 \exp(-Kl) \tag{I.13}$$

De telle sorte que :

Q est le flux énergétique sortant après un parcours de longueur (l) dans l'atmosphère

Q_0 est le flux énergétique incident

K est le coefficient d'extinction caractérisant l'absorption et la diffusion

La masse atmosphérique ou (masse d'air notée AM) est l'épaisseur verticale de l'atmosphère moyen au niveau de la mer (Fig. 12), dans les conditions normales de température et de pression. La masse atmosphérique est définie par l'expression suivante :

$$AM = \frac{P}{1013} \frac{1}{\sin(h)} exp\left(\frac{-Z}{7.8}\right) \tag{I.14}$$

Où

P est la pression de l'air (N/m^2)

H est la hauteur solaire, sur l'horizon (h = 90° au zénith)

Z est l'altitude en (km)

Dans les conditions normales ($p = 1013\ N/m^2$) et au niveau de la mer (Z = 0), l'expression da la masse atmosphérique est simplifiée à :

$$\mathrm{AM} = \frac{1}{\sin(h)} \tag{I.15}$$

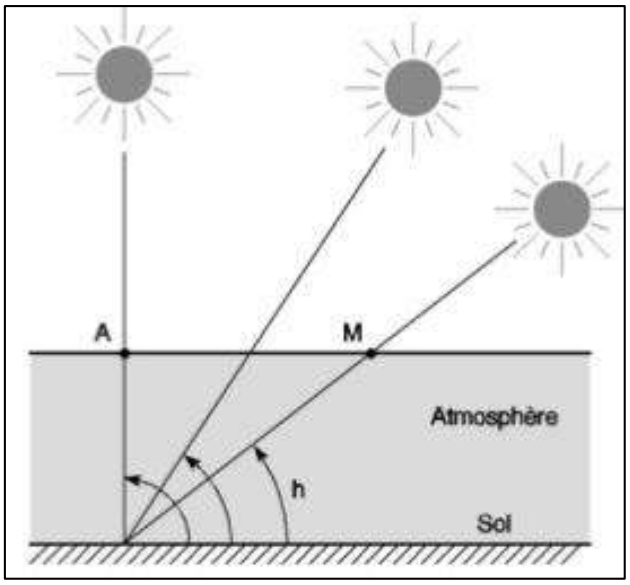


Figure I. 12 : Définition de la masse d'air (Solanki, 2015)

Ainsi lorsque le soleil est au zénith, on a AM1 avec un soleil à 30° sur l'horizon, on aura AM2 et pour le soleil à 48° l'AM est de 1.5 ; par convention AM0 désigne le rayonnement solaire hors atmosphère. Le tableau 2 nous donne la constante solaire (I_0) en fonction de la masse d'air.

Tableau I. 2: Constante solaire en fonction du nombre d'air masse pour une atmosphère de type méditerranéen (Solanki, 2015)

AM	**0**	**1**	**1.5**	**2**	**3**	**4**	**5**
I_0 (W/m^2)	1353	931	834	755	610	530	430

I.5.3. Absorption atmosphérique

L'absorption par les gaz atmosphériques est dite sélective : elle concerne des bandes de longueur d'onde réparties de façon discrète dans le spectre solaire. L'absorption atmosphérique est due essentiellement à l'ozone (O_3), l'oxygène (O_2), le gaz carbonique (CO_2), et la vapeur d'eau (H_2O) et en moindre partie à l'azote (N_2), au monoxyde de carbone (CO), aux hydrocarbones (CH_4, C_2H_4, C_2H_6, C_3H_8), aux oxydes d'azote (N_2O, NO_2, N_2O_4, N_2O_5), et aux gaz rares. Si l'azote, l'oxygène, le gaz carbonique, les gaz rares et les oxydes d'azote (par ordre décroissant de concentration) sont répartis uniformément dans l'atmosphère, il n'en est pas de même pour la vapeur d'eau et l'ozone dont les concentrations varient en fonction du lieu et du moment considéré. A l'origine de l'absorption, on distingue plusieurs phénomènes physiques, tels que la transition de la molécule d'un niveau d'énergie à

un autre, les rotations moléculaires, les transitions électroniques de liaison, ou les vibrations intramoléculaires. Ces processus ne se produisent qu'à certaines longueurs d'onde, l'absorption est donc sélective (Pavlov, 2016).

I.5.3.1. Absorption dans l'ultraviolet

Cette absorption est causée principalement par l'ozone arrêtant ainsi la quasi-totalité des longueurs d'onde comprises entre 210 et 290nm. Les gaz monoatomiques d'oxygène et d'azote absorbent les rayonnements de longueur d'onde entre 85nm et celle des rayons X. Comme ces gaz se situent dans la couche la plus haute de l'atmosphère (produits par dissociation des molécules biatomiques), alors ils constituent un véritable bouclier aux faibles longueurs d'ondes. Les gaz biatomiques d'oxygène et d'azote absorbent les rayonnements de bandes spectrales inférieures à 200nm. L'ozone a une bande de forte absorption entre 200 et 300nm et quelques-unes moins importantes entre 300 et 350nm (Pavlov, 2016).

I.5.3.2. Absorption dans le visible

C'est l'ozone et l'oxygène diatomique qui sont les principaux responsables de la diminution énergétique du rayonnement solaire. L'ozone est très absorbant dans le domaine qui s'étend de 450 à 770nm, alors que les molécules d'oxygène filtrent le rayonnement visible dans trois bandes centrées sur 630 ; 690 et 760nm. L'eau possède une légère bande autour de 720nm (Pavlov, 2016).

I.5.3.3. Absorption dans l'infrarouge

L'absorption dans l'infrarouge provient essentiellement de la vapeur d'eau et du dioxyde de carbone de sorte qu'au niveau bas de l'atmosphère, 14% du rayonnement solaire est absorbé par la vapeur d'eau principalement dans la région du proche infrarouge ; alors que l'absorption par le dioxyde de carbone est légère et se manifeste dans l'infrarouge lointain (supérieur à 2000nm).

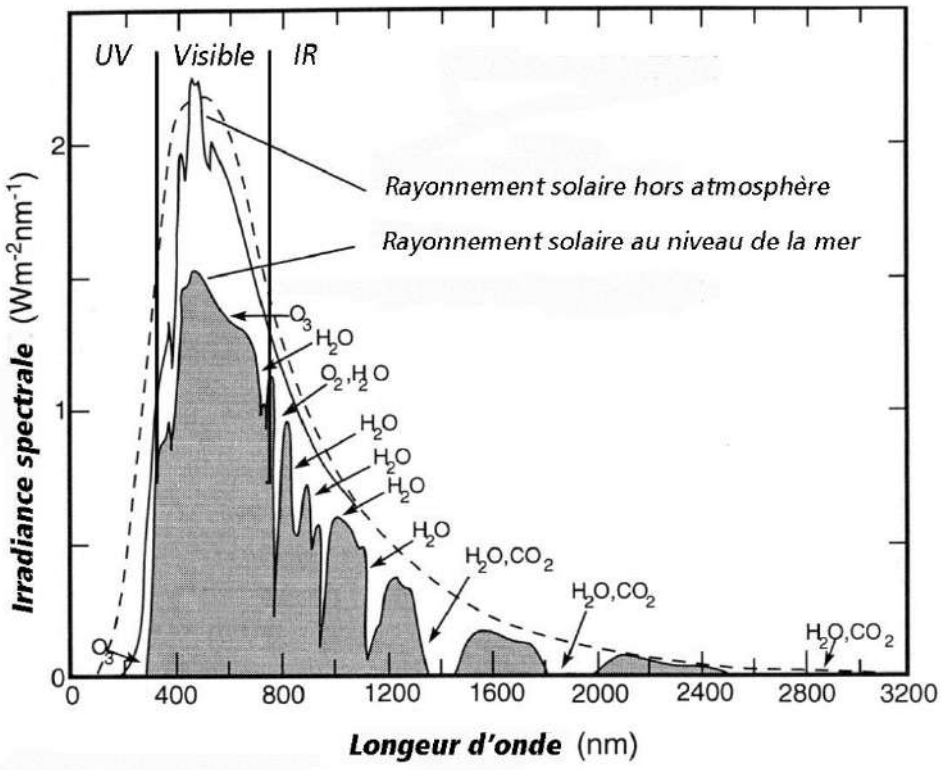


Figure I. 13 : Spectre d'absorption du rayonnement solaire au niveau de la mer (Salby,1996)

I.5.4. Diffusion atmosphérique

La diffusion atmosphérique change la direction de propagation du rayonnement. Il est généralement élastique, ce qui signifie que le rayonnement diffusé à la même fréquence que l'incident. Cependant, une petite fraction de photons subit une diffusion inélastique, dans laquelle l'énergie du rayonnement est également modifiée en raison des transitions électroniques dans les molécules de diffusion. Ceci est ce qu'on appelle *diffusion de Raman*. La diffusion atmosphérique peut être due à des particules de taille différente comme les molécules de gaz ($\backsim 10^{-4}$µm), les aérosols ($\backsim$1 µm), les gouttelettes d'eau ($\backsim$10 µm), et les gouttes de pluie ($\backsim$ 1 cm). L'effet de la dimension des particules sur la diffusion est représenté par le paramètre de taille, *x*. Pour une particule sphérique de rayon a, $x = 2\pi a/\lambda$. Si $x << 1$ (les particules sont petites par rapport à la longueur d'onde), la dispersion est appelée diffusion *de Rayleigh*. Un exemple est la diffusion de la lumière visible par les molécules de l'atmosphère. Si $x \geq 1$ (la particule dispose à peu près de la même taille que la longueur d'onde), la dispersion est appelée *diffusion de Lorenz-Mie.* Si $x >> 1$ (les particules sont grandes par rapport à la longueur d'onde), la dispersion est appelée diffusion géométrique et peut être étudiée à l'aide de l'optique géométrique de la réflexion, de la réfraction et de la diffraction. Pour de faibles densités de molécules et de particules dans l'air, la diffusion est indépendante, c'est-à-dire que chaque particule diffuse un rayonnement comme si les autres particules

n'existent pas. Si la densité augmente, comme c'est le cas à l'intérieur des nuages, chaque particule peut diffuser le rayonnement qui a déjà été diffusé par d'autres particules. Ce processus est appelé la diffusion multiple (Liou, 2002). La contribution de ces différents phénomènes est illustrée par la Figure I.14.

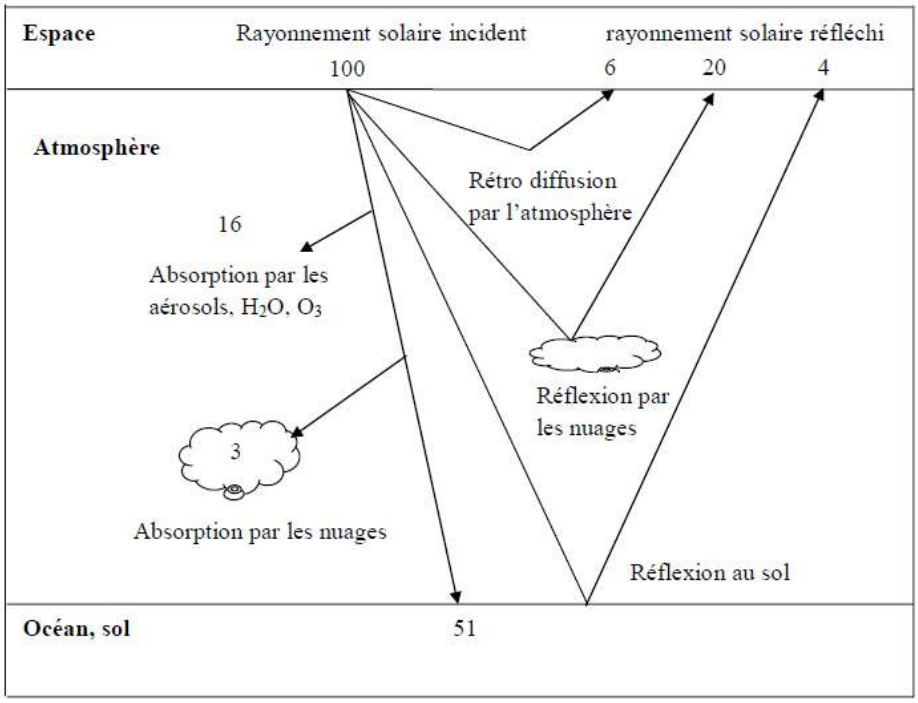


Figure I. 14 : Processus de transmission, d'absorption, de diffusion et de réflexion dans l'atmosphère (les chiffres sont des pourcentages) (Meziani 2012) .

I.5.5. Distribution spectrale du rayonnement solaire au sol

Au sol le rayonnement solaire peut être décomposé en deux parties :

Partie A. le rayonnement direct. On notera par (H_D) la puissance reçue par unité de surface normale aux rayons provenant au sol.

Partie B. le rayonnement diffus provenant de toute la voûté céleste. On notera par (H_F) la puissance reçue par unité de surface.

La puissance globale du rayonnement solaire reçu au sol s'exprime comme étant la somme de la puissance diffuse et de la puissance directe pondérée par le cosinus de l'angle zénithal du soleil (Badescu, 2008). On a alors :

$$H = H_D + H_F \cos(\theta_z) \qquad \text{(I.16)}$$

θ_z est l'angle zénithal (complément de la hauteur solaire).

Remarque : La surface du sol renvoie vers l'espace une fraction du rayonnement solaire global appelée albédo (AL), qui dépend de sa nature et de son état. Si le rayonnement réfléchi est égal à R, le flux absorbé par le sol est (1-AL) R. Le Tableau 3 donne l'albédo typique de quelques surfaces.

Tableau I. 3 : Albédo typique de différentes surfaces (Bessemoulin & Oliviéri, 2000)

Surfaces	Albédo
Neige fraiche	0.8 à 0.9
Neige ancienne	0.5 à 0.7
Sol rocheux	0.15 à 0.25
Sol cultivé	0.07 à 0.14
Forêt	0.06 à 0.2
Etendue d'eau	0.05

I.6. Mesure d'irradiation solaire

I.6.1. Radiomètres solaires

La détection du rayonnement électromagnétique optique est principalement réalisée par la conversion de l'énergie directe reçue à des signaux électriques qui peuvent être ensuite mesurées par des techniques classiques. En raison de leur sensibilité spectrale presque constante pour toute la gamme spectrale solaire, les radiomètres équipés de capteurs thermiques sont largement utilisés pour mesurer l'irradiation solaire à large bande. Les fluctuations de température (les instruments sont placés en plein air et leur température peut varier entre -20 et 70 °C), le vent, la pluie et la neige étant des facteurs qui influent sur les mesures. La minimisation de ces perturbations est une tâche difficile dans l'ingénierie des radiomètres solaires (Vignola*etal*., 2012).

A. Pyrhéliomètre

Le pyrhéliomètre est un instrument à large bande qui mesure la composante directe du rayonnement solaire H_D. Par conséquent, l'instrument doit être pointu en permanence vers le Soleil. Un mécanisme à deux axes pour suivre le soleil est le plus souvent utilisé pour ce but. Le détecteur est un thermocouple à jonctions multiples placé au fond d'un tube de collimation (Fig. 15 (a)) muni d'une fenêtre en quartz pour protéger l'instrument.

Le détecteur est recouvert de peinture noire optique (agissant comme un absorbeur complet de l'énergie solaire dans les longueurs d'onde allant de 0,28 à 3 μm). Sa température est compensée pour minimiser la sensibilité des variations de température ambiante. L'angle d'ouverture de

pyrhéliomètre est de 5°. Un dispositif de lecture est utilisé pour donner la valeur instantanée de l'irradiation directe. Son échelle est adaptée à la sensibilité de l'instrument pour afficher la valeur en unité SI, $W.m^{-2}$. Pour l'illustration, une photo d'un pyrhéliomètre Hukseflux DR01 premier classe (Hukseflux 2012) est présentée à la Figure I**.** 15(b) (Vignola, et *al*. 2012).

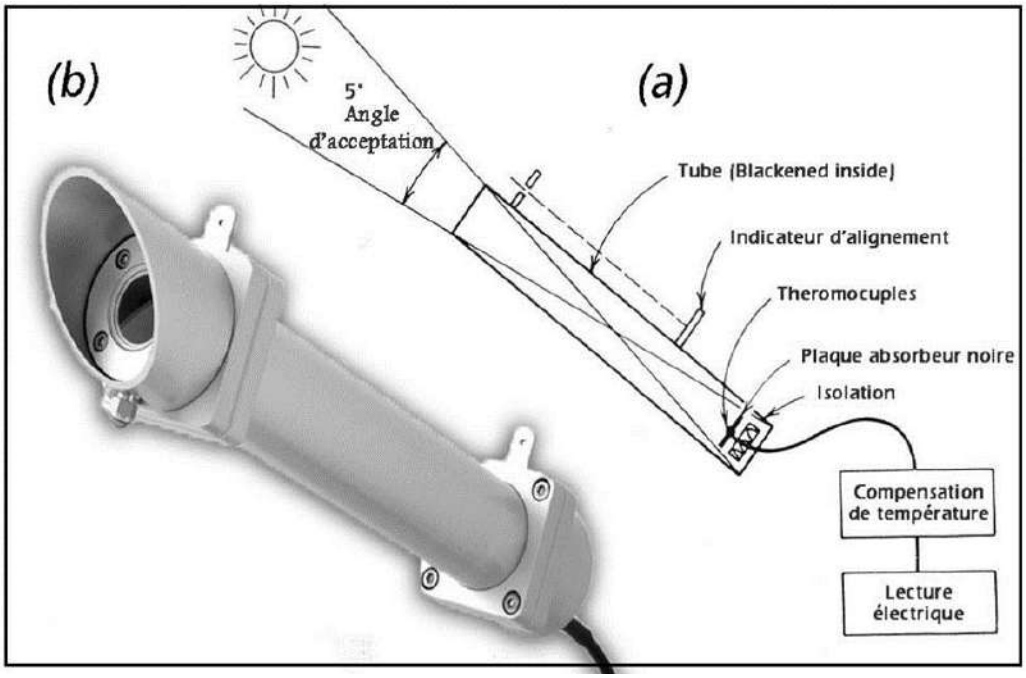


Figure I. 15 : (a) Schéma d'un pyrhéliomètre. **(b**) Photo de Hukseflux DR01(the Eppley Laboratory, Inc)

B. Pyranomètre

Les pyranomètres sont des instruments à large bande qui mesurent le rayonnement solaire global entrant à partir d'un angle solide 2π sur une surface plane. Un pyranomètre typique est représenté schématiquement sur la Figure I**.** 16 (a). Il se compose d'un disque blanc pour limiter l'angle d'acceptante à 180° et deux couvercles transparents hémisphériques concentriques en verre. Les deux dômes protègent le capteur de la convection thermique, le protègent contre les intempéries menace (pluie, vent et poussière) et limitent la sensibilité spectrale de l'instrument dans la plage de longueur d'onde 0,29 à 2,8µm. Une cartouche de gel de silice à l'intérieur du dôme absorbe la vapeur d'eau.

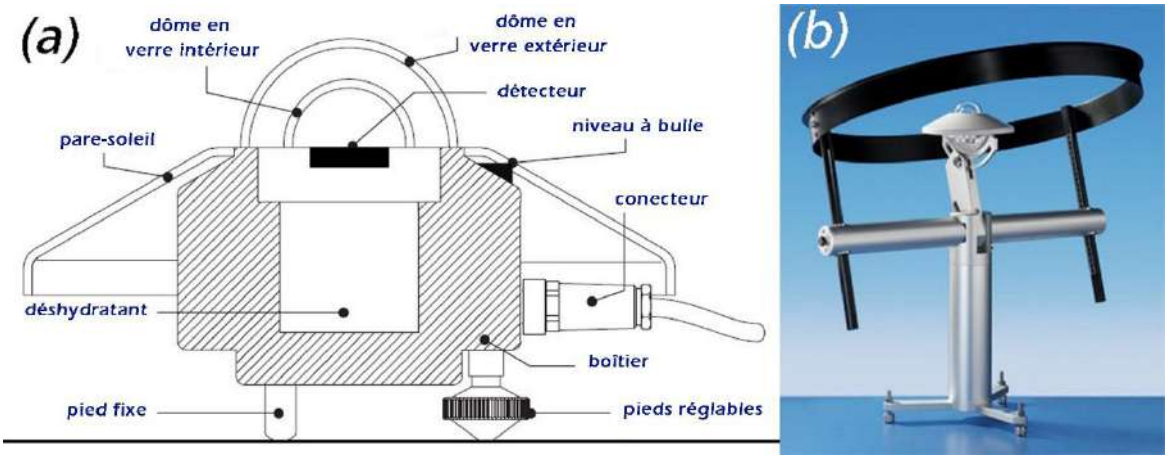


Figure I. 16 : (a) Schéma d'un pyranomètre. (**b**) Pyranomètre de première classe LP PYRA 12 AC équipé d'anneau d'ombre (the Eppley Laboratory, Inc) (Rezrazi *et al.,* 2016).

Un pyranomètre peut être également utilisé pour mesurer le rayonnement solaire diffus H_f, à condition que la contribution de la composante directe soit éliminée. Pour cela, un petit disque d'ombrage peut être monté sur un suiveur solaire automatisé pour assurer que le pyranomètre est continuellement ombragé. Alternativement, un anneau d'ombre peut empêcher la composante directe H_D d'atteindre le capteur tout au long de la journée (voir la Figure I**.** 16(b)). Parce que l'angle d'élévation maximal quotidien du soleil change de jour en jour, il est nécessaire de changer périodiquement la hauteur de l'anneau d'ombre.

C. Mesure de la durée d'ensoleillement

Selon WMO (1983), la durée d'ensoleillement dans une période donnée est définie comme la somme des intervalles de temps pour lesquels l'irradiation solaire directe dépasse le seuil de 120 Wm^{-2}. Dans la pratique, deux méthodes sont largement utilisées pour la mesure de la durée d'ensoleillement (Méthode de la carte brûlée et la méthode pyranomètrique) qui seront brièvement présentées plus tard.

La méthode de la carte brûlée est basée sur l'héliographe Campbell-Stokes, dont la configuration basique se compose d'une sphère de verre montée de manière concentrique dans un segment d'une cuvette sphérique (Figure I. 17). Le support est réglable de telle sorte que l'axe de la sphère peut être incliné à l'angle de latitude du lieu. Le segment de la cuvette sphérique détient la carte d'enregistrement. La sphère de verre focalise le rayonnement solaire direct à la carte, brûlant celle-ci en laissant une trace chaque fois que le soleil brille. La position et la longueur de la trace indiquent l'heure de début et la durée de l'intervalle d'ensoleillement. Les erreurs de cet

enregistreur sont principalement dues à la dépendance de l'initiation de brûlure sur la température et l'humidité de la carte ainsi que l'effet du brûlure excessive, notamment en cas de nuages brisés (Kerr & Tabony, 2004).

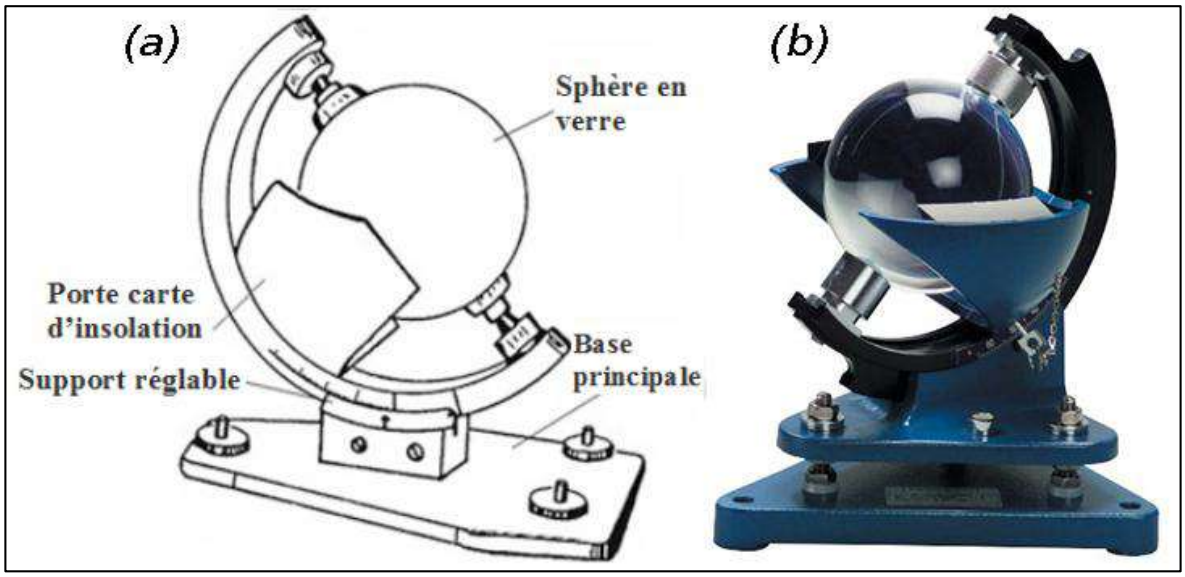


Figure I. 17: (a) Schéma d'héliographe Campbell-Stokes. (**b**) Photo typique d'héliographe Campbell-Stokes (Paulescu*et al.* 2012)

La méthode pyranomètrique implique la mesure de *H* global et l'irradiation solaire diffuse H_f. Par soustraction, l'irradiation solaire directe est ensuite dérivée, pour comparer avec le seuil de WMO en utilisant l'équation fondamentale (I.17). Le critère d'ensoleillement de WMO peut être exprimé comme suit :

$$\xi(t) = \begin{cases} 1 & if \ \frac{H-H_F}{cos\theta_z} > 120 W/m^2 \\ 0 & otherwise \end{cases} \quad \text{(I.17)}$$

I.6.2. Satellites météorologiques

Les méthodes basées sur des observations satellitaires représentent une alternative pour l'estimation du rayonnement solaire et sont largement utilisées (Cano *et al.,* 1986, Perez *et al.,* 2002, Rigollier *et al.,* 2004). Les projets d'énergie solaire utilisent couramment les données satellitaires à long terme en combinaison avec les mesures solaires au sol à court terme de haute qualité aux fins d'évaluation des ressources solaires. Selon Zelenka et al. (Zelenka *et al.*, 1999), les données d'irradiation horaires provenant de satellites sont considérées comme l'option la plus précise pour la prédiction d'irradiation solaire dans des endroits avec distance supérieure à 25 km de la station terrestre. Les

satellites météorologiques balayent la surface de la terre, et sur la base des images produites, il est possible de retrouver les composantes d'irradiation solaire au niveau du sol avec une résolution spatiale et temporelle relativement élevée.

Par exemple, les satellites de la Meteosat Seconde Génération (MSG) fournissent des images de l'Europe, l'Afrique et l'Atlantique Nord depuis 2004, avec une résolution temporelle de 15 minutes et une résolution spatiale d'environ 1 km × 1 km au point sous-satellite. Les images à bord du satellite observent la terre dans différentes bandes spectrales et fournissent des informations et des données sur l'état de l'atmosphère.

Il existe deux types de satellites météorologiques :

- Les satellites météorologiques en Orbite polaire, ainsi appelé parce que, par le tour de la terre, ils passent au-dessus des pôles. Ils sont situés à basse altitude, à environ 850 km au-dessus du sol, offrant une meilleure information de résolution. Avec les satellites polaires, chaque endroit sur la terre peut être observé deux fois par jour. Cette faible résolution temporelle limite leur utilisation opérationnelle pour l'estimation d'irradiation solaire sur le sol. Plusieurs pays exploitent les satellites météorologiques en orbite polaire, tels que *NOAA* par les États-Unis et les satellites européens *Metop-A* et *Metop-B*. La Russie possède les séries de satellites *Meteor* et *Resurs*. Récemment, Le radiomètre avancé avec très haute résolution (AVHRR), à bord de l'orbite polaire des satellites NOAA et Metop, fournit de l'information plusieurs fois par jour, ce qui permet l'estimation de l'irradiation solaire avec une plus grande confiance, comme étudié par Karlsson et al. (Karlsson *et al.,* 2013).

- Les satellites météorologiques géostationnaires sont suspendus au même endroit au-dessus de l'équateur à une altitude d'environ 36000 km. Comme ils tournent autour de la terre dans la même direction et de la même vitesse comme la rotation de la terre, ils restent immobiles comme on le voit depuis la surface de la terre et fournissent ainsi des informations en continu de l'ensemble de l'hémisphère vu par le satellite. Plusieurs satellites météorologiques géostationnaires sont en fonctionnement couvrant le monde entier à l'exception des pôles. On cite par exemple : le système environnemental opérationnel géostationnaire des Etats Unis (*GOES*), les Missions européennes *Météosat*, l'*INSAT* indienne, le *MTSAT* japonais, le satellite météorologique russe nouvelle génération *Elektro-L1* et les satellites géostationnaires chinois *Feng-Yun*.

La base de méthodes par satellite est l'équation de conservation de l'énergie, en tenant compte de l'interaction du rayonnement extraterrestre avec les constituants atmosphériques avant d'atteindre la surface de la terre. Lorsque le rayonnement solaire traverse l'atmosphère, il est en partie réfléchie vers l'espace et en partie absorbé par l'atmosphère. La partie restante, qui atteint le sol est en partie absorbée par la surface de la terre et en partie réfléchie (affecté à nouveau par la diffusion atmosphérique et absorption) vers l'espace comme l'albédo de surface. Le capteur satellitaire mesure le rayonnement rétrodiffusé par le système terre-atmosphère. À la suite de ce schéma de conservation de l'énergie et en connaissant l'énergie absorbée et l'albédo de surface, l'irradiation solaire à la surface de la terre peut être dérivée. L'irradiation extraterrestre est extraite par les équations astronomiques et l'irradiation réfléchie est mesurée par les radiomètres satellitaires. Pour plus de détails sur l'expression de la conservation de l'énergie pour la dérivation du rayonnement solaire à la surface de la terre, voir (Polo *et al.,* 2008).

I.7. Conversion énergétique du rayonnement solaire

L'énergie solaire est actuellement exploitée selon deux techniques : la conversion du rayonnement solaire en chaleur par des capteurs thermiques (conversion hélio- thermique) et sa transformation en électricité grâce à des panneaux photovoltaïques (conversion électrique). Ces transformations ont permis le développement de trois filières d'exploitation : une pour produire de la chaleur (solaire thermique) et deux pour générer de l'électricité (solaire photovoltaïque et thermodynamique).

I.7.1. Conversion photovoltaïque

L'énergie solaire photovoltaïque désigne l'électricité produite par transformation d'une partie du rayonnement solaire avec une cellule photovoltaïque. Plusieurs cellules sont reliées entre elles et forment un panneau solaire (ou module photovoltaïque). Plusieurs modules qui sont regroupés dans une centrale solaire photovoltaïque sont appelés champ photovoltaïque. Le terme photovoltaïque peut désigner soit le phénomène physique « l'effet photovoltaïque » ou la technologie associée. L'effet photovoltaïque fut observé la première fois en 1839 par le physicien français Edmond Becquerel (Rigollier*et al.,*2004). Toutefois, ce n'est qu'au cours des années 1950 que les chercheurs des laboratoires Bell, aux États-Unis, parvinrent à fabriquer la première cellule en silicium, l'élément primaire d'un système photovoltaïque dont le rendement de conversion énergétique atteint 6% (Navarro, 2008). Ils ont découvert aussi que la photosensibilité du silicium pouvait être augmentée en

ajoutant des "impuretés". C'est une technique appelée le "dopage" qui est utilisée pour tous les semi-conducteurs (matériau constituant les cellules PV). Mais en dépit de l'intérêt des scientifiques au cours des années, ce n'est que lors de la course vers l'espace que les cellules ont quitté les laboratoires. En effet, les photopiles représentent la solution idéale pour satisfaire les besoins en électricité à bord des satellites, ainsi que dans tous les sites isolés (Quaschning, 2005).

I.7.1.1. Effet photovoltaïque

L'effet photovoltaïque utilisé dans les cellules solaires permet, donc, de convertir directement l'énergie lumineuse des rayons solaires en électricité par le biais de la production et du transport dans un matériau semi-conducteur de charges électriques positives et négatives sous l'effet de la lumière. Ce matériau comporte deux parties, l'une présentant un excès d'électrons et l'autre un déficit en électrons, dites respectivement dopée de type N et dopée de type P. Lorsque la première est mise en contact avec la seconde, les électrons en excès dans le matériau N diffusent dans le matériau P. La zone initialement dopée N devient chargée positivement, et la zone initialement dopée P chargée négativement. Il se crée entre elles un champ électrique qui tend à repousser les électrons dans la zone N et les trous vers la zone P. Une jonction dite (P-N) a été formée (Goetzberger & Hoffmann, 2005). Lorsque la jonction est éclairée, les photons d'énergie égale ou supérieure à la largeur de la bande interdite communiquent leur énergie aux atomes, chacun fait passer un électron de la bande de valence dans la bande de conduction et laisse aussi un trou capable de se mouvoir, engendrant ainsi une paire électron-trou. Si une charge est placée aux bornes de la cellule, les électrons de la zone N rejoignent les trous de la zone P via la connexion extérieure, donnant naissance à une différence de potentiel : le courant électrique circule (Fig. 18). L'effet repose donc à la base sur les propriétés semi-conductrices du matériau et son dopage afin d'en améliorer la conductivité.

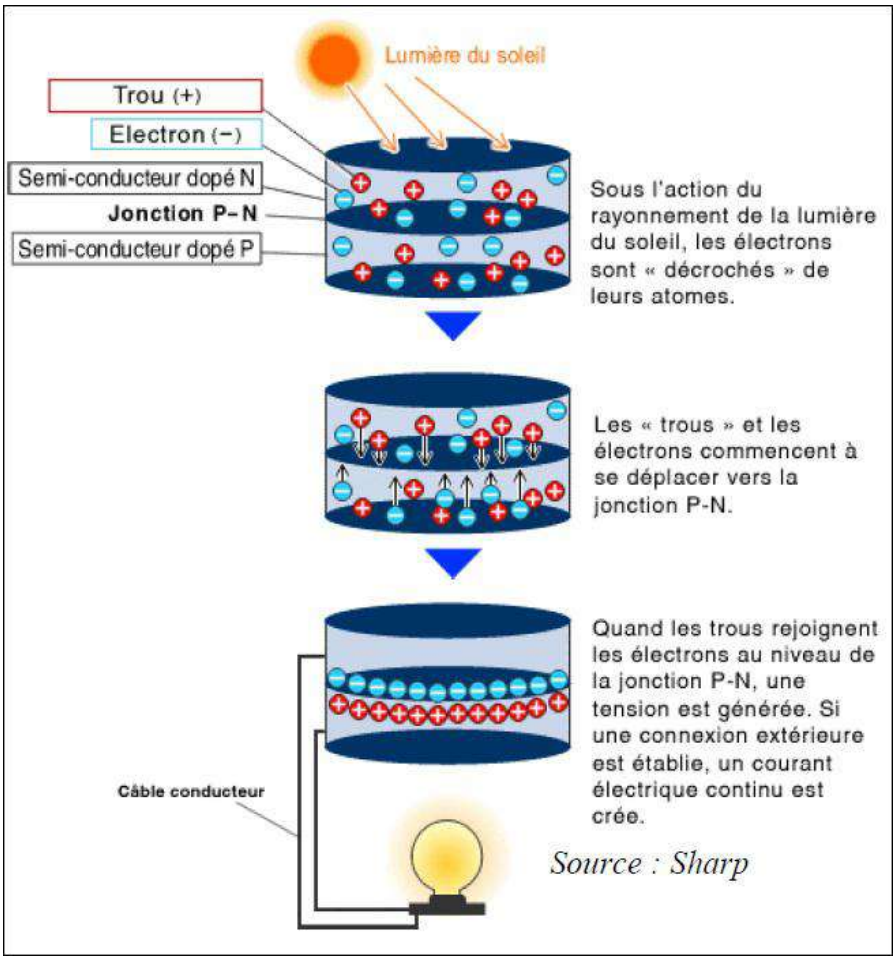


Figure I. 18 : Principe de l'effet photovoltaïque (Viridiselec, 2011)

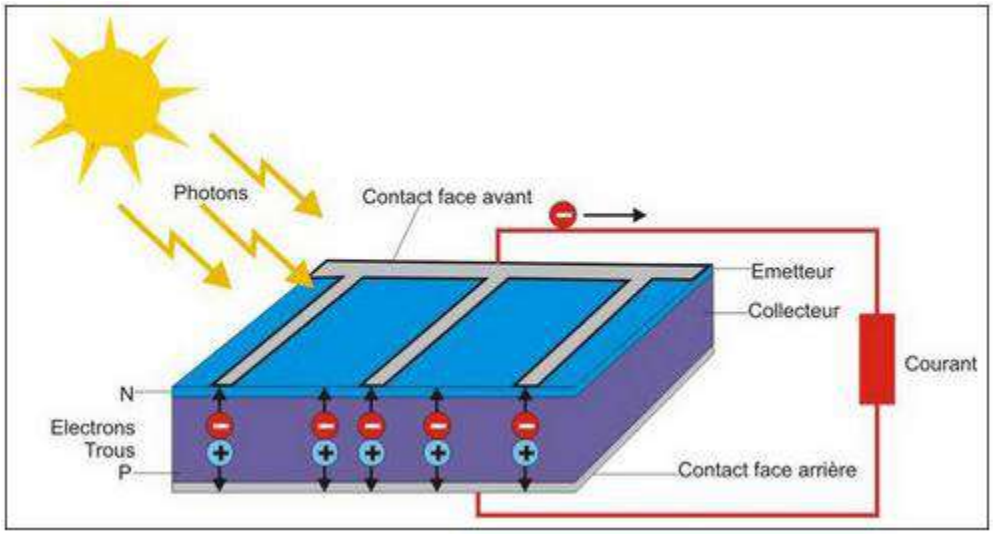


Figure I. 19 : Cellule photovoltaïque (Riolet, 2008).

I.7.1.2. Technologie de fabrication des cellules PV

Le silicium est actuellement le matériau le plus utilisé pour fabriquer les cellules photovoltaïques disponibles au niveau industriel. Le silicium est fabriqué à partir de sable quartzeux (dioxyde de silicium). Celui-ci est chauffé dans un four électrique à une température de 1700 °C (Markvart, 2003). Divers traitements du sable permettent de purifier le silicium. Le produit obtenu est un silicium dit métallurgique, pur à 98% seulement. Ce silicium est ensuite purifié chimiquement et aboutit au silicium de qualité électronique qui se présente sous forme liquide, puis coulé sous forme de lingot suivant le processus pour la cristallisation du silicium, et découpé sous forme de fines plaquettes (wafers). Par la suite, ce silicium pur va être enrichi en éléments dopants (P, As, Sb ou B) lors de l'étape de dopage, afin de pouvoir le transformer en semi-conducteur de type P ou N. La diffusion d'éléments dopants (bore, phosphore) modifie l'équilibre électronique de ces plaquettes, ce qui les transforme en cellules sensibles à la lumière.

Selon la technologie de fabrication employée, on peut distinguer plusieurs types de modules photovoltaïques :

- *les modules solaires monocristallins :* ils possèdent un très bon rendement ($\eta PV \approx 15\%$), et sont essentiellement utilisés lorsque les espaces sont restreints. Leur coût plus élevé que celui d'une autre installation de même puissance, entrave le développement de cette technique ;
- *les modules solaires poly-cristallins :* actuellement ils offrent le meilleur rapport qualité/prix et sont les plus utilisés. Ils ont un bon rendement ($\eta PV \approx 12\%$) et une durée de vie supérieure à 35 ans ;
- *les modules solaires amorphes :* ils sont très intéressants car ils peuvent être souples et ont une meilleure production par faible lumière. Le silicium amorphe possède un rendement divisé par deux par rapport à celui du cristallin ($\eta PV \approx 7\%$), ce qui nécessite plus de surface pour la même puissance installée, mais leur prix au m² étant plus faible, ils restent très compétitifs.

I.7.1.3. Courbe I-V d'un module PV

Les modules photovoltaïques fonctionnent entre deux états opposés. En effet, ils fonctionnent en court-circuit (Isc) lorsqu'il n'y a pas de tension ni de charge et en circuit ouvert (Voc) lorsqu'il n'y a pas de courant et qu'il y a une charge infinie. La courbe courant tension, couramment nommée courbe I-V, est une représentation graphique de la puissance d'un module selon des conditions spécifiques d'ensoleillement et de température. Il est important de noter que les paramètres de la courbe I-V n'ont

de sens que lorsque ces conditions sont spécifiées. L'endroit où le produit du courant et de la tension est le plus élevé représente le point maximal de puissance (Mpp). La Figure I**.** 20 représente les caractéristiques typiques mesurables d'une jonction P-N soumise à un flux lumineux constant. Trois grands facteurs influent sur le point d'opération des modules : l'ensoleillement, la température et la charge électrique. Comme l'ensoleillement et la température varient au cours de la journée et selon les saisons, le point d'opération optimal d'un module varie en conséquence. L'ensoleillement a peu d'influence sur la tension, mais est un facteur important sur le flux de courant. À l'inverse, la température a peu d'influence sur le courant, mais influence grandement le niveau de tension (Fig. 21).

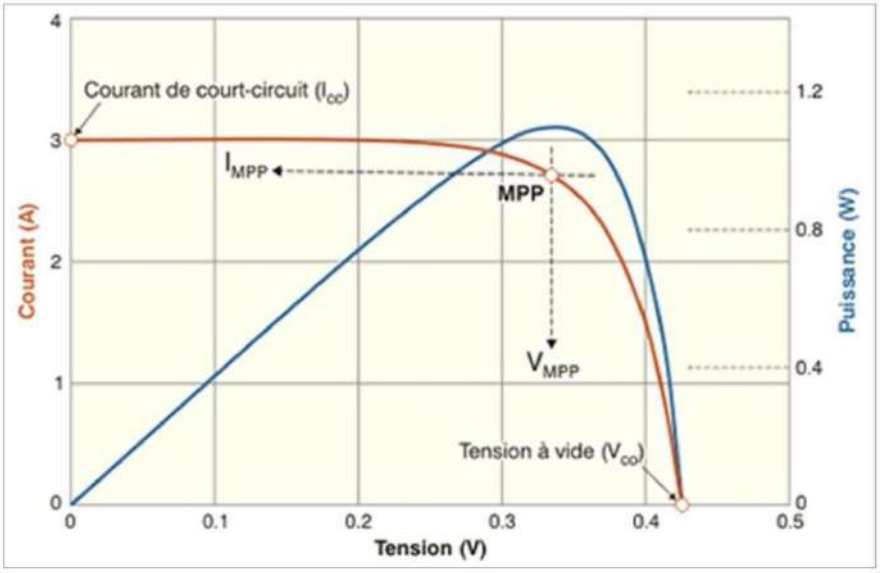


Figure I. 20 : Caractéristique I-V d'un module photovoltaïque (Oskoueiet *al.,* 2015)

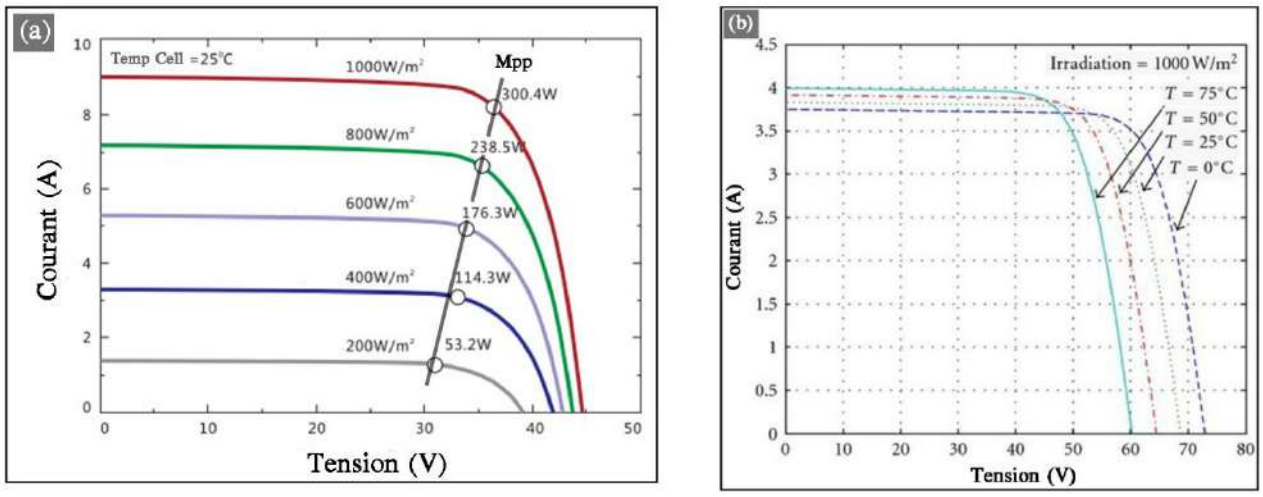


Figure I. 21 : Effet de l'éclairement (a) et de la température (b) sur les caractéristiques I-V (Subiyanto *et al.,* 2012).

I.7.1.4. Systèmes photovoltaïques

Pour produire de l'électricité à une échelle importante, le module photovoltaïque à lui seul n'est pas suffisant. Donc, il faut en fait l'associer étroitement à un système complet correspondant à une application bien spécifique. On distingue principalement deux types d'utilisation selon que l'installation photovoltaïque est connectée ou non à un réseau de distribution d'électricité :

Les installations non connectées peuvent directement consommer l'électricité produite. C'est bien souvent le seul moyen de s'électrifier lorsque le courant du réseau n'est pas disponible : (les maisons en site isolé, sur des îles, en montagne, etc.) Ce type de système nécessite l'utilisation de batteries pour le stockage de l'électricité et d'un contrôleur de charge pour assurer la durabilité des batteries.

Par système photovoltaïque connecté au réseau, on entend un système couplé directement au réseau électrique à l'aide d'un onduleur. Ce type de système offre beaucoup de facilité pour le producteur/consommateur puisque c'est le réseau qui est chargé de l'équilibre entre la production et la consommation d'électricité. Dans le cas de systèmes connectés au réseau, il est impératif de convertir le courant continu produit par le système photovoltaïque en un courant alternatif synchronisé avec le réseau.

Pour effectuer cette conversion, on utilise un onduleur. Cet appareil technologique sophistiqué fonctionne grâce à un microprocesseur et est soumis à des normes réglementaires. En transformant la nature du courant, l'onduleur est le composant du module photovoltaïque qui permet d'utiliser l'électricité produite. Pour un site isolé (non raccordé au réseau), l'onduleur sert à faire passer l'électricité photovoltaïque du module de production aux appareils à alimenter. Dans le cas d'un site connecté au réseau, l'onduleur fait passer l'électricité photovoltaïque du site de production au réseau.
La Figure I**.** 22 montre le principe de fonctionnement d'un système photovoltaïque autonome connecté au réseau électrique.

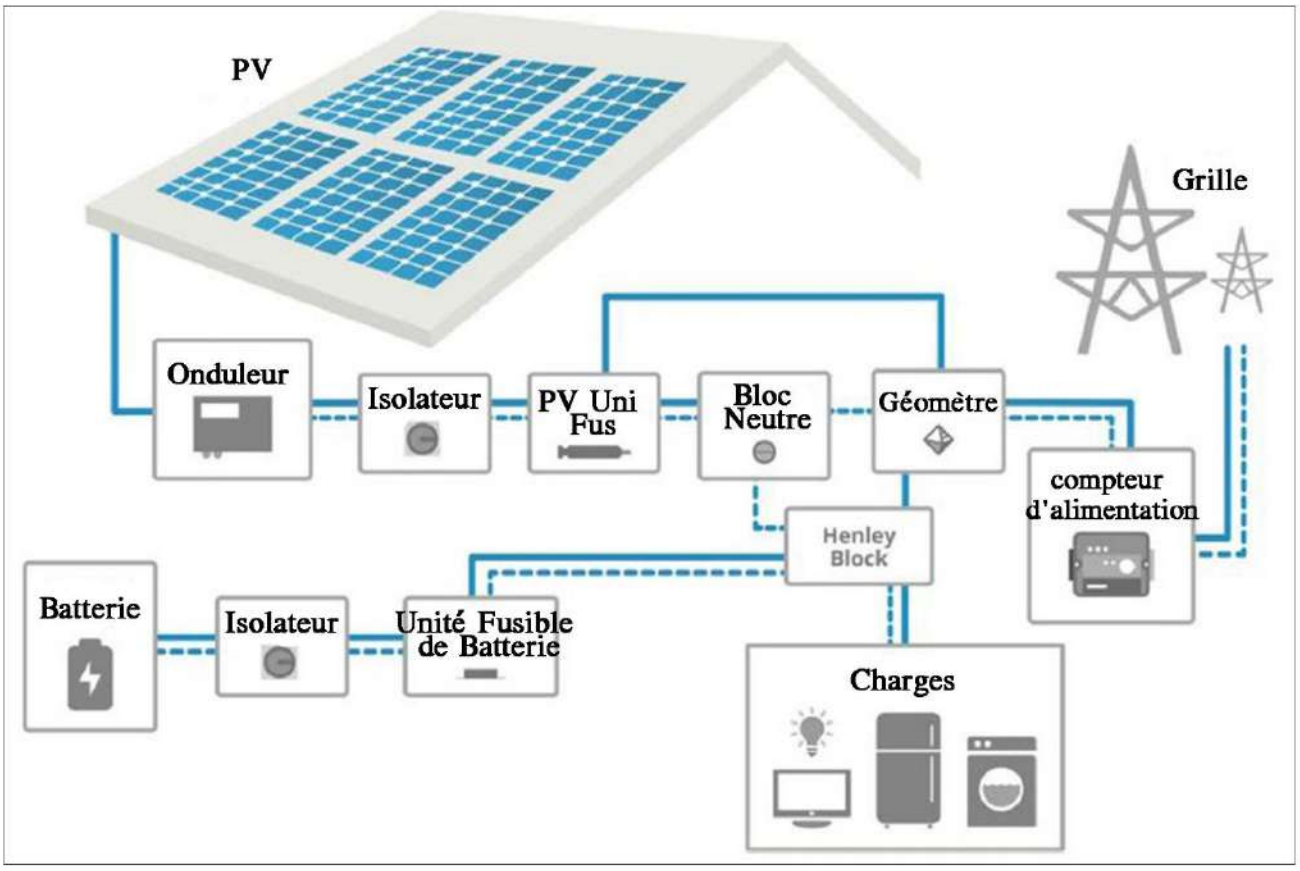


Figure I. 22 : Systèmes photovoltaïques autonomes connectés à un réseau électrique (Uddina *et al.,* 2017).

I.7.2. Conversion thermique

La conversion thermique du rayonnement solaire, désigne l'utilisation de l'énergie thermique dans le but d'échauffer un fluide (liquide ou gaz). L'énergie reçue par le fluide peut être ensuite utilisée directement comme le cas de la production d'eau-chaude sanitaire, le chauffage des habitations, ou indirectement (production de vapeur d'eau pour entraîner des alternateurs et ainsi obtenir de l'énergie électrique, production de froid, etc.). Le capteur solaire est l'instrument principal pour convertir le rayonnement solaire en chaleur et la transférer à un fluide caloporteur circulant dans le capteur. Les principes physiques fondamentaux sur lesquels se basent cette production d'énergie sont notamment l'absorption et la conduction thermique. Dans le cas particulier des systèmes à concentration (centrale solaire thermodynamique, four solaire, etc.), la réflexion joue aussi un rôle important. Donc, selon le mode d'utilisation de l'énergie thermique, on peut distinguer deux groupes distincts :

I.7.2.1. Utilisation passive

Elle concerne principalement la conception de bâtiments et la mise en place des composants de construction appropriés (architecture bioclimatique) afin d'utiliser l'énergie lumineuse pour l'éclairage naturel, le chauffage des locaux et/ou la climatisation des locaux. En plus de réduire la consommation d'énergie, un avantage primordial que procure l'utilisation passive de l'énergie est le confort ressenti par les occupants.

Le chauffage solaire passif fonctionne comme suit ; l'énergie lumineuse qui pénètre à l'intérieur des pièces par les fenêtres est absorbée par les murs, les planchers et les meubles, puis libérée sous forme de chaleur. Des baies vitrées ainsi que la thermo-circulation permettent de faire diminuer la consommation en d'autres énergies. Il permet de chauffer de l'eau par circulation de liquide caloporteur dans des tubes chauffant le ballon d'eau (il y a deux types de circulations : la forcée avec une pompe ou la spontanée grâce à la remontée naturelle du liquide chauffé).

I.7.2.2. Utilisation active

Dans un système actif, des capteurs solaires permettent la conversion de l'énergie solaire en énergie calorifique. La chaleur reçue de cette conversion est utilisée soit directement (cas du chauffage), soit elle-même convertie en énergie mécanique par l'intermédiaire des cycles thermodynamiques. Les principaux types de capteurs solaires thermiques sont les suivants :

- Capteurs plans : Leur principe de fonctionnement est basé sur l'effet de serre qui consiste à piéger le rayonnement solaire, où ce dernier arrive au niveau du couvert et le traverse pour atteindre une surface revêtue d'une peinture noire, appelée absorbeur, qui va absorber une grande partie du rayonnement solaire entraînant une augmentation de sa température. Le rayonnement réfléchi par l'absorbeur arrive sur la vitre et comme celle-ci est opaque aux rayonnements infrarouges, le rayonnement est ainsi piégé. Avec les capteurs plans on obtient de l'eau chaude à basse température, raison pour laquelle ils sont très utilisés pour de petits ou moyens systèmes de production d'eau chaude sanitaire, qui sont ainsi appelés chauffe-eau solaires (Fig. 23).

- Capteurs à concentration : Ces capteurs (Fig. 24) utilisent des miroirs réfléchissants paraboliques ou cylindre-paraboliques pour concentrer les rayons solaires respectivement dans le foyer ponctuel ou dans le foyer linéaire de ces miroirs. Dans le foyer ponctuel ou le long du foyer linéaire se trouvent les récepteurs (absorbeurs) qui captent le rayonnement solaire ainsi concentré

afin d'obtenir de très hautes températures généralement comprises entre 400 et 1000 °C. La chaleur solaire produit de la vapeur qui alimente une turbine elle-même entrainant un générateur pour produire de l'électricité.

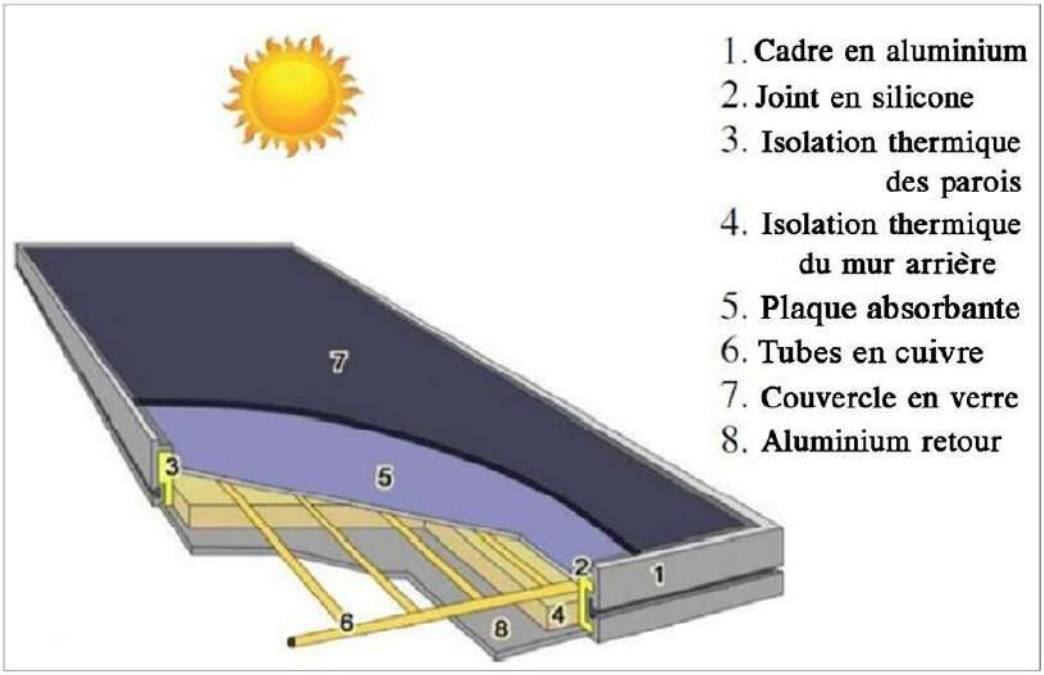


Figure I. 23 : Schéma d'un capteur plan (Camel-Solar, 2012).

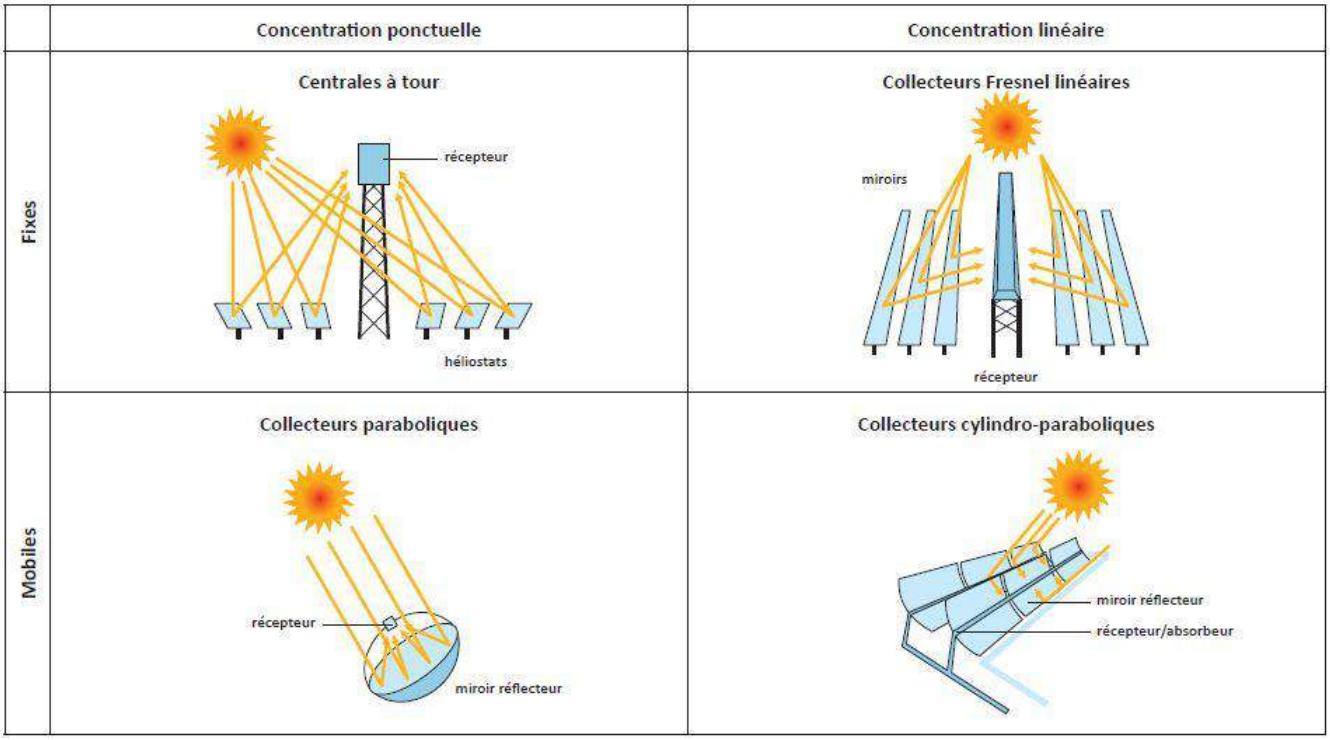


Figure I. 24 : Capteurs de concentration (Syndicat des énergies renouvelables, 2012).

I.8. Potentiel solaire dans le monde

La distribution du rayonnement solaire global atteignant la terre n'est pas uniforme. Elle peut être divisée en trois régions. Due aux variations de température entre les différentes régions du monde, des différences significatives du rayonnement solaire sont attendues.

La première région, qui a la plus grande quantité de rayonnement solaire, se situe entre la latitude 15 °N et 35 °N. La plupart de ce rayonnement solaire provient du rayonnement direct, car il y a un manque de couverture nuageuse et de précipitations. La deuxième région est comprise entre la latitude 15 °N et 0 °N. Cette région possède le deuxième plus haut niveau de rayonnement solaire, avec des niveaux élevés de rayonnement diffus en raison de l'humidité et de la couverture nuageuse. Dans cette région, il y a presque une quantité constante de rayonnement solaire pendant l'année. La troisième région, située au-dessus de 35 °N dispose du plus faible niveau de rayonnement solaire. Cela est dû à la couverture nuageuse. Presque la moitié du rayonnement dans cette région provient du rayonnement diffus. La plus faible quantité du rayonnement solaire se trouve aux pôles de la Terre (Black, 1956).

La Figure I**.** 25 représente une carte de répartition de gisement solaire mondiale pour l'année 2016. On peut voir que le rayonnement est plus élevé dans les zones équatoriales et tropicales, et plus faible dans les régions polaires. Certaines régions à l'équateur (sud-ouest américain, Moyen-Orient, Grand Sahara, les déserts d'Australie et de Chili) peuvent atteindre des valeurs supérieures à 2300 kWh/m^2 par an, tandis que le sud de l'Europe reçoit un rayonnement solaire annuel maximal de 1700 kWh/m^2 et en Allemagne par exemple, on obtient une moyenne de 1040 kWh/m^2 (Solargis, 2016).

Les pays du Maghreb ont un potentiel solaire élevé. Les taux d'irradiation solaire effectués par les satellites de l'Agence Spatiale Allemande (DLR) montrent des niveaux d'ensoleillement exceptionnels de l'ordre de 2100 kWh/m^2 /an dans le Nord du Grand Sahara (Solargis, 2016).

I.9. Potentiel solaire en Algérie

De par sa situation géographique, l'Algérie dispose d'un des gisements solaires les plus élevés au monde. La durée d'insolation sur la quasi-totalité du territoire national dépasse les 2000 heures annuellement et peut atteindre les 3900 heures (hauts plateaux et Sahara). L'énergie reçue quotidiennement sur une surface horizontale de 1m^2 est de l'ordre de *5 kWh* sur la majeure partie du territoire national, soit près de *1700KWh/m2/an* au Nord et *2263 kWh/m2/an* au Sud du pays (Laidi, 2013).

Suite à une évaluation par satellites, l'Agence Spatiale Allemande (ASA) a conclu, que l'Algérie représente un potentiel solaire le plus important de tout le bassin méditerranéen, soit : 169.000 TWh/an pour le solaire thermique, 13,9 TWh/an pour le solaire photovoltaïque et 35 TWh/an pour l'éolien. La répartition du potentiel solaire par région climatique est schématisée dans la Figure I**.** 26.

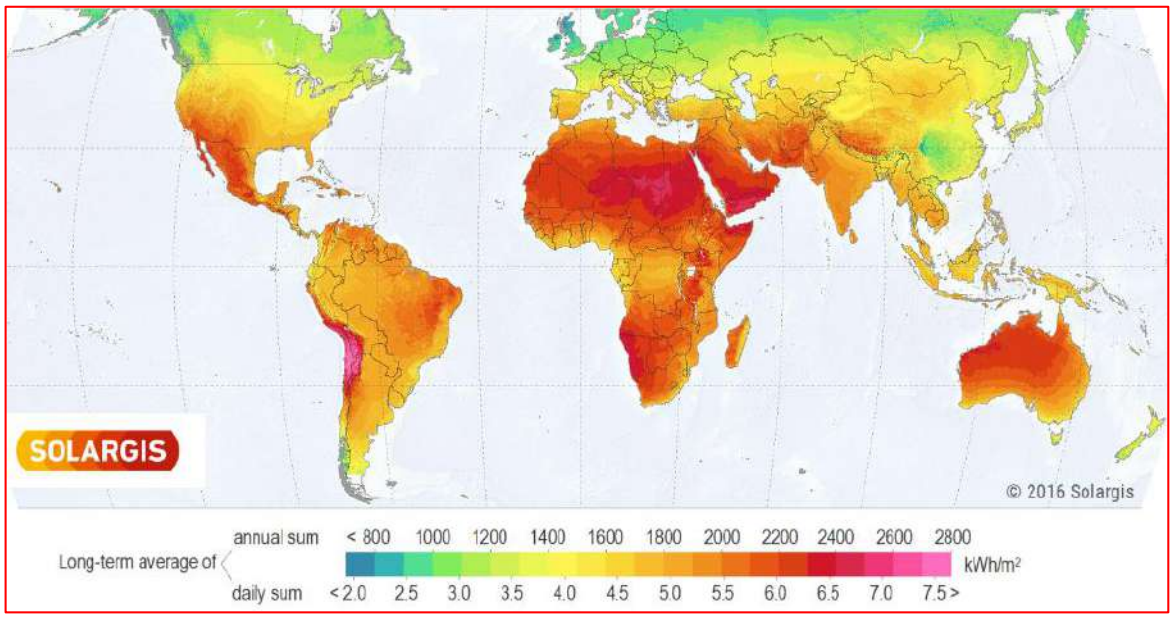


Figure I. 25 : Irradiation Solaire globale dans le monde (Solargis 2016)

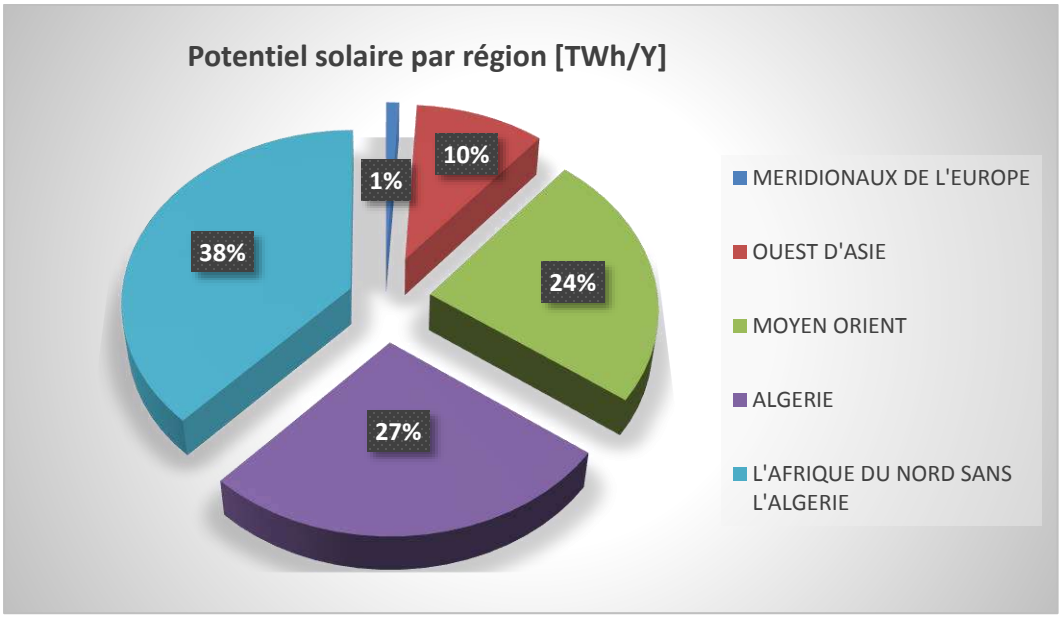


Figure I. 26 : Présentation des ratios du potentiel solaire (Rezrazi, 2016).

Selon la carte graphique ci-dessous (Fig. 27), nous pouvons détecter les zones les plus ensoleillées en Algérie à partir des taux d'irradiation journalière. D'après la Figure I**.** 28, la durée

d'insolation en Algérie est en moyenne égale à 7.3 heures dans le nord du pays, 8.3 heures dans les hauts plateaux et plus de 10 heures dans les régions sud.

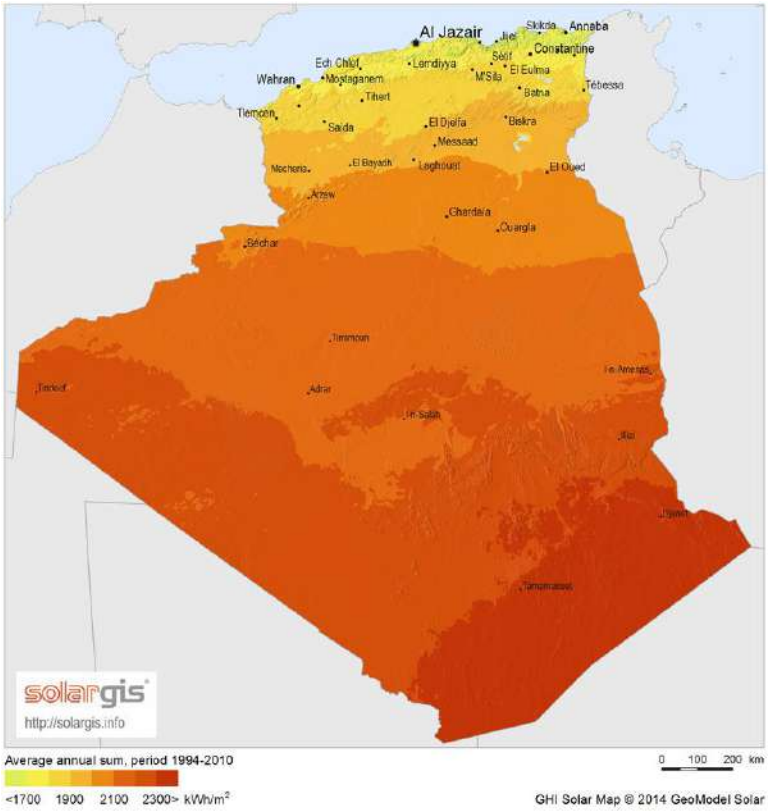


Figure I. 27 : Irradiation Solaire globale dans l'Algérie (Ministère de l'énergie et des mines 2011).

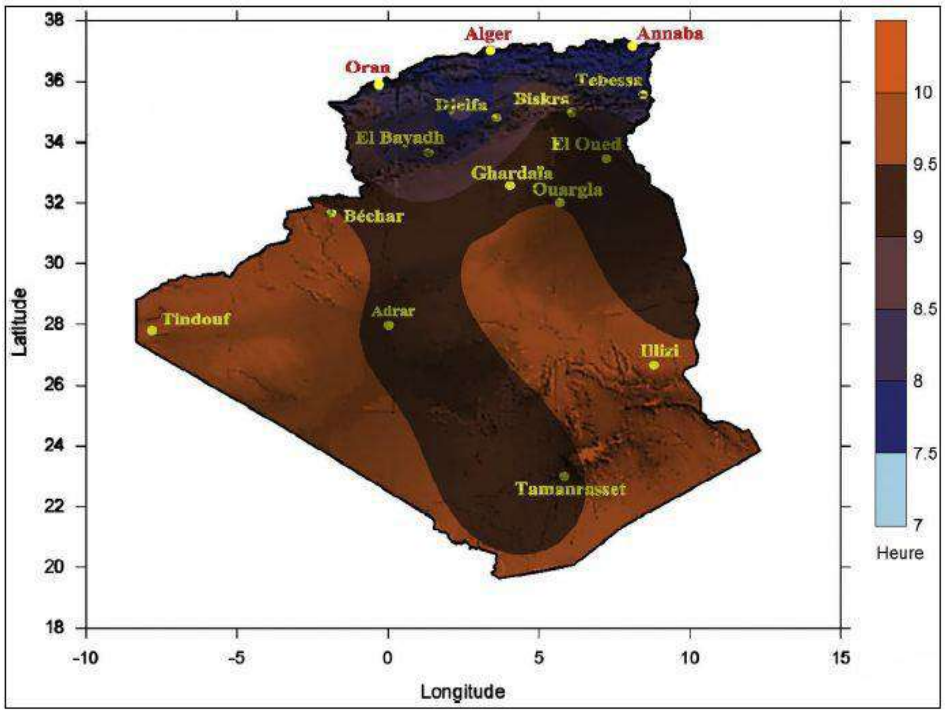


Figure I. 28 : Durée d'insolation en Algérie (Yaiche 2014).

I.10. Conclusion

On peut tirer de ce chapitre les points suivants :

- Ce chapitre a exposé les bases de l'énergie solaire et a clarifié l'origine de celle-ci. Il a également révélé la relation existante entre le soleil et la terre. Il a différencié les concepts de l'irradiation, afin qu'on puisse avoir des points de repère lorsqu'on évalue le potentiel solaire ;
- En plus de la latitude et de la température, le rayonnement solaire capté dépend de l'inclinaison et de l'orientation du plan de captage. Pour cela, on a décrit les coordonnées solaires équatoriales et horizontales, et les relations qui nous ont permis de savoir la direction du rayonnement ;
- Les rayons solaires, lors de leur trajet depuis le soleil vers la surface terrestre subissent des interactions avec l'atmosphère, en produisant deux phénomènes : l'absorption et la diffusion atmosphériques. Une brève analyse de ceux-ci a été faite.
- De ce qui précède ressort que le rayonnement solaire comprend trois composantes, une introduction concise pour les instrumentations utilisées pour mesurer ces composantes, leurs principes de fonctionnement ainsi que les méthodes de mesures sont présentées.
- Concernant la situation du gisement solaire dans le monde entier, et principalement en Algérie, des cartes d'ensoleillement supportées par des statistiques prouvant le potentiel solaire mondial et algérien ont été présentées. Ces connaissances nous ont permis aussi de comprendre le rôle que peut et doit jouer l'énergie solaire dans l'avenir énergétique de la terre.
- L'importance qu'il y'a de connaitre ce potentiel solaire conjuguée à la difficulté d'avoir des stations de mesure partout dans le monde, nous amène à réfléchir sur le développement des méthodes modernes et efficaces pour mieux connaitre l'énorme potentiel solaire à forte potentialité d'exploitation. C'est ce qui sera abordé dans les chapitres suivants.

Chapitre II

Etat de l'art sur la modélisation de l'irradiation solaire

II.1. Introduction

Une revue sur la littérature est considérée comme une pierre angulaire dans la recherche scientifique. Il permet aux chercheurs de tirer parti des connaissances antérieures accumulées dans le passé pour être un point de départ dans son étude. Il ne peut en aucun cas faire un travail dans l'isolement des problèmes qui ont une relation directe ou indirecte sur le cas à étudier. Au contraire, chercher à intégrer les idées, les théories et les hypothèses préalables avec la connaissance actuelle nous a conduit forcément à des résultats intéressantes. Une revue attentive donne également au chercheur une compréhension de la méthodologie de recherche qui se réfère à la manière et à l'étude à mener. Il aide le chercheur à connaître les outils et les instruments qui se sont avérés utiles. Il fournit une preuve de la connaissance du chercheur dans le champ d'investigation et aussi elle va l'aider dans l'évolution de nouvelles idées et construit de nouvelles approches du problème. L'avantage de la documentation connexe donne aussi un aperçu sur les méthodes statistiques à travers laquelle la validité des résultats doit être établie.

Il est convenu de noter que dans de nombreuses stations météorologiques, on remarque la non disponibilité des données de radiation solaire par rapport à celles de la température, d'humidité et de la précipitation, et si elles sont disponibles, elles sont souvent soit incomplètes, soit en dehors de la fourchette prévue. Cette situation que nous trouverons surtout dans les pays en développement, est due à deux choses principales :

- le cout élevé des équipements et des instrumentations de mesure ;
- la maintenance, l'étalonnage et les défaillances fréquentes des équipements.

Il est généralement admis que la modélisation du rayonnement solaire est nécessaire, et il est alors compréhensible que de nouveaux modèles et l'amélioration des techniques de modélisation existantes sont continuellement proposées à l'intention d'améliorer les estimations avec l'utilisation de variables météorologiques plus facilement disponibles.

Par conséquent, des travaux vastes ont été effectués par les chercheurs en vue de trouver un modèle approprié pour estimer ou prédire l'irradiation solaire. et ça ce qu'on veut montrer dans ce chapitre, où nous revenons à la littérature afin de voir les différentes techniques utilisées en terme de "modélisation de l'irradiation solaire" et en montrant aussi qu'il est possible d'aborder ce sujet à plusieurs angles.

II.2. Production scientifique mondiale sur la modélisation d'irradiation solaire

Avant d'aller plus en détail sur les différentes techniques utilisées pour la modélisation de l'irradiation solaire, nous avons décidé de faire une étude bibliométrique concernant les publications scientifiques centrées sur ce domaine.

Cette étude, indépendamment à leur utilité dans le domaine de l'histoire de la science, elle nous a permet d'évaluer la croissance de la production scientifique, sa qualité, sa quantité et surtout le champ d'intérêt des chercheurs.

Dans ce sens, la Figure II. 1 résume l'évolution de nombre des articles publiés dans ce domaine, en fonction des périodes, en utilisant 'ISI web of knowledge' et 'Google scholar' comme des références, on note un développement remarquable dans les dernières années. La méthodologie est basée sur la recherche des mots-clés proposés dans les publications antérieures, ce qui nous a conduits à établir une série de mots-clés pour chacune des techniques de modélisation, et exécuter aussi une union logique du même ordre pour éviter l'apparition de publications dupliqués.

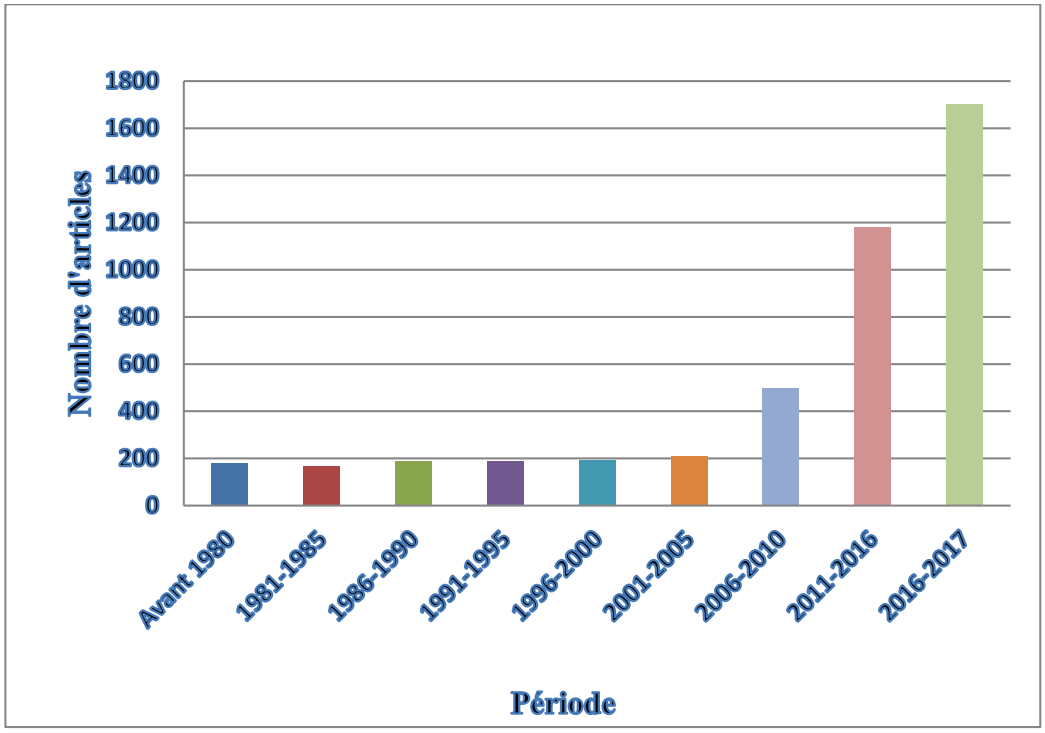


Figure II. 1 : Evolution du nombre d'articles publiés sur la modélisation d'irradiation solaire

II.3. Modèles de prédiction

En revenant à la littérature, on peut diviser les modèles utilisés dans l'estimation et la prédiction de l'irradiation solaire sur trois grandes catégories en suivant la classification déjà proposée par (Figure II. 2) :

- les modèles empiriques (physiques)
- les modèles de séries temporelles.
- les modèles simulés (statistiques)
- les modèles optimisés

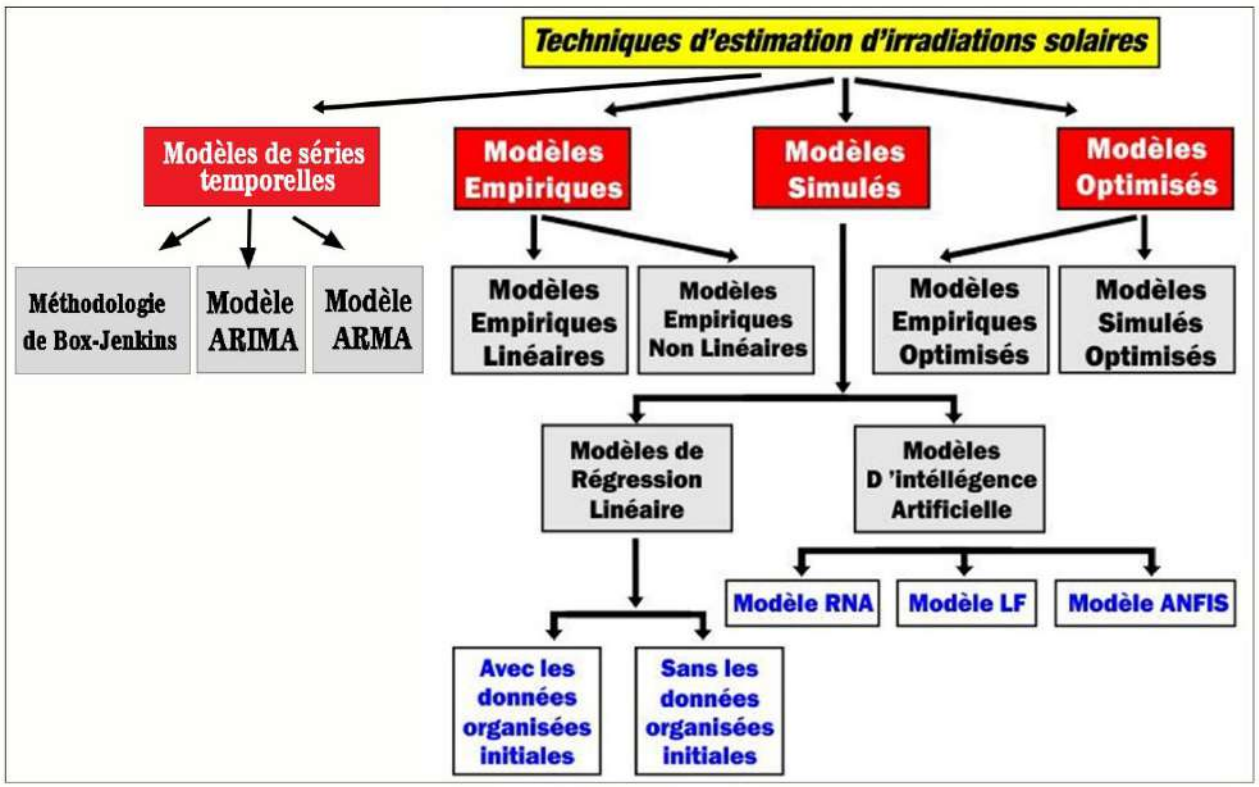


Figure II. 2 : Techniques de modélisation d'irradiation solaire

II.3.1. Modèles empiriques

L'apparition de ces modèles dès le milieu du XX^{ème} siècle, les chercheurs ont compté sur différents paramètres d'entrée comme : les heures d'ensoleillement, la nébulosité, la température, l'humidité relative, la précipitation, la déclinaison solaire, la durée astronomique du jour, la constante solaire, la latitude, l'altitude, …etc. Le nombre et le type de paramètres d'entrée varient, et ainsi, le modèle qui comporte plusieurs paramètres est le modèle le plus sophistiqué. Les modèles de première génération reposent sur un ou deux paramètres, souvent la durée d'ensoleillement, la couverture

nuageuse ou une combinaison des deux avec des paramètres secondaires tels que l'humidité ou la précipitation,...etc.

Ces modèles peuvent être des modèles linéaires ou non linéaires. En général, une technique de régression statistique est utilisée pour obtenir le coefficient de modèles empiriques. La simplicité et la non-exigence d'une phase d'apprentissage sont les principaux avantages des modèles empiriques.

Les techniques qui relèvent de cette catégorie peuvent être divisées en deux sous-catégories principales :

- les modèles empiriques linéaires
- les modèles empiriques non linéaires

Il est également possible de les classées selon le paramètre utilisé comme entrée dans ces modèles, dans ce cas on distingue :

- Des modèles basés sur la durée d'ensoleillement ;
- Des modèles basés sur la couverture des nuages ;
- Des modèles basés sur la température ;
- Des modèles basés sur d'autres paramètres météorologiques.

II.3.1.1. Modèles empiriques linéaires

Les modèles linéaires sont des modèles dérivées de l'équation de régression d'Angström développée en 1924 (Angstrom, 1924). Prescott (1940) a modifié ce modèle, par l'utilisation du rayonnement extraterrestre sur une surface horizontale plutôt que le rayonnement d'une journée claire, et il devient connu comme le modèle d'Angstrom-Prescott, qui peut être exprimé sous la forme d'une expression de régression linéaire:

$$H = H_0\left(a + b\left(\frac{S}{S_0}\right)\right) \qquad \text{(II.1)}$$

Où H est le rayonnement solaire global, H_0 est le rayonnement solaire extraterrestre, S est le nombre d'heures d'ensoleillement réels, S_0 est la durée maximale possible de soleil, et a et b sont des coefficients empiriques qui seront obtenus à partir des résultats de la première analyse de régression d'ordre(Spencer, 1971).

Par la suite, plusieurs tentatives ont été faites dans le but de l'amélioration de la précision de ce modèle, Parfois par la fixation des coefficients a et b (Jain ,1986 ; El-Metwally, 2005 ; Bakirci, 2009), et d'autres fois par la proposition des paramètres supplémentaires. Glover et McCulloch (1958), Swartman et

Ogunlade (1967), Abdalla (1994), et Jin et al. (2005) ont proposé des modèles linéaires qui sont présentés par les équations (II.2), (II.3) (II.4) et (II.5) respectivement :

$$H = H_0\left(a.cos\varphi + b\left(\frac{S}{S_0}\right)\right) \quad \text{(II.2)}$$

$$H = a + b\left(\frac{S}{S_0}\right) + cRH \quad \text{(II.3)}$$

$$H = H_0\left(a + b\left(\frac{S}{S_0}\right) + cRH + dT\right) \quad \text{(II.4)}$$

$$H = H_0\left(a + b.cos\varphi + cZ + d\left(\frac{S}{S_0}\right)\right) \quad \text{(II.5)}$$

Où φ est latitude du lieu, *RH* est l'humidité relative moyenne, *T* est la température quotidienne moyenne de l'air, *Z* est l'altitude du lieu et *a-d* sont les coefficients empiriques.

Tableau (II. 1) résume quelques valeurs des constantes empiriques du modèle Ångström-Prescott pour certains sites dans le monde :

Tableau II. 1 : Valeurs des constantes du modèle Angstrom-Prescott (Eq. II.1 à II.5)

Source	Lieu	a	b	c	d
(Chegaar & Chibani, 2001)	Algérie	0.309	0.368	-	-
(Li *et al.*, 2011)	Chine	0.2223	0.6529	-	-
(El-Metwally, 2005)	Egypte	0.228	0.527	-	-
(Katiyar & Pandey, 2010)	Inde	0.2281	0.5093	-	-
(Al-saad, 1990)	Jordanie	0.174	0.615	-	-
(Said, 1998)	Libye	0.1	0.874	-0.255	-
(Ampratwum & Dorvlo, 1999)	Oman	0.9428	-1.202	0.9336	-
(Firoz & Intikhab, 2004)	Pakistan	0.348	0.32	0.07	-
(Almorox & Hontoria, 2004)	Espagne	0.184	0.6792	-0.113	-
(Ulgen & Hepbasli, 2002)	Turquie	0.2408	0.3625	0.4597	-0.3708
(Gladius, 1992)	USA	0.81	-3.34	7.38	-4.51

II.3.1.2. Modèles empiriques non linéaires

Il a été constaté que l'équation de type linéaire ne peut pas être applicable pour certains jours avec des valeurs extrêmes, ce qui conduit à une surestimation de la radiation totale des jours sans nuages (S/S_0=1) et des jours nuageux (S/S_0 =0). La turbidité atmosphérique, l'épaisseur des nuages, la turbulence dans la couche limite planétaire, et les variations temporelles et spatiales provoquent l'incorporation d'éléments non linéaires dans le phénomène de rayonnement solaire. Une forme quadratique (Eq. II.6) a ensuite été suggérée pour la relation entre H/H_0 et S/S_0 (Ögelman *et al.,* 1984; Akinoğlu & Ecevit, 1990).

D'autres suggèrent des équations de régression multilinéaires avec des combinaisons d'un ou plusieurs paramètres tels que la température, l'humidité relative, et la durée d'ensoleillement (Sen, 2008 ; Akinoglu & Ecevit, 1990). Une autre méthode empirique qui a été largement utilisé est le modèle à la base de la température de l'air, étant donné que les mesures de température de l'air sont disponibles dans la majorité des stations météorologiques. La méthode est basée sur le calcul de la différence entre les températures maximales et minimales, qui a une portée différente dans le temps clair que les jours nuageux ou pluvieux (Hargreaves, 1982 ; Allen, 1997 ; Chen *et al.*, 2004,).

$$H = H_0 \left(a + b \left(\frac{S}{S_0} \right) + c \left(\frac{S}{S_0} \right)^2 \right) \quad \text{(II.6)}$$

Bahel et al. (1987) ont proposé un modèle non linéaire polynômial d'ordre supérieur pour estimer le rayonnement solaire global comme suit (Bahel *et al.,* 1987):

$$H = H_0 \left(a + b \left(\frac{S}{S_0} \right) + c \left(\frac{S}{S_0} \right)^2 \right) + d \left(\frac{S}{S_0} \right)^3 \quad \text{(II.7)}$$

Coppolino (1994) a développé une fonction de puissance et incorporé un terme trigonométrique pour estimer le rayonnement solaire global (Coppolino, 1994)

$$H = H_0 . \left(e^a . \left(\frac{S}{S_0} \right)^b . (sinh_\alpha)^c \right) \quad \text{(II.8)}$$

Almorox et Hontoria (2004) ont suggéré la relation suivante entre le rayonnement solaire et les heures d'ensoleillement :

$$H = a + b \, exp \left(\frac{S}{S_0} \right) \quad \text{(II.9)}$$

Bakirci (2009) a développé le modèle suivant pour l'estimation du rayonnement :

$$H = a + b \left(\frac{S}{S_0} \right) + cexp \left(\frac{S}{S_0} \right) \quad \text{(II.10)}$$

Ampratwum et Dorvlo (1999) ont suggéré un modèle de type logarithmique :

$$H = a + b \, log \left(\frac{S}{S_0} \right) \quad \text{(II.11)}$$

Ojosuet Komolafe (1987) ont proposé l'équation suivante :

$$H = a + b \left(\frac{S}{S_0} \right) + c \left(\frac{T_{min}}{T_{max}} \right) + d \left(\frac{RH}{RH_{max}} \right) \quad \text{(II.12)}$$

Behrang et al. (2011) ont introduit cinq équations non linéaires pour l'estimation du rayonnement solaire et les résultats ont montré que les nouveaux modèles non linéaires ont un meilleur rendement que les modèles linéaires.

Un examen détaillé sur les modèles empiriques peut être trouvée sur (Besharat *et al.,* 2013). L'une des principales limites des modèles empiriques est leurs coefficients dépendant du site. Ces coefficients peuvent être déterminés avec précision que pour les stations météorologiques où le rayonnement solaire a été mesuré, même s'ils peuvent être interpolés pour d'autres endroits. La précision de ces modèles sera diminué lorsque leurs coefficients empiriques ne peuvent être déterminés à l'endroit où le modèle est appliqué.

II.3.2. Modèles de séries temporelles

Une série temporelle (chronologique) est un ensemble séquentiel de points de données, mesurée généralement sur des temps successifs. Elle est défini mathématiquement comme un ensemble de vecteurs x (t), t = 0, 1,2, ... où t représente la mesure du temps. Les variables x (t) sont traitées comme variables aléatoires. Les mesures effectuées au cours d'un événement dans une série temporelle sont disposées dans un ordre chronologique adéquat. Une série temporelle contenant une seule variable est nommé comme uni-variée, tandis que une série de plus d'une variable est appelée multi-variée. Une série temporelle peut être continue ou discrète. Dans un temps continu, les observations de la série sont évaluées à chaque instance de temps (mesure de la température, écoulement d'une rivière, concentration d'un processus chimique, etc.), alors qu'une série de temps discret contient des observations mesurées à des points de temps discrets (production d'une entreprise, densité de population d'une ville, taux de change entre deux monnaies, etc.). Habituellement, dans une série temporelle discrète, des observations consécutives sont enregistrées à des intervalles de temps égaux : horaire, quotidienne, hebdomadaire, mensuelle ou annuelle. Le choix d'un modèle approprié est extrêmement important car il reflète la structure sous-jacente de la série, et ce modèle ajusté à son tour est utilisé pour la prévision. En général, les modèles de séries temporelles peuvent avoir de nombreuses formes et représentent différents processus stochastiques. Cependant, il existe deux types de modèles largement utilisés dans la littérature, à savoir : le modèle autorégressif et moyen mobile (*ARMA*) et le modèle autorégressif intégré et moyen mobile (*ARIMA*).

A. Modèle ARMA

Les modèles Autorégressive et moyen mobile (*ARMA*) sont des modèles mathématiques dont leurs applications nécessitent une grande quantité des données historiques comme les finances, l'ingénierie et les statistiques. Les modèles *ARMA* fournissent une description statistique du processus stochastiques stationnaire, en utilisant un polynôme à deux parties : une partie autorégressif (*AR*) et une partie moyenne mobile (*MA*). La forme générale de ce modèle est illustrée dans l'équation suivante :

$$Y_t = \sum_{i=1}^{p} \emptyset_i \, Y_{t-1} - \sum_{j=1}^{q} \theta_j \, e_{t-1} + e_t \qquad \text{(II.13)}$$

Où : Y_t peut être n'importe qu'elle composante solaire (G_h, D_h, DNI), ϕ_i sont les paramètres de la partie autorégressive, θ_i sont les paramètres de la partie moyenne mobile et e_t est un bruit blanc ayant une moyenne égale à zéro et une variance constante σ_e^2. Ce modèle est un excellent outil pour comprendre et prédire les valeurs futures d'une série temporelle. Il est très flexible, car il peut se représenter par différents types de séries en utilisant des ordres différents. Il a prouvé sa capacité en matière de prévision quand il y a une corrélation linéaire sous-jacente se situant dans la série de données.

B. Modèle ARIMA

L'application des modèles de type *ARMA* requièrent que les séries temporelles soient stationnaires, c'est à dire la distribution de probabilité du processus stochastique est supposée rester constante même lorsqu'elle est décalée dans le temps. En réalité, beaucoup de séries chronologiques, y compris le rayonnement solaire, ont une tendance et une périodicité dépendant du temps (l'irradiation solaire varie dans la journée, et a la variabilité saisonnière). Une méthode de prévision des séries temporelles non stationnaires a été d'abord proposée par Box-Jenkins (Box *et al.,* 2008) sous la forme d'un modèle d'Autorégressif intégrée moyenne mobile (*ARIMA*). Les modèles *ARIMA* constituent une classe générale de modèles statistiques qui peuvent être convertis en processus stationnaire, toute 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 différentiation (*d*) ; il est désigné couramment par ARIMA (*p, d, q*) et donné par l'expression mathématique suivante :

$$Y_t = (1 - B)^d y_t \quad \text{(II.14)}$$

$$Y_t = \sum_{j=1}^{p} \emptyset_j Y_{t-j} + \sum_{j=1}^{q} \theta_j Z_{t-j} \quad \text{(II.15)}$$

Où B est un opérateur de retard, Z_t est un terme d'erreur distribué comme un bruit blanc gaussien, et les paramètres p, d, q et sont déterminée à l'aide de divers outils d'identification ; on prend des valeurs de p et q les plus petites (plus souvent vu comme une bonne pratique). Une fois ces paramètres sont déterminés, les coefficients d'ajustement ϕ_j et θ_j sont estimées en utilisant la procédure de minimisation (Box *et al.,* 2008).

C. Méthodologie de Box-Jenkins

Après avoir décrit les modèles de séries temporelles, reste à savoir comment sélectionner un modèle approprié qui peut produire des prévisions précises sur la base de l'historique d'une base de données, et la façon à déterminer les ordres optimaux du modèle. Les statisticiens George Box et Gwilym Jenkins (2008) ont développé une approche pratique pour construire les modèles de séries temporelles (*ARIMA*), mieux adapté à une série donnée et de satisfaire également le principe de parcimonie. Leurs concept est d'une immense importance dans le domaine de l'analyse des séries chronologiques et de leurs prévision (Mellit & Pavan, 2010). La méthode Box-Jenkins se base sur une approche itérative en trois étapes :

L'identification : consiste à déterminer l'ordre du modèle, c.-à-d. déterminer les paramètres *p, d, q, à* partir des graphes de la fonction d'autocorrélation (*ACF*) et de la fonction de l'autocorrélation partiel (*PACF*). Le comportement de ces deux fonctions est représenté dans le Tableau II. 2. Cette étape est la plus délicate car dans la pratique les graphes observés n'engendrent pas un choix décisif. Cette raison, on est amené à utiliser des critères supplémentaires pour choisir convenablement le modèle désiré. Parmi ces critères les plus usités, on trouve le critère d'information d'Akaike (*AIC*) et le critère d'information bayésien (*BIC*), qui sont données par les formules suivantes :

$$AIC(p,q) = \ln(\sigma^2) + 2\frac{m}{N} \quad \text{(II.16)}$$

$$BIC(p,q) = \ln(\sigma^2) + (m)\frac{\ln(N)}{N} \quad \text{(II.17)}$$

Où σ_2 est la variance des erreurs de prévision, $m = (p + q)$ et N est le nombre d'observations effectives, utilisés pour ajuster le modèle. L'ordre du modèle optimal est choisi par le nombre de paramètres du

modèle, ce qui minimise soit *AIC* ou *BIC*. D'autres critères similaires ont également été proposés dans la littérature pour l'identification du modèle optimal (Box *et al.,* 2008).

L'estimation : une fois le modèle est choisi par le processus décrit dans l'étape précédente, la phase estimation consiste à déterminer les paramètres requis par le modèle en question et à discuter de leur qualité et de leur aptitude à modéliser la série de données. Il existe plusieurs méthodes d'estimation des paramètres du modèle allant d'une simple analyse de régression, au lissage par la méthode des moindres carrés non linéaire.

Tableau II. 2 : Comportement du *ACF* et *PACF* pour le choix du modèle *ARMA*.

	ACF	***PACF***
***AR*(p)**	Mélange de sinusoïdes amorties et décroissances géométriques	Nulle au-delà de p
***MA*(p)**	Nulle au-delà de p	Mélange de sinusoïdes amorties et décroissances géométriques
***ARMA*(p)**	Mélange de sinusoïdes amorties et décroissances géométriques au-delà de p	Mélange de sinusoïdes amorties et décroissances géométriques au-delà de p

Vérification et diagnostic : il s'agit de vérifier statistiquement si le modèle trouvé lors de la phase d'identification et dont les coefficients ont été estimés, est considéré adéquat pour la prévision. Les principales vérifications à effectuer portent sur les points suivants :

- Inspection visuelle des valeurs d'ACF et de PACF de la série des résidus qui doivent être toutes nulles.
- On applique le test du bruit blanc pour voir si les résidus obtenus ont cette particularité. En effet, une statistique couramment utilisée (Q), dénommée le test du portemanteau de Box et Pierce, est donnée par la relation suivante :

$$Q = n(n+1)\sum_{k=1}^{h}\frac{\rho_k^2}{n-k} \qquad \text{(II.18)}$$

Où : ρ_k est l'autocorrélation au décalage k. La valeur du Q peut être vérifiée sur une base comprise entre un quart et la moitié des observations et ne doit pas être significative pour que l'hypothèse du bruit blanc puisse être conservée pour la série des résidus.

Cette approche itérative a pour but de déterminer le meilleur modèle parcimonieux d'une classe générale de modèles *ARIMA* (Box *et al.,* 2008 ; Mellit & Pavan, 2010). Ce processus est répété

plusieurs fois jusqu'à ce qu'un modèle satisfaisant soit finalement sélectionné. Ensuite, ce modèle peut être utilisé pour prévoir les valeurs futures de la série chronologique. La méthodologie de Box-Jenkins est résumée dans le schéma suivant :

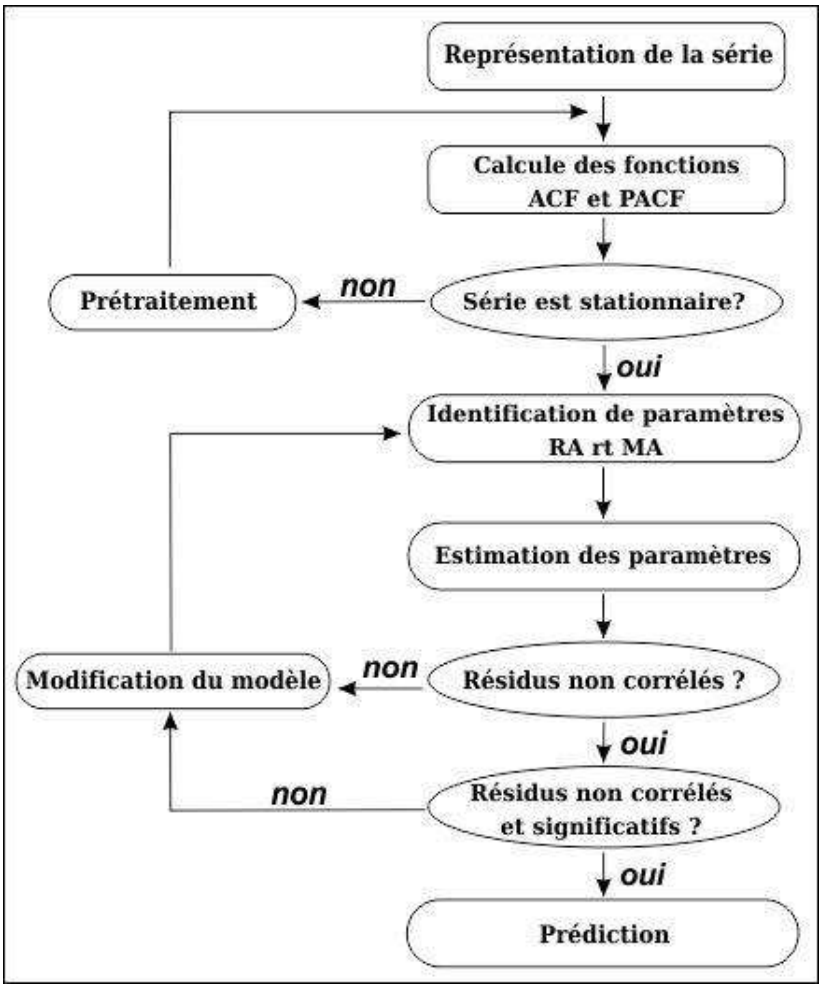


Figure II. 3 : Méthodologie de Box-Jenkins pour la sélection d'un modèle optimal.

II.3.3. Modèles simulés

La caractéristique la plus importante qui distingue ces modèles aux autres est qu'ils sont basés sur l'apprentissage et le test. Dans la plupart des techniques qui relèvent sous cette catégorie, la phase d'apprentissage peut être réalisée par la méthode essai-erreur. D'après la littérature, on remarque qu'ils sont plus efficaces par rapport aux modèles empiriques, mais ils donnent une plus grande complexité.

En général, les modèles sous ce type de catégorie peuvent être divisés en :

- des modèles à base de la régression linéaire locale (LLR)
- et des modèles à base de l'intelligence artificielle (AI)

II.3.3.1. *Modèles de régression linéaire locale (LLR)*

La technique de LLR est une technique de régression non paramétrique qui a été largement utilisé dans la prévision et le lissage de nombreux problèmes de faibles dimensions. Cette méthode est basée sur l'adaptation au niveau local d'une ligne au lieu d'une constante. L'estimation linéaire locale supprime le terme de biais de l'estimateur du noyau qui lui fait d'avoir un meilleur comportement. L'avantage de cette technique est qu'elle donne une modélisation statistique raisonnablement fiable et qu'elle peut être effectuée localement à l'aide d'un petit ensemble de données d'échantillon. Dans le même temps, la *LLR* peut produire des prévisions très précises dans les régions où la densité de données est élevée. Le seul problème avec la *LLR* est la détermination de la taille de V_{max} (le nombre de voisins proches à inclure pour la modélisation linéaire locale). La méthode de choisir V_{max} pour la régression linéaire, est appelée *les statistiques d'influence* (Remesan *et al.*, 2008 ; Shamim *et al.*, 2015). Étant donné un quartier de points V_{max}, l'équation de la matrice linéaire suivant devrait être résolue:$X_m = y$, Où X est un $V_{max} \times d$ (matrice des points d'entrée V_{max} à d dimensions), x_i ($1 \leq i \leq V_{max}$) sont les points voisins les plus proches, y est un vecteur de colonne de longueur V_{max} des sorties correspondantes, et m est un vecteur colonne de paramètres qui doivent être déterminés pour fournir la cartographie optimale de X à y (Remesan *et al.,* 2008).

Les modèles LLR ne nécessitent pas d'apprentissage de la même manière que celle du réseau neuronal artificiel (RNA) ou la logique floue (FL). Son nombre optimal de voisins les plus proches pour LLR (en fonction principalement du niveau de bruit) est généralement déterminé en utilisant un simple apprentissage via la méthode essai-erreur.

Tableau II. 3 : Exemples représentatifs de l'utilisation de LLR à la prédiction du rayonnement solaire

Source	Utilisation de la régression linéaire locale
(Durrant, 2001)	Le modèle LLR peut être implémenté en utilisant un nombre minimum d'évaluations directes en utilisant un *kd*-tree (abréviation de k-dimensionnel tree) pour organiser les données d'apprentissage à l'entrée
(Remesman *et al.,* 2008)	ont utilisé un modèle LLR avec 16 voisins les plus proches pour la prédiction du rayonnement solaire avec le test gamma (GT). Un *kd*-tree est utilisé pour organiser les données d'apprentissage à l'entrée.
(Moghaddamnia *et al.,* 2009)	ont utilisé LLR pour estimer les valeurs quotidiennes d'irradiation globale avec le GT, sur la base de différentes données d'entrée météorologiques
(Asagha & Udo, 2014)	ont mis en œuvre une nouvelle perspective dans la modélisation non-linéaire pour la prédiction du rayonnement solaire global à Bauchi, Nigeria. Ils ont proposé 32 voisins pour arriver au statistique gamma.

II.3.3.2. *Modèles d'intelligence artificielle (IA)*

L'intelligence artificielle est une discipline très avancée de l'informatique dont elle essaye de réaliser des automates adoptant une démarche proche de la pensée humaine. Ainsi, elle concerne l'ensemble des modélisations de la connaissance et des techniques permettant d'atteindre ce but. Les techniques d'intelligence artificielle deviennent très populaires comme une approche alternative aux techniques conventionnelles ou comme composants de systèmes intégrés (Haton & Haton, 1989 ; Russell *et al.*, 1995). Elles ont été utilisées pour résoudre des problèmes pratiques complexes dans divers domaines (Poole *et al.,* 1998).

IA se compose de plusieurs branches telles que, systèmes experts (SE), réseaux de neurones artificiels (RNA), algorithmes génétiques (GA) et Fuzzy Logic (FL) et divers systèmes hybrides (HS), qui sont des combinaisons de deux ou de plusieurs branches mentionné précédemment (Medsker, 1996).

Les trois applications bien connues dans la modélisation de l'irradiation solaire sont :

- Réseau de neurones artificiels (RNA) ;
- Logique floue (LF) ;
- Systèmes d'inférence neuro-flous adaptatifs (ANFIS)

A. Modèle réseau de neurones artificiels (RNA)

Inspiré du fonctionnement du cerveau humain, les réseaux de neurones artificiels(*RNA*) sont relativement nouveaux. Ils constituent un modèle mathématique pour l'approximation des relations entre les variables. Contrairement aux approches classiques, les réseaux de neurones sont réalisés sans imposer aucune forme particulière aux données, et sans faire aucune hypothèse sur la répartition des variables.

Les *RNA* représentent des modèles aussi souvent utilisés dans la prévision de séries temporelles. Ils sont considérés comme des outils utiles pour les problèmes de classification et de régression, ils sont caractérisés par la capacité de corréler des comportements non linéaire, et ont été largement employés avec succès pour la prévision dans divers domaines(Mc Culloch & Pitts, 1943 ; Bishop, 1995). Dans le cadre du traitement des données, les *RNA* constituent une méthode d'approximation de systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l'aide des méthodes statistiques classiques.

Les premiers travaux sur les *RNA* ont été menés par Mc Culloch et Pitts en 1943 (Touzet, 1992). Leur but était de comprendre les propriétés des systèmes nerveux à partir de composants élémentaires. Grâce à des modèles à base de neurones simplifiés (les neurones formels), ils montrent qu'il est possible de construire des systèmes capables de calculer des fonctions logiques. En 1949, Donald Hebb (Hopfield, 1982). Amorce le problème de l'apprentissage où il a décrit la manière dont les cellules apprennent à modifier l'intensité des connexions (appelées poids) qui les relient. Les travaux sur les *RNA* ont continué ensuite à développer progressivement au cours des années. En 1957, Rosenblatt conçut le premier réseau de neurones dédié à la reconnaissance des formes. A son tour, Widrow (1960) a développé le modèle Adaline (Adaptative Linear Element) qui est à l'origine de de l'algorithme de rétropropagation de gradient très utilisé aujourd'hui avec les Perceptrons-Multicouches. Cependant, les *RNA* ont connus un recule suite aux critiques de Minsky et Papert (1969), lorsqu'ils ont publié un ouvrage qui met en évidence l'incapacité du Perceptron à une seule couche de résoudre les systèmes non linéaires. Après un abandon au profil des méthodes classiques, les *RNA* ont connu un renouveau dès le début des années quatre-vingts, avec les travaux de Hopfield (Hopfield, 1984 ; Mc Cleland & Rumelhart, 1986). sur les réseaux interconnectés, et ceux de Mc Clelland et Rumelhart (Da Silva *et al.,* 2016) qui introduisent l'algorithme d'apprentissage de rétro-propagation de l'erreur.

A.1. Le neurone formel

Le neurone formel est une modélisation mathématique qui simule les principes du fonctionnement du neurone biologique (Figure II.4), en particulier la sommation des entrées. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées x_i en provenance de neurones amont (Figure II.5). A chacune de ces entrées est associé un poids w_j pour donner le produit $x_j w_{ij}$ ensuite à partir de cette valeur, une fonction de transfert (ou d'activation) g calcul la valeur de l'état de neurone pour former la sortie y_i :

$$y_i = g(\sum_{j=1}^{n} x_j w_{ij} + b_i) \tag{II.19}$$

Le poids qui n'est pas connecté aux entrées est défini par un biais (b_i)

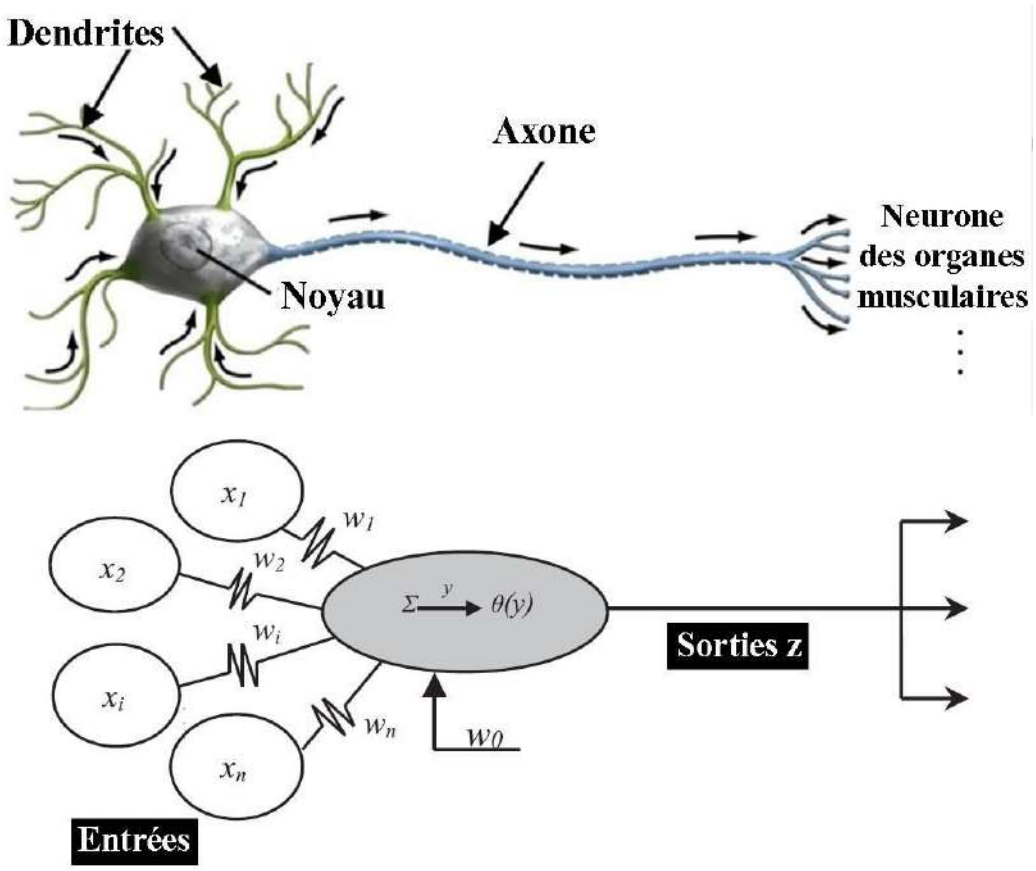


Figure II. 4 : Correspondance entre le neurone biologique et le neurone artificiel (Inman *et al.,* 2013)

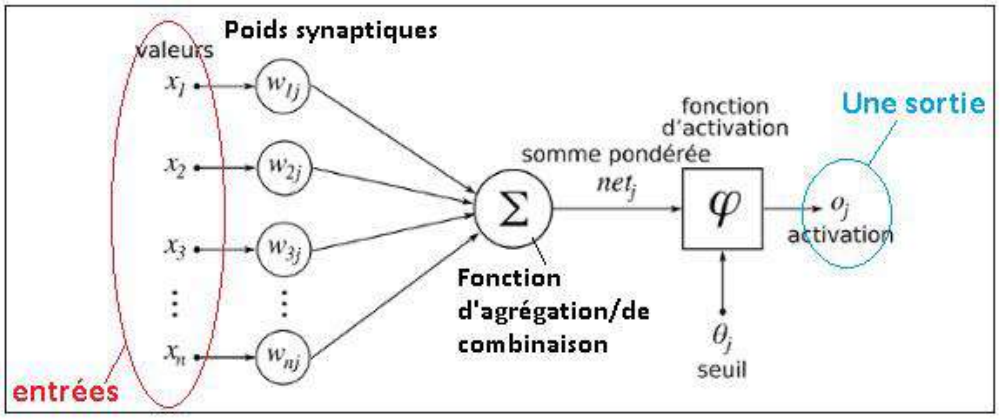


Figure II. 5 : Principe du neurone formel (Hopfield, 1984 ; Touzet, 1992)

Cependant, il existe plusieurs types de fonction d'activation qui servent à limiter l'amplitude du signal de sortie du neurone et reproduire l'effet de seuil observé sur les neurones biologiques. Les fonctions les plus employées sont :

- fonction linéaire affecte directement son entrée à sa sortie : g(x)=x,
- fonction de tangente hyperbolique exprimée par : g(x) = tanh (x)= $(e^x - e^{-x})/ (e^x + e^{-x})$
- fonction sigmoïde standard g(x)= 1/ (1+e-x).

Nous pouvons remarquer que la fonction de transfert sigmoïde possède un régime quasi-linéaire au voisinage de 0 et non-linéaire ailleurs. Cette particularité offre au réseau la possibilité de s'adapter aussi bien aux problèmes linéaires qu'aux problèmes non linéaires.

A.2. Type des réseaux de neurones

Généralement, l'utilisation d'un seul neurone isolé n'a pas d'effet et d'intérêt de point de vue pratique. Mais lorsqu'il est lié et connecté à d'autres neurones, il est possible de former un réseau capable de résoudre des problèmes complexes tel que : la reconnaissance des formes, prédiction des séries temporelles, etc. Le premier réseau le plus employé dans la littérature, est celui du Perceptron à Multicouches(*PMC*) ou Multi-layer Perceptron (*MLP*) en anglais. En effet, les neurones sont organisés de manière à constituer plusieurs couches. Le nombre de couches varie de 3 à 4 dont une couche d'entrée, une couche de sortie et une ou deux couches cachées, et l'information circule de la couche d'entrée vers la couche de sortie uniquement. La couche d'entrée contient autant de neurones que la dimension de l'espace d'entrée et la couche de sortie contient un neurone unique pour la valeur de la

prévision. Enfin, une ou plusieurs couches cachées contiennent un nombre variable de neurones (Figure II. 6).

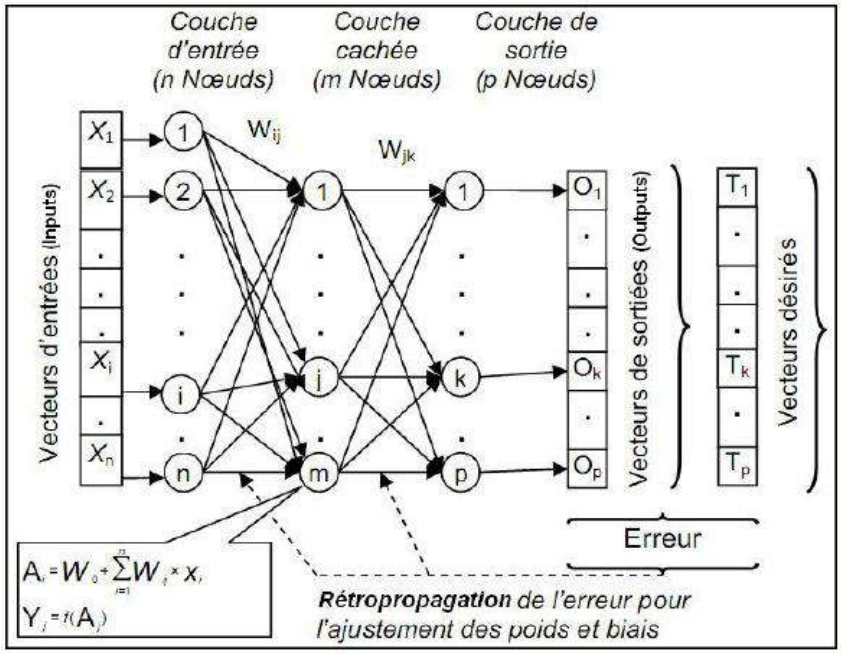


Figure II. 6 : Architecture du réseau neuronal de perceptron multicouche MLP (Heddam *et al.,* 2011).

L'autre catégorie de RNA est celle des réseaux bouclés ayant des connexions récurrentes qui ramènent aux entrées la valeur d'une ou plusieurs sorties, contrairement aux réseaux non bouclés (le cas du PMC) où l'information se propage de l'entrée vers la sortie sans aucun retour vers l'arrière. Le meilleur exemple de ce type de réseaux récurrents est celui élaboré par Hopfield (Hopfield, 1984) le plus communément connu sous le nom de réseau Hopfield. Cette architecture neuronale a les caractéristiques suivantes :

- Comportement dynamique,
- Capacité à mémoriser des relations,
- Possibilité de stocker des informations,
- Mise en œuvre facile dans des supports analogiques.

La figure suivante illustre un exemple d'un réseau récurrent, où l'un de ses signaux de sortie est renvoyé à la couche intermédiaire.

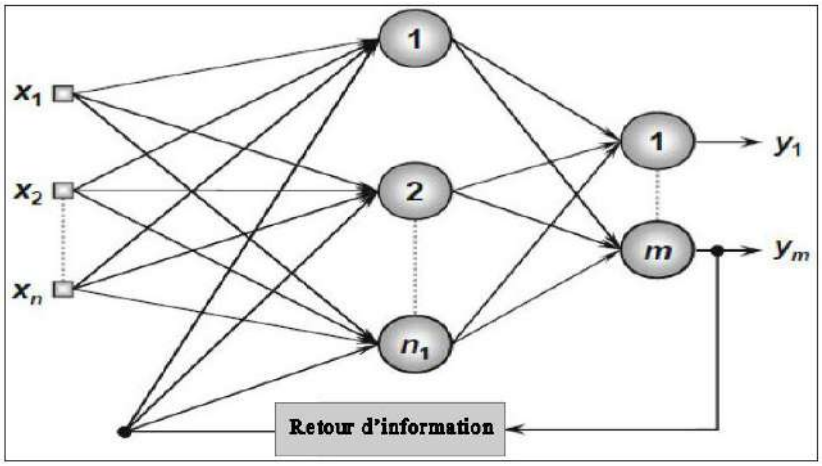


Figure II. 7 : Exemple d'un réseau récurrent (Da Silva *et al.,* 2016).

Les réseaux de fonction radiale (*RBF* : Radial Basis Function) est une autre famille des *RNA* ; ils peuvent également être utilisés dans presque tous les types de problèmes résolus par les réseaux *MLP*.

A l'inverse de ces derniers qui peuvent être composées de plusieurs couches intermédiaires, la structure typique du *RBF* est composée d'une seule couche dont la fonction d'activation est gaussienne. L'une des principales particularités des réseaux *RBF* est l'entrainement utilisé pour ajuster les poids des deux couches de neurones. Une autre caractéristique des RBF est la fonction d'activation utilisée par les neurones de la couche intermédiaire, qui est toujours une fonction de base radial et elle que la fonction gaussienne. Les réseaux *RBF* appartiennent aussi à l'architecture *MLP*, dont la l'entrainement est supervisée. De la Figure II. 8, il est possible de vérifier que les informations qui circule dans sa structure commence de la couche d'entrée, se propage à la couche intermédiaire (neurones avec fonction d'activation gaussienne) et se termine dans la couche de sortie de neurones (neurones avec fonction d'activation linéaire).

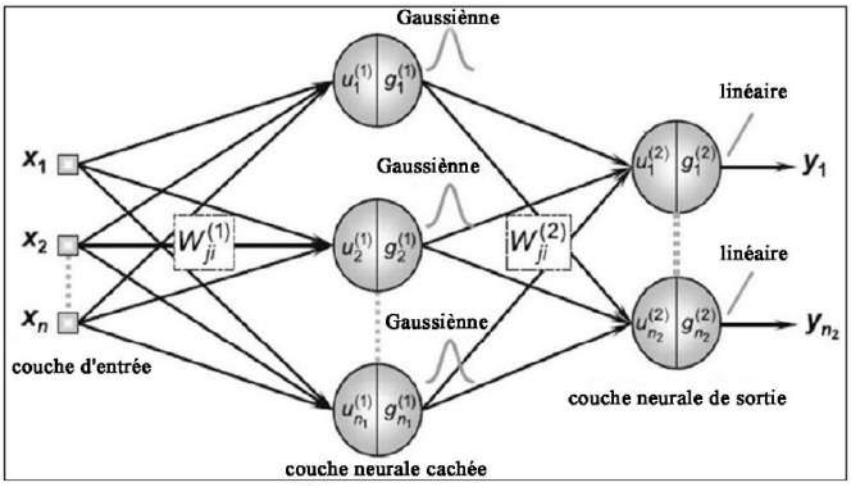


Figure II. 8 : Configuration typique d'un réseau RBF (Da Silva *et al.,* 2016).

L'une des caractéristiques les plus pertinentes des *RNA* est leurs apprentissages ou "entrainement", qui consiste à modifier les poids du réseau en fonction des données d'entrées jusqu'à l'obtention des sorties proche de jeu de données d'entrée souhaité. Il existe trois modes d'apprentissage : l'apprentissage supervisé, c'est lorsqu'on force le réseau à converger vers un état final bien précis, en même temps qu'on lui donne un motif. En d'autre terme, le réseau s'adapte par comparaison entre le résultat qu'il a calculé, en fonction des entrées fournies, et la réponse attendue en sortie. De ce fait, le réseau va se modifier jusqu'à ce qu'il trouve la bonne sortie.

L'algorithme basé sur l'apprentissage non supervisé ne nécessite aucune connaissance à priori sur la sortie désirée ; le réseau est laissé libre de converger vers n'importe quel état final lorsqu'on lui donne une entrée.

L'apprentissage renforcé est une technique similaire à l'apprentissage supervisé à la différence qu'au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade (ou score) qui est une mesure du degré de performance du réseau après quelques itérations.

A.3. Revue des travaux de la prédiction de l'irradiation solaire par le modèle RNA

Les efforts pour la mise en place du modèle RNA dans l'estimation de l'irradiation solaire ont commencé dans la fin des années 1990. Ce qui est très intéressant de noter que, dans moins de 30 ans d'applications de RNA aux études du rayonnement solaire, une grande variété d'approches de formation de réseau de neurones a été utilisée (différents algorithmes d'apprentissage, architectures, etc.) et une multitude de variables d'entrée ont été explorées (météorologiques, géographique,...etc.). Ce qui est

commun dans presque toutes ces études est la validation de la méthodologie proposée respective avec des données indépendantes.

Un regroupement de la littérature disponible est fait concernant l'objectif principal des modèles dans le tableau au-dessous. Le Tableau II. 4 résume plusieurs exemples représentatifs de l'utilisation des réseaux de neurones artificiels (RNA) pour la prédiction du rayonnement solaire global. On note que presque tous les modèles qui estiment le rayonnement solaire global, sont appliqués à l'échelle mensuelle. En effet, Les données mensuelles sont considérés plus stables que les autres en raison du changement de temps rapide. Nous avons énuméré dans le Tableau II. 5 quelques travaux figurant La modélisation de l'irradiation solaire sur une surface inclinée à partir des données de l'irradiation sur une surface horizontale qui reste le choix le plus approprié. Le rayonnement solaire global quotidien est considéré comme le paramètre le plus important dans la météorologie, la conversion solaire et les énergies renouvelables, en particulier pour le dimensionnement des panneaux solaire photovoltaïques autonomes. Sa prédiction a été donnée par un certain nombre de chercheurs comme ce qui est montré dans le Tableau II. 6. Dans certaines applications, nous devons prévoir des radiations solaires à court terme par exemple sur une base horaire, Une minorité de chercheurs ont choisi de modéliser le rayonnement solaire à court terme, nous avons mentionné certains d'entre eux dans le Tableau II. 7.

Tableau II. 4 : Exemples représentatifs de l'utilisation de RNA à la prédiction du rayonnement solaire

Source	***Lieu***	***Les paramètres d'entrés***	***Type RNA/ algorithme d'apprentissage/ fonction d'activation***	***Nombre de Neurones dans la couche cachée***	***Erreur de prédiction***	***Intervalles des données***
(Ouammi et al., 2012)	Maroc	latitude, longitude, altitude	FFMLPBP/../..	20	EAM = 0.14 à 4%	1998 à 2010
(Lazzús *et al.*, 2011)	La Serena (Chili)	vitesse du vent, humidité relative, température de l'air, température du sol	FF MLP BP / LM / tansig	16 - 8	R2 = 94.37 %	2001 à 2007
(Linares *et al.*, 2011)	Espagne	latitude, longitude, jour de l'année, rayonnement quotidien à ciel clair, couverture totale des nuages, température, vapeur d'eau totale de la colonne, colonne d'ozone totale	FF MLP BP / BR/..	25	RMSE = 14.29 à 16.4% R = 94%	1999 à 2009
(Koca *et al.*, 2011)	Turquie	latitude, longitude, altitude, mois de l'année, nébulosité moyenne, vitesse du vent, durée d'ensoleillement	FF MLP BP /…/Tangent sigmoid	8	R2 = 97.86 à 99.87% RMSE = 3.58 à 6.9% COV = 5.41 à 10.26	2005 à 2008
(Voyant *et al.*, 2012)	Corsica (France)	pression, température, nébulosité, vitesse du vent, direction de vitesse, durée d'ensoleillement, humidité relative, précipitation	FF MLP BP / LM / hyperbolic tangent	3 à 5	nRMSE =0.5 to 1% R2 = 72 %	1998 à 2007
(Khatib *et al.*, 2012)	Malaisie	Jour, latitude, longitude, durée d'ensoleillement	FF MLP BP /../ logistic sigmoid	-	MAPE = 5.92% MBE = 1.46% RMSE = 7.96%.	1984 à 2004
(Rahimi, 2010)	Ahwaz (Iran)	la température de l'air maximale et minimale, le rayonnement extraterrestre	FFMLPBP /../ sigmoid	6	RMSE = 2.534 MJ/m2/day R2 = 88.9%	1994 à 2003
(Hasni *et al.*, 2012)	Algérie	température, humidité relative	FFMLPBP / LM / hyperbolic tangent sigmoid	3	MAPE = 2.9971% R2 = 99.99%	02 février à 31 juin 2011

Tableau II. 4 : Exemples représentatifs de l'utilisation de RNA à la prédiction du rayonnement solaire global (Suite)

Source	***Lieu***	***Les paramètres d'entrés***	***Type RNA/ algorithme d'apprentissage/ fonction d'activation***	***Nombre de Neurones dans la couche cachée***	***Erreur de prédiction***	***Intervalles des données***
(Yildiz *et al.*, 2013)	Turquie	latitude, longitude, altitude, mois, température de surface de la terre (mesurée et satellitaire)	FFMLPBP/RP, SCG/ hyperbolic tangent sigmoid	-	R2 = 80.41 à 82.37%	2000 à 2002
(Şenkal *et al.*, 2010)	Turquie	latitude, longitude, altitude, mois, température de surface de la terre	GRNN	-	RMSE= 0.0144 à 4.91%	1988 à 2002
(Maitha *et al.*, 2013)	Émirats arabes unis	la température maximale, la vitesse moyenne du vent, l'ensoleillement et l'humidité relative moyenne	FF MLP BP/ LM / BFGS/ … tangent sigmoid, log sigmoid.	155	R2=0.93 RMSE=0.435% MBE=0.001% MAPE=7.08%	1995 à 2007
(Amit *et al.*, 2014)	Inde	la température, la température maximale, la température minimale, le niveau de la hauteur au-dessus de la mer et les heures d'ensoleillement	FF MLP BP/ LM /-	10	R=91.22 MAPE=6.89%	1986 à 2000
(Younas *et al.*, 2016)	Ethiopia	température minimale et maximale, humidité, ensoleillement et vitesse du vent	FF MLP BP	-	RMSE=0,11% R=0,901	1985 et 1987
(Çelik *et al.*, 2016)	Turquie	mois, latitude, longitude, l'altitude , température moyenne mensuelle et la durée mensuelle moyenne d'ensoleillement.	FF MLP BP	_	R=0.99 MAPE=5%	_
(Premalatha & Valan, 2016)	Inde	la température moyenne de l'air ambiant, la pression moyenne au niveau de la station, la vitesse du vent moyenne, l'humidité relative moyenne	FF MLP BP/ LM / GD/ RP… tangent sigmoid.	24	R= 98–99% MAPE=4.24%	2000 à2009

Tableau II. 4 : Exemples représentatifs de l'utilisation de RNA à la prédiction du rayonnement solaire global (Suite)

Source	***Lieu***	***Les paramètres d'entrés***	***Type RNA/ algorithme d'apprentissage/ fonction d'activation***	***Nombre de Neurones dans la couche cachée***	***Erreur de prédiction***	***Intervalles des données***
(Rajiv & Saurabh 2016)	Inde	Humidité relative, température maximale et la durée d'ensoleillement	FF MLP BP/ tangent sigmoid.	21-25	R= 0.92 RMSE= 4.97	9 années
(Nait *et al.*, 2017)	Maroc	température moyenne, durée d'ensoleillement, humidité relative.	FF MLP BP/ LM/GD…. tangent sigmoid.	25	R=0.988 RMSE=4.07%	1996 à 2005
(Loghmari *et al.*, 2017)	Tunisie	Longitude, Latitude, Altitude, Mois, la durée d'ensoleillement, la température moyenne, Humidité moyenne, l'évaporation cumulée.	FF MLP BP/ LM	10	RMSE= 4,14% -10,1% MBE=6.74%	2008 à 2012

Tableau II. 5 : Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire à des surfaces inclinées

Source	*Lieu*	*Les paramètres d'entrés*	*Type RNA/ algorithme d'apprentissage/ fonction d'activation*	*Nombre de Neurones dans la couche cachée*	*Erreur de prédiction*	*Intervalles des données*
(Mehleri *et al.*, 2010)	Athènes Grèce	Irradiance solaire globale sur une surface horizontale, rayonnement extraterrestre, angle zénithal solaire, angle d'incidence solaire sur un plan incliné	RBF / Gaussian	-	R2 = 96% RMSE = 0.0580% ME = 7.6969% MBE = 0.462%	2004
(Chatterjee & Keyhani, 2012)	Inde, états unis	latitude, réflectivité du sol, valeurs d'éclairement pour 12 mois	FFMLPBP / LM / hyperbolic tangent	15-15	RMSE = 3.2033%	-
(Notton *et al.*, 2012)	Ajaccio France	heure, déclinaison, angle zénithal, irradiation solaire globale horizontale, rayonnement solaire horizontal extraterrestre	FFMLPBP / LM / sigmoid	30	RRMSE = 6% RMAE = 3.5%	2006 à 2010
(Celik & Muneer, 2013)	Iskenderun Turquie	irradiation solaire globale sur une surface horizontale, déclinaison, angle horaire	GRNN / LM / Gaussian	2-1 (couche de motif - couche de sommation)	MAE = 14.9 Wh/m2 R = 98.7% RMAE = 9.1%	Juin 2004 à Mars 2006
(Mehdi Shaddel et al. 2016)	Iran	angle de déclinaison, irradiation solaire extraterrestre, angle d'altitude solaire et l'irradiation horizontale solaire	FF MLP BP/LM tangent sigmoid, log sigmoid.	45-60	R=0.93 MAE=0.02 RMSE=0.05	2013

Tableau II. 6 : Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire quotidien

Source	***Lieu***	***Les paramètres d'entrés***	***Type RNA/ algorithme d'apprentissage/ fonction d'activation***	***Nombre de Neurones dans la couche cachée***	***Erreur de prédiction***	***Intervalles des données***
(Mellit *et al.*, 2010)	Jeddah (Arabie saoudite)	Irradiation globale, durée d'ensoleillement, température de l'air, humidité relative	FFMLPBP / LM /	12 à 17	R = 97% MBE = 0.8	1998 à 2002
(Benghanem & Mellit, 2010)	al-Madinah (Arabie saoudite)	température de l'air, durée d'ensoleillement, humidité relative	RBF	7	MPE = 1.7501% RMSE = 0.013101 MBE = 0.8748 R = 98.80%	1998 à 2002
(Bilgili & Ozgoren, 2011)	Adana (Turquie)	durée d'ensoleillement, température de l'air, vitesse du vent, mois de l'année, jour du mois	FFMLPBP / LM / logsig	5 à 15	MAE = 0.89 à 1 MJ/m2J MAPE = 7.88 à 9.23 % R = 0.9824 à 0.9751 R2 = 0.9651 à 0.9508	2004 à 2007
(Asl, Karami *et al.*, 2011)	Dezful (Iran)	température du sol, jour de l'année, température moyenne quotidienne de l'air, humidité relative, heures d'ensoleillement, évaporation, vitesse du vent	FFMLPBP / LM / logsig	3 - 2	MAPE = 6.08% R2 = 99.03% MSE = 0.0042 SSE =5.9278	2002 à 2006
(Yacef *et al.*, 2012)	al-Madinah (Arabie saoudite)	température de l'air, humidité relative, durée d'ensoleillement, rayonnement extraterrestre	BNN / LM / sigmoid	20	RMSE= 7.489 à59.23% MBE = 3.503 à 9.653% MAE= 4.243 à 13.407% R = 0.833 à 0.951	1998 à 2002

Tableau II. 6 : Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire quotidien (suite)

Source	*Lieu*	*Les paramètres d'entrés*	*Type RNA/ algorithme d'apprentissage/ fonction d'activation*	*Nombre de Neurones dans la couche cachée*	*Erreur de prédiction*	*Intervalles des données*
(Voyant *et al.*, 2012)	France	précipitations, nébulosité, pression, température	FFMLPBP / LM / hyperbolic tangent	-	nRMSE= 14.9%	Octobre 2002 au Décembre 2008
(Vakili *et al.*, 2015)	Iran	température maximale et minimale, humidité relative, vitesse du vent	FF MLP BP/LM/ tangent sigmoid, log sigmoid.	12-24	R=0.99 RMSE=4% MAPE =9.5%	2012-2013
(Shanmuga & Iqbal 2015)	Inde	la température moyenne (T), la température maximale (Tmax), la température minimale (Tmin) et l'altitude	FF MLP BP/LM/	-	R=0.886 MAPE=5.13%	-
(Vakili *et al.*, 2016)	Iran	température maximale et minimale, humidité relative, vitesse du vent	FF MLP BP/ tangent sigmoid, log sigmoid.	12-24	MAPE= 3.04%	1 année
(Muhammed *et al.*, 2017)	Égypte	Rayonnement solaire extraterrestre, Fréquence solaire, Température moyenne journalière, Pression barométrique moyenne quotidienne, Nombre jour, Humidité relative moyenne quotidienne, Vitesse du vent moyenne journalière	FF MLP BP/LM/ hyperbolic tangent sigmoid	2-200	PRMSE= 4.75-31.69%,	octobre 2012 au mai 2016,
(Gasser & Mohamed, 2017)	Egypte	la température ambiante et rayonnement solaire extra-terrestre	FF MLP BP/LM/ tangent sigmoid	1-5	R=0.99 MAPE=0.71%	1er juillet 1983 au 30 juin 2005

Tableau II. 7 : Principaux travaux utilisant RNA dans la prédiction du rayonnement solaire à court terme

Source	***Lieu***	***Les paramètres d'entrés***	***Type RNA/ algorithme d'apprentissage/ fonction d'activation***	***Nombre de Neurones dans la couche cachée***	***Erreur de prédiction***	***Intervalles des données***
(Mellit & Pavan 2010)	Trieste (Italie)	Irradiance solaire quotidienne moyenne, température quotidienne moyenne de l'air, jour du mois	FFMLPBP / LM /	11 à 17	R = 94 à 99%	De 1ier juillet 2008 au 23 mai 2009 et de 23 novembre 2009 au 24 janvier 2010
(Wang *et al.*, 2011)	NREL	Rayonnement diffus, température, humidité relative, temps	FFMLPBP / LM /tangent sigmoid	6 - 15	R2 = 0.9912 MPE = 0.7720 MABE = 0.0138	2006 à 2010
(Capizzi *et al.*, 2012)	Catania (Italie)	Coefficients d'ondelettes	WRNN	16 - 16	R= 98.58 à 98.75%	2 jours
(Faceira *et al.*, 2015)	Portugal	Date, heure, latitude, longitude	FFMLPBP	-	MAPE =5.1%	pendant les jours nuageux d'un jour à l'avance.
(Federico *et al.*, 2016)	Espagne	Température, l'humidité, la pression, le vent ……	FFMLPBP/ log sigmoid.	-	RMSE=1.06%	1 à 6 h

B. Modèle Logique floue (LF)

La logique floue (fuzzy logic) est une technique utilisée en intelligence artificielle ; elle a été formalisée par Zadeh en 1965 (Sen, 1998) et utilisée dans divers domaines tels que le contrôle aérien, la robotique (reconnaissance de formes), l'environnement (météorologie, climatologie, sismologie), etc. Elle s'appuie sur la théorie mathématique des sous-ensembles flous. Zadeh a motivé son travail sur la logique floue avec l'observation que les éléments clés de la pensée humaine ne sont pas des nombres, mais des niveaux d'ensembles flous. En outre, il a vu que chaque mot linguistique dans une langue naturelle comme une description sommaire d'un sous-ensemble flou à un univers du discours représentant le sens de ce mot. En conséquence, il a introduit des variables linguistiques comme des variables dont les valeurs sont des phrases dans une langue naturelle ou artificielle. L'importance de la logique floue dérive du fait que la plupart des modes de raisonnement humain et le raisonnement de sens commun en particulier sont approximatifs et floues en nature.

Donc, la théorie des sous-ensembles flous est une extension de la théorie des ensembles classiques pour la prise en compte d'ensembles définis de façon imprécise. C'est une théorie formelle et mathématique, partant du concept de fonction d'appartenance pour modéliser la définition d'un sous-ensemble d'un univers donné, et élaborant un modèle complet de propriétés et de définitions formelles. Cette théorie des sous-ensembles flous se réduit effectivement à la théorie des sous-ensembles classiques dans le cas où les fonctions d'appartenance considérées prennent des valeurs binaires (0,1).

Contrairement à logique booléenne, la logique floue permet à une condition d'être en un autre état que vrai ou faux, et tient compte de l'imprécision de la forme des connaissances et propose un formalisme rigoureux afin d'inférer de nouvelles connaissances. Ainsi, la notion d'un sous ensemble flou permet de considérer des classes d'objets, dont les frontières ne sont pas clairement définies, par l'introduction d'une fonction caractéristique (fonction d'appartenance) prenant des valeurs entre 0 et 1, à l'inverse de l'ensemble "booléens" dont la fonction caractéristique ne prend que deux valeurs possibles 0 et 1.La base de la théorie de la logique de Zadeh est le concept de l'ensemble flou, qui est défini comme suit : si X est une collection d'objets, l'ensemble flou associé A est défini comme :

$$A = \{(x, m_A(x)) : x \in X\} \tag{II.20}$$

Où $m_A(x)$ est la fonction d'appartenance exprimant le degré d'éléments x dans l'ensemble flou A. Différents sous-ensembles de A sont séparés par les différentes fonctions d'appartenance. Une variable physique est nommée variable linguistique et ses valeurs ne sont pas des nombres, mais des

valeurs linguistiques, appelé attributs, exprimés par des mots ou des phrases. Une fonction d'appartenance est associée à chaque attribut, une variable linguistique ; il indique le niveau de confiance avec lequel cet attribut caractérise un certain élément de l'ensemble X. Une application floue (Figure II. 9) se compose de trois étapes, lafuzzification, l'inférence et la défuzzification.

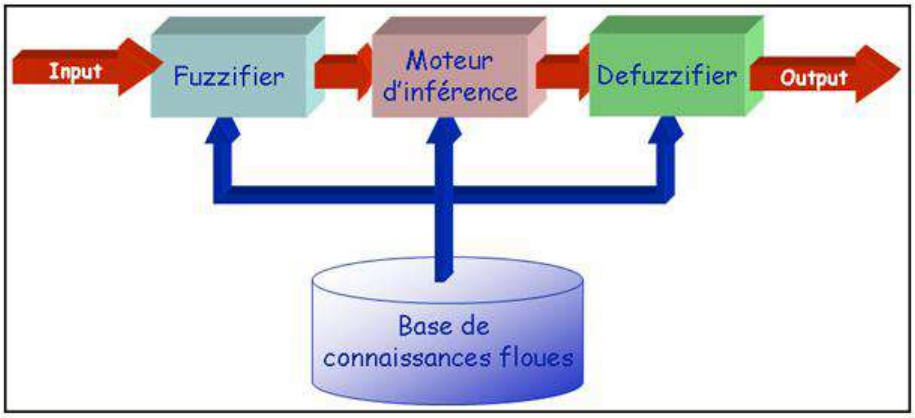


Figure II. 9 : Modèle d'un système floue.

La fuzzification est un procédé de codage, dans lequel chaque entrée numérique d'une variable linguistique est transformée en fonction d'appartenance.

L'inférence est un processus qui se réfère à la base de règles floues contenant les règles (IF, THEN, AND, OR, etc.) pour dériver les valeurs linguistiques pour les variables intermédiaires et de sortie.

La défuzzification est une opération de décodage de l'information contenue dans la sortie des ensembles flous, résultante du processus d'inférence, pour obtenir la valeur nette de sortie la plus appropriée.

Il existe de nombreuses méthodes de défuzzification, parmi lesquelles, on peut citer la méthode du centre de gravité, qui est l'une des méthodes les plus populaires employée. La valeur nette de sortie appropriée est calculée par l'équation suivante

$$y_{nette} = \frac{\sum_i C_i \int m_{y_i}(x)dx}{\sum_i \int m_{y_i}(x)dx} \qquad \text{(II.21)}$$

Où : C_i est le centre de la fonction d'appartenance (généralement la valeur de la variable x, dans laquelle la fonction d'appartenance atteint son pic) et l'intégrale $\int m_{yi}(x)$ dx représente la surface sous la fonction d'appartenance $m_{yi}(x)$ correspondant à l'attribut i de la variable linguistique de sortie y.

Pour illustrer ce modèle, on donne l'exemple suivant : on suppose une séquence de mesures de fraction d'insolation journalière σ (définit dans le chapitre III). Soit X_σ = [0,1] correspond à l'ensemble X

d'après l'Equation (II.21). Une valeur peut être établie (par exemple, σ_0= 0.5) pour séparer l'ensemble X_σ en deux sous-ensembles nommés : ciel Nuageux si $\sigma \in X_{\sigma 1}$= [0,σ_0] et ciel Clair $\sigma \in X_{\sigma 2}$= [σ_0, 1]. Nous sommes habitués à exprimer qu'une journée est ensoleillée, si σ appartient à $X_{\sigma 2}$ par la fonction f : $X_\sigma \rightarrow$ {0,1} définie comme $f(\sigma)$=1 si $\sigma \geq \sigma_0$ autre, $f(\sigma)$=0, comme est illustré dans la Figure II. 10.

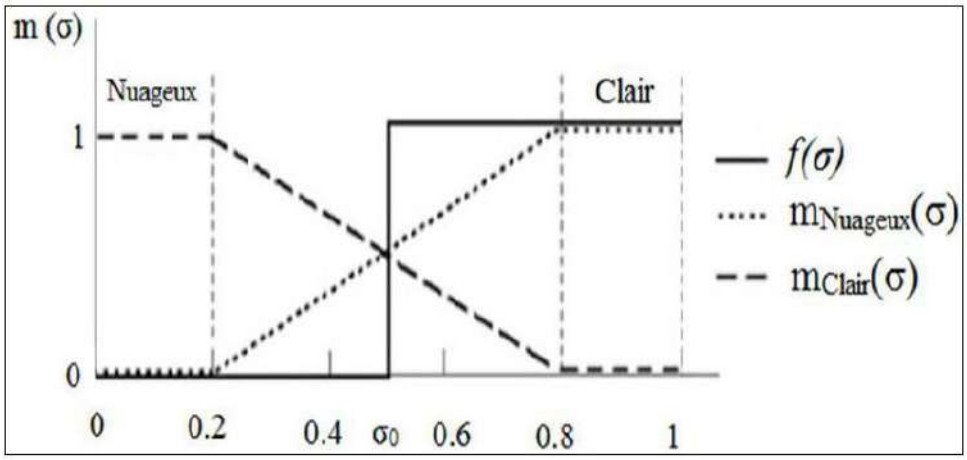


Figure II. 10 : Fonction caractéristique $f(\sigma)$ et fonction d'appartenance ($m_{Nuageux}$ et m_{Clair}) de la fraction d'insolation journalière (Sen, 2008).

Dans la figure ci-dessus $m_{Nuageux}$ (σ) tend vers 0 lorsque l'on approche la situation Nuageux,i.e. large valeur de σ0. De même m_{Clair} (σ) tend vers 1 lorsque l'on approche la situation Clair, i.e. large valeur de σ_0. La théorie des ensembles flous détend la traversée de $X_{\sigma 1}$ à $X_{\sigma 2}$ en remplaçant la limite abrupte entre les attributs Nuageux et Clair avec une traversée variant lentement dans un intervalle fini autour de σ_0. La fonction binaire $f(\sigma)$ est remplacée par les fonctions d'appartenance $m_{Nuageux}$(σ) et m_{Clair}(σ), qui prend des valeurs dans l'intervalle [0,1].

A partir de la dernière figure, on peut constater qu'une journée caractérisée par un σ inférieur à 0.2, certainement a un attribut Nuageux, tandis que la journée qui a un σ supérieur à 0.8 a un attribut Clair. La différence fondamentale par rapport à la théorie des probabilités, qui assignent pour chaque jour une probabilité d'être Clair ou Nuageux, est que la théorie des ensembles flous prétend que chaque jour a à la fois les attribues clair et Nuageux simultanément, le premier avec le niveau de confiance m_{Clair}(r) et le second avec le niveau de confiance $m_{Nuageux}$(r). Théoriquement, la fonction d'appartenance peut avoir une forme quelconque ; mais en pratique, on distingue trois formes qui sont fréquemment utilisées, à savoir : triangulaire, trapézoïdale et gaussien.

Un autre exemple pour l'estimation de rayonnement solaire avec cette méthodologie a été donné par Sen (Sen, 1998 ; Sen, 2008) où il a utilisé des déclarations logiques sous forme ***IF-THEN***. Parmi une multitude de propositions, deux d'entre eux sont déduites :

- IF la durée d'insolation est "longue" THEN la quantité de rayonnement solaire est «grande».
- IF la durée d'insolation est "courte" alors la quantité de rayonnement solaire est «petit».

Dans ces deux propositions, il a suggéré que les deux variables (durée d'insolation et rayonnement solaire) sont décrites en termes de variables linguistiques comme *long, Medium, Short* et *Small*. Ces variables linguistiques sont seulement un certain jeu de partie de l'ensemble du domaine de variabilité. Il a constaté également qu'à partir de cet argument, un ensemble de relations est recherché entre les deux variables, comme illustré dans la Figure II. 11 où elle montre une architecture d'une proposition floue à deux variables.

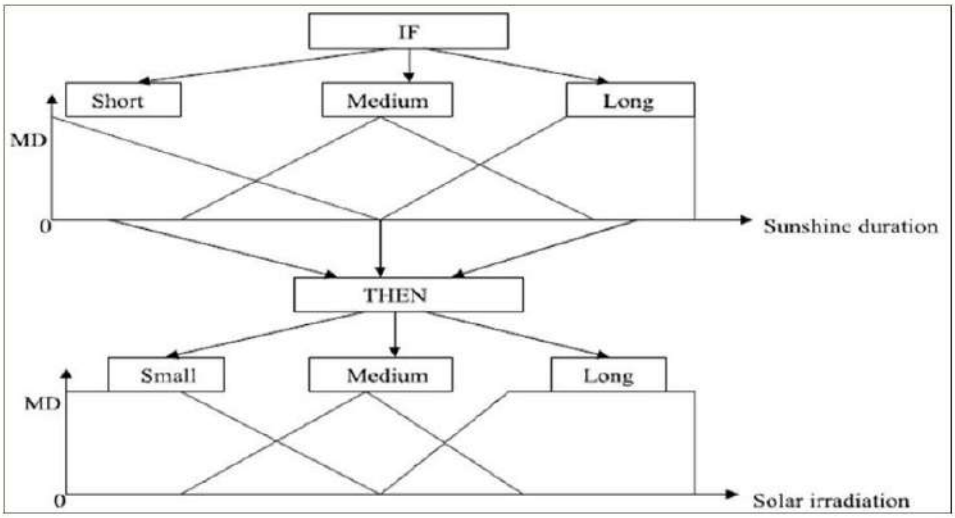


Figure II. 11 : Ensembles et relations floues pour l'estimation de l'irradiation solaire (Sen, 1998).

Les trois premières cases sur la même ligne représentent les mots linguistiques de la durée d'insolation, et la deuxième ligne les trois mots pour le rayonnement solaire. Par conséquent, il a déduit neuf différentes relations « *IF-THEN* » utilisées pour l'estimation du rayonnement solaire.

C. Modèles hybrides

Les modèles hybrides ont été introduits pour résoudre les imprécisions induites par l'utilisation d'un seul modèle, tel que les méthodes statistiques (*ARIMA*, régression multiple, etc.) et les méthodes d'intelligence artificielle. Les modèles hybrides combinent les différentes méthodes à la fois pour améliorer la précision de la prédiction. Donc, ils peuvent être élaborés sous trois différentes formes : hybridation entre les modèles linéaires, hybridation entre modèles non linéaires et hybridation entre modèles linéaires et non linéaires au même temps. Chaque technique intelligente a des propriétés de calcul (par exemple de la capacité d'apprendre, explication des décisions) qui les rendent aptes à des problèmes particuliers et non pour d'autres. Par exemple, les réseaux neuraux sont bons pour

reconnaître les modèles, et ils ne sont pas aptes à expliquer comment ils prennent leurs décisions. Les systèmes flous qui peuvent raisonner avec des informations imprécises, sont bons à expliquer leurs décisions, mais ils ne peuvent pas acquérir automatiquement les règles qu'ils utilisent pour prendre ces décisions. Ces limitations ont été une force motrice derrière la création de ces modèles hybrides, où deux ou plusieurs techniques sont combinées d'une manière à pallier les limites d'un modèle individuelle. L'utilisation des méthodes hybrides se développe rapidement avec des applications réussies (Medsker, 1995) dans de nombreux domaines tels que le contrôle des processus, le diagnostic médical, la simulation cognitive, etc. Donc, différentes méthodes d'hybridation ont été proposées dans la littérature en vue d'améliorer les résultats de prédiction ; parmi ces méthodes, nous pouvons citer le modèle hybride neurone-floue (ANFIS), ondelette-ANN et ARMA-ANN comme des modèles les plus utilisés pour la prédiction du rayonnement solaire. En ce qui suit, nous donnerons plus de détails sur les modèles hybrides les plus fréquemment utilisés dans la prédiction du rayonnement solaire.

C.1. Modèle système d'inférence adaptatif neuro-flou (ANFIS)

L'ANFIS est un réseau feed-forward multicouche, qui utilise des algorithmes d'apprentissage du réseau neuronal et le raisonnement flou pour cartographier les entrées en une sortie. ANFIS tire son nom du système d'inférence neuro-flou adaptatif qui utilise une combinaison des moindres carrés et l'algorithme de rétro-propagation pour l'estimation de la fonction d'activation. ANFIS est basé sur des outils mathématiques classiques qui combinent les propriétés de la logique floue et de réseaux de neurones pour former un système intelligent hybride. Il améliore la capacité d'apprendre et d'adapter automatiquement. L'utilisation conjointe des réseaux de neurones et de la logique floue, permet de tirer les avantages des deux méthodes : les capacités d'apprentissage de la première et la lisibilité et la souplesse de la seconde (Jang*et al.,* 1997 ; Abraham, 2005 ; Azeem, 2012).

Pour simplifier le modèle, nous considérons un système à deux entrées x_1 et x_2, une sortie y et un modèle flou de type Takagi Sugeno de ce système, composé des deux règles suivantes :

Règle1 : Si x est A_1 et y est B_1, al $f_1 = p_1 x + q_1 y + r_1$ (II. 22)

Règle2 : Si x est A_2 et y est B_2, al $f_2 = p_2 x + q_2 y + r_2$ (II.23)

L'algorithme ANFIS permet de construire un réseau implémentant ces règles selon l'architecture suivante :

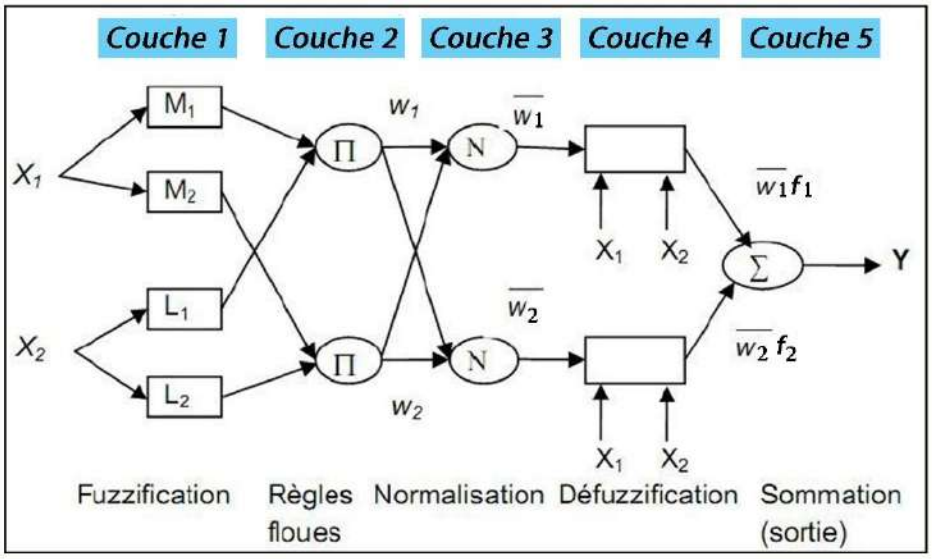


Figure II. 12 : Architecture du modèle ANFIS (Heddam *et al.,* 2011).

Le réseau adaptatif ANFIS est donc, un réseau multicouche dont les connexions ne sont pas pondérées ou elles ont toutes un poids égal à 1. Les nœuds sont de deux types différents selon leur fonctionnalité : des nœuds adaptatifs (carrés), et des nœuds fixes (circulaires). Dans la structure ANFIS:

- **Couche 1** : chaque nœud de cette couche est un nœud carré adaptatif avec une fonction :

$$O_{1,i} = \mu_{Mi}(x_1) \text{ pour } i = 1, 2, \ldots, m \quad \text{(II.24)}$$

$$O_{1,i} = \mu_{L_{i2}}(x_2) \text{ pour } i = 1, 2, \ldots, m \quad \text{(II.25)}$$

Où x_1 (ou x_2) est l'entrée du nœud i, M_i (ou L_i) est le terme linguistique associé à sa fonction. Les nœuds de cette couche représentent le degré d'appartenance de x_1 (ou x_2) à M_i (ou L_i) ; c'est la phase défuzzification.

- **Couche 2** : chaque nœud de cette couche est un nœud circulaire fixe, appelé (Π), qui reçoit les sorties des nœuds défuzzification et calcule leur activation. Le nombre de nœuds dans cette couche est égal au nombre de règles « Si…..Alors » dans le système d'inférence flou.

$$O_{2,i} = w_i = \mu_{Mi}(x_1) \cdot \mu_{Li}(x_2), \; i = 1, 2 \quad \text{(II.26)}$$

- **Couche 3** : chaque nœud de cette couche est un nœud circulaire fixe, appelé (N). C'est la couche de normalisation dans laquelle chaque nœud calcule le degré d'appartenance normalisé à une règle floue donnée. Le résultat obtenu représente la participation de chaque règle floue au résultat final. Cette couche renvoie des sorties normalisées de défuzzification.

$$O_{3,i} = \overline{w}_i = \frac{w_i}{w_1 + w_2} \tag{II.27}$$

- **Couche 4** : Chaque nœud i de cette couche est un nœud carré adaptatif qui correspond à l'entrée initiale pondérée par le degré d'appartenance normalisé de la règle floue.

$$O_{4,i} = \overline{w}_i f_i = \overline{w}_i \left(pi.x_1 + qi.x_2 + ri \right) \tag{II.28}$$

Où w_i est la sortie normalisée de la couche 3, et {pi, qi, ri} est l'ensemble des paramètres de sortie de la règle i. C'est la phase de défuzzification.

- **Couche 5** : composée d'un seul nœud fixe circulaire appelé (Σ) qui reçoit la somme des sorties de tous les nœuds de défuzzification, et fournit la sortie du modèle ANFIS.

$$O_{5,i} = \sum_i \overline{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \tag{II.29}$$

C.2. Modèle RNA-AG

L'activité de recherche et le développement sur les systèmes hybrides génétiques et neuronaux a augmenté d'une façon extraordinaire depuis la fin des années 1980. La plupart de l'activité a été axée sur l'exploitation des avantages de l'algorithme génétique (AG) et de d'améliorer la conception et l'utilisation des réseaux de neurones.

Les travaux publiés dans la littérature, utilisent la capacité des AG pour chercher de grands espaces complexes afin de préparer les données pour les réseaux de neurones, trouver des ensembles de paramètres initiaux pour l'entrainement des réseaux et utiliser l'AG et les techniques d'évolution plus récentes pour faire évoluer les topologies des RNA.

Les algorithmes génétiques peuvent être utilisés pour améliorer les données présentées à un réseau neuronal car, la représentation et la sélection des données d'entrée est souvent l'aspect critique de la conception et la mise en œuvre d'un RNA. En outre, un réseau peut être utilisé à analyser les données pour l'optimisation par l'AG. Par exemple, le réseau de neurone peut identifier des groupes de données qui peuvent être analysées par l'algorithme génétique.

Dans un réseau fixe, les paramètres peuvent être optimisés en générant des tests de populations ayant des valeurs différentes pour les paramètres tels que le taux d'apprentissage et le nombre de nœuds cachés. Les informations relatives à la mise en place de chaque réseau est contenu dans le chromosome correspondant dans le réseau candidat. L'opérateur de Mutation apporte des modifications aux populations actuelles sous certaines contraintes pour l'application.

C.3. Modèle FL-AG

L'intégration des algorithmes génétiques avec les systèmes flous est une méthode plus récente et moins explorée que la combinaison d'AG ou la logique floue avec les systèmes neuronaux. Cependant, Les systèmes flous et génétiques fonctionnent bien dans des environnements similaires, notamment dans les systèmes non linéaires qui exigent des niveaux élevés de performance en termes d'efficacité et de rapidité d'exécution. Ainsi, ces deux technologies sont parfois alternatives et peuvent être bien utilisés dans les modes autonomes ou transformationnels (Jang, 1993 ; Mellit *et al.,* 2009).
Dans un système FL-AG, les composants flous fournissent une représentation claire de la connaissance des règles ou des expressions mathématiques. L'utilisation des fonctions d'appartenance et les paramètres associés offrent une flexibilité simplifiant la conception des systèmes très complexes, donc, l'AG facilite l'optimisation des performances du système flou. Dans la conception du système flou, l'AG peut être utilisé pour ajuster les valeurs d'appartenance et d'en tirer des règles floues.

II.3.4. Modèles optimisés

L'optimisation est une méthode permettant de trouver les conditions qui donnent valeur maximum ou minimum de la fonction objective pour obtenir des résultats précis dans des conditions spécifiées. Il est utile dans la conception, la construction et l'entretien d'un système d'ingénierie (Rao, 2009).

Les modèles optimisés sont des modèles basés sur les algorithmes d'optimisation (AO). Les algorithmes d'optimisation (AO) désignent une méthode de calcul qui optimise un problème en essayant d'améliorer itérativement une solution candidate par rapport à une mesure de qualité donné. Les algorithmes d'optimisation mis en place un peu ou aucunes hypothèses sur le problème en cours d'optimisation et faire la recherche dans de très grandes espaces à des solutions candidates. Cependant, une optimisation aléatoire ne garantit pas une solution optimale (Blum & Roli, 2003). De nombreux algorithmes d'optimisation mettent en œuvre une certaine forme d'optimisation stochastique. Ils ont été conçues et créés pour «sauter» de l'optimum local pour atteindre le global. Ils sont censés pour ne pas

"se coincer" dans un optimum local. En d'autres termes, parce que les algorithmes d'optimisation effectuent une large recherche aléatoire, le risque d'être pris au piège dans un optimum local est profondément diminué (Talebi *et al.,* 2010). De nombreux algorithmes d'optimisation existent, et de nouvelles variantes sont continuellement proposées. Certaines des contributions les plus significatives sur le terrain sont : l'optimisation aléatoire, les algorithmes génétiques AG, la recherche Tabou, PSO, L'algorithme de colonie d'abeille artificielle, BA, et la concurrence impérialiste algorithme ICA…etc. (Kennedy & Eberhart, 1942 ; Matyas, 1965 ; Holland, 1975 ; Glover, 1986 ; Shi & Eberhart, 1998 ; Karaboga, 2005 ; Atashpaz-Gargari & Lucas, 2007 ; Pham *et al.,* 2006 ; Shah-Hosseini, 2011).

Les algorithmes d'optimisation peuvent être utilisés sur les deux modèles : empiriques et simulées dans l'estimation d'irradiation solaire. En conséquence, les modèles optimisés (basés sur AO) peuvent être divisés en deux groupes :

- Modèles empiriques optimisés par les algorithmes d'optimisation ;
- Modèles optimisés simulés par les algorithmes d'optimisation.

II.3.4.1. Modèles empiriques optimisés

Dans cette sous-catégorie, l'installation des séries de données est utilisée pour trouver les meilleurs coefficients des modèles empiriques et de l'intensité d'irradiation solaire à travers les algorithmes d'optimisation (au lieu de SRT en première classe). Le crédit des résultats obtenus sera évalué par une série de données de validation. Les principaux avantages de cette sous-catégorie sont l'élimination de la phase d'apprentissage et donc de réduire la complexité plutôt que des modèles simulés, ainsi que les coefficients calculés sont plus précis aux modèles empiriques et là-dessus l'estimation de l'intensité d'irradiation solaire avec plus de précision en comparant avec les modèles empiriques basées sur SRT.

Behrang et al. (2011) ont utilisé la combinaison de PSO et certains modèles empiriques linéaires et non linéaires pour estimer la moyenne mensuelle quotidienne du rayonnement solaire global sur une surface horizontale pour 17 régions différentes de l'Iran. Les quantités de coefficients empiriques pour tous les modèles ont été déterminées en utilisant la technique de PSO pour toutes les villes. Les modèles ont été validés à l'aide des séries de données de validation. Les résultats ont montré que le coefficient empirique obtenu pour le modèle d'Angstrom basé sur PSO a une plus grande précision que les techniques statistiques classiques pour toutes les villes testées (Behrang *et al.,* 2011).

Tolabi et al. (2013) ont proposé la concurrence impérialiste algorithme (ICA) sur la base du modèle d'Angström classique pour la prédiction de rayonnement solaire global dans quatre villes à différentes climats en Iran. Comme tous les coefficients d'Angström obtenus par l'ICA dans cette étude ont des valeurs de fraction de variance (R2) plus que les résultats de la technique conventionnelle statistique, il est confirmé que la nouvelle technique hybride est plus précise que les méthodes conventionnelles statistiques dans l'estimation de rayonnement solaire pour tous les emplacements testés (Tolabi *et al.*, 2013).

II.3.4.2. Modèles simulés optimisés

Dans cette sous-catégorie, les algorithmes d'optimisation sont utilisés pour améliorer l'étape de l'apprentissage pour atteindre un modèle simulé optimal. Ces modèles sont plus efficaces par rapport aux modèles empiriques et simulées, mais ils donnent une plus grande complexité plutôt que les derniers modèles.

Jianmin Su et al. (2009) ont utilisé les AG pour améliorer la performance du réseau de neurones dans l'estimation d'irradiation solaire (Su *et al.,* 2009). Etant donné que les réseaux de neurones à rétro-propagation sont aptes à converger au point optimal local, ils ont utilisé un algorithme génétique pour optimiser les poids de réseaux de neurones à rétro-propagation et les valeurs de seuil. Ils ont prouvé que cette précision de prédiction des algorithmes composés avait de meilleures performances pour estimer le rayonnement solaire.

Wang et al. (2011) ont proposé un algorithme génétique d'optimisation du modèle de réseau neuronal (GAO-WNN) pour l'estimation du rayonnement solaire quotidien (Wang *et al.,* 2011). Ils croyaient qu'elle est une méthode précise et fiable pour prédire le rayonnement quotidien, parce que l'utilisation de la combinaison de l'optimalité globale d'AG et les propriétés locales favorables de WNN pour trainer le modèle, non seulement fournit un moyen efficace pour l'initialisation des paramètres, mais aussi pour trouver l'optimum global rapidement.

Mohandes (2012) a utilisé le PSO pour la modélisation de rayonnement solaire global (Mohandes, 2012). Dans cette étude, le PSO a été utilisé pour former un RNA (PSO-RNA) en utilisant les données des stations de mesure disponibles pour estimer la moyenne mensuelle quotidienne du rayonnement solaire dans le Royaume d'Arabie Saoudite. La comparaison avec BP-RNA et un modèle empirique a montré la supériorité de la PSO-RNA.

II.4. Performance et évaluation des prédicteurs

La précision des modèles de rayonnement solaire est importante non seulement pour les étapes finales des projets solaires, mais en particulier dans les étapes initiales avant toute construction de modèles. Il existe de nombreux outils statistiques usités pour vérifier si un prédicteur est efficace ou non. La précision des modèles prédits est jugée par des indicateurs statistiques tels que le coefficient de détermination (R2), l'erreur de biais moyen (MBE), la racine de l'erreur quadratique moyenne (RMSE), l'erreur moyenne absolue (MAEP), etc. Ces tests sont généralement appliqués dans la comparaison des modèles de rayonnement solaire. Ces outils sont exposés dans ce qui suit :

II.4.1. Coefficient de détermination (R^2)

Le coefficient de détermination est la proportion de la variabilité dans un ensemble de données qui est comptabilisée pour un modèle statistique, où la variabilité est mesurée quantitativement comme la somme des écarts carrés. Le plus souvent, il est défini comme :

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(Y_{i,exp} - Y_{i,cal})^2}{\sum_{i=1}^{n}(Y_{i,exp} - \overline{Y_{i,exp}})^2} \quad \text{(II.30)}$$

Le coefficient de détermination est une statistique qui donne des informations sur la qualité d'ajustement d'un modèle. En régression, le coefficient R^2 est une mesure statistique dans laquelle la droite de régression se rapproche des points de données réels. Un R^2 =1 indique que la droite de régression correspond parfaitement aux données, contrairement, lorsque R^2 =0 cela signifié qu'aucune corrélation n'est possible entre le modèle et les données réels.

II.4.2. Racine de l'erreur moyenne quadratique (*RMSE*)

La racine de l'erreur moyenne quadratique fournit des informations sur la performance des prédicteurs, en permettant la comparaison des écarts réels entre les valeurs estimées et les valeurs mesurées. Plus la valeur du *RMSE* n'est faible, plus la performance du prédicteur est meilleure. Cet indicateur statistique est donné par la relation c'est après :

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(Y_{i,exp} - Y_{i,cal})^2}{n}} \quad \text{(II.31)}$$

II.4.3. Erreur de Biais Moyen (*MBE*)

L'MBE est défini comme étant la moyenne arithmétique des erreurs. Si sa valeur est égale à zéro, cela ne signifie pas que le modèle donne des estimations sans erreur. Donc, le *MBE* fournit une mesure de la tendance générale d'un estimateur donné, c'est-à-dire une surestimation (valeurs positives) ou une sous-estimation (valeurs négatives). Cependant, plus les valeurs du *MBE* sont petites, plus on a un meilleur résultat du modèle. Le *MBE* est donné par l'équation suivante :

$$\mathrm{MBE}= \sum_{i=1}^{n} \frac{(Y_{i,exp}-Y_{i,cal})}{n} \tag{II.32}$$

II.4.4. Erreur moyenne absolue en pourcentage (*MAPE*)

L'*MAPE* exprime la précision en pourcentage de l'erreur. Etant donné que ce nombre est un pourcentage, il est peut-être plus facile à comprendre que les autres statistiques. Cette erreur est définie par :

$$\mathrm{MAPE}= \frac{100}{n} \left(\sum_{i=1}^{n} \left| \frac{Y_{i,exp}-Y_{i,cal}}{Y_{i,exp}} \right| \right) \tag{II.33}$$

En terme général, ces formulations d'erreur fournissent des mesures quantitatives qui ont les mêmes unités physiques comme la variable dépendante « Y_i ». Dans certains cas, des formulations normalisées de ces erreurs (*nMBE*), (*nRMSE*) sont requises ; elles sont définies comme suit :

$$\mathrm{nRMSE}= \frac{RMSE}{(Y_{max,exp}-Y_{min,exp})} \tag{II.34}$$

$$\mathrm{nMBE}= \frac{MBE}{(Y_{max,exp}-Y_{min,\mathrm{exp}})} \tag{II.35}$$

II.5. Conclusion

L'objectif principal de ce chapitre était de fournir une évaluation des différents modèles de rayonnement solaire, ce qui pourrait être utile dans le choix du modèle le plus approprié et précise basée sur les données météorologiques disponibles. Dans cette étude, une analyse statistique détaillée et la classification des modèles de rayonnement solaire disponible est menée.

La revue que nous avons faite sur la littérature, nous a permis de tirer les principales étapes de l'établissement d'un modèle d'estimation ou de prédiction de l'irradiation solaire, :

- Collecte de données pour autant d'endroits dans le monde entier
- Choix de la technique suivie dans la modélisation est soumis à la qualité des données disponibles
- Exploration des corrélations des différents paramètres météorologiques avec l'irradiation solaire
- Choix de la structure du modèle
- Choix des paramètres dominants en fonction de leur disponibilité et de sa force de corrélation avec le rayonnement solaire
- Essai du modèle à l'aide de données disponibles pour les régions élargissant progressivement
- Test du modèle en termes de l'indépendance et de la cohérence
- Validation du modèle.

Chapitre III

Modélisation neuronale de l'irradiation solaire globale

Première contribution

III.1.1. Introduction

L'exploration du potentiel de l'énergie solaire en Algérie jouit d'une attention sérieuse. L'Algérie est située entre 19° et 37° N Latitudes, 8°W et 9.5E longitudes. Le climat d'Algérie est un climat de transition entre maritime (nord) et semi-aride à aride (au milieu et au sud). Selon une étude de l'Agence spatiale allemande (DLR), l'Algérie possède avec ses 1.787.000 km², le plus grand potentiel solaire terrestre sur le long terme pour un potentiel thermique solaire concentré. Il est doté d'un rayonnement solaire suffisant qui peut être efficacement exploité comme source d'énergie renouvelable, allant de 5,6 kWh/m^2 à 7,2 kWh/m^2, ce qui correspond à 1700 kWh/m²/an dans le nord et 2650 kWh/m²/an dans le sud. Il est considéré comme étant l'une des zones les mieux ensoleillées dans le monde, la moyenne annuelle des heures d'ensoleillement y atteint 2650 dans le Nord, 3000 dans les hauts plateaux et 3500 dans les régions du Sahara. Le potentiel technique et économique pour la production d'électricité par la technologie thermique solaire concentré (CSTP) en Algérie est d'environ 169000 TWh (Trieb, 2005; OBG, 2013).

Par conséquent, puisque la technologie pour exploiter l'énergie solaire en Algérie est encore à ses débuts, de nombreuses options sont ouvertes pour contribuer à sa croissance. Dans cette contribution, nous avons choisi de mettre l'accent sur la question de l'évaluation de la disponibilité de l'énergie solaire en diverses régions du pays. Afin d'arriver à une politique à l'échelle nationale sur l'exploitation de l'énergie solaire, les planificateurs auraient besoin d'une évaluation fiable de la disponibilité du rayonnement solaire à différents endroits du pays.

La mesure directe du rayonnement solaire à pour un très grand nombre d'emplacements sur l'échelle horaire, journalière, mensuelle, et même annuelle, s'avère très couteuse et empêcherait ainsi la mise en œuvre d'une telle démarche. Au lieu de cela, les avantages de la modélisation neuronale cités auparavant sont une alternative qui peut être explorée pour fournir une estimation du rayonnement solaire disponible à un endroit donné avec une précision raisonnable.

III.1.2. Bases de données employées

Des moyennes journalières de l'irradiation globale reçue sur plan horizontal ont étés utilisées pour cette étude sur un ensemble de 4 stations, à travers le territoire national, représentant les différents climats du pays. Sur le Tableau III. 1. 1, sont données les coordonnées géographiques des différentes stations concernées pour cette étude. Quatre stations ont étés considérées : la première station est située

dans la région Nord- Est (Souk Ahras), la deuxième station se situe dans la région Nord des Hauts plateaux (Médéa), la troisième est située dans la région du nord-ouest (Tlemcen) et enfin la quatrième station se trouve dans la région sud-ouest (Adrar). Les données satellitaires des stations météorologiques ont été obtenues par le service SoDa, disponible gratuitement sur http://www.soda-pro.com. Les coordonnées de chaque station sont présentées sur la Figure III.1. 1.

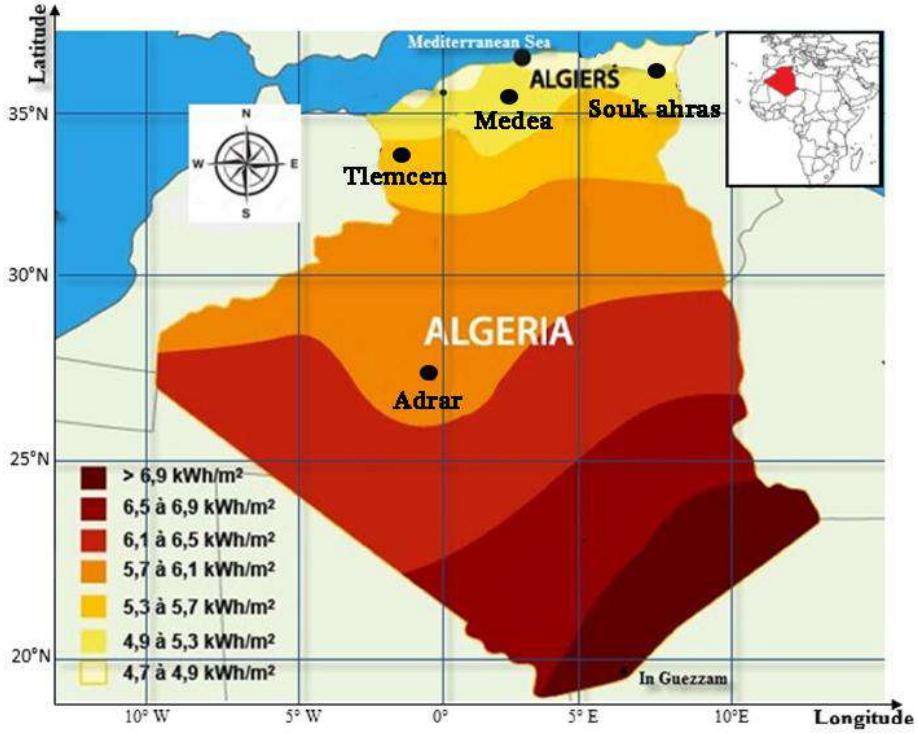


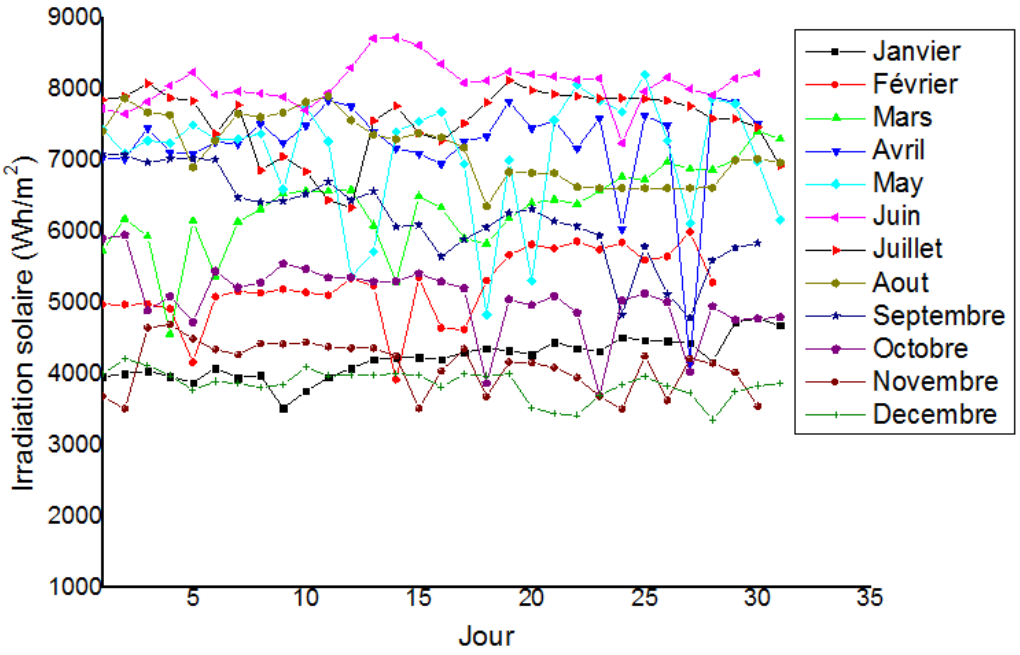
Figure III. 1. 1 : Distribution des différents sites utilisés pour le modèle du réseau de neurone sur la carte géographique algérienne (Yaiche *et al*., 2014).

Tableau III. 1. 1 : Liste des stations météorologiques retenues pour l'étude.

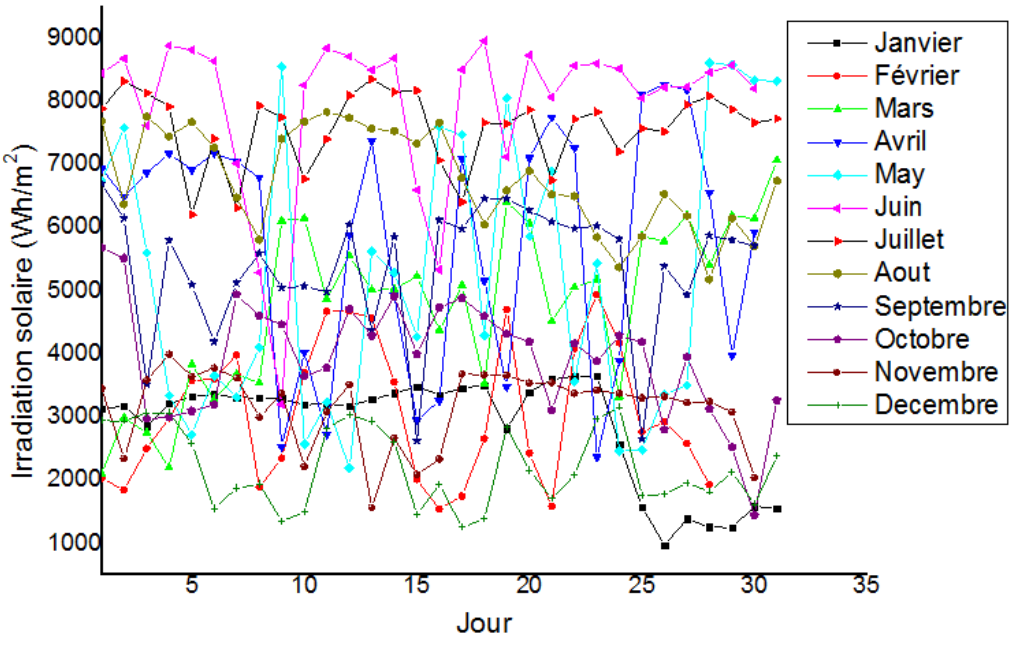
Station	Latitude(°)	Longitude(°)	Altitude (m)
Souk Ahras	36.40	7.99	699
Médéa	36.26	2.78	981
Tlemcen	34.88	-1.31	810
Adrar	27.91	-0.17	279

L'une des caractéristiques les plus communes des processus atmosphériques, comme le processus de l'irradiation solaire est le double périodicité, c'est-à-dire la variation diurne et saisonnière du processus. Par conséquent, pour une génération robuste d'une série chronologique de synthèse, nous devons analyser les caractéristiques statistiques mensuelles de l'irradiation solaire (Giannis, 2017).

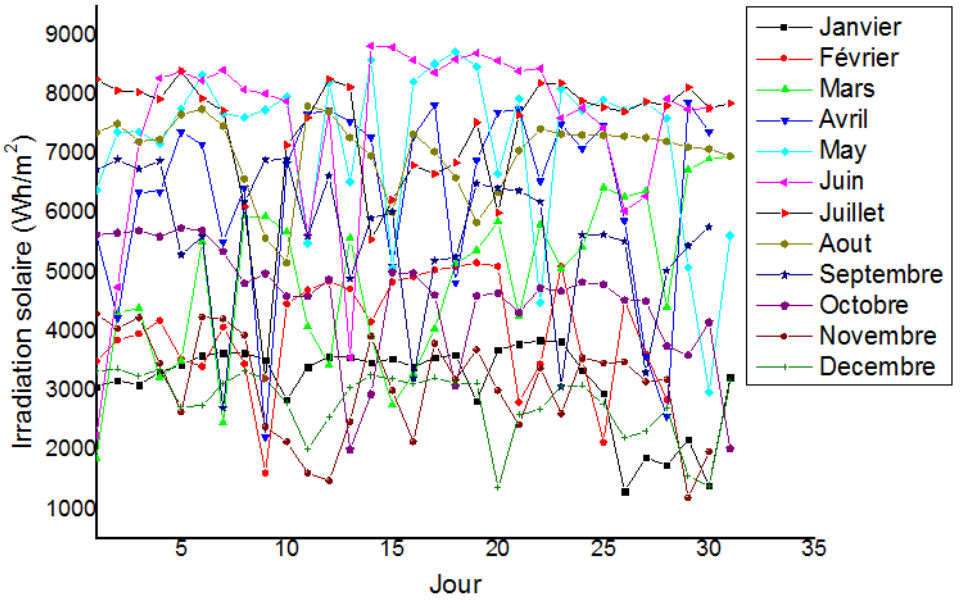
L'évolution mensuelle de l'irradiation solaire horizontale pour les différentes stations considérées (Adrar, Médéa, Tlemcen, et Souk Ahras) est donnée sur la Figure III. 1. 2 pour l'année 2005. On remarque la même évolution saisonnière pour toutes les stations considérées avec un maximum en été et un minimum en hiver. La valeur maximale a été enregistrée dans les quatre stations avec une valeur dépassant les 8 kWh/m^2 au mois de Juin et Juillet.



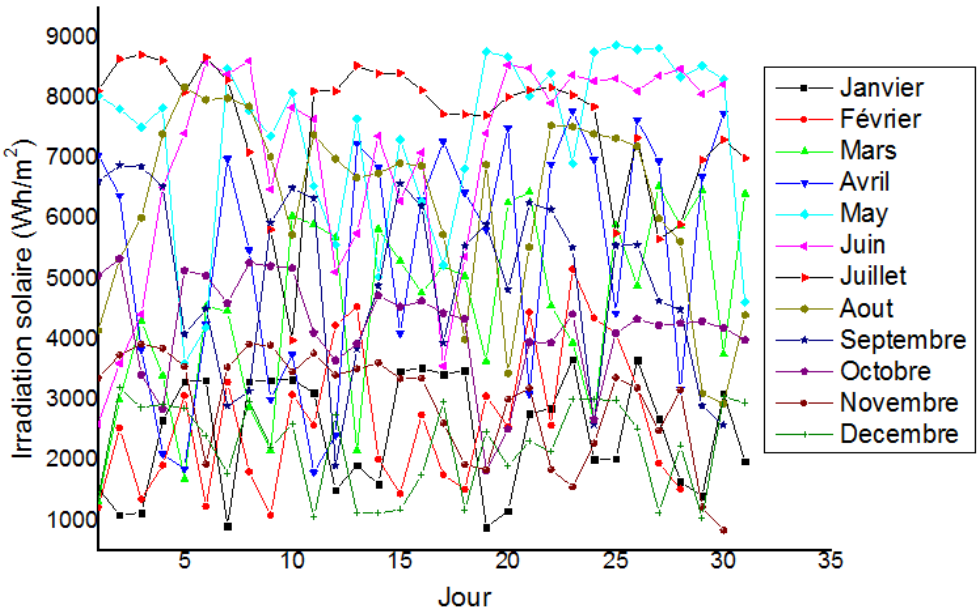
(a)



(b)



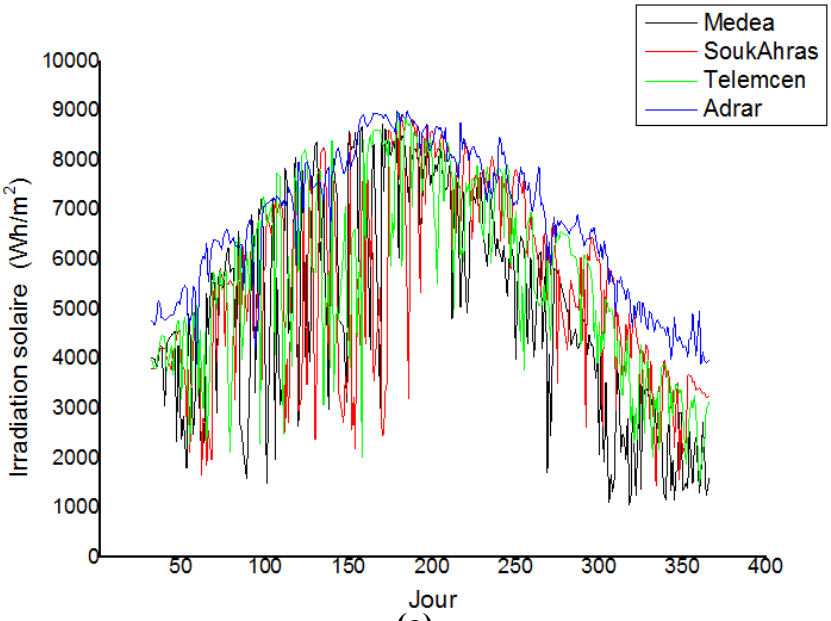
(c)



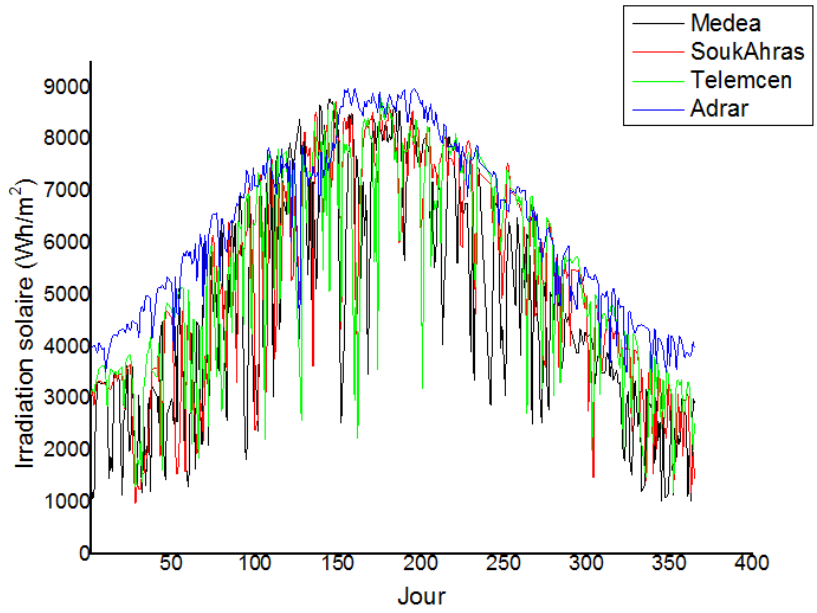
(d)

Figure III. 1. 2 : Evolution mensuelle de l'irradiation solaire reçue sur un plan horizontal de l'année 2005 pour les quatre stations : (a) Adrar, (b) Médéa, (c) Tlemcen et (d) Souk Ahras.

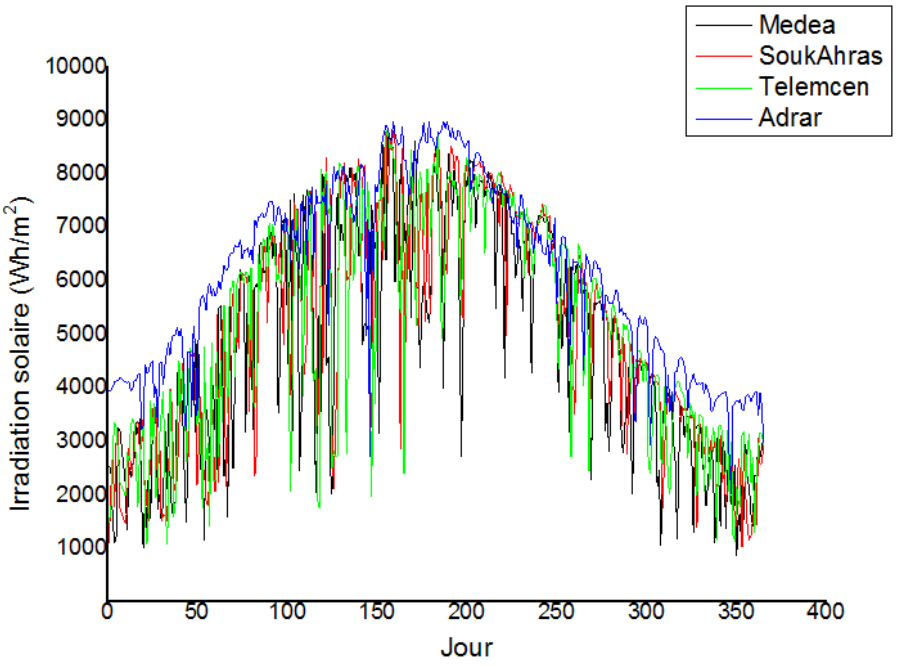
La Figure III. 1. 3 représente la valeur annuelle de l'irradiation globale reçue sur plan horizontal des différentes stations. On remarque bien que l'irradiation solaire est plus importante dans la région du sud-ouest (Adrar), avec des valeurs se situant entre les 5 et 9 kWh/m^2 pour les trois années (2004, 2005, et 2006). Par contre, ces valeurs diminuent en allant vers le Nord (Souk Ahras, Médéa et Tlemcen) avec des valeurs inférieures à 4 kWh/m^2



(a)



(b)



(c)

Figure III. 1. 3 : Evolution annuelle de l'irradiation globale reçue sur plan horizontal pour les quatre stations pendant les années 2004 (a), 2005 (b), et 2006 (c).

Dans cette étude, les données expérimentales de trois années (2004, 2005 et 2006) pour les quatre stations Médéa, Souk Ahras, Tlemcen et Adrar sont utilisées pour constituer les trois ensembles (apprentissage, validation et test) et ce dans le but de prédire l'irradiation solaire horizontale.

III.1.2.1. Sélection des entrées du modèle neuronal

La sélection des entrées consiste à déterminer les variables pertinentes par rapport à la grandeur à modéliser. Elle vise deux points essentiels (Dreyfus *et al*., 2002) :

- Réduction de la dimension de l'espace de représentation des variables du modèle
- Elimination des entrées qui n'ont pas ou qui ont peu d'influence sur la sortie.

Il est important de mentionner que chaque ajout d'une variable encombre le modèle et entraine une multiplication des paramètres du réseau. Raison pour laquelle, la représentation des entées doit contenir tous les facteurs pertinents par rapport à la grandeur à modéliser, mais seulement ceux-ci.

Selon une enquête réalisée par Kumar et al. (2014), il a été constaté que la précision de la prédiction de l'irradiation solaire par les modèles neuronaux change avec les variables géographiques et météorologiques utilisées comme paramètres d'entrée. Pour la sélection des paramètres de l'entrée pertinente, le chercheur doit utiliser les différentes combinaisons des paramètres d'entrée d'un réseau de neurone pour trouver la plus forte influence sur la prédiction de l'irradiation solaire (Laidi *et al.,* 2016).

Entées :

- Jour (varie entre 1 et 365 pour l'année 2005-2006 et de 32 vers 365 pour l'année 2004 car les données du mois de janvier sont manquantes).
- Latitude
- Longitude
- Température (k)
- Humidité relative (%)
- Pression atmosphérique (hpa)
- Vitesse du vent (m/s)
- Direction du vent (°)

Sortie :

- Irradiation solaire globale (Wh/m^2)

Ce qui donne une matrice de 9 colonnes et 4260 lignes.

Remarque : l'altitude n'a pas été prise en compte

III.1.2.2. Préparation et partage de la base de données

Afin de développer une application à base de réseaux de neurones, il est nécessaire de disposer de deux bases de données : une base pour effectuer l'apprentissage et une autre pour tester le réseau obtenu et déterminer ses performances.

Afin de contrôler la phase d'apprentissage, il est souvent préférable de posséder une troisième base de données appelée "base de validation croisée" (Pados *et al.,* 1994).

Afin d'arrêter l'apprentissage juste avant que ne se produise ce phénomène de surapprentissage, plusieurs méthodes ont été proposées. La plus simple consiste à disposer de trois bases de données distinctes : une base d'apprentissage, une base de test et une base dite de "validation croisée". Cette

dernière base est utilisée pendant l'apprentissage afin d'examiner le comportement du réseau pour des données qui lui sont inconnues. Ainsi, l'apprentissage est arrêté lorsque l'erreur atteint un minimum.

Notons que cette technique nécessite d'avoir suffisamment de données pour constituer trois bases à la fois représentatives et distinctes. Dans le cas où on ne disposerait pas suffisamment de données, une technique a été développée pour n'utiliser que la base d'apprentissage ; elle consiste à effectuer deux apprentissages successifs. Pour le premier apprentissage, la base d'apprentissage est divisée en deux de manière à constituer une plus petite base d'apprentissage et une base de validation croisée. Le nombre de cycles d'apprentissage nécessaire pour parvenir à la zone de généralisation optimale est conservé. Ce nombre est ensuite utilisé pour stopper l'apprentissage avec la base d'apprentissage globale (Lang *et al.,* 1990).

Il n'y a pas de règle pour déterminer ce partage de manière quantitatif. Il résulte souvent d'un compromis tenant compte du nombre de données dont on dispose et du temps imparti pour effectuer l'apprentissage.

La Figure III. 1. 4. Illustre le pourcentage de partage de la phase d'apprentissage, test et validation.

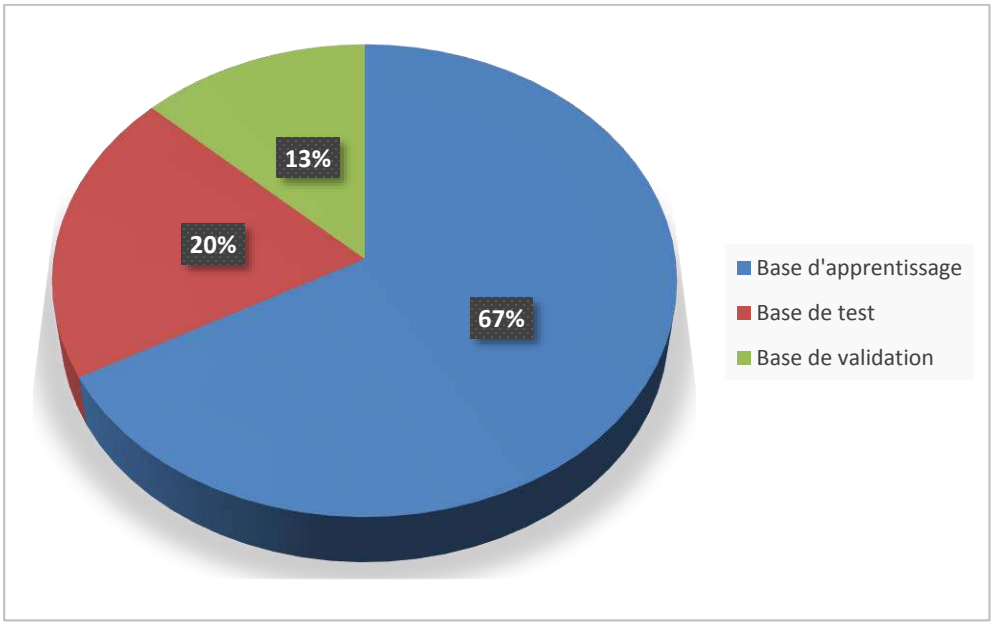


Figure III. 1. 4 : Pourcentage de partage de la base de données.

III.1.2.3. Normalisation des données

La normalisation est une étape importante dans le processus de l'élaboration des données. Elle devient dans la plupart des cas, une exigence pour les matrices des inputs, du fait qu'on utilise souvent des fonctions de transfert bornées de type sigmoïdes dans les modélisations statiques.

Dans ce présent travail, on a effectué la normalisation par la fonction ***'premnmx'***, en langage MATLAB qui effectue une normalisation par ligne de la matrice des inputs selon l'expression suivante :

Chaque paramètre des entrées et de sortie (x_i) est normalisé(x_{in}) par l'expression suivante :

$$x_{in}\frac{2\{x_i-\min(x_i)\}}{\{\max(x_i)-min(x_i)\}}-1 \qquad \text{(III.1)}$$

La fonction inverse de dénormalisation est réalisée par la fonction "***postmnmx"***. Comme les réseaux de neurones ne peuvent pas être extrapolés, nous avons représenté dans le Tableau III. 1. 2 les valeurs minimales et maximales des entrées utilisées de chaque station.

Tableau III. 1. 2 : Minimums et maximums des entrées utilisées.

	Paramètres	Jour	Latitude (°)	Longitude (°)	Température (K)	Humidité (%)	Pression (hpa)	Vitesse du vent (m/s)	Direction du vent (°)
Souk Ahras	**Minimums**	1	36.27	7.96	272.56	26.2	970.98	0.13	0 .14
	Maximums	365	36.27	7.96	304.6	95.12	932.49	11.51	395.85
Médéa	**Minimums**	1	36.26	2.72	272.71	21.99	936.03	0.08	0 .01
	Maximums	365	36.26	2.72	305.71	92.59	972.84	8.63	359.88
Telemcen	**Minimums**	1	34.88	-1.31	273.04	22.45	958.22	0.07	0 .36
	Maximums	365	34.88	-1.31	305.51	92.72	920.71	10.43	359.9
Adrar	**Minimums**	1	27.9	-0.17	279.04	77.81	970.71	0.13	1.14
	Maximums	365	27.9	-0.17	314.13	5	998.33	8.79	359.87

III.1.3. Conception du modèle neuronal

La conception d'un modèle neuronal consiste à faire une étude d'évaluation des éléments constitutifs du réseau en fonction de la performance de modélisation souhaitée. Elle vise à fixer les éléments suivants :

- Le type du réseau ;
- Le nombre de couches cachées :
- Le nombre de neurones dans les couches cachées ;
- La fonction de transfert ;

- L'algorithme d'apprentissage ;
- Le nombre d'itération ;

L'organigramme de la méthodologie de calcul du réseau de neurone statique optimale RNSO est illustré par la Figure III. 1. 5.

L'objectif principal de ce travail est décrit dans cette partie. La question qu'on peut se poser est la suivante : quelles sont la combinaison et l'architecture de modèle neuronal de type multicouche (MLP) qui peut nous donner des meilleurs résultats ? Pour répondre à cette question, la conception et l'optimisation du modèle neuronal est basée sur trois étapes principales : la première étape consiste en la détermination des paramètres fondamentaux du modèle neuronal, comme la fonction d'activation et l'algorithme d'apprentissage. La deuxième étape est relative au prétraitement des données (la normalisation des données). La troisième et dernière étape est dédiée à la détermination du nombre de couches cachées et du nombre de neurone dans chaque couche cachée. Vues les recherches basées sur les réseaux de neurones artificiels, le modèle qui donne une erreur minimale sera choisi (Lee *et al*., 1991). Durant la première étape de l'optimisation du réseau, les paramètres fondamentaux ont été examinés pour avoir une bonne performance.

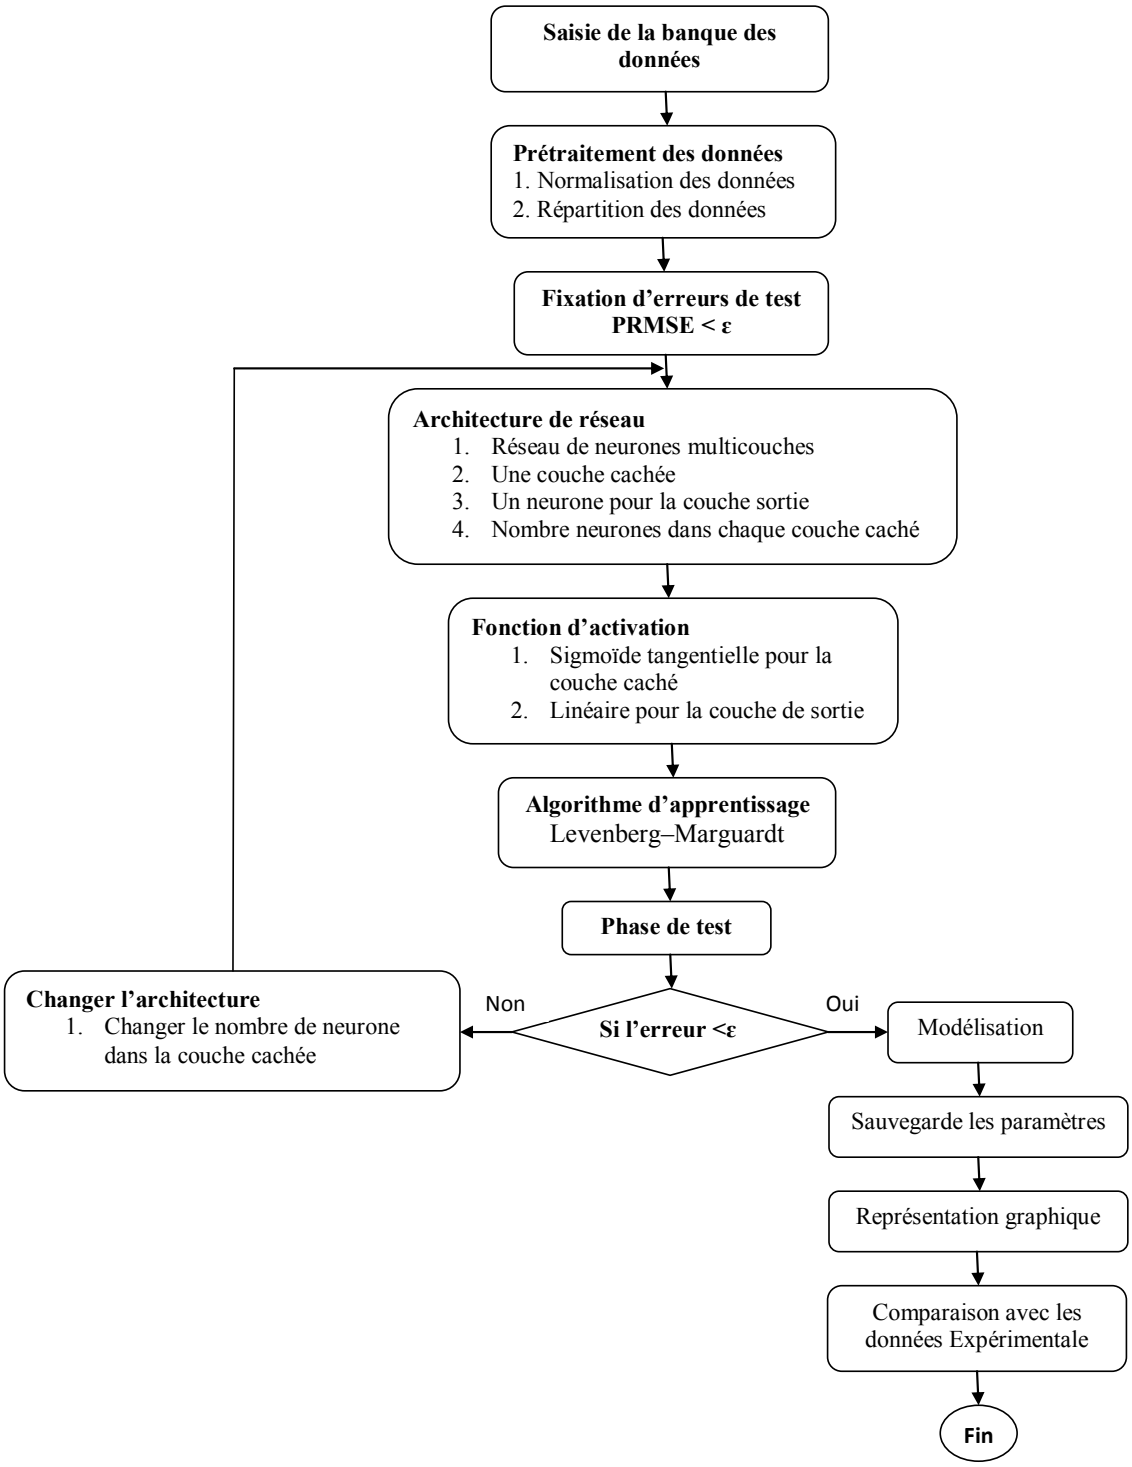


Figure III. 1. 5 : Organigramme de la méthodologie de calcul du RNSO

La sélection de l'algorithme d'apprentissage est plus compliquée que la sélection des fonctions d'activation parce qu'il y' a un nombre important d'algorithmes d'apprentissage qui peuvent produire un modèle neuronal exact, rapide et fiable. Quatre algorithmes d'apprentissage ont été appliqués (Tab. 09) pour avoir un seul algorithme qui puisse donner une erreur quadratique moyenne (PRMSE) minimale. La Figure III. 1. 6 présente la variation de la PRMSE de l'irradiation solaire horizontale pour trois réseaux de neurone avec différents algorithmes d'apprentissage en fonction du nombre d'itérations. D'après les résultats trouvés, l'algorithme d'apprentissage choisi est celui désigné sous le nom d'algorithme de Levenberg–Marquardt qui présente une erreur quadratique moyenne (PRMSE) minimale. Néanmoins, ayant remarqué que les valeurs de l'erreur n'étaient pas bonnes, nous étions dans l'obligation d'optimiser les autres paramètres.

Tableau III. 1. 3 : Noms des codes des réseaux et les noms des algorithmes d'apprentissage utilisés lors de la phase de conception du modèle neuronal.

Algorithme d'apprentissage	**Code Matlab**
1. Régularisation bayésienne	1. Trainbr
2. Levenberg–Marquardt	2. Trainlm
3. BFGS Quasi-Newton	3. Trainbfg

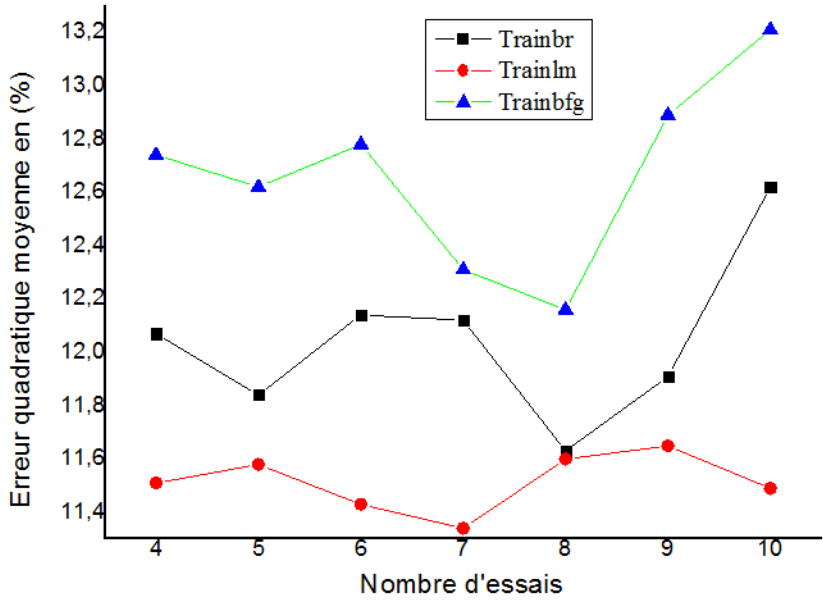


Figure III. 1. 6 : Effet de l'algorithme d'apprentissage sur la performance des réseaux de neurones en termes d'erreur quadratique moyenne.

Une étude sur l'effet de normalisation sur la performance du modèle neuronal est représentée sur la Figure III. 1. 7. Nous avons appliqué la normalisation des entrées par des fonctions existante dans MATLAB. Deux fonctions sont testées (Premnmx, Prestad), puis le système a été testé sans normalisation. Le Tableau III. 1. 4 présente les différentes fonctions de normalisation utilisées dans cette partie à fin d'avoir une fonction qui donne des meilleurs résultats.

Tableau III. 1. 4 : Différentes fonctions de normalisation utilisées.

Méthodes de prétraitement	**Code MATLAB**
Méthode de **MMM (Min-Max Méthode)**	**Premnmx**
Méthode de **MSDM (Mean and standard deviation methode)**	**Prested**
Sans normalisation primaire	**-**

La Figure III. 1. 7, montre l'influence de la normalisation sur la performance de modèle. On remarque que l'apprentissage sans normalisation a une faible influence sur le modèle. La fonction qui présente un bon résultat est la fonction (Premnmx).

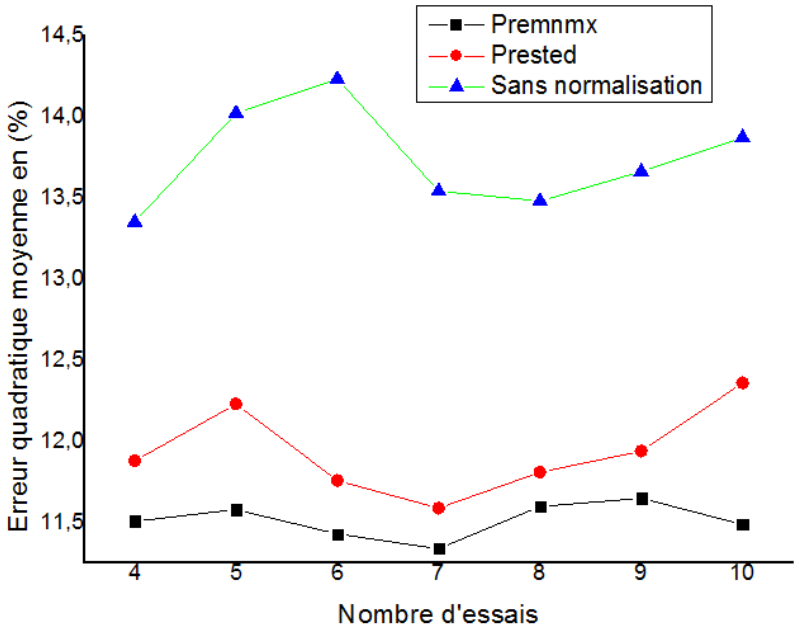
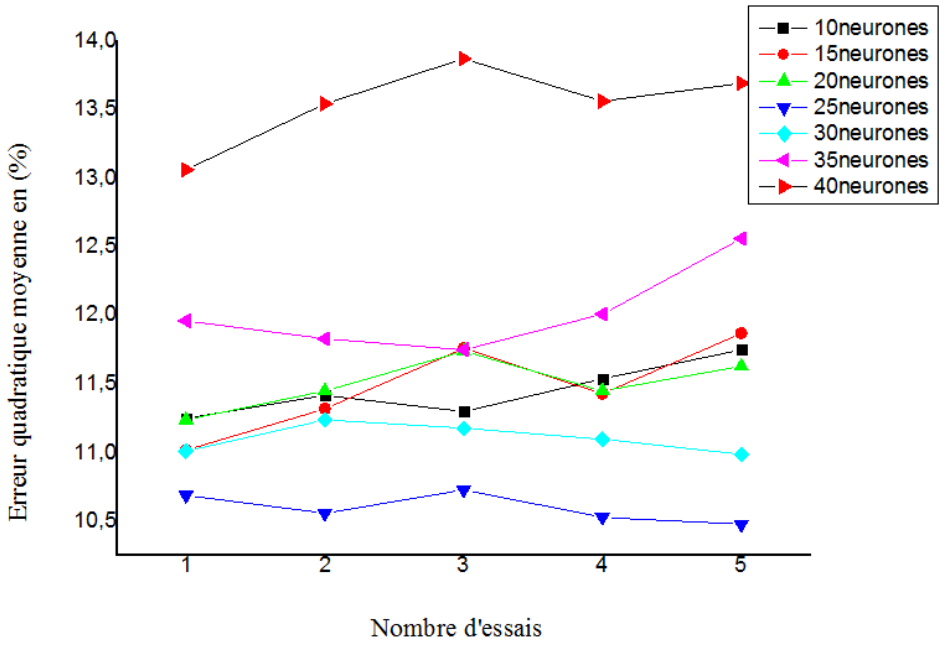


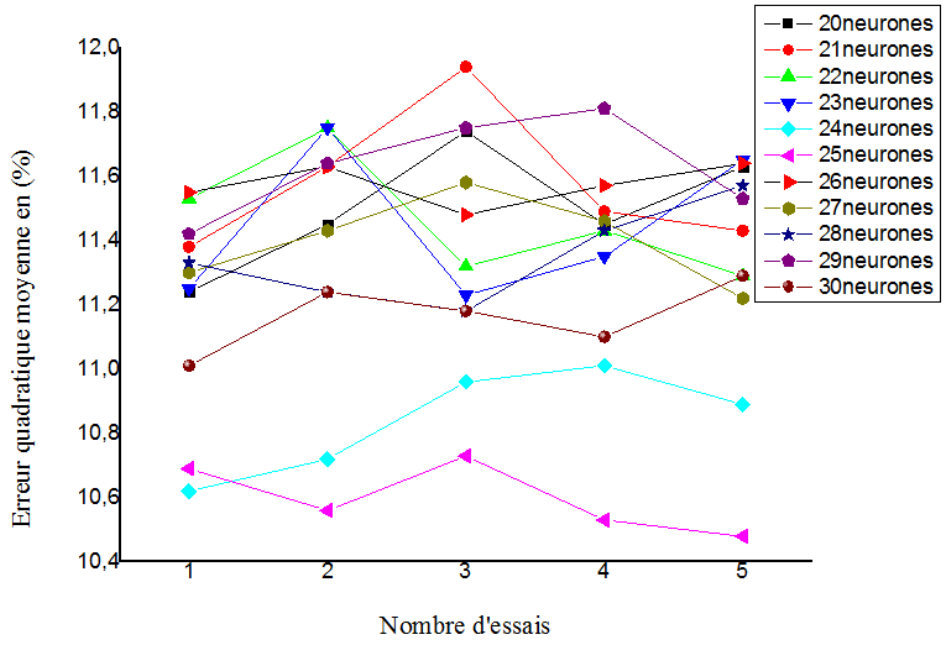
Figure III. 1. 7 : Effet de la fonction de normalisation sur la performance d'apprentissage du réseau de neurones.

La troisième étape a été consacrée au test des différentes architectures en modifiant le nombre de neurones dans une couche cachée, puis dans deux couches cachées. On remarque sur la Figure III. 1. 8

que lorsque le nombre de neurones augmente, l'erreur diminue jusqu'à un nombre de neurones égal à 25. Cette diminution est due à l'augmentation de nombre de connexion du modèle neuronal.



(a)



(b)

Figure III. 1. 8 : Effet du nombre de neurones de la couche cachée sur la performance d'apprentissage du réseau de neurones :(a) chaque 5 neurones, (b) un neurone.

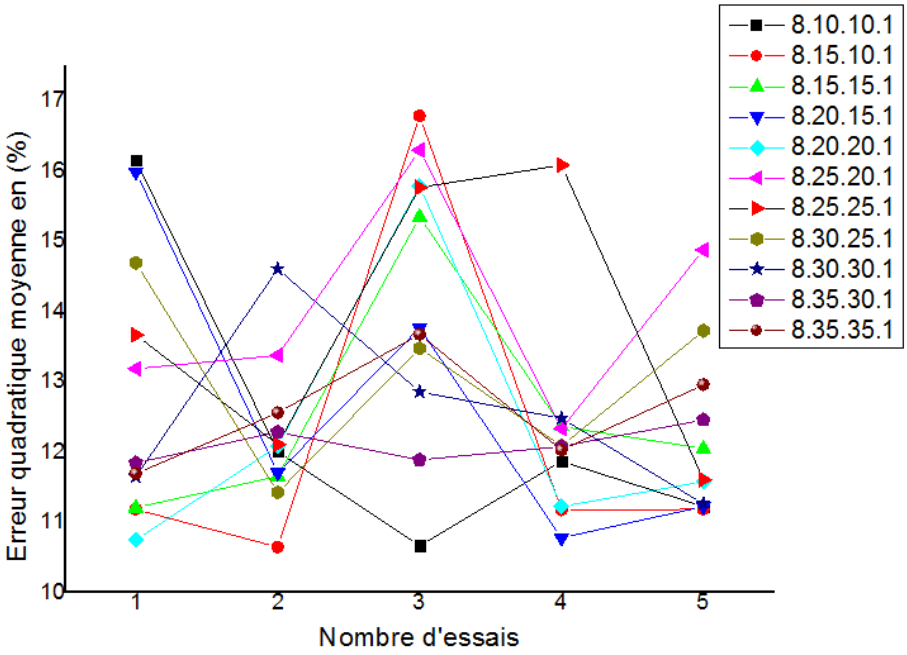


Figure III. 1. 9 : Effet du nombre de neurones dans les deux couches cachées sur la performance d'apprentissage du réseau de neurones.

III.1.4. Analyse de sensibilité par la méthode des "poids"

La contribution des variables d'entrées (le jour, la latitude et longitude du site, température et humidité relative, la direction et la vitesse du vent, la pression atmosphérique) sur la sortie a été déterminée par une analyse de sensibilité en utilisant la méthode des "poids". Cette méthode, proposée d'abord par Garson (1991) et reprise par Goh (1995) donne une quantification de l'importance relative (*Ir*) des différentes entrées sur la sortie du RN (Gevrey *et al*., 2003). Le processus de calcul, composé de quatre étapes, est schématisé sur l'organigramme ci-dessous (Khaouane, 2013).

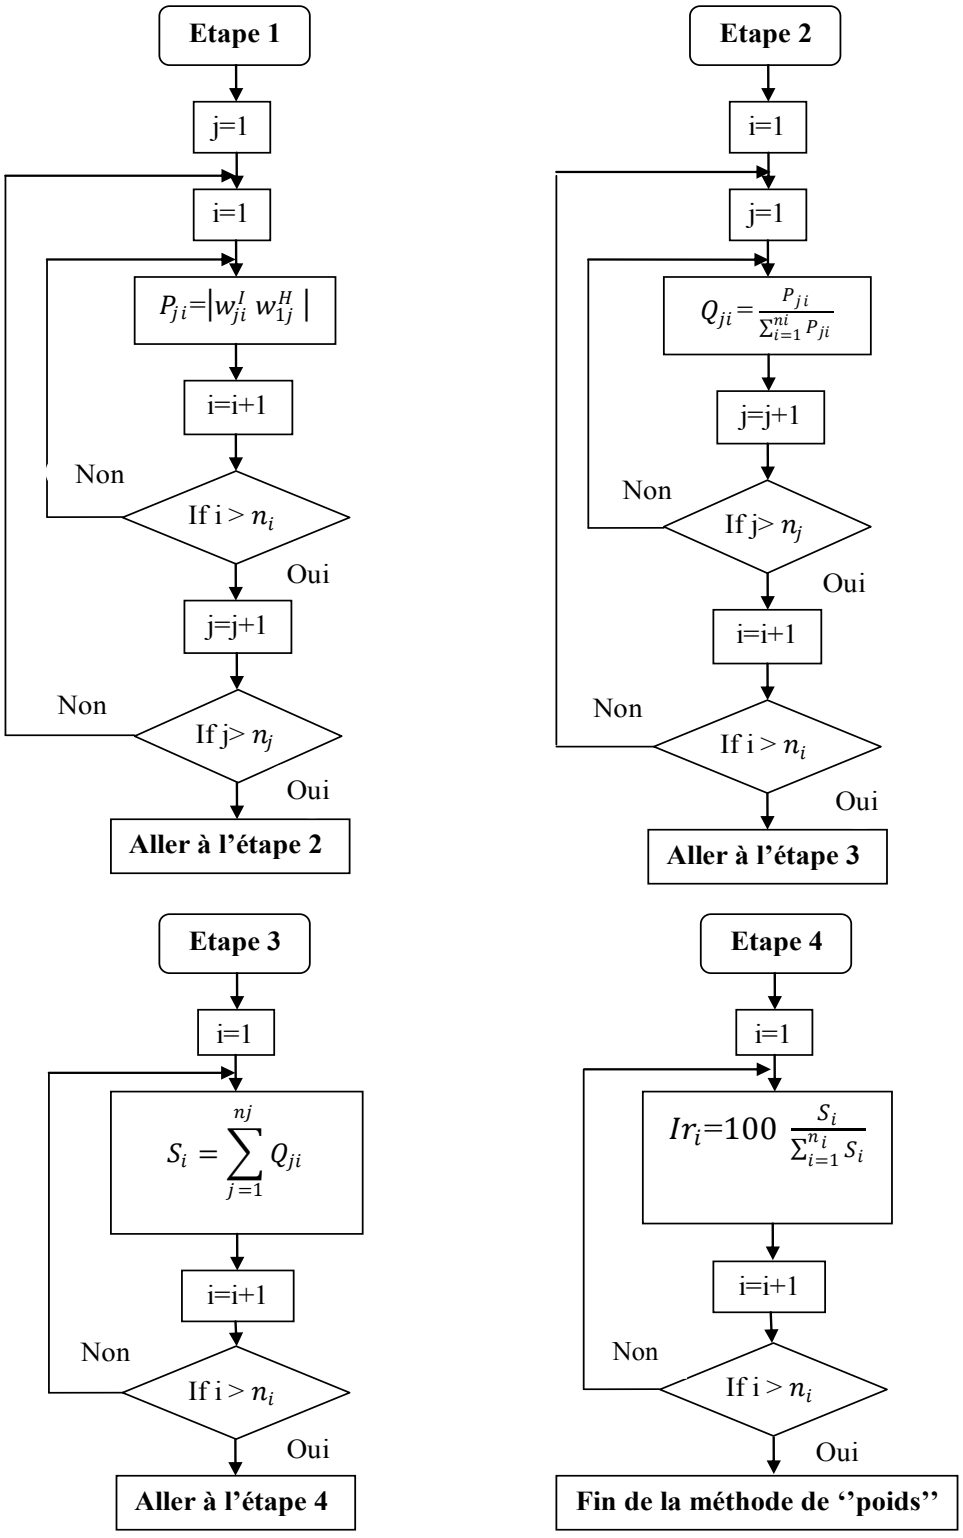


Figure III. 1. 10 : Organigramme de la méthode de "poids" (Khaouane , 2013).

III.1.5. Résultats et discussion

III.1.5.1. Performances des modèles

Afin de modéliser l'irradiation solaire sur des surfaces horizontales avec un modèle élaboré par l'utilisation d'un réseau de neurone, huit variables ont été sélectionnées comme entrées : le jour, la latitude et la longitude du site, la température et l'humidité relative, la direction et la vitesse du vent et la pression atmosphérique. Une seule sortie représentant l'irradiation solaire mesurée sur des surfaces horizontales enregistrées en fonction de leur altitude a été utilisée. Le type du réseau de neurones utilisé est le Feed forward avec l'algorithme d'apprentissage Levenberg-Marquardt Back propagation. Une couche cachée a été choisie parce qu'elle convient à modéliser la relation entre les données d'entrée et la variable de sortie (Witek-Krowiak *et al*., 2014).

Dans cette étude, la performance d'un réseau de neurone (RNA) avec un nombre variable de neurones (de 1 à 40) dans la couche cachée a été étudiée. Chaque architecture d'un RNA a été construite 15 fois afin d'éviter les effets aléatoires. La meilleure performance a été obtenue avec vingt-cinq neurones cachés. D'après la Figure III. 1. 9, on remarque que les tests effectués pour plus d'une couche cachée et avec différents paramètres n'ont montré aucune amélioration significative.

L'architecture optimale du réseau de neurone à une seule couche cachée est présentée sur la Figure III. 1. 11. Comme fonction de transfert de la couche d'entrée vers la couche cachée, on a utilisé la fonction tangente sigmoïde, alors qu'une fonction linéaire (identité) l'a été entre la couche cachée et la couche de sortie. Il a été prouvé que l'algorithme d'apprentissage de rétro-propagation le mieux adapté d'après le test des différents algorithmes d'apprentissage est celui de Levenberg–Marquardt. Le Tableau III. 1. 5 récapitule les différents éléments structurels du réseau de neurones utilisé dans la modélisation de l'irradiation solaire globale.

Tableau III. 1. 5 : Structure du réseau de neurones optimisé.

Algorithme	**Couche-Entrée**	**Couche-Cachée**		**Couche-Sortie**	
Algorithme d'apprentissage	Nombre de neurone	Nombre neurone	fonction d'activation	Nombre neurone	fonction d'activation
trainlm	8	25	Tansig	1	linéaire

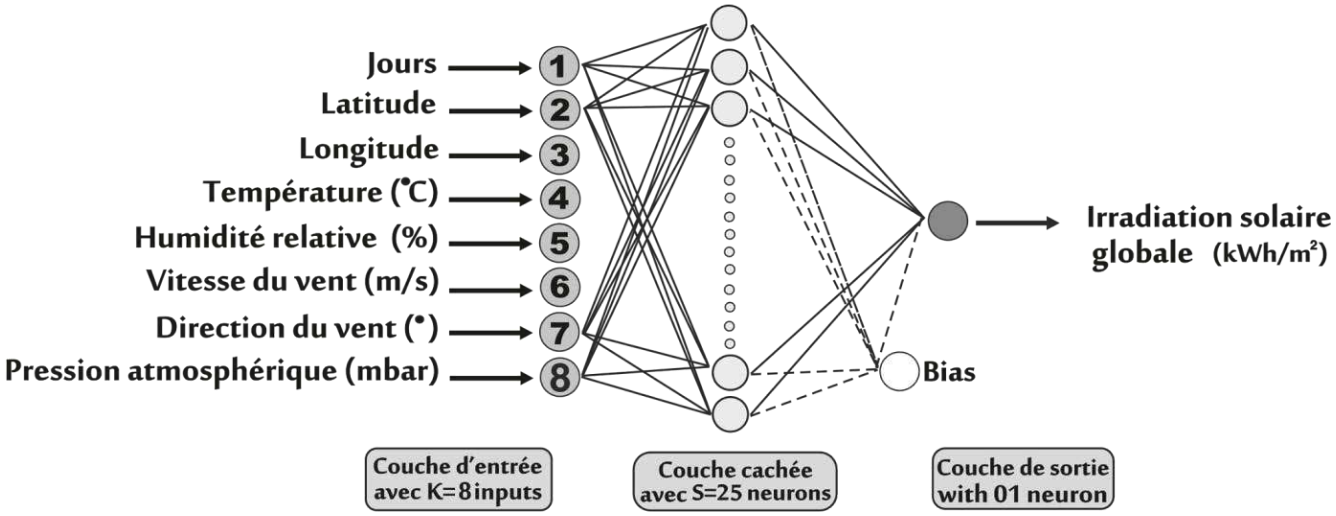
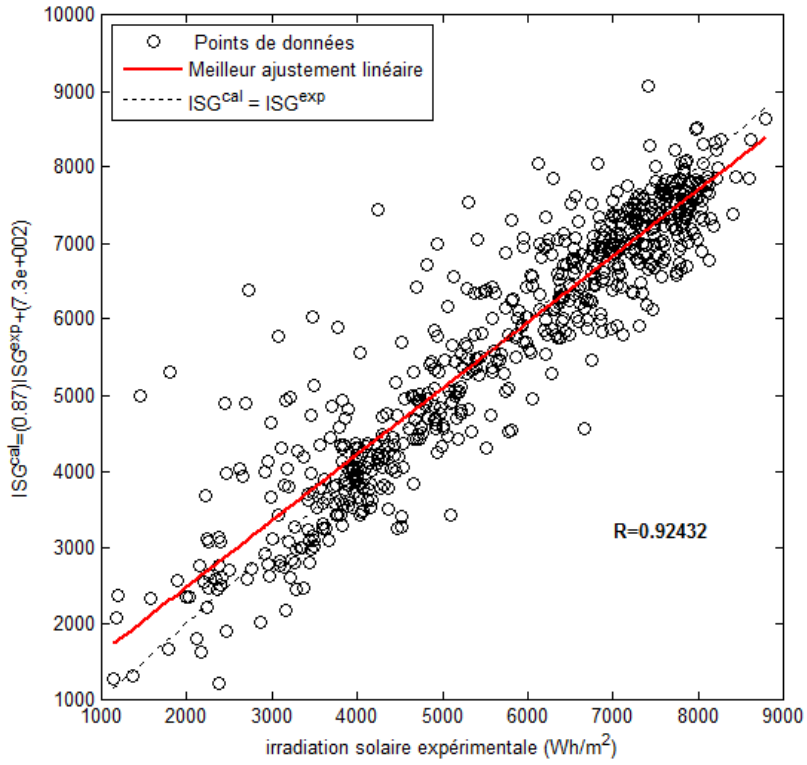


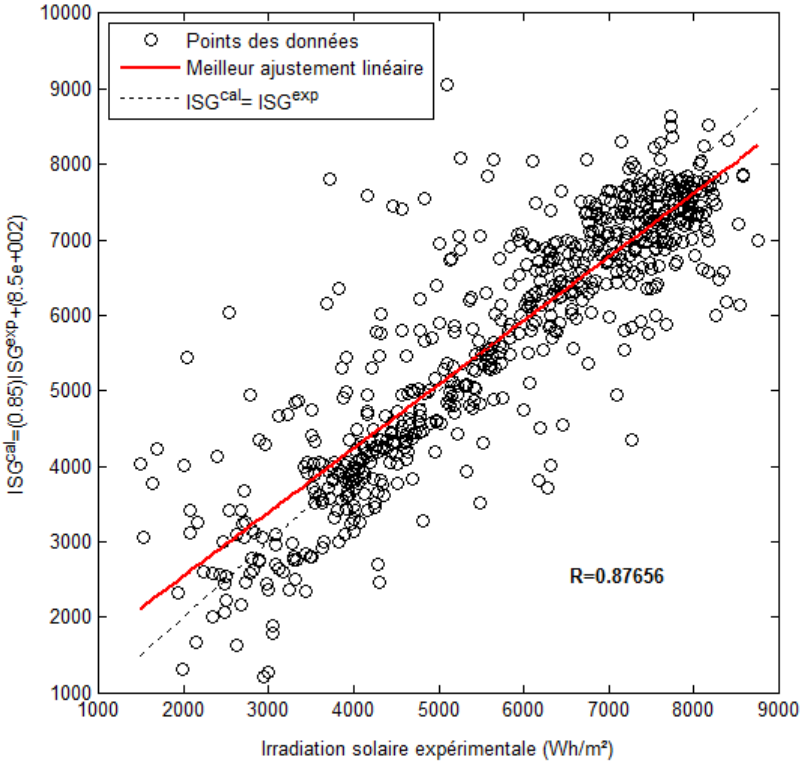
Figure III. 1. 11 : Schéma simplifié de l'architecture du réseau neuronal.

Comme indiqué précédemment, le modèle obtenu à l'aide des réseaux de neurones a été développé dans le but de prédire l'irradiation solaire horizontale. La performance du modèle a été mesurée statistiquement par l'erreur quadratique moyenne (RMSE) et le coefficient de corrélation *R*. Une valeur de *R* supérieure à 0.5 est généralement considérée comme satisfaisante, alors qu'une valeur supérieure à 0.9 est excellente (Golbraikh & Tropsha, 2002).

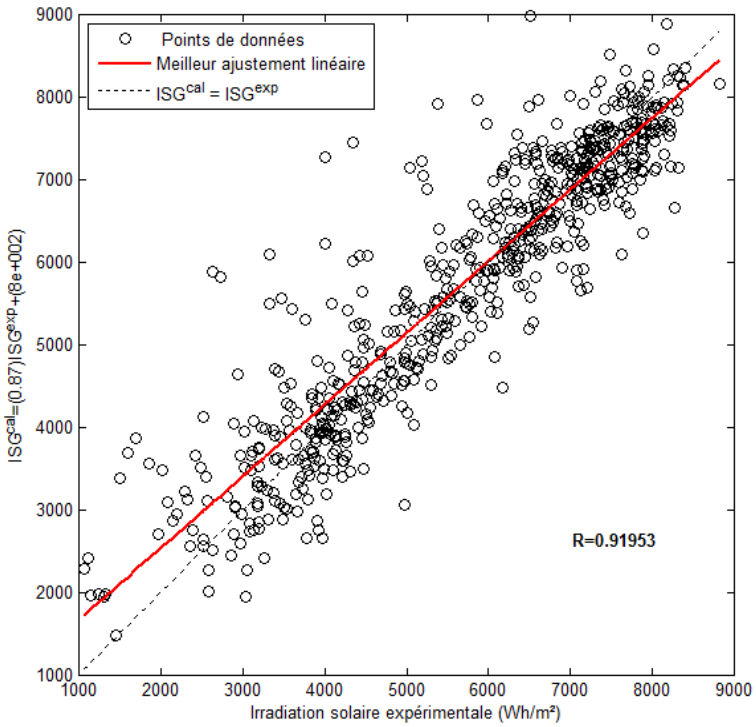
La Figure III. 1. 12 illustre les courbes de régression linéaire de l'irradiation solaire prédite par le modèle avec l'irradiation solaire expérimentale. Pour l'ensemble d'apprentissage, les valeurs des vecteurs de régression se rapprochent des valeurs idéales ([α, β, R] = [0.87, 73, 0.9243] avec une erreur quadratique moyenne (PRMSE) de 10,48 %. Les valeurs obtenues pour l'ensemble de validation sont les suivantes : [α, β, R] = [0.85, 85, 0.8765] avec une PRMSE de 12,44%. Pour l'ensemble de test, on a eu les valeurs suivantes : [α, β, R] = [0.87, 80, 0.9195] avec une PRMSE de 11,05 %. Les coefficients de corrélation sont généralement considérés comme excellents ($0.90 \leq R \leq 1.00$) pour la phase d'apprentissage et la phase de test. Par ailleurs, Le coefficient de corrélation est couramment considéré comme satisfaisant ($0.50 \leq R < 0.90$) pour la phase de validation, ce qui montre une bonne robustesse du modèle neuronal établi.


Points de données
Meilleur ajustement linéaire
ISG^cal = ISG^exp
R=0.92432
ISG^cal=(0.87)ISG^exp+(7.3e+002)
irradiation solaire expérimentale (Wh/m^2)

(a)


Points des données
Meilleur ajustement linéaire
ISG^cal= ISG^exp
R=0.87656
ISG^cal=(0.85)ISG^exp+(8.5e+002)
Irradiation solaire expérimentale (Wh/m²)

(b)



(c)

Figure III. 1. 12 : Comparaison entre les valeurs expérimentales et les valeurs prédites pour l'irradiation solaire globale : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test.

III.1.5.2. Expressions mathématique des modèles neuronaux optimisés

À partir du RN*S* optimisé et qui est représenté sur la Figure III. 1. 13, on peut exprimer L'irradiation solaire par un modèle mathématique qui y incorpore toutes les entrées *Ei* (*jour, altitude, longitude, température, humidité, vitesse du vent, direction du vent, pression atmosphérique*) comme suit :

Les sorties *Zj* de la couche cachée :

$$Z_j = f(x)[\sum_{i=1}^{8} w_{ji}^{I} \; E_i + b_j^H] = \frac{2}{1+e^{(-2\sum_{i=1}^{8} w_{ji}^{I} \; E_i + b_j^H)}} - 1 \qquad \text{(III.2)}$$

j=1, 2, … , 25

La sortie *S*:

$$S = f_0[\sum_{j=1}^{25} w_{1j}^{H} Z_j + b_1^0] = \sum_{j=1}^{25} w_{1j}^{H} Z_j + b_1^0 \qquad \text{(III.3)}$$

La combinaison des équations (III.2) et (III.3) mène à la formule mathématique suivante qui décrit l'irradiation solaire en prenant en compte toutes les entrées E_i :

$$S=\sum_{j=1}^{25} w_{1j}^{H}\left[\frac{2}{1+e^{(-2\sum_{i=1}^{8} w_{ji}^{I}E_i+b_j^{H})}}-1\right]+b_1^0 \qquad \text{(III.4)}$$

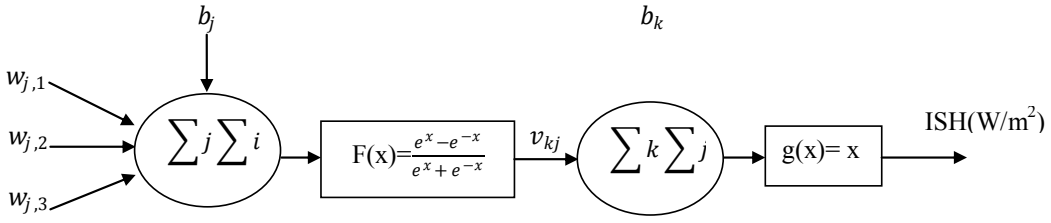


Figure III. 1. 13 : Représentation schématique du RN*S* optimisé.

Où w_{ji}^{I}représente le poids synaptique de la connexion du neurone *i* de la couche d'entrée au neurone *j* de la couche cachée ; w_{1j}^{H} représente le poids synaptique de la connexion du neurone *j* de la couche cachée au neurone de la couche de sortie ; b_j^Het b_1^0 représentent respectivement les biais du neurone *j* de la couche cachée et du neurone de la couche de sortie. Les matrices des poids et biais, d'un RNS optimisés, sont donnés dans le Tableau III. 1. 6.

Tableau III. 1. 6 : Poids et biais du RNS optimal.

Connexions Couche d'entrée-Couche cachée									**Connexions Couche cachée-Couche de sortie**	
Poids								**Biais**	**Poids**	**Biais**
w_{j1}^I	w_{j2}^I	w_{j3}^I	w_{j4}^I	w_{j5}^I	w_{j6}^I	w_{j7}^I	w_{j8}^I	b_j^H	w_{1j}^H	w_{1j}^H
-3,597	-0,277	-2,177	2,441	3,006	1,863	-0,052	-0,754	1,200	-0,166	
0,373	-1,944	1,674	-1,160	1,000	1,301	1,496	-3,511	1,247	0,033	
-1,618	-0,012	-0,094	1,921	-0,015	-0,008	-0,112	-0,062	0,629	0,544	
-4,371	0,117	1,762	-1,036	-0,249	0,027	1,827	-0,395	3,173	0,158	
-2,243	1,064	1,045	-1,502	3,171	-0,211	-0,822	1,730	-0,790	0,013	
-0,258	-0,677	-0,268	-2,178	-1,569	0,956	-1,352	-0,911	3,507	-1,016	
0,206	-0,460	-2,089	3,375	1,307	-1,919	0,4369	0,620	-1,197	-0,260	
-3,005	-0,204	-0,384	-0,395	0,049	-0,592	-0,123	-0,230	1,402	0,578	
-1,693	0,663	-1,604	-0,113	0,853	-1,903	-0,752	-1,073	0,062	-0,166	
-0,474	-0,819	-2,751	-2,857	-1,760	-2,631	1,786	3,051	-0,487	-0,174	
0,730	-2,411	1,619	-2,990	-1,143	2,164	0,413	0,347	-1,179	-0,158	
-0,047	0,308	-0,345	0,004	1,936	0,086	0,226	-0,177	0,097	0,137	
-0,492	0,755	-0,486	-0,373	2,416	-0,905	-0,475	2,822	-3,116	0,286	-0.003
2,930	-1,820	-0,673	-1,152	0,940	0,656	-0,335	2,689	3,278	-0,133	
0,701	-0,837	-2,568	1,243	-0,948	-0,344	2,490	0,648	-0,643	0,090	
-0,707	0,216	0,807	4,169	1,288	1,741	-0,659	-1,643	-0,202	-0,188	
-0,874	-1,323	-1,023	-2,735	-0,762	-0,031	-1,084	0,022	1,492	0,351	
-1,675	-0,506	-0,073	1,479	1,533	-0,104	0,082	0,098	-0,505	-0,428	
-0,881	-2,253	-0,454	-2,188	1,551	1,593	1,167	-1,737	2,829	0,057	
-2,313	1,099	-1,798	1,328	-0,902	0,330	-1,680	1,885	-0,878	0,022	
-1,453	1,325	-0,428	-1,593	-0,018	0,113	-0,155	-1,637	2,764	-0,455	
0,807	-1,670	-0,025	0,380	-1,412	0,540	-0,281	-0,119	2,257	0,675	
3,673	2,406	-2,970	-0,967	2,617	2,033	-0,037	0,907	-1,626	0,082	
1,843	-0,732	0,818	0,798	0,904	0,135	-1,443	1,623	-2,148	-0,146	
4,726	-0,068	-0,421	0,717	1,058	0,174	-0,167	-0,004	3,196	0,386	

Afin de visualiser encore plus les capacités prédictives des modèles neuronaux (RN), nous avons établi une comparaison en termes d'analyse statistique à travers le calcul de *PRMSE* (Eq.III.5)

$$PRMSE = \sqrt{\frac{\sum_{i=1}^{N} \frac{(y_{cal} - y_{exp})}{N}}{\sum_{i=1}^{N} \frac{y_{exp}}{N}}} \times 100 \qquad \text{(III.5)}$$

III.1.5.3. Analyse de la sensibilité des entrées par apport à la sortie

Pour voir la contribution ainsi que le profil de variation de chaque variable d'entrée (*jour, altitude, longitude, température, humidité, vitesse du vent, direction du vent, pression atmosphérique*) sur la sortie du réseau de neurone, on a procédé à une analyse de sensibilité par la méthode de poids, en utilisant leur poids illustrés dans le Tableau III. 1. 6. La contribution des variables d'entrée obtenue par la méthode de poids pour le réseau de neurone est présentée sur la Figure III. 1. 14. Comme on peut le constater, toutes les variables ont des effets importants sur l'irradiation solaire. Par conséquent, il peut être observé que la contribution la plus élevée a été obtenue avec la température ambiante *Ta (°C)* (*15.25%*). Le jour, l'humidité relative et l'altitude ont presque la même influence sur les valeurs de l'irradiation solaire (*14%*). Par contre, la longitude (*10.98%*) et autres paramètres ont moins d'influence sur la valeur de l'irradiation solaire.

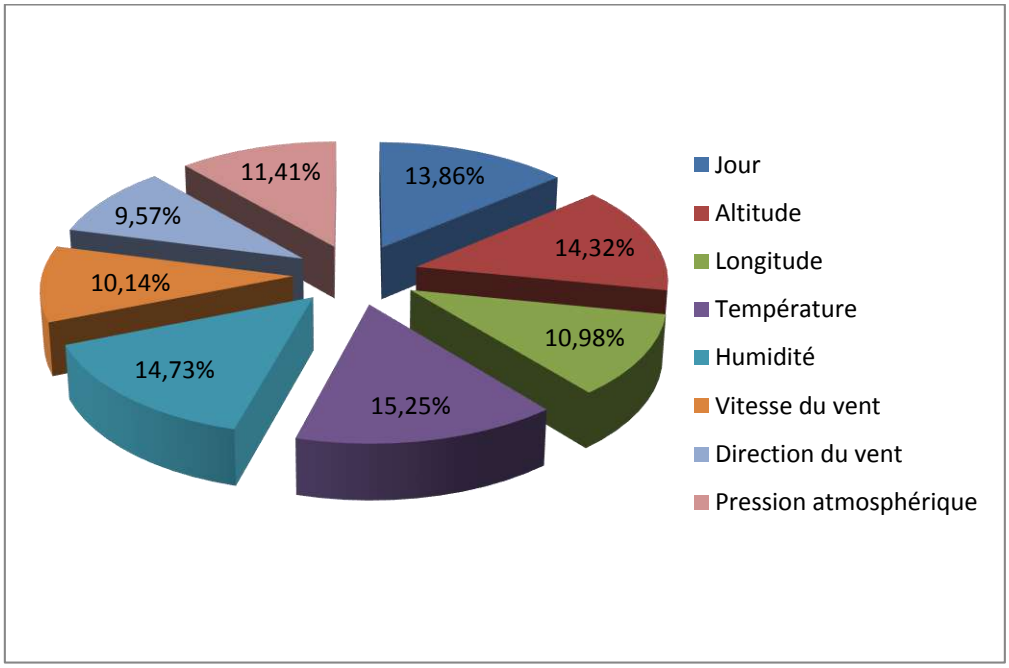


Figure III. 1. 14 : Importance relative des variables d'entrées sur la prédiction de l'irradiation solaire.

III.1.5.4. Interface de calcul de l'irradiation solaire globale

Après avoir optimisé le modèle du réseau de neurones, un programme a été développé dans MATLAB. Celui-ci permettra d'utiliser toutes les entrées nécessaires pour l'exécution du modèle et calculer l'irradiation solaire globale.

Cette démarche a été faite dans le but d'apporter plus de souplesse à l'utilisation du modèle neuronal élaboré. Le programme va donc permettre de faire un calcul simple et rapide de l'irradiation solaire. La méthodologie suivie dans cette partie est résumée sur l'organigramme de la Figure III. 1. 15.

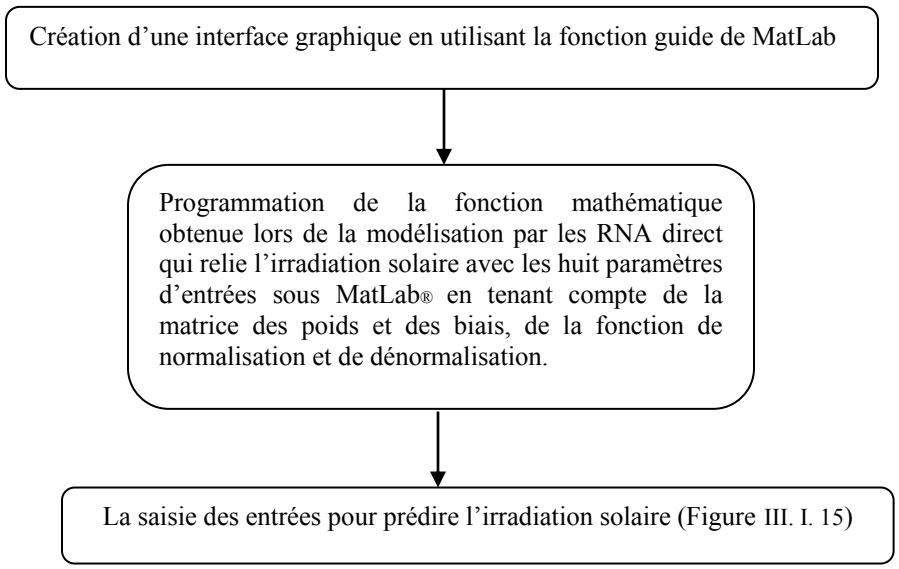


Figure III. 1. 15 : Etapes à suivre pour l'élaboration de l'interface graphique de RNSO par MatLab®.

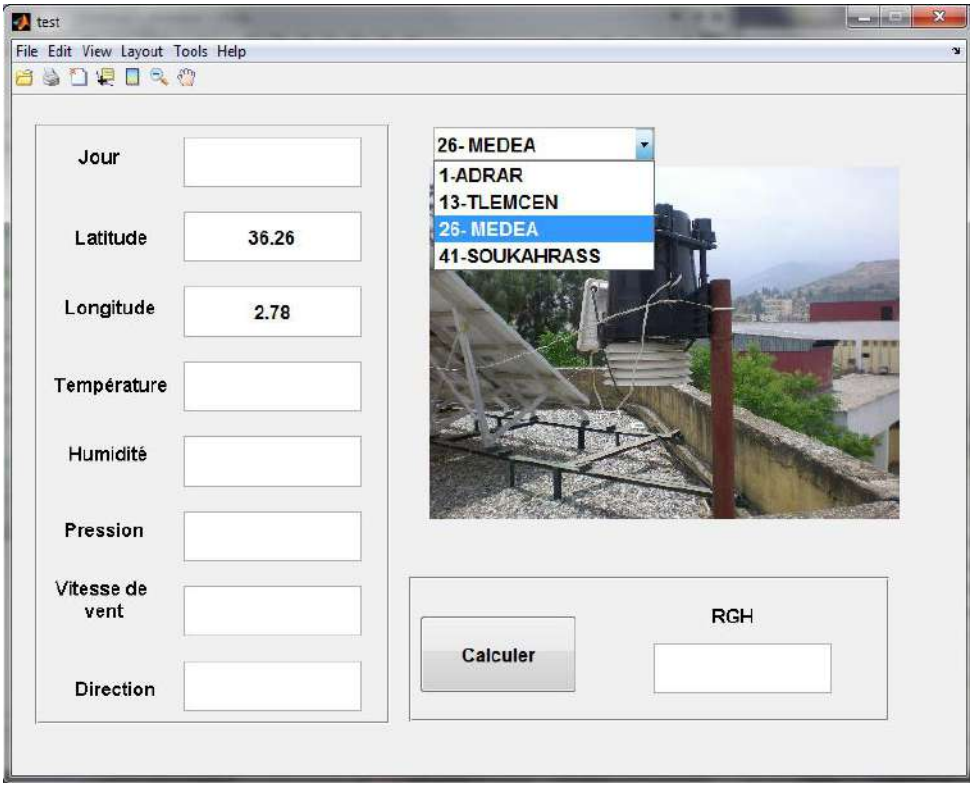


Figure III. 1. 16 : Interface graphique développée pour le calcul l'irradiation solaire.

III.1.6. Conclusion

Le modèle présenté dans cette contribution, emploie plus d'un paramètre météorologique pour prédire le rayonnement solaire global. Ce modèle fait une bonne prédiction de l'irradiation solaire, mais il est limité en raison de l'utilisation des différents paramètres météorologiques comme des entrées du modèle. Ces paramètres ne sont pas facilement disponibles dans la plupart d'emplacement d'intérêt. Les résultats obtenus sont satisfaisants, mais on pense qu'ils pourraient être améliorés en utilisant des mesures de l'irradiation solaire sur le sol. De plus, Nous tenons à souligner que ce modèle pourrait aider à illustrer les régions optimales pour la localisation des systèmes d'énergie solaire.

Deuxième contribution

III.2.1. Introduction

De nos jours, l'utilisation de l'énergie solaire est considérée comme une question importante à l'ordre du jour des scientifiques dans le cadre de la tendance générale du développement des nouvelles énergies renouvelables qui font face à la pénurie et la fluctuation des prix des énergies conventionnelles. Il est question aussi d'éviter les effets négatifs sur l'environnement comme l'appauvrissement de la couche d'ozone, l'effet de serre, le chauffage global, … etc. L'Algérie a un avantage significatif en ce qui concerne le potentiel de l'énergie solaire en raison de sa situation géographique. Le potentiel des énergies renouvelables est fortement dominé par la source d'énergie solaire, et donc la disponibilité du rayonnement solaire mesuré est nécessaire pour développer des applications d'énergie solaire (Yacef *et al*.2014).

Malheureusement, pour de nombreuses régions du pays, les mesures du rayonnement solaire ne sont pas faciles à obtenir en raison de la difficulté de se procurer les équipements de mesure et les techniques impliquées (coût, entretien, étalonnage). Malgré l'existence d'un certain nombre de stations météorologiques en de nombreux endroits en Algérie, parfois les mesures ne sont pas disponibles en permanence en raison des déficiences enregistrées causées par les coupures de courant (en particulier en été) ou par le nombre des variables d'enregistrement limitées. Il est donc important d'élaborer des méthodes permettant d'estimer avec précision le rayonnement solaire sur la base de données météorologique disponibles.

Dans la littérature, différentes approches ont été utilisées pour prédire le rayonnement solaire, mais la plupart des modèles soufrent de la connaissance détaillée de divers paramètres, qu'ils soient géographiques ou météorologiques, et ils seront sous-performant lorsqu'ils sont utilisés pour modéliser des systèmes non linéaires. Pour surmonter ces problèmes, la nécessité d'une modélisation précise devient de plus en plus importante.

Récemment, la technique du réseau de neurones artificiels (RNA) a reçu beaucoup d'attention en tant qu'approche computationnelle fournissant un moyen alternatif et complémentaire de modélisation, en raison de sa capacité à faire face à des problèmes complexes et mal définis dans de nombreux domaines scientifiques. Dans le domaine météorologique, la modélisation des variables du rayonnement solaire par les modèles de réseau de neurone artificiel a connu un développement très prometteur qui a amélioré la performance des approches statistiques existantes (Lopez *et al.,* 2000(a), 2000(b)). Dans l'estimation du rayonnement solaire, les RNA les plus couramment utilisés sont les perceptrons multicouches (MLP) qui utilisent la formation de rétro-propagation.

L'objectif principal de cette contribution est de développer un modèle précis pour prédire les valeurs horaires de l'irradiation solaire globale reçues sur la surface horizontale basée sur presque tous les aspects de la modélisation du RNA tels que la fonction d'activation, les algorithmes d'apprentissage, le nombre de couches cachées, …ect, et ce en utilisant sept paramètres climatologiques et météorologiques sur un an dans la région de Ghardaïa-Algérie. Les résultats obtenus à l'aide du modèle RNA sont comparés à ceux obtenus avec le modèle développé selon la méthode de régression linéaire multiple (MLR).

III.2.2. Réseaux de neurones artificiels

Selon Haykin (1994), un réseau de neurones est un processeur distribué massivement parallèle qui a une propension naturelle à stocker les connaissances expérientielles et à la rendre disponible pour l'utilisation. Il ressemble au cerveau humain à deux égards : la connaissance est acquise par le réseau à travers un processus d'apprentissage et les forces de connexion entre neurones connues sous le nom de poids synaptiques sont associées à la connaissance.

Un RNA fonctionne comme un modèle de boîte noire (Sulafa, 2014) ; Il apprend la relation entre les entrées et les variables de sortie en étudiant les données précédemment enregistrées. Les RNA sont des outils efficaces pour modéliser des systèmes non linéaires et nécessitent moins d'intrants que les modèles mathématiques classiques.

Dans ce travail, la base de données a été arbitrairement divisée en trois ensembles : 80% pour l'apprentissage, 10% pour le test et 10% pour la validation. Le pouvoir du réseau réside dans les interconnexions : poids (w) et biais (b) entre les neurones, qui sont ajustés pendant la phase d'apprentissage. L'apprentissage se fait en exposant le réseau à un ensemble de données spécifiques d'information et en appliquant un algorithme de formation pour permettre au réseau de produire la sortie souhaitée. La précision du modèle RNA proposé a été évaluée à l'aide d'un ensemble de données de test non utilisé dans la phase d'apprentissage. Une échelle linéaire dans l'intervalle de [-1, +1] a été utilisée dans la présente étude en calculant le minimum et le maximum de chaque variable vectorielle et la normalisation des données par rapport à ces limites. Les fonctions de la normalisation et la dénormalisation des données d'apprentissage et de test sont la fonction premnmx et postmnmx, respectivement. Ces fonctions sont données dans les équations (III.6) et (III.7) (Benghanem, 2012 ; Benghanem, 2013 ; Abdallah El Hadj *et al.*, 2015 ; Ammi *et al.,* 2015,).

Pour l'équation de normalisation des données :

$$Y = Y_{min} + \frac{X - X_{min}}{X_{max} - X_{min}} (Y_{max} - Y_{min}) \quad \text{(III.6)}$$

Où: $X_{min} \leq X \leq X_{max}$ and $Y_{min} \leq Y \leq Y_{max}$

Pour dé-normaliser (à la valeur réelle) des données estimées par RNA,

$$Y = \frac{Y - Y_{min}}{Y_{max} - Y_{min}} (X_{max} - X_{min}) + X_{min} \quad \text{(III.7)}$$

L'algorithme le plus couramment utilisé pour la prédiction est le réseau multicouches feed-forward communément appelé "back-propagation", qui est une architecture typique incorporant une rétropropagation avec au moins trois couches (Rezrazi *et al*., 2016). Cette architecture peut comporter plus d'une couche cachée en fonction de la complexité du problème. Dans le RNA-MLP, où la couche cachée est conçue pour le traitement des données (Mellit, 2008 ; Kurtgoz & Deniz, 2016 ; Laidi *et al*., 2016), les entrées sont propagées vers l'avant à travers chaque couche du réseau pour émerger comme sorties. Les erreurs entre ces sorties et la cible sont alors propagées vers l'arrière à travers le réseau et ensuite les poids de connexion sont ajustés de façon à minimiser l'erreur de la *somme* des *carrés* (Alsina *et al*., 2016). Quel que soit le nombre d'entrées, les RNA doivent être aussi simples que possible (Si-Moussa *et al*., 2008). En général, les réseaux de neurones sont sensibles au nombre de neurones dans leurs couches cachées.

La fonction d'activation sigmoïde (tangente hyperbolique) pour les couches cachées est habituellement utilisée pour introduire la non-linéarité dans le réseau (Rezrazi *et al.,* 2016). Pour la couche de sortie, la fonction de transfert purelin peut satisfaire l'exigence.

La configuration optimale du meilleur modèle RNA est obtenue en fonction de l'analyse des erreurs (erreur moyenne quadratique : PRMSE), (l'erreur moyenne biaisée : MBE), la validation interne Q^2_{Loo}et la validation externe Q^2_{Ext} du model et le coefficient de corrélation linéaire maximal R de l'ensemble des données du test. Les résultats de régression sont représentés par des valeurs entre 0 et 1 où une valeur de 1 indique une corrélation parfaite entre les cibles et les sorties réelles des réseaux et une valeur égale à 0 indique le contraire. Les valeurs de RMSE et de la MBE sont toujours positives, équivalant zéro dans le cas idéal. Le code informatique de la stratégie ci-dessus a été mis en œuvre dans un logiciel STATISTICA utilisant la boîte à outils du réseau neuronal. Le modèle RNA utilisé dans ce travail a été entrainé jusqu'à obtention de la meilleure performance. Une fois que ce critère a été atteint, les pondérations optimales et les biais ont été sauvegardés pour une utilisation ultérieure dans le test du modèle.

III.2.3. Procédure de modélisation

Dans cette étude, une procédure basée sur la conception et l'optimisation de l'architecture du réseau neuronal est décrit dans la Figure III. 2. 1.

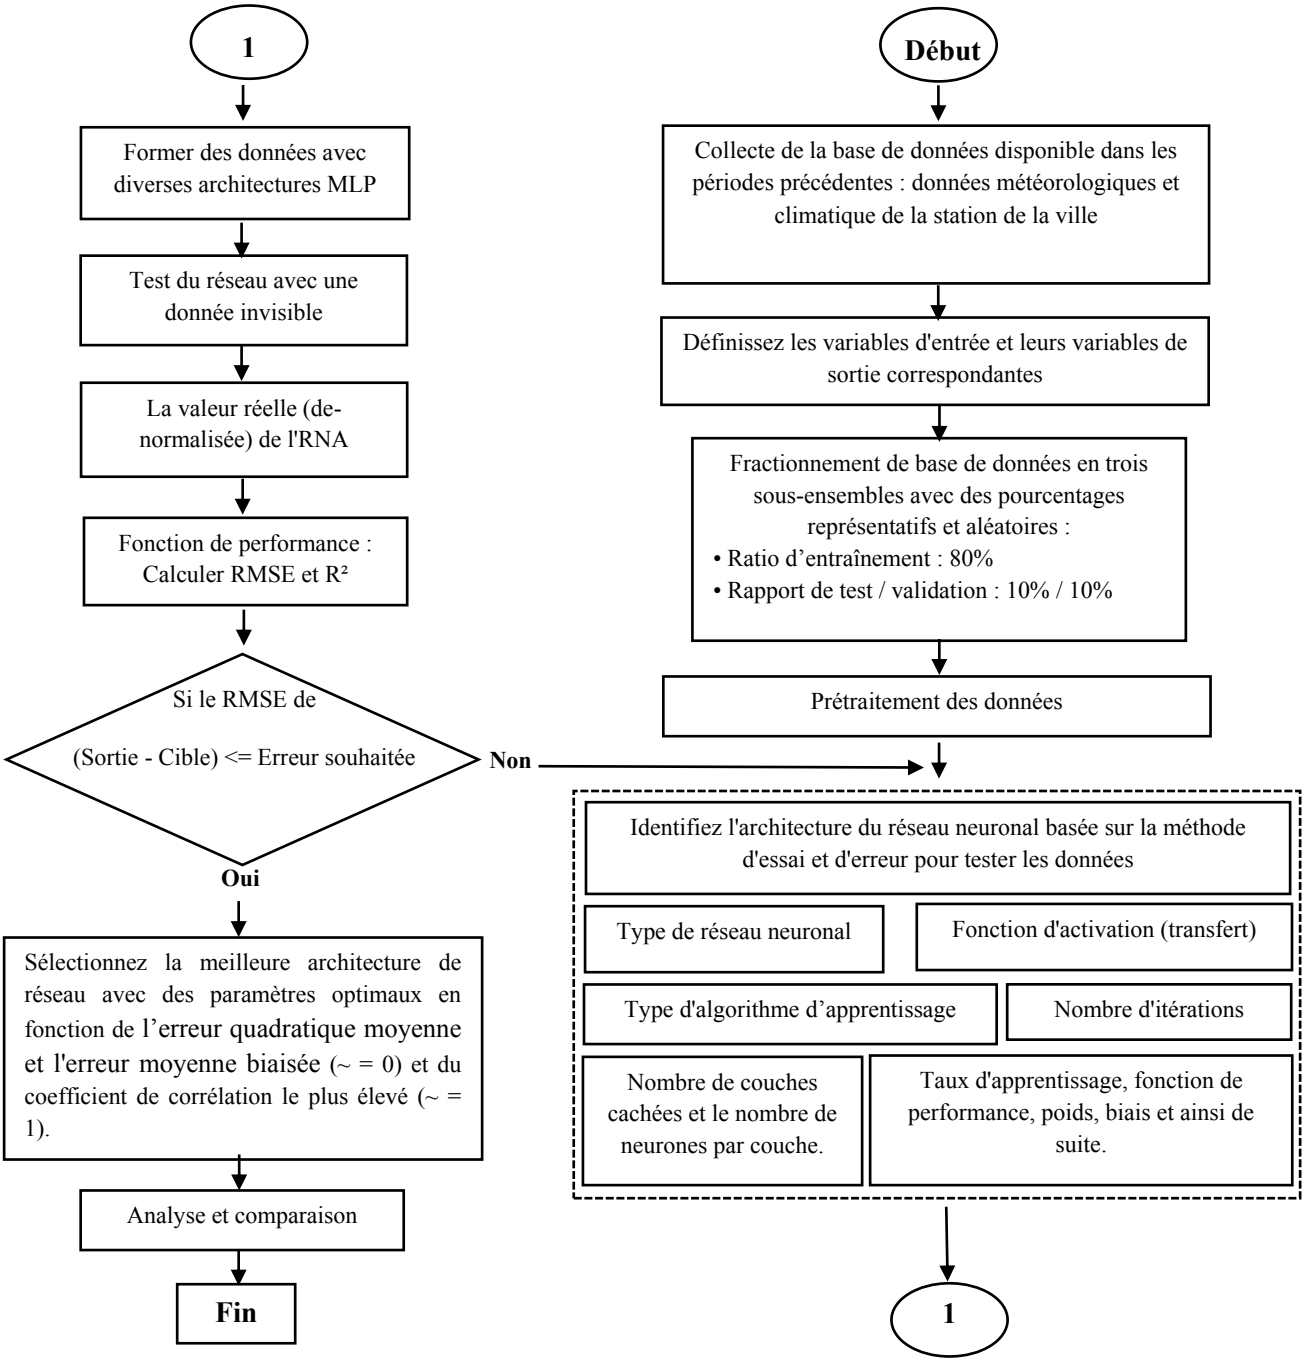


Figure III. 2. 1 : Procédure de conception et d'optimisation de l'architecture d'un réseau de neurone artificiel (Laidi *et al*., 2016).

III.2.3.1. Collecte et division de la base de données

La base de données de l'année 2013 utilisée dans ce travail a été fournie par l'unité de la recherche appliquée des énergies renouvelables (URAER) de Ghardaïa (Figure III. 2. 2), située au sud de l'Algérie. Cette ville se caractérise par une latitude de + 32,37 °, une longitude de + 3,77 ° et une altitude de 450m au-dessus du niveau moyen la mer.



Figure III. 2. 2 : Localisation géographique de Ghardaïa, Algérie.

Le climat de la région est semi-aride (doux en hiver et très chaud en été), connaissant une température d'air allant de 14°C à 47 °C et de 2°C à 37°C pendant les périodes d'été et d'hiver respectivement. Le RSG quotidien varie entre 607 Wh / m2 / jour au minimum et 7,574 Wh / m2 / jour maximum. La moyenne quotidienne annuelle est d'environ 5,656 Wh / m2 / jour (Yacef *et al*., 2014). Les données météorologiques sont enregistrées toutes les heures avec une grande précision au moyen d'une station radiométrique installée sur le toit de l'unité des énergies renouvelables (URAER). Le type pyranomètre EKO a été utilisé pour mesurer le rayonnement solaire global sur le plan incliné horizontal. La température et l'humidité relative sont également mesurées à l'aide d'un thermo-

hydrographe installé à la station URAER (Yacef *et al*., 2014). La station météorologique unitaire fournit des données sur la direction et la vitesse du vent.

Dans ce travail, la base de données (2390 points, huit paramètres) a été utilisée dans le but d'optimiser les paramètres d'un RNA. Dans la base de données, nous avons exclu toutes les valeurs inférieures à 120 W / m2 en fonction de l'organisation météorologique mondiale qui définit la durée du soleil lorsque les valeurs globales de rayonnement solaire sont supérieures à 120 W / m2 (Kalogirou, 2009).

III.2.3.2. Modélisation avec les réseaux de neurones

Comme indiqué précédemment, le modèle neuronal a été développé pour prédire le profil du rayonnement solaire global pour l'année 2013 au site de Ghardaïa.

Avant l'étape d'optimisation du modèle, la base de données utilisée dans ce travail couvrant les données d'entrée (le jour, le temps, la température ambiante, l'humidité relative, la vitesse moyenne du vent, la direction du vent et la pression atmosphérique) et la sortie (irradiation solaire globale ISG) a été analysée de manière statistique (Tableau III. 2. 1). L'étape d'optimisation de l'architecture RNA pour l'estimation du rayonnement solaire a été effectuée à l'aide du logiciel STATISTICA qui se déroule en plusieurs étapes telles que : algorithmes, répartition de la base de données, nombre de couches cachées, nombre de neurones dans la couche cachée, les fonctions de transfert pour la couche cachée et la couche de sortie respectivement (Hamadache et *al*., 2016).

Tableau III. 2. 1 : Analyse statistique des entrées et de sortie

	Min	**Max**	**Moy**	**Std**
J	1	359	182.36	94.87
t (h)	4	18	11.35	3.62
T (°C)	5	45.2	26.66	8.62
H (%)	6	95	27.95	14.25
Vm (m/s)	0	13	2.86	1.77
Dv (°)	0	360	177.28	108.84
P_a (mbar)	943.1	980.7	963.67	5.12
ISG(kWh/m^2	2.77	1,052.77	493.15	313.89

Dans ce travail, le nombre de neurones dans la couche cachée varie de 1 à 24. Les fonctions tangentes hyperboliques (tanh) et log sigmoïde (logsig) ont été utilisés pour la couche cachée. Les fonctions de purification linéaire (purelin), hyperbolique tangente (tanh) et sigmoïde logarithmique (logsig) ont été utilisées pour la couche de sortie. Le réseau a été formé en utilisant trois algorithmes de propagation quasi-newton (BFGS : Broyden-Fletcher- Goldfarb-Shanno), Gradient conjugué

échelonné (SCG) et gradient conjugué descente (CGP). Dans cette étude, nous avons testé toutes ces étapes pour obtenir le réseau neuronal optimal illustré dans les Tableaux III. 2. 2 et 3 et la Figure III. 2. 3.

Tableau III. 2. 2 : Paramètres sélectionnés du RNA optimal

Les parqamètres étudiés	RMSE (%)	Paramètres séléctionnés
La distribution de la base de données		
App (80%) test (10%) et validation (10%)	**5.05**	Apprentissage (80%). test (10%) et validation (10%)
App (70%) test (15%) et validation (15%)	5.65	
App (60%) test (20%) et validation (20%)	5.11	
Les fonctions d'activation (neurones cachés/sortie)		
Sigmoid-sigmoid	6.56	Tangent hyperbolic-linear
Sigmoid-linear	5.51	
Sigmoid-tangent hyperbolic	5.53	
Tangent hyperbolic-sigmoid	6.19	
Tangent hyperbolic-linear	**4.82**	
Tangent hyperbolic- Tangent hyperbolic	5.37	
Le nombre de neurone dans la couche caché2-25		24 Neurons
Algorithmes d'apprentissage		
Quasi-Newton back propagation(BFGS)	**4.82**	Quasi-Newton back propagation(BFGS)
gradient conjugué à l'échelle (SCG)	14.72	
Conjugate gradient descent (CGP)	21.63	

Tableau III. 2. 3 : Structure du modèle RNA optimisé

Model	Algorithmes d'apprentissage	Couche d'entrée	Couche cachée		Couche de sortie	
		Nombre de neurone	Nombre de neurone	Fonction d'activation	Nombre de neurone	Fonction d'activation
RNA	BFGS	7	24	Tanh	1	linéaire

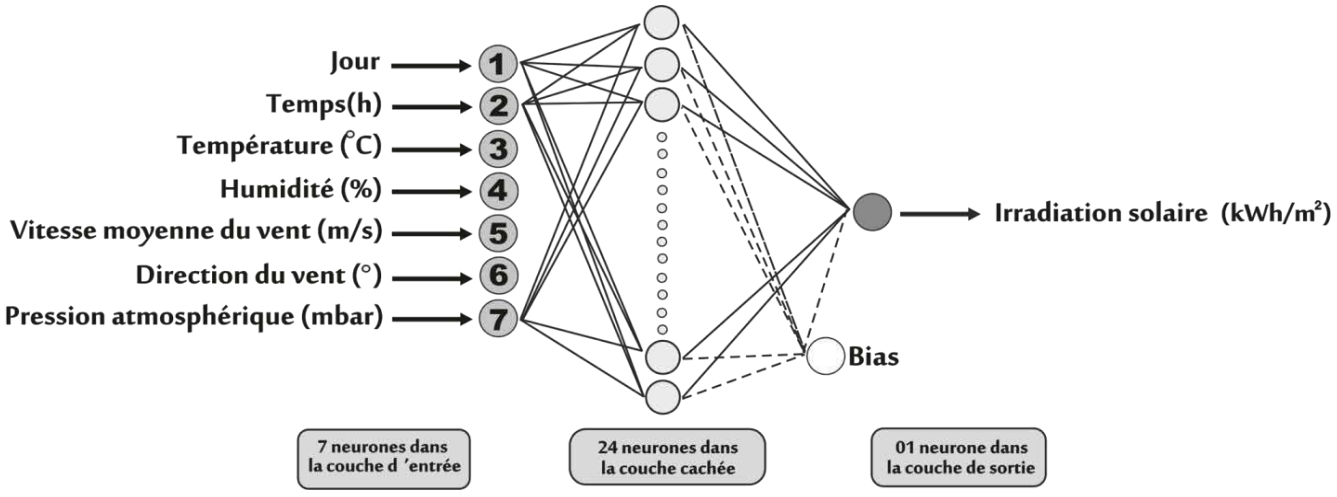


Figure III. 2. 3 : Réseau de neurones à trois couches.

La meilleure distribution de la base de données a été trouvée avec 80% des données pour la phase d'apprentissage, 10% pour la phase de validation et les 10% restants pour la phase de test. Tanh et linéaire étaient les meilleures fonctions de transfert pour les couches cachées et de sortie respectivement. Une couche cachée était suffisante pour prédire le rayonnement solaire avec une précision suffisante. Le nombre de neurones dans la couche cachée est de 24 neurones. Enfin, l'algorithme de formation BFGS associé à sa technique d'amélioration de la généralisation correspondante était le meilleur algorithme avec une grande vitesse de convergence.

III.2.3.3. Modélisation par régression linéaire multiple (MLR)

Les régressions linéaires multiples (MLR) sont les méthodes de modélisation les plus utilisées et les plus connues (Sarkhosh et *al*., 2012), utilisée comme base pour un certain nombre des méthodes multi-variées. MLR est une méthode d'exploration des données pour étudier la relation et la dépendance entre les variables dépendantes et les variables indépendantes par l'équation suivante :

$$y = a_0 + \sum_{i=1}^{7} a_i x_i \qquad \text{(III.8)}$$

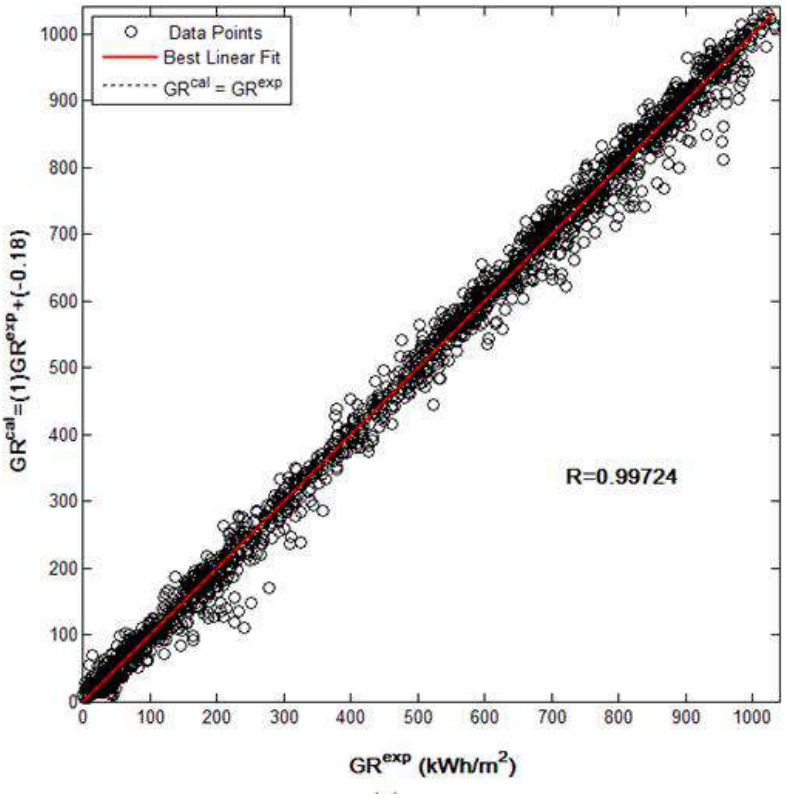
i=1, 2, 3, ..., 7

Ou y est la sortie de MLR, a_0 est l'interception de l'équation, a_1, a_2, ... a_8 sont des coefficients de ces variables, x_i représentes l'ensemble des variables.

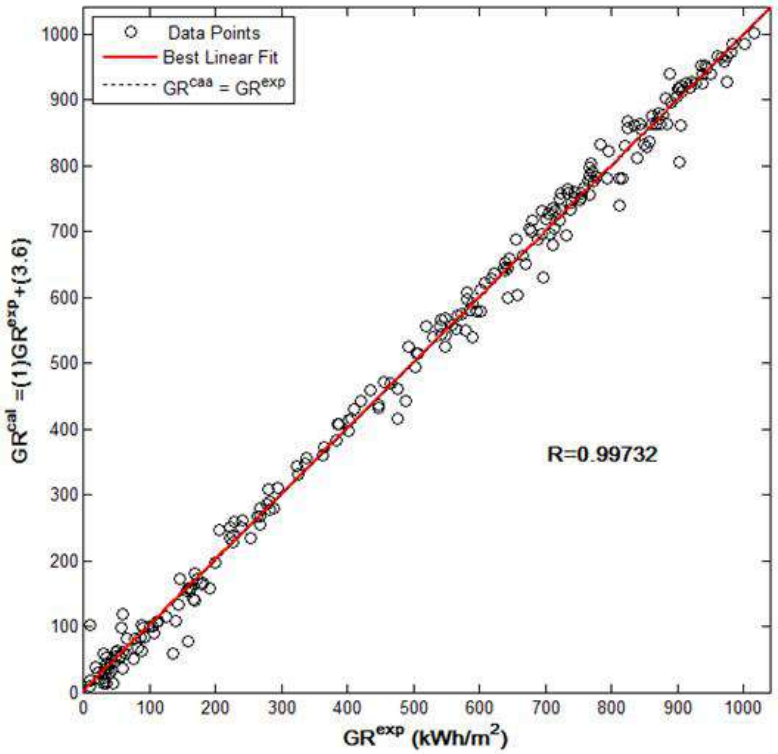
III.2.4. Résultats et discussion

III.2.4.1. Réseaux de neurones

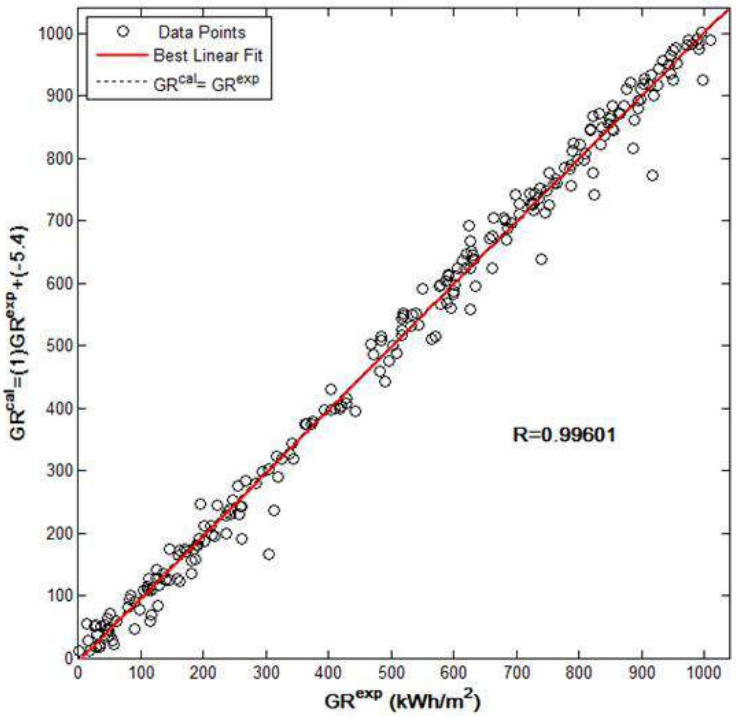
L'intrigue et les paramètres de la régression linéaire sont, directement obtenus à l'aide de la fonction "plotregression" sous MATLAB (voir la Figure III. 2. 4). La comparaison entre les valeurs expérimentales et calculées du rayonnement solaire obtenues par la simulation de modèles RN optimisés pour l'ensemble de données montre qu'il existe un bon accord entre elles (les valeurs expérimentales et calculées) et avec des vecteurs approchant l'idéal [a (la pente), β (Interception y), (coefficient de corrélation)] = [1, -0,29, 0,9971] pour le RNA. Cela signifie qu'il existe un lien linéaire fort entre les variables dépendante (Y : la sortie du réseau) et indépendantes (X : les entrées).


Data Points
Best Linear Fit
GR^cal = GR^exp
R=0.99724
GR^cal=(1)GR^exp+(-0.18)
GR^exp (kWh/m^2)

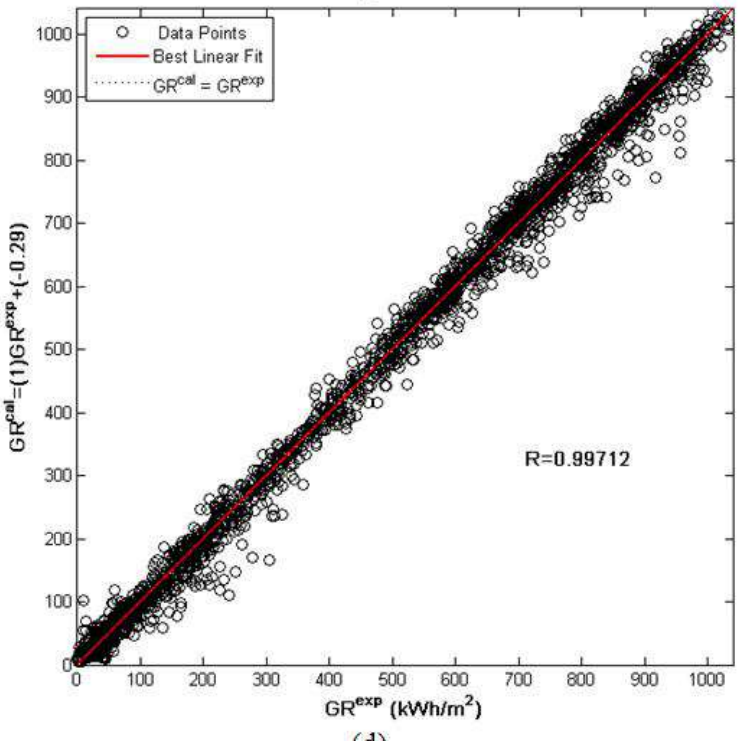
(a)


Data Points
Best Linear Fit
GR^caa = GR^exp
R=0.99732
GR^cal =(1)GR^exp+(3.6)
GR^exp (kWh/m^2)

(b)



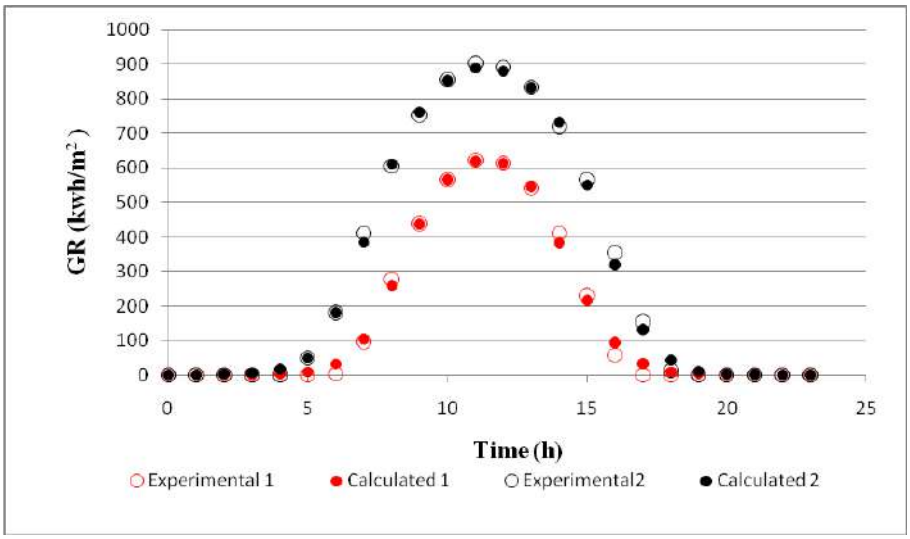
(c)



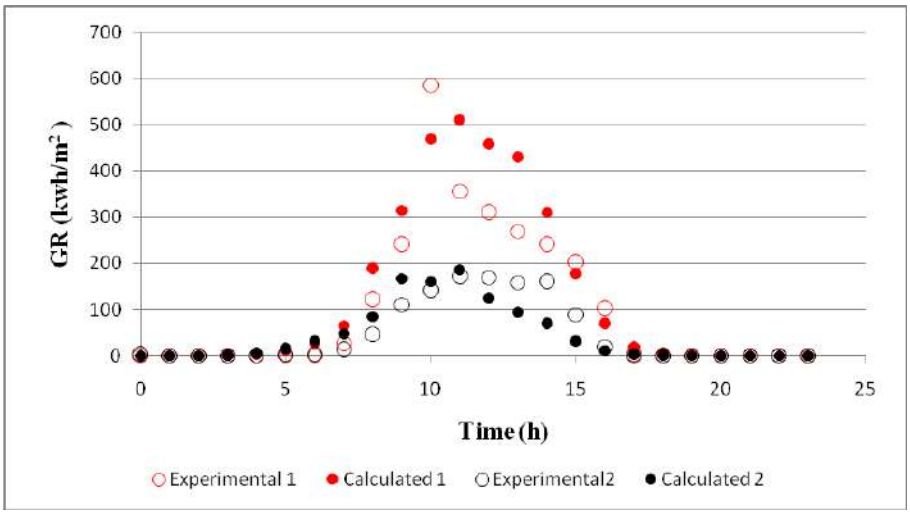
(d)

Figure III. 2. 4 : Comparaison entre les valeurs expérimentales et prédites pour l'ensemble des données : (a) apprentissage, (b) validation, (c) test et (d) la phase de généralisation.

Pour vérifier l'exactitude de modèle RNA précédemment développé et optimisé, deux représentations ont été faites (voir Figures III. 2. 5 et 6). La Figure III. 2. 5 (a) contient un ensemble de points de deux jours parmi les plus favorables pour l'année 2013 entre les points expérimentaux et prédits de l'irradiation solaire globale. La figure III. 2. 5 (b) contient un ensemble de points de deux jours parmi les plus défavorables pour la même année entre les points expérimentaux et prédits de l'irradiation solaire globale.



(a)



(b)

Figure III. 2. 5 : Comparaison entre les valeurs expérimentales et prédites de l'irradiation solaire globale pendant quelques jours, (a) représente deux jours parmi les plus favorables (b) représente deux jours de la plus défavorable.

La Figure III. 2. 6 montre la comparaison entre les valeurs expérimentales et calculées de l'irradiation solaire globale tout au long de l'année 2013. Des Figures excellentes et modérées des valeurs expérimentales de l'irradiation solaire globale sont représentées ci-contre (Figures III. 1.5 et III. 1. 6). Comme le réseau de neurone optimisé a été obtenu avec une grande précision car il est également démontré dans (Figure III. 2. 4) que cette RN peut traiter la tendance non linéaire de l'irradiation solaire. Le taux élevé du désaccord entre les résultats expérimentaux et prédits présentés à la figure III. 2. 5 (b) est dû au fait que les données expérimentales ont été affectées par les conditions météorologiques non stables des jours sélectionnés.

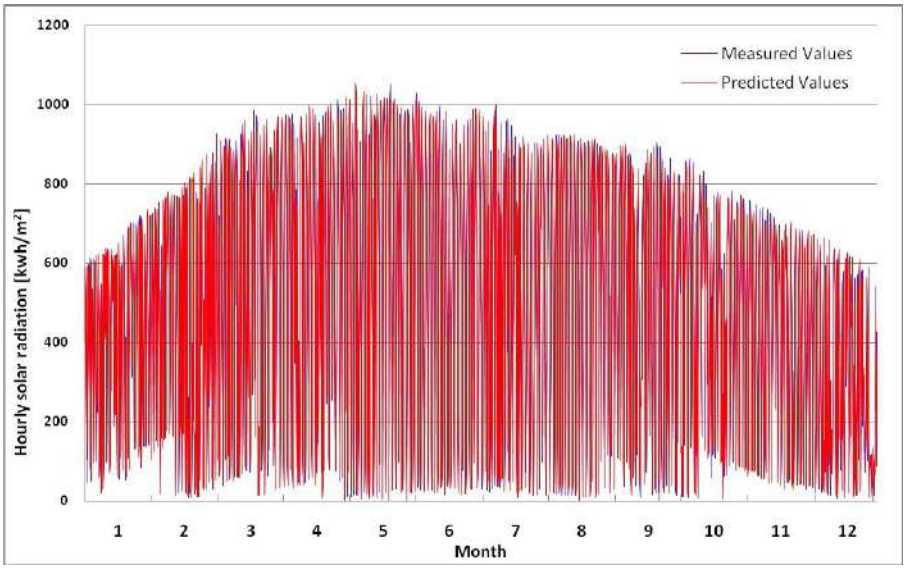


Figure III. 2. 6 : Comparaison entre les valeurs expérimentales et calculées de l'irradiation solaire globale pendant toute l'année 2013.

La performance du RN optimisé a été évaluée en fonction du pourcentage de l'erreur quadratique moyenne (PRMSE) et de l'erreur moyenne biaisée (MBE).

PRMSE (l'erreur quadratique moyenne) est donnée dans l'équation (III.9) :

$$PRMSE = \frac{\sqrt{\sum_{i=1}^{N} \frac{(y_{cal} - y_{exp})^2}{N}}}{\sum_{i=1}^{N} \frac{y_{exp}}{N}} \times 100 \qquad \text{(III.9)}$$

L'erreur moyenne biaisée(MBE) est présentée dans l'équation (III.10) :

$$MBE = \frac{1}{N}\left(\frac{\sum_{i=1}^{N}(y_{cal} - y_{exp})}{\sum_{i=1}^{N} Y_{exp}}\right) \times 100 \qquad \text{(III.10)}$$

Où N est le nombre total de données ; représente la sortie prévue du modèle de réseau neuronal pour

une entrée donnée, tout en étant la valeur expérimentale. Le Tableau III. 2. 4 résume l'analyse statistique, les vecteurs d'accords de validation et les performances du modèle RNA.

Tableau III. 2. 4 : Analyses statistiques, vecteurs d'accords de validation et la performance du modèle RNA

	PRMSE (%)	**MBE *(%)***	**α**	**B**	**R**	Q^2_{Loo}	R_{ext}	Q^2_{ext}
Apprentissage	4.71	0.021	1	-0.18	0.9972	0.9984	-	-
Validation	4.79	0.398	1	3.6	0.9973	-	-	-
Test	5.60	0.421	1	-5.4	0.9960	-	0.9960	0.9977
généralisation	4.82	0.020	1	-0.29	0.9971	-	-	-

À partir de ce Tableau, on déduit que les paramètres de régression obtenus par le RNA sont favorables à la prédiction de l'irradiation solaire globale, et ceci grâce aux résultats très satisfaisants, avec un accord étroit des valeurs vectorielles idéales pour les coefficients de corrélation 'R' ou par rapport à '$\boldsymbol{\alpha}$ ' Et 'B' dans la définition des profils des RNA. Concernant l'analyse des résultats de recherche statistiques, le pourcentage d'erreur moyenne quadratique (RMSE) et MBE s'est révélé être de 4,82% et 0,020% pour l'ensemble des données du modèle optimal avec une précision supérieure à 99,7%, ce qui prouve que les valeurs estimées sont en bon accord avec les valeurs réelles.

La Figure III. 2. 7 donne les valeurs résiduelles pour le modèle développé. Chaque point du graphique correspond à une erreur relative entre la valeur réelle et la valeur prédite d'irradiation solaire horaire. On constate que le pourcentage d'erreur relative de chaque heure dépasse rarement ± 10%. Toutes les barres d'erreur traversent la ligne zéro, indiquant qu'il n'y a pas de valeurs aberrantes dans les données. Les résultats peuvent être considérés comme assez satisfaisants.

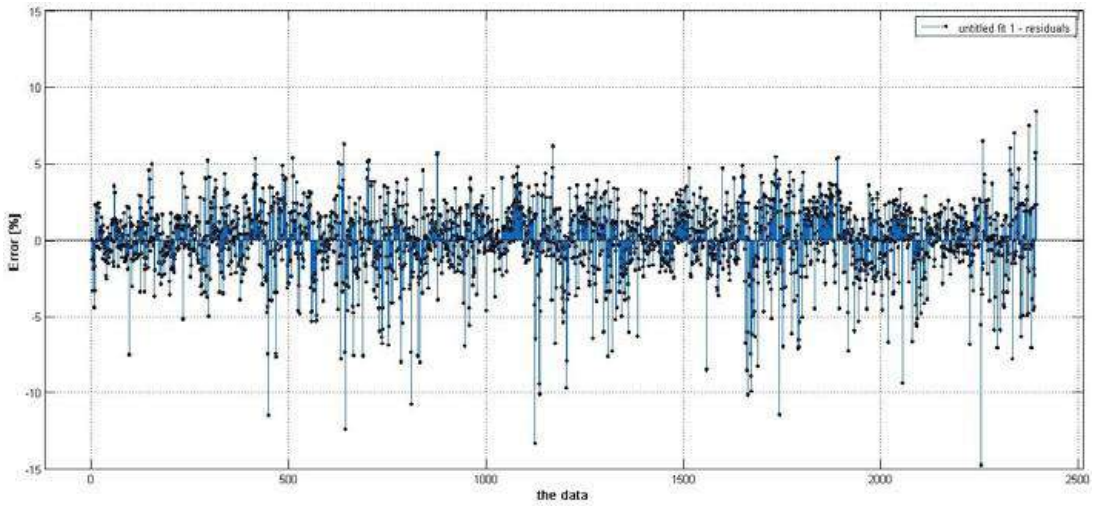


Figure III. 2. 7 : Traces de résidus pour les données.

La qualité d'un modèle est évaluée à l'aide de paramètres statistiques, comme le coefficient de corrélation et l'erreur. Des études récentes ont montré l'existence de deux principes de base (validation interne et validation externe) qui sont utilisés dans le but de valider la puissance prédictive d'un modèle. Pour évaluer la capacité prédictive interne du modèle développé, nous avons pris la validation croisée. Cela a été calculé à la suite de cette équation (Yousefinejad & Hemmateenejad, 2015) :

$$Q_{int}^2 = 1 - \frac{\sum(y_{\exp(appr)} - y_{\mathrm{pred}(appr)})^2}{\sum(y_{\exp(appr)} - \overline{y}_{\exp(appr)})^2} \qquad \text{(III.11)}$$

Oùy_{exp}, y_{pred} et $\overline{y}_{exp}$ sont les valeurs expérimentale, prédite et la moyenne d'irradiation solaire pour l'ensemble d'apprentissage, respectivement. Une valeur de Q_{int}^2> 0,5 est considérée comme satisfaisante, et Q_{LOO}^2> 0.9 signifie que le modèle est robuste (Eriksson *et al.,*2003).

De plus, la validation externe est une méthode de validation importante et nécessaire qui est utilisée pour déterminer la propagation et la capacité prédictive réelle d'un modèle pour l'irradiation solaire. La capacité prédictive externe des modèles développés sur l'ensemble de prédiction externe a été évaluée par Q_{ext}^2, ce qui pourrait être calculé comme suit (Yousefinejad & Hemmateenejad, 2015) :

$$Q_{ext}^2 = 1 - \frac{\sum(y_{\exp(test)} - y_{\mathrm{pred}(test)})^2}{\sum(y_{\exp(test)} - \overline{y}_{\exp(appr)})^2} \qquad \text{(III.12)}$$

Où y_{exp} et y_{pred} sont les valeurs expérimentales prédites d'irradiation solaire pour l'ensemble de test respectivement, et $\overline{y}_{exp}$ valeurs moyennes de l'irradiation solaire pour l'ensemble d'apprentissage. Une valeur de Q_{ext}^2> 0,5 est considérée comme satisfaisante, et une valeur de Q_{ext}^2>n0.9 est excellente (ce

qui signifie que le modèle a un bon pouvoir prédictif) (Eriksson *et al,.* 2003).

III.2.4.1.1. Equation du réseau de neurone optimisé

À partir du réseau neuronal artificiel optimisé, nous pouvons exprimer l'irradiation solaire globale par un modèle mathématique qui incorpore toutes les entrées E_i à l'intérieur comme suit :

- Les sorties de l'instance Z_j de la couche cachée :

$$Z_j = f_H\left(\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right) = \frac{\exp\left(\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right) - exp\left(-\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right)}{\exp\left(\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right) + exp\left(-\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right)} \quad \text{(III.13)}$$

Où t = 1.2 ... n, représente le nombre de neurones de la couche d'entrée pour chaque modèle RNA, et j = 1.2 ... 24, représente le nombre de neurones dans la couche cachée.

- La sortie ISG :

$$ISG = f_0\left[\sum_{j=1}^{24} W_{1j}^H z_j + b_1^0\right] = \left[\sum_{j=1}^{24} W_{1j}^H z_j + b_1^0\right] \quad \text{(III.14)}$$

La combinaison des équations (III.13) et (III.14) conduit à la formule mathématique pour l'ISG en tenant compte de toutes les entrées E_i :

$$ISG = \left[\sum_{j=1}^{24} W_{1j}^H \left(\frac{\exp\left(\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right) - exp\left(-\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right)}{\exp\left(\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right) + exp\left(-\sum_{i=1}^{n} W_{ji}^I E_i + b_j^H\right)}\right) + b_1^0\right] \quad \text{(III.15)}$$

Où W_{jt}^1 est le poids synaptique de la connexion du neurone t de la couche d'entrée au neurone j dans la couche cachée ;W_{1j}^H1 Hj W représente le poids de la connexion du neurone synaptique j le neurone de la couche cachée de la couche de sortie ;b_j^H et b_1^0 représentent respectivement le neurone de polarisation j dans la couche cachée et le neurone de la couche de sortie.

III.2.4.1.2. Analyse de sensibilité

La méthode des poids utilisée dans l'analyse de sensibilité a permis de déterminer la contribution des variables d'entrée sur la sortie ISG (kWh/m^2). La quantification de l'importance relative (IR) des entrées sur la sortie du réseau neuronal a été fournie par cette dernière méthode Gevrey et al. (2003), proposée initialement par Garson (1991) et répétée par Goh (1995). Elle est basée sur la partition des connexions des poids à :

- Les poids de connexion de l'entrée - caché (I) Wjt
- Les poids de connexion de la sortie -cachée 1 (). HjW

La contribution des variables d'entrée obtenues par la méthode des poids pour le réseau neuronal est illustrée à la Figure III. 2. 8.

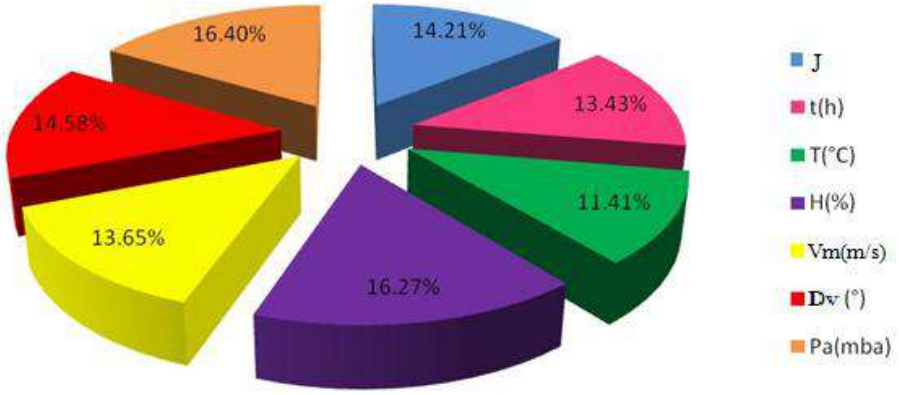


Figure III. 2. 8 : Tarte graphique illustrant l'importance relative des variables d'entrée, sur le rayonnement solaire global (voir la version en ligne pour les couleurs).

Les variables les plus importantes qui peuvent influencer sur l'irradiation solaire globale sont : La pression atmosphérique Pa (mbar) et l'humidité relative H (%) avec RI = 16,40% et16,27% respectivement. Les contributions de la direction du vent Dv (°) et du jour, ne sont pas significativement différentes (elles ont presque la même contribution avec une IR = 14%). Le temps t (h) et la vitesse moyenne du vent Vm (m / s) ont moins d'effet sur le modèle RNA avec IR = (13%), suivie de la température ambiant Ta (°C) avec IR = 11%. Les résultats de l'analyse de sensibilité montrent que tous les paramètres d'entrée ont une importance relative supérieure à > 5%, ce qui explique l'effet des paramètres sélectionnés sur la sortie.

III.2.4.2. Régression linéaire multiple (MLR)

Le modèle de régression linéaire multiple relie un ensemble de variables "prédictives" à la puissance de la variable de réponse. Les mêmes jeux de données utilisés pour développer le modèle RNA ont été utilisés pour développer le modèle MLR. Il a été mis en œuvre en utilisant la fonction MATLAB "régress". L'équation linéaire de MLR pour prédire l'irradiation solaire globale est suivante :

$$ISG = -12474{,}5246 - 0{,}85760J - 6{,}4320t + 12{,}8254T_a - 2{,}7088H_r + 50{,}1316V_m - 0{,}0826\,D_v + 13{,}0270P_a \quad \text{(III.16)}$$

Selon la Figure III. 2. 9, on voit que les valeurs d'irradiation solaire prédites selon le modèle MLR sont très faibles par rapport aux valeurs observées «ensembles de données totales» (R = 0,53489).

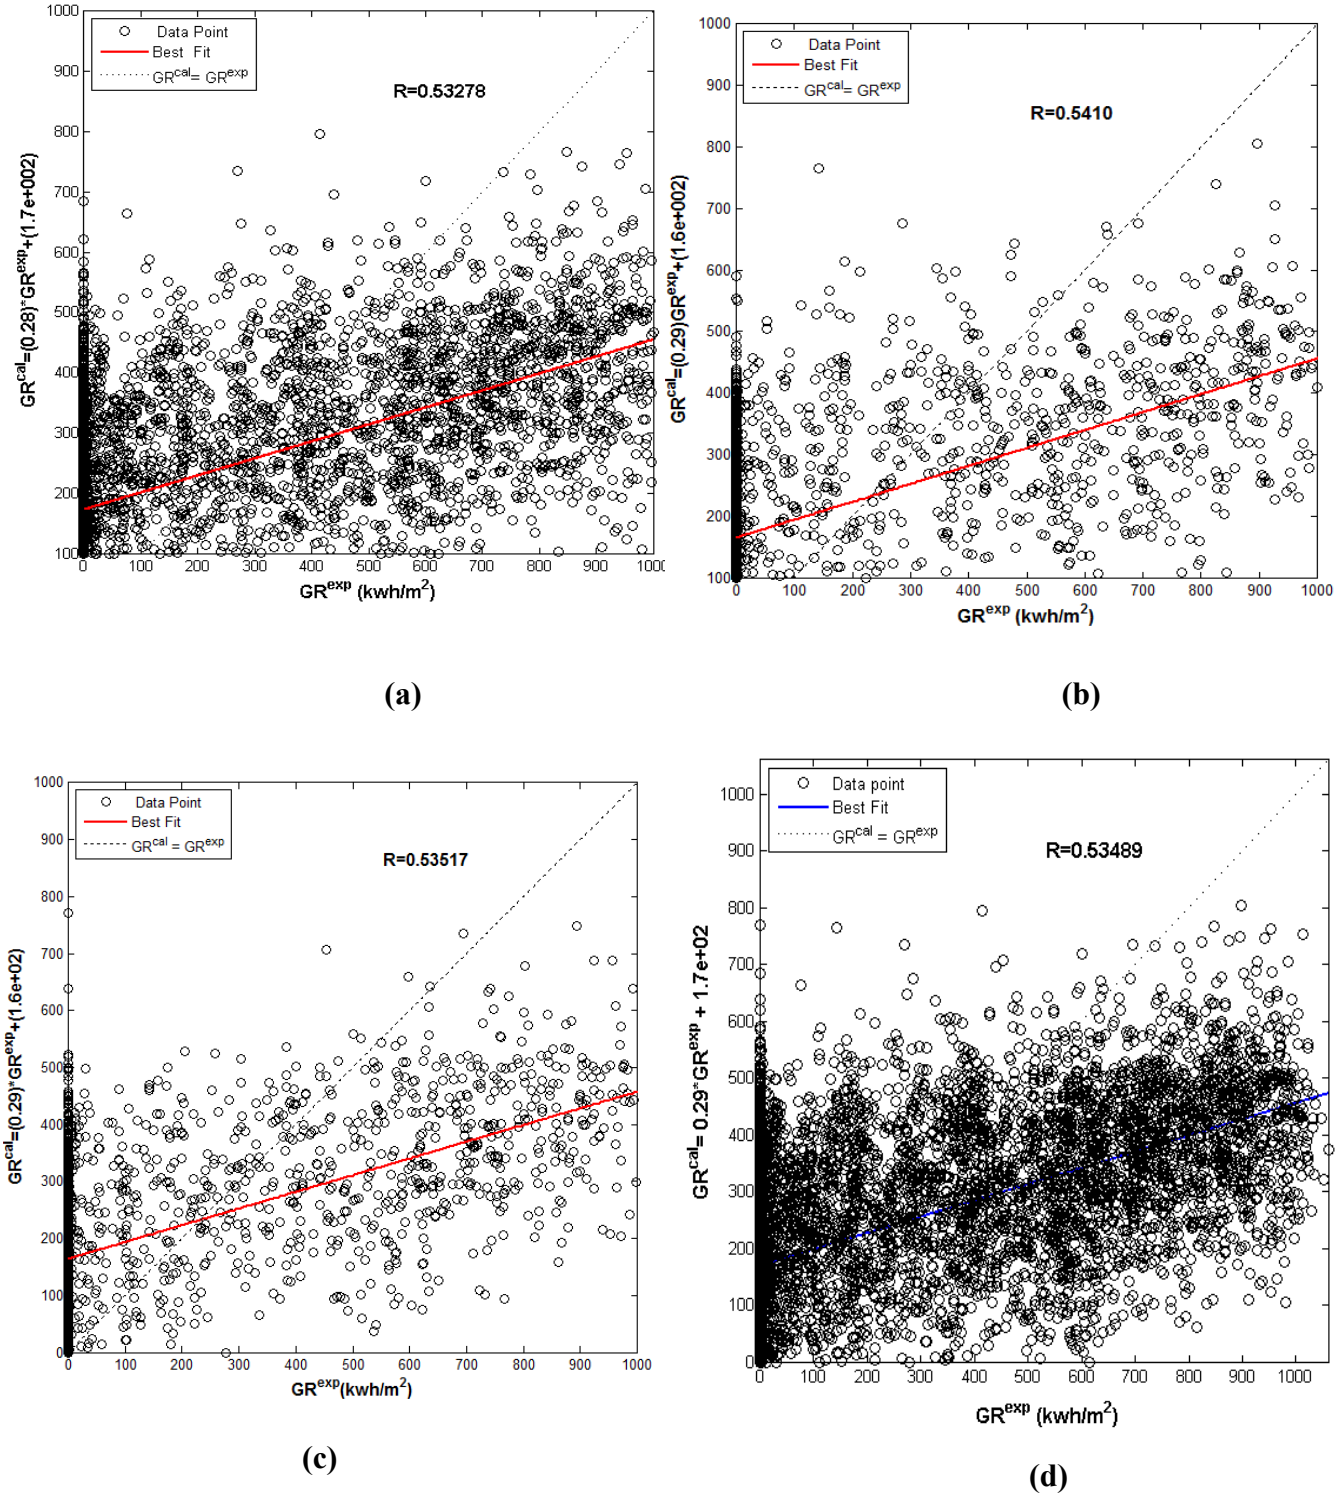


Figure III. 2. 9 : Comparaison entre les valeurs expérimentales et les valeurs prédites par le modèle MLR pour les données : (a) apprentissage, (b) validation, (c) test, et (d) généralisation.

Afin de distinguer l'importance de chaque variable sur l'irradiation solaire globale, les valeurs P-Val impliquées figurent également dans le Tableau III. 2. 5. L'estimation de divers paramètres du modèle inconnu (Tableau III. 2. 5) révèle que tous les coefficients du modèle polynomial sont considérés comme significatifs (Valeur P <0,05).

L'analyse de régression peut être utilisée comme technique d'analyse de sensibilité. Les techniques de régression sont utilisées pour évaluer la sensibilité des entrées du modèle, compte tenu de l'impact simultané des autres paramètres du modèle sur le résultat (Cullen, 1999). L'analyse de régression comme méthode d'analyse de sensibilité est appliquée dans divers domaines tels que la science vétérinaire (Taylor *et al*. 1992), les sciences sociales (Barrett, 1986), les sciences de l'alimentation (Cliff *et al*., 1995). L'importance des entrées a été indiquée par l'erreur standard dans le modèle MLR. L'importance (Std. Err) de chaque entrée sur l'irradiation solaire globale est indiquée dans le Tableau III. 2. 5. Il est à noter que les entrées (jour, temps, température ambiante, humidité relative, vitesse moyenne du vent, la direction du vent et la pression atmosphérique) ont une importance qui est loin de zéro. Cette analyse de sensibilité a montré a posteriori la signification des sept paramètres sélectionnés pour la modélisation de l'irradiation solaire globale.

Tableau III. 2. 5 : Coefficients de modèle estimé par analyse de la régression linéaire multiple.

Paramètres énergétique	Coeff. SC	Std. Err.	P-Value
Moyenne /interceptée	-12474,52	600,93	0
J	-0,85	0,33	0,010
t	-6,43	0,42	0
T_a	12,82	0,56	0
H_r	-2 ,70	0,28	0
Vm	50,13	1,76	0
D_V	-0,08	0,02	0,009
P_a	13,03	0,62	0

*Terms significant (P-value <0.05)

III.2.5. Comparaison

III.2.5.1. Comparaison entre le modèle neuronal et la régression linéaire multiple

D'après les Figures III. 2. 4 et 9, les valeurs estimées (ou prédites) par le modèle élaboré par les réseaux de neurones sont beaucoup plus proches des valeurs expérimentales celles obtenues avec le modèle établi par la régression linéaire multiple.

L'évaluation statistique des deux modèles donnée sur la Figure III.2.10 nous permet de comparer les performances et la qualité de la prévision des deux méthodes utilisées dans ce travail

(RNA et MLR). Le coefficient de corrélation entre les valeurs expérimentales et prédites est un indicateur important pour vérifier la validité des modèles de prédiction. S'il est proche de la valeur 1, la prédiction est précise. Pour le modèle RNA, il se trouve que le coefficient de corrélation pour l'ensemble de données (apprentissage, validation et test) est supérieur à 0,99. Ce qui indique qu'il y'a une très bonne corrélation entre les valeurs simulées et observées. Le modèle MLR fournit par contre un coefficient de corrélation qui ne dépasse pas 0,53 (comme le montre la Figure III. 2. 10). De plus, le modèle MLR donne de plus grandes valeurs d'erreur par apport au modèle neuronale : pour l'ensemble de données global, la PRMSE et la MBE sont respectivement de 17.38 (%) et 1,11(%) le modèle MLR alors qu'elles sont de 4.82 (%) et 0,02 (%) pour le modèle neuronal. Les erreurs du modèle RNA étant inférieures à celles du modèle MLR, on déduit que le modèle de neurones à une capacité de prédiction très élevée par rapport au modèle de la régression linéaire multiple.

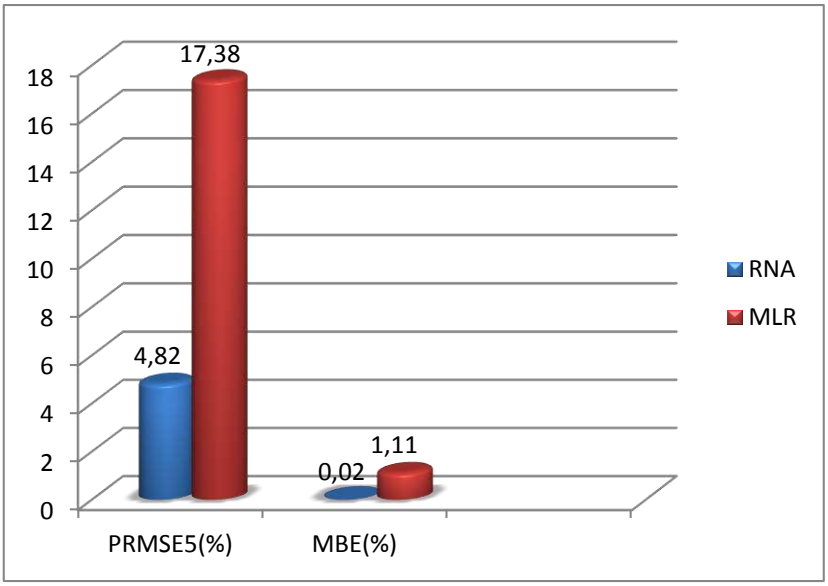


Figure III. 2. 10 : Comparaison entre les erreurs des résultats prédits par les modèles RNA et MLR.

III.2.5.2. Comparaison avec différents modèles

Pour évaluer l'importance des résultats obtenus, nous avons essayé de les comparer avec des études similaires, avec des modèles qui ont la plupart des intrants comme nous l'avons utilisé pour déterminer l'irradiation solaire globale sur les plans horizontaux. Al-Alawi et Al-Hinai (1998) ont utilisé la position, le mois, l'humidité relative moyenne, la température moyenne, la pression moyenne, la pression moyenne de la vapeur, la vitesse moyenne du vent et les heures de soleil moyennes en tant qu'entrées du réseau de neurones multi-couches feed-forward pour prédire le rayonnement global dans

les emplacements de fuit. Lazzús et al. (2011) ont utilisé l'humidité relative, la vitesse du vent, la température de l'air et la température du sol, en tant que variables d'entrée d'un modèle RNA pour l'estimation du Rayonnement solaire global horaire à La Serena (Chili). Linares-Rodríguez et al. (2011) ont développé un modèle RNA en utilisant la latitude, la longitude, le jour de l'année, les rayons globaux quotidiens du ciel clair, la couverture nuageuse totale, la température, la vapeur d'eau de colonne totale et l'ozone à colonne totale comme intrants pour estimer le rayonnement solaire mondial quotidien en Espagne. Elminir et al. (2005) a proposé un réseau de neurones avancés multicouches pour la prévision horaire de différentes bandes spectrales solaires, en utilisant la direction du vent, la vitesse du vent, la température ambiante et l'humidité relative comme paramètres d'entrée. Différentes combinaisons de paramètres d'entrée ont été utilisées (température de l'air, humidité relative, durée du soleil et jour de l'année) par Benghanem et al. (2009) pour estimer le rayonnement solaire à Al-Madinah (Arabie Saoudite). Fadare (2009) a élaboré un modèle RNA avec une architecture différente utilisant la latitude, la longitude, l'altitude, le mois, la durée moyenne du soleil, la température moyenne et l'humidité relative comme intrants, pour prédire le potentiel de l'énergie solaire sur 195 villes au Nigeria. Les résultats obtenus à partir de ces modèles mentionnés et mes résultats sont ressemblés dans le Tableau III. 2. 6. Nous observons que tous ces modèles donnent une forte capacité de prédiction (coefficient de corrélation). Mais, notre modèle dépasse les modèles précédemment publiés dans la plupart des indices statistiques disponibles pour comparaison (Tableau III. 2. 6). Nous avons obtenu le coefficient de corrélation de valeur la plus élevée qui a dépassé 99 %, avec une faible erreur de PRMSE (4,82 %) et de MBE (0,020 %) pour l'ensemble des données. Selon ces résultats, nous pouvons dire que notre modèle offre de meilleures performances par rapport aux autres modèles.

Tableau III. 2. 6 : Résultats de notre modèle par rapport aux différents modèles similaires

Les Modèles	Les variables d'entrées	MBE (%)	PRMSE (%)	R (%)	Q^2_{Loo} (%)	Q^2_{ext} (%)
Travail présent	le jour, le temps, la température ambiante, l'humidité relative, la vitesse moyenne du vent, la direction du vent, et la pression atmosphérique	0.020	4.71	99.71	99.84	99.77
Al-Alawi & al.-Hinai, (1998)	Mois, l'humidité relative moyenne, température moyenne, la pression moyenne, pression moyenne de la vapeur, la vitesse moyenne du vent et heures de soleil moyenne.	-	-	93 - 95	-	-
Lazzús *et al.*, (2011)	L'Humidité relative, la vitesse du vent, la température de l'air et température du sol	-	-	94	-	-
Linares-Rodríguez *et al.,* (2011)	latitude, longitude, le jour de l'année, les rayons globaux quotidiens du ciel clair, la couverture nuageuse totale, la température de la peau, la vapeur d'eau de colonne totale et l'ozone de colonne totale	-	16.4	94	-	-
Elminir *et al.*, (2005)	Direction du vent, vitesse du vent, température ambiante, humidité relative	0.38	3.97	29-96	-	-
Benghanem *et al.,* (2009)	Température de l'air, humidité relative, durée du soleil et jour de l'année	-	-	97.65	-	-
Fadare, (2009)	Latitude, longitude, altitude, mois, durée moyenne du soleil, température moyenne et humidité relative	-	-	90	-	-

III.2.6. Programme de calcul d'ISG

Apres avoir construit le modèle neuronal, c'est-à-dire déterminer ses poids synaptiques et ses biais, nous avons développé un programme informatique en langage MatLab®. Cette démarche permet à l'utilisateur d'avoir tous les inputs nécessaires à l'exécution de ce modèle pour calculer la sortie. L'interface était conçue pour fournir plus de flexibilité dans l'utilisation de model neuronal pour un calcul rapide et facile de l'irradiation solaire globale.

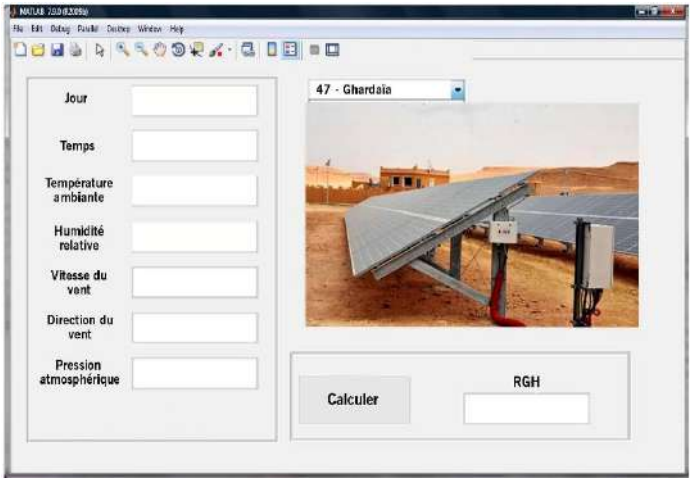


Figure III. 2. 11 : Interface MALAB pour le calcul l'irradiation solaire globale**.**

III.2.7. Conclusion

Dans ce travail, un réseau de neurones a été utilisé pour prédire les valeurs globales de l'irradiation solaire de la ville de Ghardaïa en Algérie. Le RNA développé a une architecture à trois couches : sept neurones dans la couche d'entrée, une couche cachée contenant 24 neurones à tangente hyperbolique en tant que fonction de transfert et un neurone dans la couche de sortie avec une fonction de transfert linéaire pure. L'algorithme de formation utilisé était le BFGS. Un bon accord entre les valeurs d'irradiation solaire expérimentales prédites a été observé. Pour le modèle RNA, on constate que les coefficients de corrélation pour l'ensemble de données (formation, validation et Test) sont tous supérieurs à 99 (%), ainsi qu'une meilleure robustesse R = 99.7(%) ; Q_{int}^2 =99.8 (%) pour l'ensemble d'apprentissage, et des valeurs élevées prédictives de Rext et Q_{ext}^2 (99.6 (%) et 99.7 (%) pour l'ensemble de tests. Toutes les validations indiquent que le modèle neuronal était robuste et très satisfaisant. En conclusion, le modèle neuronal développé dans cette étude a pu montrer la nature non linéaire qui lie plusieurs paramètres à l'irradiation solaire. Le résultat de l'analyse de sensibilité montre l'importance de toutes les variables sélectionnées pour la modélisation de l'irradiation solaire globale.

Conclusion générale

Conclusion générale

La modélisation de l'irradiation solaire joue un rôle très important dans la conception des systèmes d'énergie solaire, car elle permet aux ingénieurs et aux concepteurs d'avoir une base de données à long terme pour évaluer le potentiel de leurs applications.

Les réseaux de neurones possèdent une propriété remarquable dont l'apport est manifesté pour la modélisation des processus non linéaires : ce sont des approximateurs universels parcimonieux. Les modèles des réseaux neurones artificiels (RNA) ont finalement été appliqués pour la prévision de l'irradiation solaire. Les techniques neuronales présentent un intérêt accru dans la modélisation de ces domaines.

L'objectif de cette thèse est d'établir un modèle neuronal capable de prédire l'irradiation solaire globale sur une surface horizontale. Cette modélisation s'articule sur l'élaboration d'un programme sur MatLab® dans la première contribution et à travers l'utilisation du logiciel STATISTICA dans la deuxième contribution.

Dans la première contribution, une méthodologie pour l'élaboration d'un réseau de neurones artificiels RNA a été recommandée avec de grandes chances d'atteindre une solution optimale. La méthode est basée sur la méthode test-erreur pour déterminer la structure interne du réseau : l'algorithme d'apprentissage, la technique de normalisation, l'architecture du réseau. La base de données géo-satellite de Soda comporte des données géographiques et météorologiques de 4 villes, qui représentent des climats différents, pour une période de 3 ans (2004-2006). On note que l'erreur quadratique moyenne en pourcentage "PRMSE" dans le modèle optimal RNA atteint 10%. En plus, le modèle donne un coefficient de corrélation de 0,92. On peut en déduire à partir des résultats que la méthodologie d'optimisation proposée est fiable pour estimer et/ou prédire l'irradiation solaire.

Dans la deuxième contribution, on a élaboré un modèle neuronal pour prédire l'irradiation solaire dans la ville de Ghardaïa. La base de données expérimentale pour l'année 2013 nous a été fournie par l'Unité de Recherche Appliquée pour les Energies Renouvelables (URAER) Ghardaïa– Algérie. Les résultats ont montré un assez bon accord entre les valeurs mesurées et les valeurs prédites avec un coefficient de corrélation qui dépasse 99.0%. De plus, La précision de la prédiction pour la validation interne de la phase d'apprentissage en termes de (Q_{int}^2), d'erreur quadratique moyenne (PRMSE) et d'erreur moyenne biaisée (MBE) donnent 0,9984, 4,71% et 0,021% pour les trois paramètres respectivement. Tandis que la validation externe de la phase de test (Q_{ext}^2) donnent 0,9977, 5,60% et 0,42% respectivement.

Ces résultats montrent que le modèle optimisé est robuste et que la bonne puissance prédictive est expliquée par un bon accord entre les valeurs expérimentales et prédites de l'irradiation solaire. Bien que le travail ait porté sur les données météorologiques de la ville de Ghardaïa, l'analyse pourrait être étendue aux régions climatiques avec des conditions météorologiques semblables.

En outre, la comparaison des résultats entre le modèle du réseau de neurone artificiel (RNA) et le modèle de la régression linéaire multiple (RLM) a montré la supériorité du modèle RNA.

L'analyse de sensibilité a été réalisée comme une technique pour déterminer la contribution des variables d'entrée à la sortie en utilisant la méthode des poids de connexion. Il est à noter que les paramètres les plus importants qui peuvent influencer sur le rayonnement solaire global pour l'obtention de résultats de haute précision sont : La température ambiante, le jour, et l'humidité relative avec un IR de 15% pour la première contribution, et la pression atmosphérique et l'humidité relative avec RI = 16,40% pour la deuxième contribution.

Un programme en langage Matlab® a été développé à partir des poids synaptiques et des biais du RNSO élaboré, permettant à l'utilisateur de calculer l'irradiation solaire globale à partir de sept entrées à savoir : "le jour, le temps, la température ambiante, l'humidité relative, la vitesse moyenne du vent, la direction du vent, et la pression atmosphérique".

Comme perspectives à notre étude nous envisageons :

- D'appliquer la méthode neuronale d'autre région sous conditions climatiques algériennes pour prédire l'irradiation solaire sur des plans horizontaux et/ou inclinés.
- D'utiliser d'autres types de réseaux de neurones pour la prédiction de l'irradiation solaire globale, ou des méthodes hybrides par exemple les réseaux de neurones et les algorithmes génétiques pour assurer une bonne précision.
- D'utiliser une carte de rayonnement solaire disponible sur l'Algérie pour les applications de l'énergie solaire, car elle peut illustrer les régions optimales pour localiser les systèmes d'énergie solaire.

Références bibliographiques

Abdalla, Y.A. (1994). New correlations of global solar radiation with meteorological parameters for Bahrain. International Journal of Solar Energy 16(2) : 111-120.

Abdallah El Hadj, A., Laidi, M., Si-Moussa, C. & Hanini, S. (2015). "Novel approach for estimating solubility of solid drugs in supercritical carbon dioxide and critical properties using direct and inverse artificial neural network (ANN)", Neural Computing and Applications 28(1) : 87–99.

Abraham, A. (2005). Adaptation of fuzzy inference system using neural learning.Fuzzy systems engineering, Springer : 53-83.

Akinoğlu, B. & Ecevit, A. (1990). Construction of a quadratic model using modified Ångstrom coefficients to estimate global solar radiation. Solar Energy 45(2) : 85-92.

Al-Alawi, S. & Al-Hinai, H. (1998). An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. Renewable Energy 14(1) : 199-204.

Allen, R.G. (1997). Self-calibrating method for estimating solar radiation from air temperature. Journal of Hydrologic Engineering 2(2) : 56-67.

Almorox, J. & Hontoria, C. (2004). Global solar radiation estimation using sunshine duration in Spain. Energy Conversion and Management. 45(9) : 1529-1535.

Al-saad, M.A. (1990). Characteristic distribution of global solar radiation for Amman, Jordan. Solar and Wind Technology. 7(2-3) : 261-266.

Alsina, E.F., Bortolini, M., Gamberi, M. & Regattieri, A. (2016). Artificial neural network optimisation for monthly average daily global solar radiation prediction.Energy Conversion and Management 120 : 320–329.

Amit Kumar, Y., Hasmat, M. & Chandel, S.S. (2014). Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. Renewable and Sustainable Energy Reviews. 31 : 509–519.

Ammi, Y., Khaouane, L. & Hanini, S. (2015). Prediction of the rejection of organic compounds (neutral and ionic) by nanofiltration and reverse osmosis membranes using neural networks', Korean Journal of Chemical Engineering 32 (11) : 2300–2310.

Ampratwum, D. B. & Dorvlo, A.S. (1999). Estimation of solar radiation from the number of sunshine hours. Applied Energy 63(3) : 161-167.

Angstrom, A. (1924). Solar and terrestrial radiation. Quarterly Journal of the Royal Meteorological Society 50(210) : 121-126.

Asagha, E.N. & Udo, S.O. (2014). Predicting Global Solar Radiation using Gamma Test and Local Linear Regression Data Models in Bauchi, Nigeria. International Journal of Science and Research 3 (6) : 1375-81

Asl, S.F.Z., Karami, A., Ashari, G. & Hedayat, N. (2011). Daily global solar radiation modeling using multi-layer perceptron (MLP) neural networks. World Academy of Science, Engineering and Technology. 79 : 740-742.

Aschwanden, M. (2006). Physics of the solar corona: an introduction with problems and solutions. 2nd edition, Springer Science & Business Media.

Atashpaz-Gargari, E. & Lucas, C. (2007). Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition." Evolutionary Computation, 2007. CEC 2007. IEEE Congress on, IEEE.

Azeem, M.F. (2012). Fuzzy Inference System: Theory and Applications. InTech Publications, doi 10(5772) : 23-41.

Badescu, V. (2008). Modeling Solar Radiation at the Earth's Surface.Recent Advances. Springer Verlag. 511 p.

Bahel, V., Bakhsh, H. & Srinivasan, R. (1987). A correlation for estimation of global solar radiation. Energy 12(2) : 131-135.

Bakirci, K. (2009). Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey. Energy 34(4) : 485-501.

Bakirci, K. (2009). Models of solar radiation with hours of bright sunshine: a review. Renewable and Sustainable Energy Reviews 13(9) : 2580-2588.

Barrett, G.V., Alexander, R.A., Anesgart, M.N. & Doverspike, D. (1986). Frequently Encountered Problems in the Application of Regression-Analysis to the Investigation of Sex-Discrimination in Salaries. Public Personnel Management 15(2) : 143-157.

Behrang, M., Assareh, E., Noghrehabadi, A.R. & Ghanbarzadeh, A. (2011). New sunshine-based models for predicting global solar radiation using PSO (particle swarm optimization) technique. Energy 36(5) : 3036-3049.

Benghanem, M. (2013). Solar radiation estimated from measured air temperature: a review and proposed a new model. International Journal of Renewable Energy Technology 4(2) : 191–211.

Benghanem, M. (2012). Artificial intelligence techniques for prediction of solar radiation data: a review. International Journal of Renewable Energy Technology 3(2) : 189–220.

Benghanem, M. & Mellit, A. (2010). Radial basis function network-based prediction of global solar radiation data: application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia. Energy 35(9) : 3751-3762.

Benghanem, M., Mellit, A. & Alamri, S.N. (2009). ANN-based modelling and estimation of daily global solar radiation data: A case study. Energy Conversion and Management 50(7) : 1644-1655.

Benkaciali, S. & Gairaa, k. (2014). Modelisation de l'irradiation solaire globale incidente sur un plan incliné. Revue des Energies Renouvelables 17(2) : 245-252 .

Besharat, F., Dehghan, A.A. & Faghih, A.R. (2013). Empiricalmodels for estimating global solarradiation:Areview and casestudy. RenewableandSustainableEnergyReviews 21 : 798-821.

Bessemoulin, P. & J. Oliviéri (2000). Le rayonnement solaire et sa composante ultraviolette. La météorologie, 8(31) : 42-59.

Bilgili, M. & Ozgoren, M. (2011). Daily total global solar radiation modeling from several meteorological data. Meteorology and Atmospheric Physics. 112(3-4) : 125-138.

Bishop, C.M. (1995). Neural networks for pattern recognition. Oxford university press, London, UK.

Black, J. (1956). The distribution of solar radiation over the earth's surface. Archivfür Meteorologie, Geophysik und Bioklimatologie, Serie B 7(2) : 165-189.

Blum, C. & Roli, A. (2003). Metaheuristics in combinatorial optimization: Overview and conceptual comparison. ACM Computing Surveys (CSUR) 35(3) : 268-308.

Bouden , A. (2008) . Analyse optimisée de système de pompage photovoltaïque**.** These de doctorat, Université Mentouri, Constantine, Algérie.

Boudghene, S.A., Khiat, Z., Flazi, S. & Kitamura Y. (2012). A review on the renewable energy development in Algeria: current perspective, energy scenario and sustainability issues. Renew Sust Energy Rev. (16) : 4445 – 4460.

Box, G.E.P., Jenkins, G.M. & Reinsel, G.C. (2008). Time series analysis: forecasting and control. 4th ed. Edition Wiley. 501 p.

Cano, D., Monget, J.M., Albuisson, M., Guillard, T., Regas, H.N. & Wald, L. (1986). A method for the determination of the global solar radiation from meteorological satellite data. Solar Energy 37(1) : 31-39.

Camel-solar. (2012). Flat-Plate Solar Collector.<http://www.camel-solar.-com/cs/wp content/uploads/2012/01/flat-plate-cross-section.jpg>.

Capizzi, G., Napoli, C. & Bonanno, F. (2012). Innovative second-generation wavelets construction with recurrent neural networks for solar radiation forecasting. Neural Networks and Learning Systems, IEEE Transactions on. 23(11) : 1805-1815.

Celik, A.N. & Muneer, T. (2013). Neural network based method for conversion of solar radiation data.Energy Conversion and Management. 67 : 117–24.

Chaba Mouna, S., Hanini, S., Laidi, M., & Khaouane, L. (2017). Artificial neural networks based prediction of hourly horizontal solar radiation data: case study. International journal Applied Decision Sciences 10 (2): 156-174.

Chaba Mouna, S., Hanini, S., & Laidi, M. (2014). Modélisation numérique d'un capteur stockeur solaire. Le 3ème Séminaire internationale sur les Technologies Mécaniques Avancées à Université Abou BekrBelkaid de Tlemcen, du 08 et 09 Novembre 2014.

Chaba Mouna, S., Hanini, S., & Laidi, M. (2017). Modélisation des paramétres énergétique solaires par les réseaux de neurones artificiels. . Le 3ème conférence internationale de Mécaniques à Université Badji Mokhtar de Annaba, du 26 et 27 Avril 2017.

Chaba Mouna, S., Hanini, S., Laidi, M. & Khaouane , L. (2017). Prédiction de l'irradiation solaire horizontale par les réseaux de neurones artificiels et la régression linéaire multiple. Le Séminaire internationale de Mécaniques au Centre Universitaire Ahmed Zabana de Relizane, du 14 et 15 Novembre 2017.

Chatterjee, A. & Keyhani, A. (2012). Neural network estimation of microgrid maximum solar power.IEEE Transaction son Smart Grid . 3(4) : 1860–6.

Chen, R., Ersi, K., Yang, J., Lu, S. & Zhao, W. (2004). Validation of five global radiation models with measured daily data in China. Energy Conversion and Management 45(11) : 1759-1769.

Chegaar, M. & Chibani, A. (2001). Global solar radiation estimation in Algeria. Energy Conversion and Management. 42 : 967-973.

Cliff, M.A., Dever, M.C., Hall, J.W. & Girard, B. (1995). Development and evaluation of multiple regression models for prediction of sweet cherry liking. Food Research International. 28(6) : 583-589.

Cooper, P. (1969). The absorption of radiation in solar stills. Solar Energy. 12(3) : 333-346.

Coppolino, S. (1994). A new correlation between clearness index and relative sunshine. Renewable Energy. 4(4) : 417-423.

Coulson, K. (2012). Solar and terrestrial radiation: methods and measurements. 2nd edition, Elsevier, 334 p**.**

Cullen, A., Frey, C. & Christopher, H. (1999). Probabilistic Techniques in Exposure Assessment. Plenum Press: New York.

Daouad, A. (2013). Contrôle de la Puissance d'un Générateur Photovoltaïque pour le Pompage Solaire. These de doctorat, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, Algérie , 112 p.

Dasilva, I.N., Spatti, D.H., Flauzino, R.A., BartocciLiboni, L.H. & Reis Alves, S.F. (2016). Artificial neural networks : a practical course. Edition Springer.

Dreyfus, G., Martinez, J.M., Samuelides, M., Gordon, M.B., Badran, F., Thiria, S. & Herault, L. (2002). Réseaux de neurons : Méthodologie et applications. Eyrolles. Paris.

Duffie, J.A. & Beckman ,W.A. (1980). Solar engineering of thermal processes. 1st edition, Wiley New York etc., 919 p.

Durrant, P.J. (2001). Win Gamma TM: a non-linear data analysis and modelling tool with applications to flood prediction. Ph.D. dissertation, Department of computer science, Cardiff University, Wales, UK.

El-Metwally, M. (2005). Sunshine and global solar radiation estimation at different sites in Egypt. Journal of Atmospheric and Solar-Terrestrial Physics 67(14) : 1331-1342.

Elminir, H.K., Areed, F.F. & Elsayed, T.S. (2005). Estimation of solar radiation components incident on Helwan site using neural networks. Solar Energy 79(3) : 270-279.

Eriksson, L., Jaworska, J., Worth, A.P., Cronin, M.T.D., McDowell, R.M. & Gramatica, P. (2003). Methods for reliability and uncertainty assessment and for applicability evaluations of classification and regression based QSARs. Environmental Health Perspectives. 111 : 1361-1375.

Faceira, J., Afonso, P. & Salgado, P. (2015). Prediction of Solar Radiation Using Artificial Neural Networks. 587 Springer International Publishing: 397–406.

Fadare, D. (2009). Modelling of solar energy potential in Nigeria using an artificial neural network model. Applied Energy, 86(9) : 1410-1422.

Federico-Vladimir, G.C., Miguel-Angel, M.C., Maria-Pilar, M.R. & Maria-Teresa, M.S. (2016). Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations. Solar Energy, 134(2016) : 119–131.

Firoz, A. & Intikhab, U. (2004). Empirical Models for the Correlation of Monthly Average Daily Global Solar Radiation with Hours of Sunshine on a Horizontal Surface at Karachi, Pakistan. Turk J Phys 28(5) : 301-307.

Froehlich, C., Foukal, P.V., Hickey, J.R., Hudson, H.S. & Willson, R.C. (1991). Solar irradiance variability from modern measurements. The Sun in Time, C. P. Sonett, M. S. Giampapa, and M. S. Matthews, Eds., The University of Arizona Press : 11–29.

Garson, G.D. (1991). Interpreting neural network connection weights. Artificial Intelligence Expert 6 (7) : 47–51.

Gasser, E.H. & Mohamed, A.A. (2017). Performance evaluation of artificial neural networks in estimating global solar radiation, case study: New Borg El-arab City, Egypt. International Journal on: Environmental Science and Sustainable Development. 1(2): 7 p.

Gevrey, M., Dimopoulos, I. & Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. Ecological Modelling, 160 (3) : 249–264.

Giannis, K., Panariotis, D., Theano, I., Nikos, M. & Demetris, K. (2017). Investigation on the stochastic nature of the solar radiation process. Energy Procedia, 125 : 398- 404.

Gladius, L. (1992). An empirical relation for estimating global irradiation for Tennessee, U.S.A. Energy Conversion and Management. 33(12) : 1097-1099.

Glover, F. (1986). Future paths for integer programming and links to artificial intelligence. Computers & operations research, 13(5) : 533-549.

Glover, J. & Mc Culloch, J. (1958). The empirical relation between solar radiation and hours of sunshine. Quarterly Journal of the Royal Meteorological Society, 84(360) : 172-175.

Goetzberger, A. & Hoffmann, V.U. (2005). Photovoltaic energy generation. Springer-Verlag, Berlin/Heidelberg.

Goh, A.T.C. (1995). Back-propagation neural networks for modeling complex systems. Artificial Intelligence in Engineering, 9 (3) : 143–151.

Golbraikh, A. & Tropsha, A. (2002). Beware of q^2!. Journal of Molecular Graphics and Modelling 20(4) : 269-276.

Hamadache, M., Benkortbi, O., Hanini, S., Amrane, A., Khaouane, L. & Si Moussa, C. (2016). A quantitative structure activity relationship for acute oral toxicity of pesticides on rats: validation, domain of application and prediction. Journal of Hazardous Materials, 303 : 28–40.

Hargreaves, G. H. & Samani, Z.A. (1982). Estimating potential evapotranspiration. Journal of the Irrigation and Drainage Division, 108(3) : 225-230.

Hasni, A., Sehli, A., Draoui, B., Bassou, A. & Amieur, B. (2012). Estimating global solar radiation using artificial neural network and climate data in the south-western region of Algeria.Energy Procedia, 18 : 531–7.

Haton, J.P. & Haton, M.C. (1989). L'intelligence artificielle, Que sais-je nº2444, Presses universitaires de France.

Haykin, S. (1994). Neural networks: a comprehensive foundation. NY: Macmillan College Publishing. 696 p.

Heddam, S., Bermad, A. & Dechemi, N. (2011). Modélisation de la dose de coagulant par les systèmes à base d'inférencefloue (ANFIS) application à la station de traitement des eaux de Boudouaou (Algérie). Revue des sciences de l'eau, 25(1) : 1-19.

Halawa, E., Ghaffarian Hoseini, A., & Hin Wa Li, D. (2014) . Empirical correlations as a means for estimating monthly average daily global radiation: a critical overview . Renewable Energy. 72: 149–153.

Hay, J. E. (1979). Calculation of monthly mean solar radiation for horizontal and inclined surfaces. Solar Energy 23(4): 301-307.

Hirsch, R. L., Bexdek, R. & Wendling, R. (2010). Peaking of World Oil Production and Its Mitigation. Driving Climate Change: Cutting Carbon from Transportation: 9.

Hocaoğlu, F.O. (2011). Stochastic approach for daily solar radiation modeling. Solar Energy. 85(2): 278–287.

Holland, J.H. (1975). Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence.", U Michigan Press.

Homer, E.N. (2011). Beyond the Atmosphere: Early Years of Space Science (The NASA historical series). Kindle Edition. 657 p.

Honsberg, C. & Bowden, S. (2009). PVCDrom. Disponiblesur http://pvcdrom. pveducation. org/index. html.

Hopfield, J.J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. Proceedings of the National Academy of Sciences, 79 : 2554-2558.

Hopfield, J.J. (1984). Neurons with Graded Response Have Collective Computational Properties like Those of Two-State neurons. Proceedings of the National Academy of Sciences, 81 : 3088-3092.

IEA. (2013). Key World Energy Statistics. International energy agency technical report.

Inman, R.H., Pedro, H.T. & Coimbra, C.F. (2013). Solar forecasting methods for renewable energy integration. Prog Energy Combust Sci. 39(6) : 535–76.

Iqbal, M. (2012). An introduction to solar radiation. Elsevier,Amsterdam, 390 p.

Jain, P. (1986). Global irradiation estimation for Italian locations. Solar & wind technology, 3(4): 323-328.

Jang, J.S.R. (1993). ANFIS : Adaptative-Network-Based Fuzzy Inference System. IEEE Trans on Systems, Man and Cybernetics.

Jang, J.S.R., Sun, C.T. & Mizutani, E. (1997). Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. 1st edition, Pearson, New jersey, USA. 614 p.

Jenkins, J.L. (2013). Observing the Sun : A Pocket Field Guide (Astronomer's Pocket Field Guide).Springer New York. 242 p.

Jin, Z., Yezheng, W. & Gang, Y. (2005). General formula for estimation of monthly average daily global solar radiation in China. Energy Conversion and Management, 46(2) : 257-268.

Kalogirou, S.A. (2009). Solar Energy Engineering Processes and Systems, 1st ed., Academic Press, USA.

Kaltschmitt, M., Streicher, W. & Wiese, A. (2007). Renewable energy: technology, economics and environment. Springer Science & Business Media, 564 p.

Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization, Technical report-tr06, Erciyes university, engineering faculty, computer engineering department.

Karlsson, K.G., Riihelä, A., Müller , R., Meirink, J.F., Sedlar , J., Stengel , M., Lockhoff, M., Trentmann , J., Kaspar, F., Hollmann, R. & Wolters, E. (2013). CLARA-A1: a cloud, albedo, and radiation dataset from 28 yr of global AVHRR data. Atmospheric Chemistry and Physics, 13(10) : 5351-5367.

Katiyar, A.K. & Pandey, C.K. (2010). Simple correlation for estimating the global solar radiation on horizontal surfaces in India. *Energy*, 35(12) : 5043-5048.

Kennedy, J. & Eberhart,R. (1942). Particle swarm optimization. u: Proc. IEEE Int. Neural Networks, Perth, Australia, str 1948.

Kerr, A. & Tabony, R. (2004). Comparison of sunshine recorded by Campbell–Stokes and automatic sensors. Weather, 59(4) : 90-95.

Keller, B. & Costa, A.M.S. (2011). A Matlab GUI for calculating the solar radiation and shading of surfaces on theearth. Computer Applications in Engineering Education, 19(1) : 161-170.

Khaouane, L. (2013). Etude et Modélisation de la Biosynthèse des Antibiotiques à partir de Différentes Souches Productrices – Cas de Pleuromutiline.Thèse de doctorat. Université de Médéa. Médéa. Algérie.

Khatib, T., Mohamed, A. & Sopian, K. (2012). Areview of solar energy modeling techniques .Renewable and Sustainable Energy Reviews.16 : 2864–9.

Koca, A., Oztop, H.F., Varol, Y. & Koca, G.O. (2011). Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of AnatoliainTurkey.Expert Systems with Applications. 38 : 8756–62.

Kurtgoz, Y. & Deniz, E.E. (2016). Global solar radiation estimation using artificial neural network by the addition of nearby meteorological stations.solar radiation data and exergy of solar radiation: a case study. International Journal of Energy, 21(3) : 315–330.

Laidi, M., Hanini, S., Rezrazi, A., Yaiche, M.R,. Abdallah El Hadj, A.A. &Chellali, F. (2016). Supervised artificial neural network-based method for conversion of solar radiation data (case study: Algeria). Theoretical and Applied Climatology : 1–13.

Laidi, M. (2013) . Etude et modelisation d'un refrigerateur solaire.These de doctorat, Université de Médea.

Lazzús, J.A., Pérez Ponce, A.A. & Marín , J. (2011). Estimation of global solar radiation over the City of La Serena (Chile) using a neural network. Applied Solar Energy, 47(1) : 66-73.

Lee, Y., Hoon, S.O.H & WonKim, M. (1991). The effect of initial weights on premature saturation in Back-propagation Learning**.**international joint conference on Neural Networks, 1 : 765-770.

Li, H., Ma, W., Lian, Y., Wang ,X. & Zhao, L. (2011). Global solar radiation estimation with sunshine duration in Tibet, China. Renewable Energy, 36(11) : 3141-3145.

Linares-Rodríguez, A., Ruiz-Arias, J.A., Pozo-Vázquez, D. & Tovar-Pescador, J. (2011). Generation of synthetic daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks. Energy, 36(8) : 5356-5365.

Liou, K.N. (2002). An introduction to atmospheric radiation. Academic press.

Loghmari, I., Timoumi, Y. & Messadi, A. (2017). Performance comparison of two global solar radiation models for spatial interpolation purposes. Renewable and Sustainable Energy Reviews, 82 (2018) : 837–844.

Lopez,G., Martinez, M., Rubio, M.A., Torvar, J., Barbero, J. & Batlles, F.J. (2000)(a). Estimation de la radiation global solardianamediante un modelo de red neural. Proceedings of the Congresolbenco de Energia Solar, III JornadasTecnicassobreBiomasa, Spain: 115- 118.

Lopez, G., Martinez, M., Rubio, M.A., Tovar, J., Barbero, J. & Batlles F.J. (2000)(b). Estimation of hourly diffuse fraction using a neural network model. Instituto Geofisico do Infante, Luis D editors. 2nd Asamblea Hispano Portuguesa de Geodesia y Geofisica, Lagos, Portugal: 425-426.

Maitha, H., Al-Shamisi, A., Ali, H., Assi, B., Hassan, A.N. & Hejase, A. (2013). Artificial neural networks for predicting global solar radiation in al ain city – uae. International Journal of Green Energy, 10(5) : 443-456.

Manjubala, B. & Neeraj, K.G. (2015). Prediction of software inter-failure times using artificial neural network and particle swarm optimisation models, International Journal of Software Engineering, Technology and Applications, 1(2–4) : 222–244.

Markvart, T. & Castafier, L. (2003). Practical handbook of photovoltaics: fundamentals andapplications. Elsevier Science Ltd.

Matyas, J. (1965). Random optimization. Automation and Remote control ,26(2) : 246-253.

Mc Cleland, J.L. & Rumelhart, D,E. (1986). A distributed model of human learning and memory. Journal of experimental psychology, 114 : 159-188.

Mc Culloch, W.S. & Pitts, W.H. (1943). A logical calculus of the immanent in nervous activity. Bulletin of Mathematical biophysics, 5 : 115-133.

Medsker, L.R. (1995). Hybrid intelligence systems. Edition springer.

Medsker, L.R. (1996). Microcomputer applications of hybrid intelligent systems. Journal of Network and Computer applications, 19(2) : 213-34.

Mehdi, S., Dawood, S.J. & Parisa, B. (2016). Estimation of hourly global solar irradiation on tilted absorbers from horizontal one using Artificial Neural Network for case study of Mashhad. Renewable and Sustainable Energy Reviews, 53 : 59–67.

Mehleri, E.D., Zervas, P.L., Sarimveis, H., Palyvos, J.A. & Markatos, N.C. (2010). Determination of the optimal tiltangle and orientation for solar photovoltaic arrays.Renewable Energy: 35 : 2468–75.

Mellit, A. (2008). Artificial Intelligence technique for modelling and forecasting of solar radiation data: a review. International Journal of Artificial Intelligence and Soft Computing, 1(1) : 52–76.

Mellit, A., Kalogirou, S.A., Hontoria, L. & Shaari, S. (2009). Artificial intelligence techniques forsizing PV systems : a review. Renew Sustain Energy Rev. 13: 406-419.

Mellit, A. & Pavan, A.M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. Solar Energy, 84(5) : 807-821.

Mellit, A., Eleuch, H., Benghanem, M., Elaoun, C. & Pavan, A.M . (2010) . An adaptive model for predicting of global, direct and diffuse hourly solar irradiance. Energy Conversion and Management . 51 : 771–782.

Meziani, F.(2012). Détermination du gisement solaire par traitement d'images MGS. These de Magister , Université de Tizi Ouzou.

Ministère de l'énergie et des Mines (2011). Programme des énergies renouvelables et de l'efficacité énergétique . Disponible sur www.mem-algeria.org.

Moghaddamnia, A., Remesan, R., Hassanpour Kashani, M., Mohammadi, M., Han, D. & Piri, J. (2009). Comparison of LLR, MLP, Elman, NNARX and ANFIS Models—with a case study in solar radiation estimation. Journal of Atmospheric and Solar-Terrestrial Physics, 71(8) : 975-982.

Mohandes, M.A. (2012). Modeling global solar radiation using Particle Swarm Optimization (PSO). Solar Energy, 86(11) : 3137-3145.

Muhammed, A., Hassan, A., Khalil, S., Kaseb, M. & Kassem, A. (2017). Potential of Four Different Machine-Learning Algorithms in Modeling Daily Global Solar Radiation. Renewable Energy. Doi: 10.1016/j.renene..03.083

Nait Mensour, O., Bouaddi, S., Abnay, B., Hlimi, B. & Ihlal, A. (2017). Mapping and Estimation of Monthly Global Solar Irradiation in Different Zones in Souss-Massa Area, Morocco, Using Artificial Neural Networks. International Journal of Photoenergy 2017 : 19 p.

Navarro, J.M. (2008). Cellules photovoltaïquesorganiquestransparentesdans le visible. Thèse de doctorat,Université Toulouse III, 104 p.

Notton, G., Paoli, C., Vasileva, S., Nivet, M.L., Canaletti, J. & Cristofari, C. (2012). Estimation of hourly global solar irradiation on tilted planes from horizontal one using artificial neural networks.Energy, 39 : 166–79.

OBG (2013). The Report: Algeria 2013., Oxford Business Group.

Ögelman, H., Ecevit, A. & Tasdemiroğlu, E. (1984). A new method for estimating solar radiation from bright sunshine data. Solar Energy, 33(6) : 619-625.

Ojosu, J. & Komolafe, L. (1987). Models for estimating solar radiation availability in South Western Nigeria. Nigerian Journal of Solar Energy, 16(69) : 378-390.

Olatomiwa, L., Mekhilef, S., Shamshirband, S. & Petković, D. (2015). Adaptive neuro-fuzzy approach for solar radiation prediction in Nigeria. Renewable and Sustainable Energy Reviews. 51(C): 1784–1791.

Oskouei, A.B., Banaei, M.R., & Sabahi, M. (2015). Hybrid PV/wind system with quinary asymmetric inverter without increasing DC-link number. Ain Shams Engineering Journal, 7(1) : 579-592.

Ouammi, A., Zejli, D., Dagdougui, H. & Benchrifa, R. (2012). Artificial neural network analysis of Moroccan solar potential.Renewable and Sustainable Energy Reviews, 16 : 4876–89.

Oumbe, A. (2009). Exploitation des nouvelles capacités d'observation de la Terre pour évaluer le rayonnement solaire incident au sol. P.hD Thesis, MINES ParisTech.

Pados, D. A., Papantoni-Kazakos, P. A. (1994). Note on estimation of the generalization error and the prevention of overfitting. Proceeding of IEEE International Conference on Neural Networks USA, 1: 321-326.

Paulescu, M., Paulescu, E., Gravila, P . & Badescu, V. (2012). Weather modeling and forecasting of PV systems operation. Green Energy and Technology, : 17-42.

Pavlov , A.V. (2016) . Influence of Atmospheric Solar Radiation Absorption on Photodestruction of Ions at D-Region Altitudes of the Ionosphere. SurvGeophys.

Perez, R., Ineichen, P., Moore, K., Kmiecik, M,. Chain, C., George, R. & Vignola, F. (2002). A New Operational Satellite-to-Irradiance Model--Description and Validation., proceedings of the solar conference, American solar energy society; American institute of architects.

Pham, D.T., Ghanbarzadeh, A., Koc, E., Otri, S., Rahim, S. & Zaidi, M . (2006). The Bees Algorithm–A Novel Tool for Complex Optimisation. Intelligent Production Machines and Systems-2nd I* PROMS Virtual International Conference 3-14 July 2006, Elsevier, : 454-459.

Polo, J., Zarzalejo, L.F. & Ramírez, L. (2008). Solar radiation derived from satellite images. Modeling Solar Radiation at the Earth's Surface, Springer, : 449-462.

Poole, D.L., Mackworth, A. & Goebel, R. (1998). Computational intelligence: a logical approach. Oxford University Press, New York, 576 p.

Premalatha, N., Valan, A. & Amir, T. (2016). Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. Journal of Applied Research and Technology, 14 : 206–214.

Prescott, J. (1940). Evaporation from a water surface in relation to solar radiation. Transactions of the Royal Society of South Australia, 64(1) : 114-118.

Quaschning, V. (2005). Understanding renewable energy systems. Earthscan.

Rahimi Khoob, A. (2010). Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment.Renewable Energy, 35(9) : 2131-2135.

Rajiv, G. & Saurabh, S. (2016). Prediction of Global Solar Radiation in India using Artificial Neural Network. Journal of Sustainable Development of Energy. Water and Environment Systems, 4(2) : 94-106

Rao, S.S. (2009). Engineering optimization: theory and practice. 4th edition, John Wiley & Sons, 840 p.

Remesan, R., Shamim, M.A. & Han, D. (2008). Model data selection using gamma test for daily solar radiation estimation. Hydrological processes, 22(21) : 4301-4309.

Rezrazi, A., Hanini, S. & Laidi, M. (2016). An optimisation methodology of artificial neural network models for predicting solar radiation: a case study.Theoretical and Applied Climatology,123(3) : 769–783.

Rezrazi, A. (2016). Contribution à la modélisation de l'irradiation solaire. These de doctorat, Université de Médea.

Rigollier, C., Lefèvre, M. & Wald, L. (2004). The method Heliosat-2 for deriving shortwave solar radiation from satellite images. Solar Energy, 77(2) : 159-169.

Riolet, E. (2008). L'énergie solaire et photovoltaique pour le particulier. Eyrolles, paris, France, 123 p.

Russell, S., Norvig, P. & Intelligence, A (1995). A modern approach. Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs, 905 p.

Said, R., Mansor, M. & Abuain, T. (1998) . Estimation of global and diffuse radiation at Tripoli. Renewable Energy, 14(1) : 221-227.

Salby, M.L. (1996). Fundamentals of Atmospheric Physics. Academic Press, New York, 624 p.

Sarkhosh, M., Ghasemi, J.B. & Ayati, M. (2012). A quantitative structure- property relationship of gas chromatographic/mass spectrometric retention data of 85 volatile organic compounds as air pollutant materials by multivariate methods. Chem Cent J, v6.

Sen, Z. (1998). Fuzzy algorithm for estimation of solar irradiation from sunshine duration. Solar Energy, 63(1) : 39-49.

Sen, Z. (2008). Solar energy fundamentals and modeling techniques: atmosphere, environment, climate change and renewable energy. Springer Science & Business Media, Istanbul, turkey, 276 p.

Şenkal, O., Şahin, M. & Peštemalci, V. (2010). The estimation of solar radiation for different time periods.Energy Sources,Part A, 32 : 1176–84.

Shah-Hosseini, H. (2011). Principal components analysis by the galaxy-based search algorithm: a novel metaheuristic for continuous optimisation. International Journal of Computational Science and Engineering, 6(1-2) : 132-140.

Shamim, A., Hassan, M.U., Yousaf, A., Iqbal, M.F., Zafar, M.A., Siddique, R.M. & Abubakar, M. (2015). Occurrence and identification of Emeriaspecies in broiler rearing under traditional system. J. Anim. Sci. Technol, 57: 41 p.

Shanmuga, S.P. & Mohammad, H.I. (2015). Solar Radiation Prediction using Artificial Neural **Network.** International Journal of Computer Application,.116(16) : 28-31.

Shi, Y. & Eberhart, R. (1998). A modified particle swarm optimizer. Evolutionary Computation Proceedings, 1998. IEEE World Congress on Computational Intelligence. The 1998 IEEE International Conference on, IEEE.

Sick, F. & T. Erge (1996). Photovoltaics in buildings: a design handbook for architects and engineers. IEA, James & James Ltd, London, 288 p.

Si-Moussa, C., Hanini, S., Derriche, R., Bouhedda, M. & Bouzidi, A. (2008). Prediction of high-pressure vapor liquid equilibrium of six binary systems, carbon dioxide with six esters, using an artificial neural network model.Brazilian Journal of Chemical Engineering, 25 (1) : 183–199.

Solargis. (2016). Disponible depuis http://solargis.com/products/maps-and-gis-data/free/download/world.

Solanki, C.S. (2015). Solarphotovoltaics: fundamentals, technologies and applications. 3rd edition, PHI Learning Pvt. Ltd. Delhi, 506 p.

Solomon, S., Qin, D., Manning, M., Chen, Z., Marquis, M., Averyt, K.B., Tignor, M. & Miller, H.L. (2007). Contribution of working group I to the fourth assessment report of the intergovernmental panel on climate change, Cambridge University Press, Cambridge. United Kingdom and New York, NY, USA, 996 pp.

Spencer, J. (1971). Fourier series representation of the position of the sun. Search, 2(5) : 172-172.

Su, J., Song, B. & Li, B. (2009). A Hybrid Algorithm of GA Wavelet-BP Neural Networks to Predict Near Space Solar Radiation. Advances in Neural Networks–ISNN 2009, Springer: 442-450.

Subiyanto, S., Azah, M. & Hussain. S. (2012). Intelligent maximum power point tracking for PV system using Hopfield neural network optimized fuzzy logic controller. Energy and Buildings, 50 : 29-38.

Sulafa, H.E. (2014). Artificial neural networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan. Alexandria EngJ, 53 : 655 –662

Swartman, R. & Ogunlade, O. (1967). Solar radiation estimates from common parameters. Solar Energy, 11(3) : 170-172.

Syndicat des énergies renouvelables (2012). Principe de fonctionnement du solaire thermodynamique. Paris.

Talebi, A., Molaeiet, M.A., & Sheikh, M.J. (2010). Performance investigation and comparison of two evolutionary algorithms in portfolio optimization: Genetic and particle swarm optimization. Information and Financial Engineering (ICIFE), 2nd IEEE International Conference on, IEEE.

Taylor, B.C., Stott, J.L., Thurmond, M.A. & Picanso, J.P. (1992). Alteration in lymphocyte subpopulations in bovine leukosis virus-infected cattle.VetImmunolImmunopathol, 31(1-2) : 35-47.

Thomas, M. (2014). Caractérisation de panneaux solairesphotovoltaïques en conditions réelles d'implantation et en fonction des différentes technologies. Thèse de doctorat, Université de Paris : 1-194.

Tolabi, H.B., Moradi, M.H., Ayob, S.B. M. & Zandebasiri, M. R. (2013). New Technique for Global Solar Radiation Prediction using Imperialist Competitive Algorithm. J. Basic. App. Sci. Res, 3(3) : 958-964.

Touzet, C. (1992). Les réseaux de neuronesartificiels : introduction au connexionnisme, cours et exercices.EC2, Collection de l'EERIE, 126 p.

Trieb, F. (2005). Concentrating Solar Power for the Mediterranean Region. MED-CSP; Final Report, DLR.Berlin, disponible à www.dlr.de/tt/med-csp.

Uddina, K., Goughb, R., Radcliffec, J., Marcoa, J. & Jenningsa, P. (2017). Techno-economicanalysis of the viability of residentialphotovoltaicsystemsusing lithium-ion batteries for energystorage in the UnitedKingdom. Applied Energy, 206 : 12-21.

Ulgen, K. & Hepbasli, A. (2002). Comparison of solar radiation correlations for İzmir, Turkey. International Journal of Energy Research, 26(5) : 413-430.

Vakili, M., Sabbagh-Yazdi, S.R., Khosrojerdi, S. & Kalhor, K. (2016). Evaluating the effect of particulate matter pollution on estimation of daily global solar radiation using artificial neural network modeling based on meteorological data. Journal of Cleaner Production.

Vakilia, M., Saeed, R., Sabbagh, Y., Koosha, K. & Soheila, K. (2015). Using Artificial Neural Networks for Prediction of Global Solar Radiation in Tehran Considering Particulate Matter Air Pollution. Energy Procedia, 74 : 1205 – 1212

Vignola, F., Vignola, J.M. & Thomas, S. (2012). Solar and infrared radiation measurements. CRC Press, Taylor and Francis Group, Boca Raton, FL, 394 p.

Viridiselec (2011). Disponible depuishttp://www.viridiselec.com/m-77-fonctionnement.html.

Voyant, C., Muselli, M., Paoli, C. & Nivet, M. (2011). Optimization of an artificial neural network dedicated to the multivariate for ecasting of daily global radiation. Energy, 36 : 348–59.

Voyant, C ., Musell, M., Paoli, C. & Laure Nivet, M. (2012). Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. Energy. 39(1) : 341-355.

Wang, Z., Wang, F. & Su, S. (2011). Solar irradiance short-term prediction model based on BP neural network. Energy Procedia, 12 : 488-494.

William, W.N.(2015) . Vers une methode automatique d'estimation de la distribution spectrale du rayonnement solaire. Cas du ciel clair. Applications a la lumiere du jour,photosynthese et ultraviolet. These de doctorat, université de Paris : 1-132.

Witek-Krowiak, A., Chojnacka, K., Podstawczyk, D., Dawiec, A. & Pokomeda, K. (2014). Application of response surfacemethodology and artificial neural network methods in modeling and optimization of biosorption process. Bioresour Technol.

WMO (1983). Guide to meteorological instruments and methods of observation. 5th edition, Secretariat of the World Meteorological Organization, Geneva, Switzerland, 358 p.

Yacef, R., Benghanem, M. & Mellit, A. (2012). Prediction of daily global solar irradiation data using Bayesian neural network: a comparative study. Renewable Energy, 48 : 146-154.

Yacef, R., Mellit, A., Belaid, S. & Sen, Z. (2014). New combined models for estimating daily global solar radiation from measured air temperature in semi-arid climates: application in Ghardaïa, Algeria. Energ Convers Manage, (79) : 606 – 615.

Yaiche, M.R., Bouhanik, A., Bekkouche, S.M. A., Malek, A. & Benouaz, T. (2014). Revised solar maps of Algeria based on sunshine duration. Energy Conversion and Management, (82): 114-123.

Yildiz, B.Y., Şahin, M., Şenkal, O., Pestemalci, V. & Emrahoğlu, N.A. (2013). Comparison of two solar radiation models using artificial neural networks and Remote sensinginTurkey.Energy Sources,Part A, 35 : 209–17.

Younas, W., Eshetie, B. & Ondrej, K. (2016) . Global Solar Radiation Prediction Using Backward Propagation Artificial Neural Network for the City of Addis Ababa, Ethiopia. International Conference on Computational Collective Intelligence.

Yousefinejad, S. & Hemmateenejad, B. (2015). Chemometrics tools in QSAR/QSPR studies: A historical perspective.Chemometrics and Intelligent Laboratory Systems.

Zelenka, A., Perez, R., Seals, R. & Renné, D. (1999). Effective accuracy of satellite-derived hourly irradiances. Theoretical and applied climatology, 62(3-4) : 199-207.