

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE



Université 20 Août 1955 Skikda
Faculté des Sciences
Département des Sciences Agronomiques



Filière : Sciences Agronomiques
Option : Aménagement Hydro-Agricole

Mémoire de fin d'études :

En vue de l'obtention du diplôme de Master II en Aménagement Hydro-Agricole

Thème

*Modélisation de la Radiation Solaire (RS) par les Algorithms du
Machine Learning : Développement Sur les plates Forme
Anaconda & Spyder et R-Studio.*

Présenté par :

Ouatouat Sara
Boulemtafes Wissam
Bouleklouk Fatma Zohra
Meksen Maroua

Membres de Jury:

Dr : KHALFAOUI Abdelhakim	(MCA)	Président	Université du 20 Août 1955- Skikda
Mr : SAADOUNE Abdelaziz	(MAA)	Examineur	Université du 20 Août 1955 - Skikda
Pr : HEDDAM Salim	(Pr.)	Promoteur	Université du 20 Août 1955 - Skikda

Année universitaire : 2024/2025



Dédicace I

Je dédie ce modeste travail en signe de reconnaissance et de respect :

. A ma mère et mon père pour tous les sacrifices qu'ils ont consenti à mon égard, et pour

qui le mot éducation veut dire : respect, droiture, morale, honneur et sens

du devoir

. A mon frères : abdou et wael, akram et khalil

.A Mes amis par tous, en particuliers : jihan ; hadil ,nihad ;chams.manel

et ma sœur djihan sghayra

.A Mes tantes pour tout le soutien

Ouatouat Sara



Dédicace2

Je dédie ce modeste travail A tous ceux qui me connaissent, en particulier,

A mon mère et à la mémoire de ma père

A mes frères : Amin et Azou

A tous mes amis et collègues.

Sans oublier tous les professeurs qui ont contribué à ma formation de l'enseignement

primaire, jusqu'à l'enseignement supérieur.

Boulemtafes Wissam



Dédicace3 :

Je dédie ce travail à mes parents,

Que Dieu les garde près de moi, à mes

Frères et sœurs, à mes amis et collègues,

Et à tous ceux qui me connaissent,

*Sans oublier le rassemblement des enseignants qui ont contribué à ma formation au
primaire, niveaux moyen et secondaire jusqu'à l'enseignement supérieur.*

Bouleklouk Fatma Zohra



Dédicace4

Je dédie ce travail de recherche pour celui qui m'a appris le sens de la vie mon père et à la

source de l'amour ma mère

Je dédie à mes chères frères et mes chères sœurs

A tous mes amies et ma grande famille

Puisse DIEU vous donne bonheur et réussite, bon santé.

Meksen Maroua

Remerciements

Nous tenons à remercier très vivement monsieur HEDDAM Salim qui nous a fait l'honneur d'accepter d'être notre promoteur pour le projet de fin cycle Master II, et qui nous a conseillé et orienté avec une grande modestie, et aussi pour son suivi tout au long de la réalisation de ce mémoire.

Nous n'omettrons pas de remercier aussi monsieur le président et les membres de jury Pour l'honneur qu'ils nous font d'avoir bien accepté de juger et d'apprécier ce travail

ملخص

ازداد الاعتماد على نماذج الذكاء الاصطناعي (ANN) بشكل ملحوظ في السنوات الأخيرة، حيث توسعت تطبيقاتها لتشمل مختلف جوانب الحياة اليومية. في مجال الري والعلوم الزراعية، بات استخدام نماذج الذكاء الاصطناعي ضرورة حتمية لتطوير حلول فعالة وتقدير إشعاع الشمس بدقة. تهدف هذه الدراسة التي تدخل ضمن إطار تحضير مذكرة تخرج في ماستر التهيئة المائية الفلاحية، إلى تطبيق نماذج الذكاء الاصطناعي واقتراح حلول بديلة لتطوير نماذج رياضية لحساب إشعاع الشمس. قمنا باستعمال نموذجان من الشبكات العصبية الاصطناعية وهما: (i) الشبكة العصبية المتعددة الطبقات (MLPNN)، (ii) شبكة الانحدار العصبي المعمم (GRNN) و (iii) نموذج الانحدار الخطي (MLR). من أجل تطوير النماذج الرياضية استعملنا معطيات مناخية تخص أربع محطات وهي: باتنة، بسكرة، الجلفة، الشلف وعلى مستوى كل محطة قمنا بجمع بيانات يومية تمتد على طول مرحلة عشر سنوات (2004-2013) وتحتوي على البيانات التالية: (1) درجة الحرارة القصوى (T_{max})، (2) درجة الحرارة الدنيا (T_{min})، (3) سرعة الرياح (U_2)، (4) الرطوبة النسبية ($H\%$)، (5) المطر (P)، والتي استعملت كمدخل لنمذجة الإشعاع الشمسي (SR). قسمت قاعدة البيانات الي قسمين: 70% من أجل تطوير و تدريب النموذج 30% من أجل تقييم قدرة النموذج على التنبؤ الصحيح بالإشعاع الشمسي اليومي. قمنا باستعمال مجموعة من معايير التحقق الاحصائي والتي هي: معامل الارتباط (R)، معامل كفاءة ناش (NSE)، متوسط الخطأ المطلق (MAE)، والجذر التربيعي لمربع الخطأ ($RMSE$). من أجل التعرف على تأثير مختلف المتغيرات المناخية على استجابة النموذج الرياضي، قمنا بالمقارنة ما بين 12 نموذج بتشكيلات مختلفة للمتغيرات المناخية. أثبتت النتائج المتحصل عليها قدرة الشبكات العصبية الاصطناعية على حساب الإشعاع الشمسي بدقة ممتازة وتجاوزت نموذج الانحدار الخطي وكانت الحسابات ذات دقة تنبؤيه عالية وصل معامل الارتباط R و معامل كفاءة NSE 0,87 و 0,76 (أحسن نموذج). تعتبر النتائج المتحصل عليها جد مشجعة وتفتح آفاق مستقبلية واعدة.

الكلمات المفتاحية:

الإشعاع الشمسي، نماذج الذكاء الاصطناعي، محطات مناخية، متغيرات مناخية، درجة الحرارة، سرعة الرياح، الرطوبة النسبية، الإشعاع الشمسي.

Résumé

L'utilisation des modèles d'intelligence artificielle (IA) a considérablement augmenté ces dernières années, avec une expansion de leurs applications pour inclure divers aspects de la vie quotidienne. Dans le domaine de l'agriculture et des sciences agricoles, l'utilisation des modèles d'IA est devenue une nécessité incontournable pour développer des solutions efficaces et estimer précisément certaines variables notamment le rayonnement solaire. Cette étude entre dans le cadre de la préparation de mémoire de master en aménagement Hydro-Agricole, vise à appliquer des modèles d'IA et à proposer des solutions alternatives pour développer des modèles mathématiques pour calculer le rayonnement solaire. Nous avons utilisé deux modèles de réseaux de neurones artificiels : (i) le réseau de neurones multicouches (MLPNN), (ii) le réseau de neurones à régression généralisé (GRNN), ainsi que (iii) le modèle de régression linéaire multiple (MLR). Pour développer les modèles mathématiques, nous avons utilisé des données climatiques provenant de quatre stations : Batna, Biskra, Djelfa, and Chlef. Pour chaque station, nous avons collecté des données quotidiennes sur une période de dix ans (2004-2013) comprenant : (1) la température maximale (T_{\max}), (2) la température minimale (T_{\min}), (3) la vitesse du vent (U_2), (4) l'humidité relative ($H\%$), (5) les précipitations (P), et le rayonnement solaire (SR) qui a été utilisé comme variable à modéliser. La base de données a été divisée en deux parties : 70 % pour le développement et l'entraînement du modèle, et 30 % pour évaluer la capacité du modèle à prédire correctement le rayonnement solaire quotidien. Nous avons utilisé plusieurs critères de validation statistique, notamment le coefficient de corrélation (R), le coefficient de Nash-Sutcliffe efficacité (NSE), la moyenne des erreurs absolues (MAE), et la racine carrée de l'erreur quadratique moyenne ($RMSE$). Pour évaluer l'impact des différentes variables climatiques sur la réponse du modèle mathématique, nous avons comparé douze modèles avec différentes combinaisons de variables climatiques. Les modèles obtenus ont démontré la capacité des réseaux de neurones artificiels à calculer avec une excellente précision le rayonnement solaire, dépassant le modèle de régression linéaire. Les prévisions étaient hautement précises avec des coefficients R et des coefficients NSE atteignant respectivement 0.87 et 0.76 (meilleur modèle). Les résultats obtenus sont très encourageants et ouvrent des perspectives prometteuses pour l'avenir.

Mots-Clés.

Rayonnement solaire, modèles d'intelligence artificielle, GRNN, MLPNN, MLR stations climatiques, variables climatiques, température, vitesse du vent, humidité relative, rayonnement solaire.

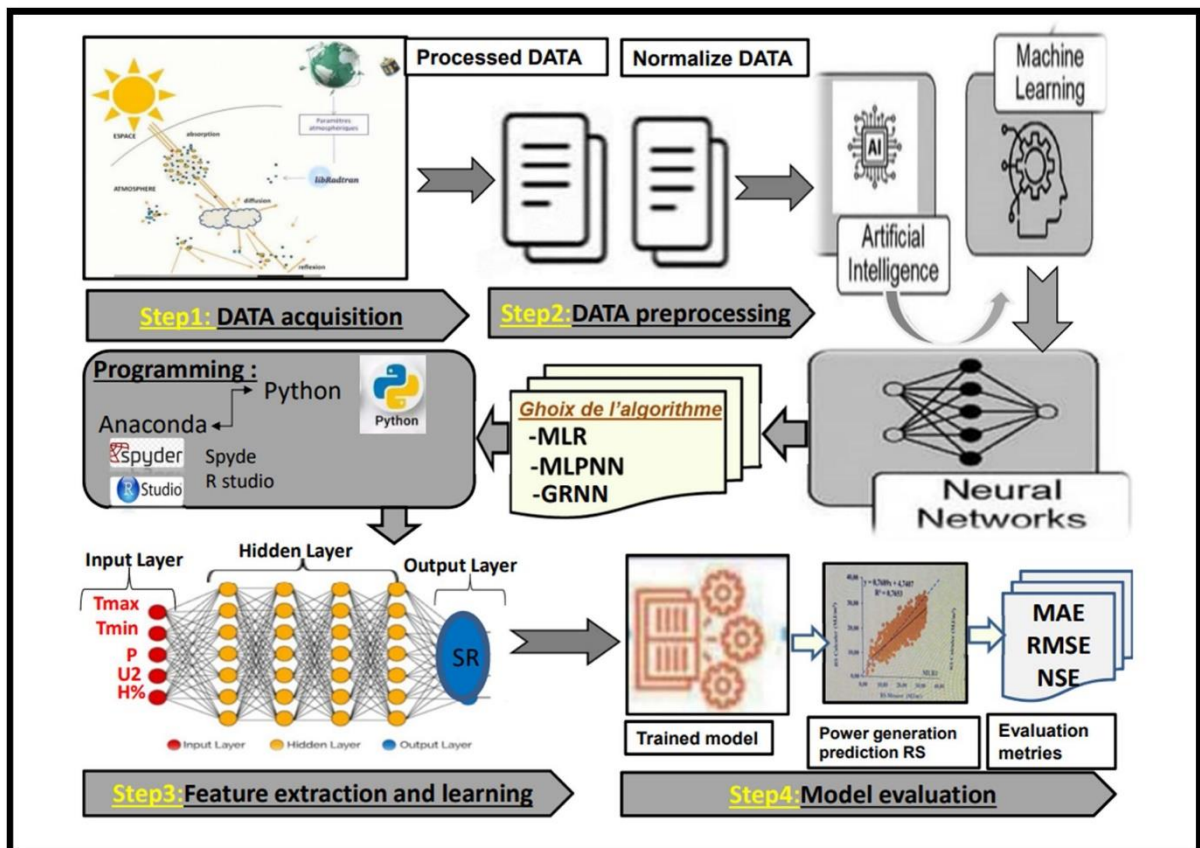
Abstract

There has been a growing importance on artificial intelligence models (AI) in recent years, with their applications expanding to encompass various aspects of daily life. In the field of irrigation and agricultural sciences, the use of artificial intelligence models has become an inevitable necessity for developing effective solutions and accurately estimating solar radiation. This study, as part of preparing a master's thesis degree in agricultural water management, aims to apply artificial intelligence models and propose alternative solutions for developing mathematical models to calculate solar radiation. We used two artificial neural network models: (i) Multilayer Perceptron Neural Network (MLPNN), (ii) Generalized Regression Neural Network (GRNN), and (iii) Multiple Linear Regression (MLR) model. To develop the mathematical models, we used climate data from four stations: Batna, Biskra, Djelfa, and Chlef. For each station, we collected daily data over a ten-year period (2004-2013) including: (1) maximum temperature (T_{\max}), (2) minimum temperature (T_{\min}), (3) wind speed (U_2), (4) relative humidity ($H\%$), (5) precipitation (P), which were used as an input for modeling solar radiation (SR). The database was divided into two parts: 70% for model development and training, and 30% for evaluating the model's ability to correctly predict daily solar radiation. We used a set of statistical validation criteria, including the correlation coefficient (R), The Nash–Sutcliffe efficiency (NSE), mean absolute error (MAE), and root mean square error (RMSE). To understand the effect of different climatic variables on the response of the mathematical model, we compared 12 models with different combinations of climatic variables. The obtained results demonstrated the ability of artificial neural networks to accurately calculate solar radiation, surpassing the linear regression model. The predictions were highly accurate with R and NSE reaching the values of 0.87 and 0.76, respectively, for the best model. The results obtained are very encouraging and open promising future prospects.

Keywords

Solar radiation, artificial intelligence models, GRNN, MLPNN, climate stations, climatic variables, temperature, wind speed, relative humidity, solar radiation.

GRAPHICAL ABSTRACT



Liste des figures

<u>Chapitre I :</u>	
Figure I.1. Radiation solaire direct et diffuse	05
Figure I.2. Pyrhéliomètre et Pyranomètre ombré	06
Figure I.3. Exemples de captures par ordre croissant de complexité de l'instrumentation et donc du niveau de détail de la caractérisation du rayonnement solaire	06
Figure I.4. photosynthèse des plantes	08
Figure I.5. cycle hydrologique	09
Figure I.6. Combinaison d'un anémomètre avec une girouette	10
Figure I.7. Hygromètre	10
Figure I.8. Thermomètre	11
Figure I.9. Exemple pluviomètre (pluviomètre de Hellmen)	12
Figure I.10. l'évaporation	12
Figure I.11. l'évapotranspiration	13
<u>Chapitre II :</u>	
Figure II.1. Situation géographique de la zone d'étude	16
Figure II.2. Matrice de corrélation pour les différentes stations climatiques.	19
Figure II.3. . Fenêtre principale du logiciel RStudios avec la fonction HydroGOF	19
<u>Chapitre III :</u>	
Figure III.1. Neurone biologique	24
Figure III.2. : Le Neurone formel	24
Figure III.3. Graphe d'un réseau de neurones artificiels	25
Figure III.4. Similitude entre un neurone biologique et artificiel.	25
Figure III.5. Schéma du perceptron de Rosenblatt	26
Figure III.6. L'architecture du MLPNN	27
Figure III.7. La structure du réseau GRNN	27
Figure III.8. Représentation de Logo d'Anaconda.	29
Figure III.9. Présentation du navigateur d'Anaconda	29
Figure III.10. . Fenêtre principale Spyder pour Python	30
Figure III.11. Flowchart et synoptique générale de l'étude	31

Chapitre IV :

Figure IV.1. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Batna & modèles MLR	37
Figure IV.2. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Batna & modèles MLPNN	38
Figure IV.3. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Batna & modèles GRNN	39
Figure IV.4. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Biskra & modèles MLR	42
Figure IV.5. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Biskra & modèles MLPNN	43
Figure IV.6. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Biskra & modèles GRNN	44
Figure IV.7. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Djelfa & modèles MLR	47
Figure IV.8. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Djelfa & modèles MLPNN	48
Figure IV.9. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Djelfa & modèles GRNN	49
Figure IV.10. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Chlef & modèles MLR	52
Figure IV.11. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Chlef & modèles MLPNN	53
Figure IV.12. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Chlef & modèles GRNN	54

Liste des Tableaux

Chapitre II :

Tableau II.1. Présentation des sites utilisés durant la modélisation de l'SR	16
Tableau II.2. Paramètres statistiques de la base de données utilisée : modélisation de l'RS	17
Table II.3. Structure des modèles utilisés	18

Chapitre IV :

Tableau IV.1. Performances des différents modèles : Station de Batna	36
Tableau IV.2. Performances des différents modèles : Station de Biskra	41
Tableau IV.3. Performances des différents modèles : Station de Djelfa	46
Tableau IV.4. Performances des différents modèles : Station de Chlef	51

Table des matières

Introduction Générale

01

<i>Chapitre I : Généralités Sur la Radiation Solaire (RS)</i>	
I.1. Introduction	04
I.2. Définition de la radiation solaire	04
I.3. Les composantes de la radiation solaire	04
I.3.1. La radiation solaire extraterrestre	05
I.4. Mesures directes de la radiation solaire	05
I.4.1. Les appareille de mesure de la radiation solaire	05
I.4.2. Les appareille de mesures de la durée d'insolation	06
I.5. Importance de la radiation solaire dans le domaine agricole	07
I.5.1. Cycle de l'eau et radiation solaire	08
I.6. Facteurs Climatiques et Radiation Solaire	09
I.6.1. Le bilan Hydrologique	09
I.6.2. La vitesse du vent	09
I.6.3. L'humidité relative	10
I.6.4. La température de l'aire	11
I.6.5. Les précipitations	11
I.6.6. L'évaporation	12
I.6.7. L'évapotranspiration	13
I.6.8. Interaction entre la radiation solaire et les facteurs climatiques	13
I.7. Conclusion	14
<i>Chapitre II : Présentation de la Zone d'Étude et Description de la Base de Données Utilisée</i>	
II.1. Introduction	16
II.2. Présentation et description des données utilisées	16
II.2.1. Situation géographique des stations climatiques utilisées	16
II.2.2. Statistiques descriptives	16
II.3. Evaluation des performances des modèles	17
II.4. Conclusion	20

<i>Chapitre III : Présentation des Modèles de Machine Learning (ML)</i>	
III.1. Introduction	22
III.2. Concepts de base de l'intelligence artificielle	22
III.3. Concepts de base de machine learning (ML)	22
III.4. Les réseaux de neurones artificiels	22
III.4.1. Historique	23
III.4.2. Le neurone biologique	23
III.4.3. Le neurone formel	24
III.4.4. Le neurone artificiel	24
III.4.5. Le perceptron	25
III.4.6. Le perceptron multicouche (MLPNN)	26
III.4.7. Le Réseau de Neurone de Régression Généralisée (GRNN)	27
III.5. La Régression linéaire multiple (MLR)	27
III.6. Apprentissage des réseaux de neurones	28
III.6.1. Apprentissage supervisé	28
III.7. Répartition des données & apprentissage et validation	28
III.8. Développement des modèles sous la plateforme ANACONDA	29
III.8.1. Présentation de la plateforme ANACONDA	29
III.9. Présentation du langage Python	29
III.8.2. Présentation de l'environnement de développement Spyder	30
III.8. Le flowchart Sommaire de l'étude	31
III.9. Conclusion	32
<i>Chapitre IV: Résultats et Interprétation</i>	
IV.1. Introduction	34
IV.2. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Batna	34
IV.3. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Biskra	40
IV.4. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Djelfa	45
IV.5. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Chlef	50
IV.4. Conclusion	55
<i>Conclusion Générale</i>	56

Liste des abréviations

IA : L'intelligence artificielle

GRNN : Le réseau neuronal de régression généralise

H% : L'humidité relative

MAE : La moyenne des erreurs absolues

MLR : La régression linéaire multiple

MLPNN : Le perceptron multicouche

NSE : Le coefficient de Nash-Sutcliffe efficacité

P : Les précipitations

R : Coefficient de corrélation

RMSE : La racine carrée de l'erreur quadratique moyenne

SR : la radiation solaire

Tmax : La température maximale

Tmin : La température minimale

U2 : La vitesse de vent

Introduction Générale

L'énergie solaire est une source vitale de subsistance pour tous les organismes vivants sur la terre, et elle provient du soleil grâce à un processus de réaction de fusion thermonucléaire. Cette énergie peut être directement exploitée ou indirectement par l'énergie éolienne, l'hydroélectricité et les combustibles fossiles. L'énergie solaire reçue sur terre varie en fonction de la latitude, longitude, de la couverture nuageuse, de l'altitude, de la pente du lieu et des paramètres météorologiques. Le rayonnement solaire (RS) peut être défini comme étant l'énergie émise par le soleil, qui se propage dans toutes les directions à travers l'espace sous forme d'ondes électromagnétiques.

L'étude du rayonnement solaire (RS) implique de prendre en compte les conditions météorologiques locales et les paramètres météorologiques pour concevoir des dispositifs efficaces à énergie solaire. Le développement rapide des concepts de l'énergie solaire, des techniques agricoles, et le suivi et contrôle des conditions climatiques, nécessite des connaissances approfondies du rayonnement solaire (RS). Malgré que la radiation solaire (RS) peut être mesurées directement en utilisant les Pyranomètre avec une grande précision (à condition qu'ils soient correctement entretenus), il existe un manque de ces appareils dans la majorité des régions de notre pays et à travers plusieurs régions dans le monde. En plus, la grande variabilité spatiale et temporelle de la radiation solaire fait que, l'utilisation des mesures des stations avoisinantes ne soit pas faisable et utile pour plusieurs applications. De ce fait, la radiation solaire doit être constamment estimé et modéliser.

Plusieurs approches ont été proposées durant les dernières décennies pour la génération et l'estimation de la radiation solaire autre les méthodes classiques couramment utilisée dans les stations météorologiques. Dans cette mémoire qui entre dans le cadre de la préparation de notre mémoire de fin d'étude en Master Aménagement Hydro-Agricole, nous développons des modèles mathématiques à base d'intelligence artificielles dans le but d'élargir nos connaissances et comprendre certains des relations qui existe entre les variables climatiques et la radiation solaire mesuré à pas de temps journalières au niveau de quatre stations en Algérie. Nous nous concentrons sur trois axes principaux qui sont :

1. L'application des techniques à base d'intelligence artificielles pour la modélisation de la radiation solaire.
2. La comparaison entre deux modèles à base de réseaux de neurones artificielles et un modèle à base de régression linéaire multiple (MLR) qui sont : le perceptron multicouches (MLPNN), un réseau neuronal de régression généralisée (GRNN), et un modèle à base de régression linéaire multiple (MLR).
3. La recherche de la meilleure combinaison entre plusieurs variables climatiques qui permet d'estimer en mieux la radiation solaire.

Le mémoire est divisé en quatre parties (chapitre).

1. Dans la première partie (Chapitre 01) nous avons présenté des généralités sur le cycle hydrologique, les différentes variables climatiques, ainsi que les concepts de base de la radiation solaire (RS).
2. Dans la deuxième partie (Chapitre 02) nous avons présenté la donnée climatique utilisée pour le développement des modèles ainsi qu'une description sommaire des stations climatique sélectionnée dans la présente étude.
3. La troisième partie (Chapitre 03) est réservée pour la présentation des concepts de base de l'intelligence artificielle ainsi que les modèles à base de réseau de neurone artificiel.
4. La quatrième et dernière partie (Chapitre 04) est réservée à la présentation détaillée des résultats obtenus par les différents modèles, ainsi qu'une évaluation et comparaison à base de critères numérique et graphique.

Chapitre I : Généralités Sur la Radiation Solaire (RS)

I.1. Introduction

La radiation solaire (RS) est fonction de plusieurs paramètres géographiques, météorologiques et astronomiques. Dans la plupart des applications spécialisées, les variables météorologiques servent de variables d'entrée pour les modèles d'estimation de la RS, et ces derniers peuvent être prédits avec précision. La modélisation de la RS et des paramètres météorologiques vise normalement à trouver un moyen approprié d'estimer ces variables, en particulier lorsque les données météorologiques sont peu disponibles ou inexistantes. Dans ce premier chapitre, nous présenterons brièvement quelques notions de base sur les variables climatiques ainsi que la RS.

I.2. Définition de la radiation solaire

La radiation solaire fait référence à l'énergie électromagnétique émise par le Soleil. Cette énergie se propage sous forme de rayonnement à travers l'espace et atteint la Terre (Jahani, 2017), où elle joue un rôle crucial dans de nombreux processus, tels que le réchauffement de la planète, la photosynthèse des plantes et le cycle de l'eau. La radiation solaire est composée de diverses longueurs d'onde, notamment les rayons gamma, les rayons X, les ultraviolets, la lumière visible, l'infrarouge et les micro-ondes. C'est un facteur clé de la photosynthèse et de l'évapotranspiration et une donnée d'entrée essentielle pour la programmation de l'irrigation, le cycle hydrologique et les modèles de simulation de la croissance des cultures

I.3. Les composantes de la radiation solaire

- Le rayonnement direct (Direct Normal Irradiance (DNI)) est la composante de la radiation solaire qui atteint la surface terrestre directement du soleil, sans diffusion ou réflexion dans l'atmosphère.
- Diffuse Horizontal Irradiance (DHI) Le rayonnement diffus est la composante de la radiation solaire qui est diffusée dans toutes les directions par l'atmosphère. Il provient principalement de la diffusion de la lumière solaire par les molécules d'air, les particules atmosphériques et les nuages. Cette composante contribue à l'éclairage global, qui est la somme du rayonnement direct et diffus.
- Global Horizontal Irradiance (GHI) L'ensemble du rayonnement solaire direct R_b et du rayonnement diffus du ciel et des nuages R_d , reçu sur un plan horizontal, constitue le rayonnement solaire global R_s (Gueymard, 2004)

La mesure de l'éclairement énergétique dû à ce rayonnement global s'effectue classiquement en climatologie à l'aide d'un pyranomètre ; le même pyranomètre équipé d'une bande pare-soleil permet la mesure du seul rayonnement diffus (par différence entre R_s et R_S on peut calculer le rayonnement solaire direct reçu sur un plan horizontal). La radiation solaire joue un rôle fondamental dans la régulation du climat terrestre et influence de nombreux processus environnementaux et météorologiques. Les interactions entre la radiation solaire et les facteurs climatiques sont complexes et diverses, et elles façonnent les conditions météorologiques et climatiques à différentes échelles de temps et d'espace




Figure I.1. Radiation solaire direct et diffuse

I.3.1. La radiation solaire extraterrestre

Le rayonnement solaire extraterrestre couvre un très large domaine de longueur d'ondes. Il ne dépend d'aucun paramètre météorologique, mais il est fonction de quelques paramètres astronomiques et géographique tel que : la latitude du lieu (φ), la déclinaison solaire (δ), et l'angle horaire au coucher du soleil (ω_0) (HAMMADOU, 2013)

I.4. Mesures directes de la radiation solaire

La radiation solaire est mesurée en termes de flux de rayonnement par unité de surface, souvent exprimée en watts par mètre carré (W/m^2). Des instruments tels que les pyranomètre sont utilisés pour mesurer l'insolation à la surface de la Terre (Duffie, 2013).

I.4.1. Les appareille de mesure de la radiation solaire

L'irradiation solaire globale est mesurée à l'aide d'un capteur actinométrique particulier dite le pyranomètre. Ce dernier contient une thermopile qui délivre une tension proportionnelle à l'irradiation. La partie supérieure de la pile s'échauffe lorsqu'elle est exposée au rayonnement solaire, tandis que la partie inférieure est protégée du rayonnement et sert de référence. D'autres capteurs actinométrique, plus rares, permettent aussi la mesure spécifique du rayonnement direct ou diffus :

- Le Pyranomètre ombré et équipé d'un anneau métallique qui masque le soleil, supprimant la composante directe du rayonnement incident
- Le Pyrhéliomètre est équipé d'un système de suivi du soleil, ainsi il ne mesure que le rayonnement direct.

Ces instruments de mesures sont relativement peu nombreux et leur rareté croît avec la complexité du dispositif. (Madden, 2017)

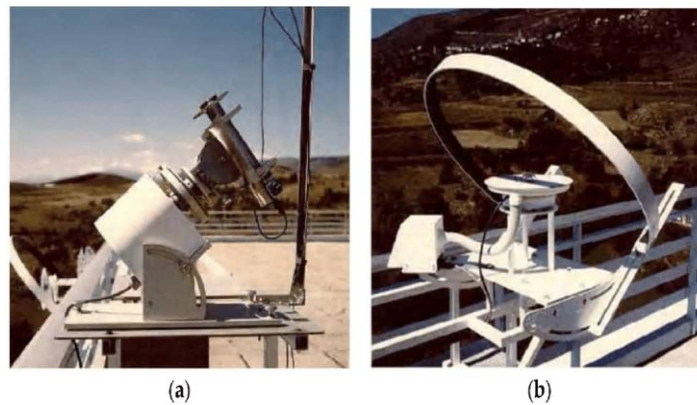


Figure I.2. Pyrhéliomètre et Pyranomètre ombré
&




Figure I.3. Exemples de capteurs par ordre croissant de complexité de l'instrumentation et donc du niveau de détail de la caractérisation du rayonnement solaire

I.4.2. Les appareils de mesures de la durée d'insolation

Il existe plusieurs appareils de mesure de la durée d'insolation, chacun ayant ses propres caractéristiques et références. Voici quelques-uns des appareils de mesure de la durée d'insolation les plus couramment utilisés :

- **Héliographe de Campbell-Stokes** : Cet instrument mesure la durée d'insolation en utilisant une sphère en verre qui concentre la lumière du soleil sur une carte spéciale. Il laisse une trace brûlée sur la carte chaque fois qu'il est exposé à la lumière directe du soleil

- **Pyranomètre** : Ce dispositif mesure le rayonnement solaire global reçu par unité de surface horizontale. Bien qu'il ne mesure pas directement la durée d'insolation, il fournit des données qui peuvent être utilisées pour calculer la durée d'insolation sur une période donnée :
- **Radiomètre solaire** : Il mesure le rayonnement solaire dans différentes longueurs d'onde, y compris la lumière visible. Bien qu'il ne soit pas spécifiquement conçu pour mesurer la durée d'insolation, il peut être utilisé en combinaison avec d'autres données pour estimer la durée d'insolation.
- **Datalogger solaire** : Les Datalogger solaires enregistrent les données météorologiques telles que l'ensoleillement, la température, l'humidité, etc. Ils peuvent être utilisés pour calculer la durée d'insolation sur une période donnée en analysant les données enregistrées
- **Capteurs de lumière solaire** : Ces capteurs sont souvent intégrés dans des stations météorologiques et peuvent être utilisés pour mesurer la lumière du soleil directe ou indirecte

I.5. Importance de la radiation solaire dans le domaine agricole

La radiation solaire est un facteur crucial dans le domaine agricole pour plusieurs raisons, notamment son rôle dans le processus de photosynthèse des plantes, sa contribution à la régulation thermique des cultures et son impact sur le cycle de l'eau dans les écosystèmes agricoles.

- **Photosynthèse des plantes** : La photosynthèse peut être définie comme le processus par lequel les organismes photoautotrophes (tels que les plantes, les algues et certaines bactéries) capturent l'énergie lumineuse du soleil pour synthétiser des composés organiques à partir du dioxyde de carbone (CO_2) et de l'eau (H_2O). L'oxygène (O_2) est produit comme sous-produit.
- La radiation solaire fournit l'énergie nécessaire à la photosynthèse, le processus par lequel les plantes convertissent la lumière en énergie chimique pour produire des hydrates de carbone. Plus la quantité de lumière solaire disponible est importante, plus les plantes peuvent produire de biomasse et de rendement. (Taiz, 2010)

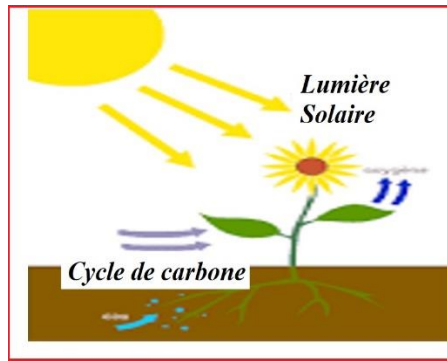


Figure I.4. Photosynthèse des plantes

I.5.1. Cycle de l'eau et radiation solaire

Le cycle hydrologique est un concept qui englobe les mouvements de l'eau sur la terre. Cette définition implique que les mécanismes régissant le cycle hydrologique ne surviennent pas seulement les uns à la suite des autres, mais sont aussi concomitants. Le terme "Cycle de l'eau" nécessite la permanence des échanges entre l'eau de surface et l'eau atmosphérique, par un jeu qui combine l'évaporation et les précipitations, alors que l'évaporation causée par le réchauffement de la surface des océans sous l'effet du rayonnement solaire, entraîne la libération de vapeur d'eau dans l'atmosphère. D'autre part, soumise à des conditions favorables, la vapeur d'eau se condense pour former les nuages qui se déplacent vers les continents et se transforment partiellement en précipitation. Que ces précipitations prennent la forme de neige ou de pluie, la majorité d'entre elles retournent aux océans, qui occupent environ 70% (AIDOUDI, 2012) de la surface de la terre. La radiation solaire fournit l'énergie nécessaire à l'évaporation de l'eau à la surface de la Terre, alimentant ainsi le cycle hydrologique. Les précipitations sont souvent le résultat de la condensation de la vapeur d'eau atmosphérique, qui est chauffée par la radiation solaire et se condense pour former des nuages et finalement des précipitations (TRENETH, 2009)




Figure I.5. Cycle hydrologique

I.6. Facteurs Climatiques et Radiation Solaire

I.6.1. Le bilan Hydrologique

Établir le bilan en eau d'une région sur une période donnée c'est chiffré les quantités d'eau qui entrent et sortent des différents bassins versants qui la composent (le bassin versant d'une rivière est la zone à l'intérieur de laquelle l'eau précipitée s'écoule et converge vers la rivière (Aidoudi, 2012) Le bilan hydrologique se situe à l'échelle du bassin versant (quelle que soit sa taille) considéré comme un système fermé, dont on peut résoudre à l'aide d'équation. Les modèles de bilan énergétique prennent en compte la radiation solaire, ainsi que d'autres paramètres météorologiques tels que la température de l'air, l'humidité relative, et la vitesse du vent, pour estimer l'évapotranspiration. Ces modèles utilisent généralement des équations basées sur les principes de la conservation de l'énergie pour quantifier les flux de chaleur et d'humidité à la surface du sol et des plantes. De nombreuses études empiriques ont été menées pour évaluer l'impact de la radiation solaire sur l'évapotranspiration dans différents contextes climatiques et environnementaux. Ces études utilisent souvent des données de terrain et des mesures in situ pour quantifier la relation entre la radiation solaire et l'évapotranspiration.

I.6.2. La vitesse du vent

Les vents sont globalement provoqués par un réchauffement inégalement réparti à la surface de la planète provenant d'énergie solaire et la rotation de la planète. La vitesse du vent est mesurée avec un anémomètre et la girouette, indique sa direction. Les unités de mesure des paramètres du vent sont le degré (°) et le mètre par seconde (m/s) pour la direction et la vitesse, respectivement. Le vent est un facteur climatique très important, il a un impact énorme sur la climatologie, l'agriculture, la navigation...etc. Dans le domaine de l'énergie, la connaissance de la vitesse et de la direction du vent est très importante pour la production et la gestion de l'énergie éolienne (Bahaghighat, M, & Al, 2021)



Figure I.6. Combinaison d'un anémomètre avec une girouette

I.6.3. L'humidité relative :

L'humidité relative de l'air, ou degré hygrométrique, couramment notée ϕ , correspond à la mesure du rapport entre le contenu en vapeur d'eau de l'air et sa capacité maximale à en contenir dans des conditions données. Il s'agit du rapport de la pression partielle de la vapeur d'eau contenue dans l'air sur la pression de vapeur saturante (ou tension de vapeur) à la même température. Elle est mesurée à l'aide d'un hygromètre. C'est une variable climatique importante qui influence directement certains secteurs majeurs tels que l'agriculture (i.e., la programmation de l'irrigation), les études hydrologiques, la santé humaine, et la production industrielle. L'une des utilisations les plus importantes de l'HR dans la gestion des ressources en eau est son inclusion dans la méthode standard de Penman-Monteith pour le calcul de l'évapotranspiration de référence (ET_0) (Allen & R, 1998). L'HR peut être mesurée à l'aide de différents instruments, telles que les psychromètres, les capteurs de point de rosée, les hygromètres mécaniques et les sondes électroniques de l'HR, l'instrument le plus utilisé pour mesurer l'HR est l'hygromètre



Figure I.7. Hygromètre

I.6.4. La température de l'air

La température de l'air (T_a) est un élément crucial du climat en raison de sa relation directe ou indirecte avec d'autres variables climatiques importantes, telles que l'humidité atmosphérique, la RS, le vent, les précipitations, l'évapotranspiration (MERABET, 2024)



Figure I.8. Thermomètre

La température est une grandeur physique mesurée à l'aide d'un thermomètre. La T_a est mesurée en degrés Celsius ($^{\circ}\text{C}$), kelvin (K) ou degrés Fahrenheit ($^{\circ}\text{F}$). La variation des Températures maximale et température minimale est reliée aux sensations de froid et de chaud. La prévision précise de la T_a est un élément essentiel de la prise de décision dans de nombreux domaines, notamment la production agricole, la gestion de l'énergie et la santé humaine et animale

I.6.5. Les précipitations

Les précipitations constituent un phénomène qui décrit le transfert de l'eau, dans une phase liquide (pluie) ou solide (neige, grêle), entre l'atmosphère et le sol. Au-dessus des continents, les précipitations représentent l'élément le plus important du cycle hydrologique. (AIDOUD, 2012) Ces hydrométéores (cristaux de ou gouttelettes d'eau), se caractérisent par trois principaux paramètres : leur volume, leur intensité et leur fréquence qui varient selon les lieux et les périodes (jours, mois ou années). Les précipitations liquides s'évaluent en hauteur d'eau équivalente sur une période donnée (exemples : mm par an, par mois, par jour). Les précipitations jouent un rôle essentiel dans la vie humaine, les animaux et les plantes. C'est un processus clé important du cycle hydrologique, et dans le maintien de l'équilibre entre les ressources en eau douce et en eau salée du globe. Une prévision des précipitations est nécessaire pour une estimation correcte du bilan hydrique. Il y a plusieurs dispositifs et techniques utilisés pour mesurer les hauteurs des précipitations liquides et solides, mais l'instrument de base de mesure c'est le pluviomètre. (MERABET K. , 2024)



Figure I.9. Exemple de pluviomètre (pluviomètre de Hellmen).

I.6.6. L'évaporation

L'évaporation est l'ensemble des phénomènes de transformation de l'eau en vapeur par un processus spécifiquement physique, les plans d'eau et la couverture végétale sont les principales sources de vapeur d'eau. Le principal facteur régissant l'évaporation est la radiation solaire et les phénomènes d'évaporation interviennent dans le cycle hydrologique dès le moment où les précipitations (MERABET & REMREM, 2019), sous forme liquide ou solide, atteignent la surface du sol. Le taux d'évaporation s'exprime généralement en mm/mois ou mm/ans

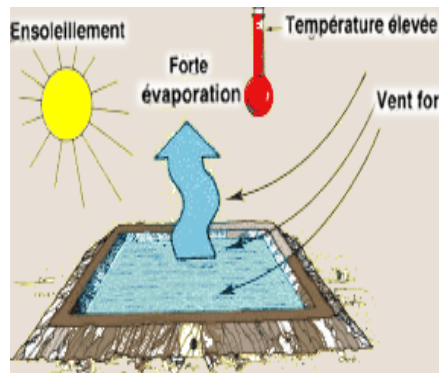


Figure I.10. L'évaporation




Figure I.11. L'évapotranspiration

I.6.7. L'évapotranspiration.

L'évapotranspiration est la combinaison de l'évaporation et la transpiration, c'est l'une des composantes du cycle hydrologique les plus difficiles, et son estimation est importante pour les programmes d'irrigation, la planification et la gestion des ressources en eau. (MERABET, 2024)L'évapotranspiration correspond à l'eau qui est transpirée par les plantes et évaporée au niveau du sol. Elle dépend de la température, du type de végétation et des propriétés physiques du sol et aussi du taux d'humidité dans l'air

- Evaporation : désigne le passage de la phase liquide à la phase gazeuse de l'eau.
- La transpiration : est le phénomène physiologique de la transformation de l'eau en vapeur par les êtres vivants et notamment les végétaux. On regroupe sous le nom d'évapotranspiration l'ensemble des deux processus

L'évaporation et l'évapotranspiration dépendent des composants de l'air (humidité, température, pression...) mais également de l'insolation et de la vitesse du vent

I.6.8. Interaction entre la RS et les facteurs climatiques

L'interaction entre la radiation solaire et les facteurs climatiques est complexe et joue un rôle crucial dans de nombreux processus environnementaux et météorologiques. Voici quelques-uns des principaux facteurs climatiques qui interagissent avec la radiation solaire

I.6.8.1. Influence de l'humidité relative sur l'absorption de la RS

L'humidité relative de l'air peut influencer la transmission et l'absorption de la radiation solaire. Une humidité plus élevée peut entraîner une augmentation de la diffusion et de la réflexion de la lumière solaire, ce qui peut réduire l'intensité de la radiation solaire atteignant la surface terrestre.

I.6.8.2. Effet de la vitesse du vent sur la dispersion de la RS

La vitesse du vent influe sur la dispersion de la radiation solaire à travers l'atmosphère. Un vent fort peut entraîner une dispersion plus importante de la lumière solaire, ce qui peut affecter l'intensité de la radiation solaire reçue à la surface terrestre

I.6.8.3. Effet de L'évapotranspiration sur la RS

L'évapotranspiration est fortement influencée par la radiation solaire incidente. Une plus grande quantité de radiation solaire entraîne généralement une augmentation de l'évaporation du sol et de la transpiration des plantes. Ainsi, la quantité et la distribution spatiale de la radiation solaire dans une région donnée sont des facteurs déterminants de l'évapotranspiration potentielle

I.6.8.4. Influence de la température de l'air sur l'absorption de la RS

La température de l'air peut influencer la quantité de radiation solaire absorbée par l'atmosphère. Des variations de température peuvent entraîner des changements dans la densité de l'air et dans sa capacité à absorber et à diffuser la lumière solaire.

I.6.8.5. Influence des précipitations sur la transmission de la RS

Les précipitations, en particulier les nuages et les particules atmosphériques associées aux précipitations, peuvent réduire la quantité de radiation solaire atteignant la surface de la Terre. Les nuages réfléchissent une partie de la lumière solaire, réduisant ainsi l'insolation directe. (Stephens, 2005)

I.7. Conclusion

La des données climatiques enregistré dans différentes stations comme les températures, la vitesse du vent, humidité relative, les précipitations et la radiation solaire, ont permet de mieux étudier la variabilité d'une variable par rapport aux autres. Dans le présent chapitre nous nous sommes intéressées à la radiation solaire et l'ensemble des variables climatiques qui vont être utilisé pour la modéliser. Étant donné que notre travail est orienté vers la modélisation de radiation solaire, nous essayé de présenter les variables les plus importante. La modélisation de la RS sera orientée vers une comparaison entre plusieurs modèles ayant différentes variables d'entrée et qui seront discuté dans les chapitres suivants.

***Chapitre II : Présentation de la Zone d'Étude et
Description de la Base de Données Utilisée***

II.1. Introduction

L'objectif de notre travail est la modélisation de la radiation solaire (RS : MJ/m^2) en fonction des variables climatiques. Nous disposons pour cela de cinq variables climatiques: la température maximale (T_{max} : $^{\circ}C$), la température minimale (T_{min} : $^{\circ}C$), les précipitations (P), la vitesse du vent (U_2 : m/s), l'humidité relative (H : $\%$).

II.2. Présentation et description des données utilisées

II.2.1. Situation géographique des stations climatiques utilisées

Dans la présente étude nous avons utilisé les données de quatre stations: Batna, Biskra, Djelfa, et Chlef. La description des stations avec la période d'enregistrement des données est présentée dans le [Tableau II.1](#). La situation géographique des stations est présentée dans la [Figure II.1](#).

Tableau II.1. Présentation de stations utilisée pour la modélisation de l'RS

Stations	Longitude ($^{\circ}$)	Latitude ($^{\circ}$)	Altitude (m)	Périodes	Durée (ans)	Jours
Batna	6° 33' 44.999"	35° 45' 0.36"	0831	2004-2013	10	3650
Biskra	7° 07' 29.999"	34°48' 48.24"	0303	2004-2013	10	3650
Djelfa	3° 07' 29.999"	34°48' 48.24"	1068	2004-2013	10	3650
Chlef	1° 33' 44.999"	36°22' 28.56"	0724	2004-2013	10	3650

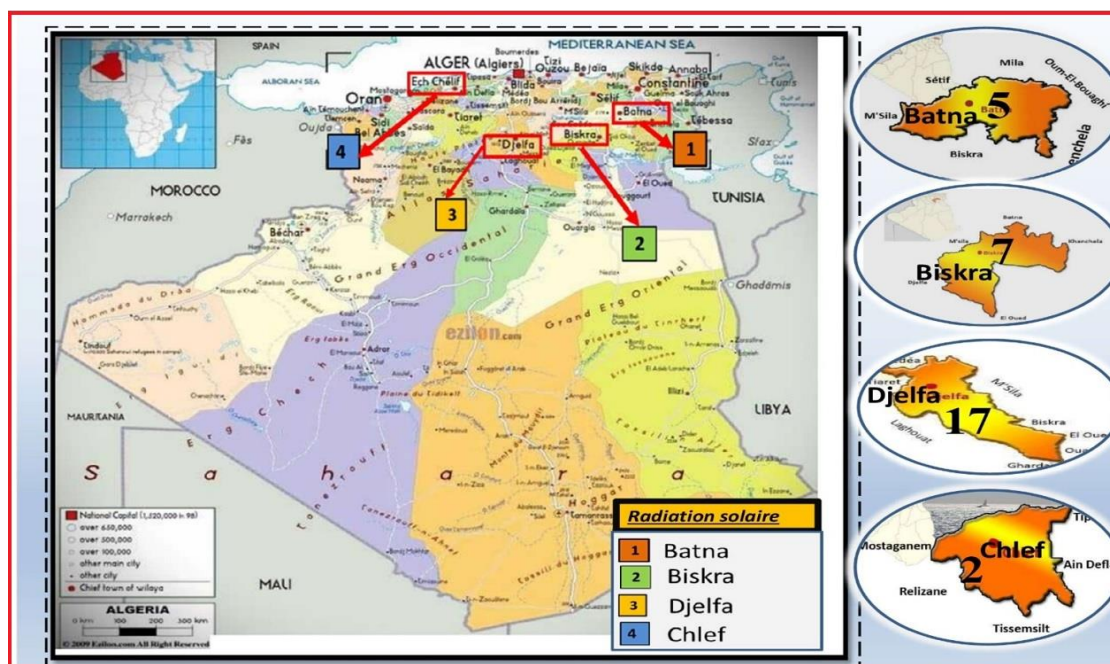


Figure II.1. Situation géographique de la zone d'étude

II.2.2. Statistiques Descriptives

Dans le présent travail, et pour chaque station climatique nous avons calculé les paramètres statistiques pour les différentes variables climatiques, qui sont présentés dans le

Tableaux II.2 présentent les résultats obtenus, avec : la valeur maximale (X_{max}), la valeur moyenne (X_{mean}), La valeur minimale (X_{min}), l'écart type (S_x), le coefficient de corrélation linéaire (R), et le coefficient de variation (C_v) qui est le rapport de l'écart-type à la moyenne. Les matrices de corrélation pour chaque station sont présentées sur la Figure II.2.

Tableau II.2. Paramètres statistiques de la base de données utilisée

Stations	Variables	Unité	X_{mean}	X_{max}	X_{min}	S_x	C_v	R
Batna	T_{max}	°C	22.870	45.438	-1.056	10.104	0.441	0.732
	T_{min}	°C	8.843	28.135	-8.362	7.113	0.804	0.435
	P	mm	0.851	34.136	0000	2.703	3.176	-0.334
	U_2	m/s	2.455	8.255	0.683	0.948	0.386	0.016
	HR	%	56.194	97.096	97.096	20.325	0.361	-0.685
	RS	MJ/m ²	18.483	32.765	0.495	8.132	0.439	1.000
Biskra	T_{max}	°C	28.006	48.517	6.827	9.577	0.341	0.798
	T_{min}	°C	15.531	32.386	-2.515	7.931	0.511	0.693
	P	mm	0.381	48.558	0.000	2.069	5.435	-0.222
	U_2	m/s	2.844	8.210	0.674	1.140	0.401	0.091
	HR	%	40.373	91.538	6.411	16.930	0.419	-0.802
	RS	MJ/m ²	20.569	32.564	1.142	7.475	0.363	1.000
Djelfa	T_{max}	°C	22.360	42.698	0.130	10.343	0.462	0.728
	T_{min}	°C	9.068	27.058	-9.167	7.305	0.805	0.495
	P	mm	1.003	39.900	0.000	3.072	3.062	-0.330
	U_2	m/s	2.426	8.723	0.594	1.032	0.425	-0.129
	HR	%	51.600	97.551	6.201	22.700	0.439	-0.714
	RS	MJ/m ²	18.738	33.456	1.285	7.995	0.426	1.000
Chlef	T_{max}	°C	22.675	44.206	0.607	8.255	0.364	0.758
	T_{min}	°C	12.382	29.190	-4.656	6.165	0.497	0.553
	P	mm	1.975	87.430	0000	5.428	2.748	-0.431
	U_2	m/s	2.322	7.843	0.333	0.990	0.426	-0.120
	HR	%	66.017	100.84	14.313	18.34	0.277	-0.690
	RS	MJ/m ²	18.223	32.210	0.425	8.701	0.477	1.000

II.3. Evaluation des performances des modèles

Dans la présente étude, nous avons sélectionné quatre critères d'évaluations des modèles : la racine carrée de l'erreur quadratique moyenne (RMSE), la moyenne des erreurs (MAE), le coefficient de corrélation (R), et le critère d'efficacité de Nash-Sutcliffe (NSE).

$$MAE = \frac{\sum_{i=1}^N |X_{cal,i} - X_{obs,i}|}{N} \quad (II.1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_{obs,i} - X_{cal,i})^2}{N}} \quad (II.2)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (X_{obs,i} - X_{cal,i})^2}{\sum_{i=1}^N (X_{obs,i} - \overline{X_{obs}})^2} \right] \quad (II.3)$$

$$R = \frac{\sum_{i=1}^N (X_{obs,i} - \overline{X_{obs}})(X_{cal,i} - \overline{X_{cal}})}{\sqrt{\sum_{i=1}^N (X_{obs,i} - \overline{X_{obs}})^2 \sum_{i=1}^N (X_{cal,i} - \overline{X_{cal}})^2}} \quad (II.4)$$

$\overline{X_{obs}}$ et $\overline{X_{cal}}$: Les valeurs moyennes observées et calculées, respectivement ; $X_{obs,i}$ et $X_{cal,i}$ Les valeurs observées et calculées, respectivement, N : Le nombre total des observations (nombre d'individus).

Enfin, pour la modélisation de la radiation solaire, nous avons comparés entre douze modèles avec des entrées différents (Tableau II.3).

Table II.3. Structure des modèles utilisés.

MLR	MLPNN	GRNN	Input combination	Output
MLR1	MLPNN1	GRNN1	T _{max} , T _{min} , P, U ₂ , H%	SR
MLR2	MLPNN2	GRNN2	T _{max} , T _{min} , P, U ₂	SR
MLR3	MLPNN3	GRNN3	T _{max} , T _{min} , P, H%	SR
MLR4	MLPNN4	GRNN4	T _{max} , T _{min} , P	SR
MLR5	MLPNN5	GRNN5	T _{max} , T _{min} , U ₂	SR
MLR6	MLPNN6	GRNN6	T _{max} , T _{min} , H%	SR
MLR7	MLPNN7	GRNN7	P, U ₂ , H%	SR
MLR8	MLPNN8	GRNN8	T _{max} , U ₂ , H%	SR
MLR9	MLPNN9	GRNN9	T _{min} , P, H%	SR
MLR10	MLPNN10	GRNN10	T _{max} , T _{min}	SR
MLR11	MLPNN11	GRNN11	T _{max} , H%	SR
MLR12	MLPNN12	GRNN12	T _{min} , P	SR

Les quatre indices statistiques précédemment présentés sont calculés en utilisant le logiciel RStudio et en utilisons le fonction HydroGOF (Figure II.3). Cette fonction permet de calculer an ensemble d'indices simultanément par la lecture des données stockés dans un fichier Excel. Les données à utiliser doivent être classé en deux colonnes : une colonne pour les valeurs mesurées (O_i) et une deuxième colonne pour les valeurs calculés pr le modèle (P_i).

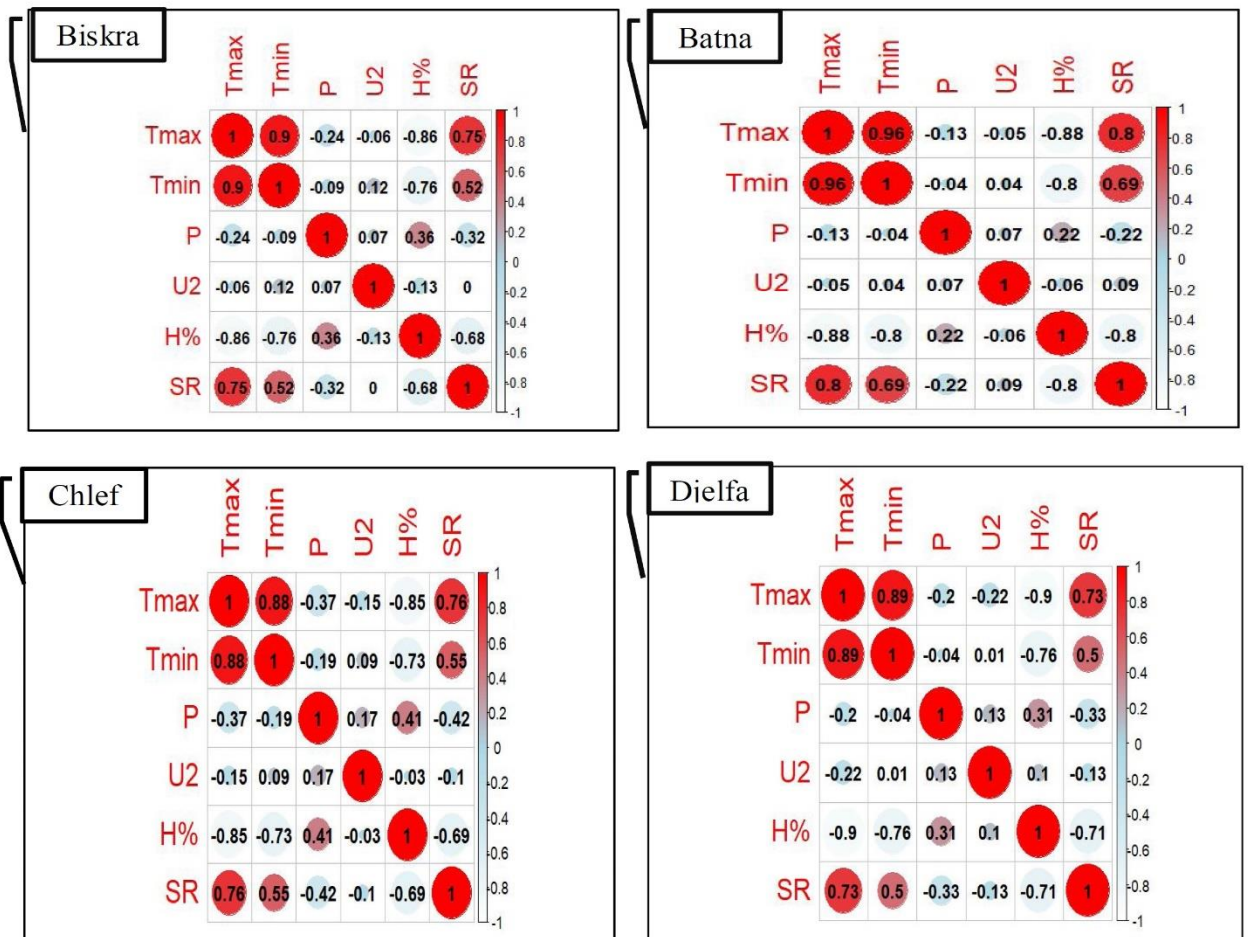


Figure II.2. Matrice de corrélation pour les différentes stations climatiques.

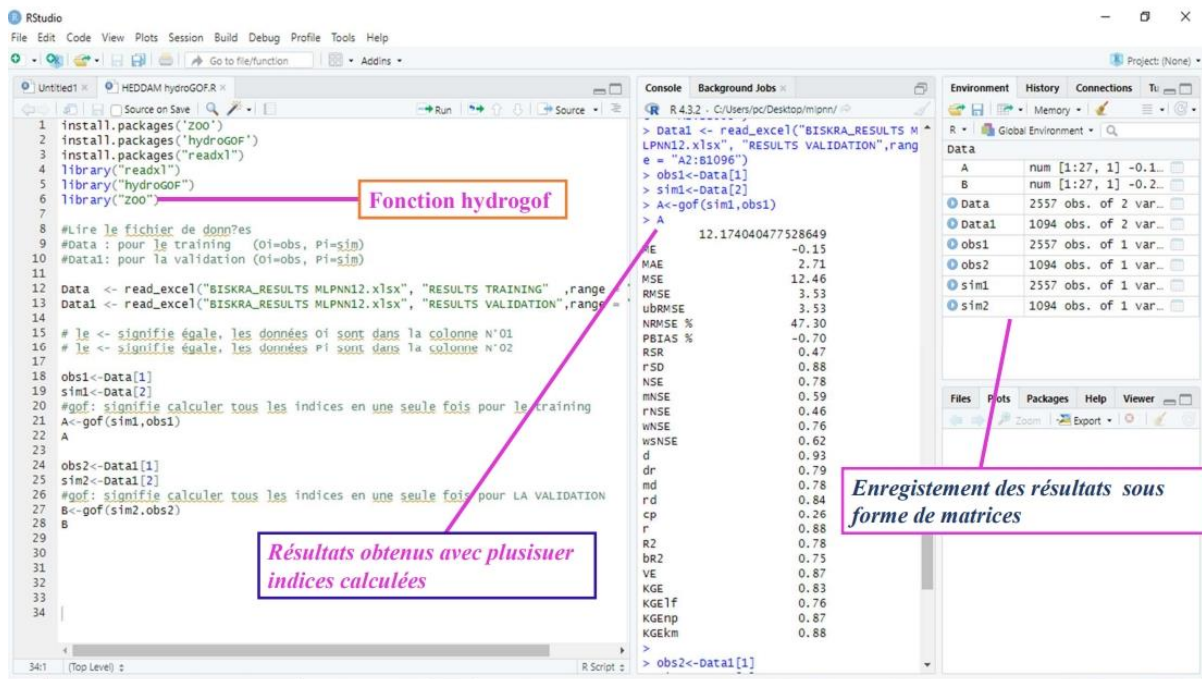


Figure II.3. Fenêtre principale du logiciel RStudios avec la fonction HydroGOF

II.4. Conclusion

Dans le présent chapitre nous avons présentés brièvement les stations et la donnée climatique utilisée pour la modélisation de la radiation solaire. D'autres parts, nous avons indiqués que les calculs des indices statistiques de performances ont été calculés par le logiciel HydroGOF sous la plateforme RStudios.

*Chapitre III : Présentation des Modèles de Machine
Learning (ML)*

III.1. Introduction

Suite au développement de la technologie ces dernières années, plusieurs domaines ont adopté l'automatisation en utilisant les algorithmes à base à l'intelligence artificielle (IA). Dans ce chapitre nous présentons brièvement les bases de l'intelligence artificielle et plus précisément les modèles à base d'apprentissage par machine Learning et réseaux de neurones artificiels. L'IA est partout : les moteurs de recherche l'utilisent pour améliorer les réponses aux requêtes, pour reconnaître la parole, pour traduire des langues, les programmes de messagerie l'utilisent pour filtrer le spam, les banques l'utilisent pour prédire les taux de change et les marchés boursiers, les médecins l'utilisent pour reconnaître les tumeurs, les robots l'utilisent.

III.2. Concepts de base de l'intelligence artificielle

L'IA est une discipline de l'informatique qui a pour but de créer des machines intelligentes, en "opposition" avec l'intelligence naturelle des êtres vivants. Les systèmes d'IA sont conçus pour apprendre et s'adapter à leur environnement, ce qui leur permet de résoudre des problèmes complexes et de prendre des décisions plus efficacement. L'IA est un ensemble algorithmes qui traite un ensemble d'informations ou données, relatives à des tâches, de manière semblable ou identique à celle qu'adopterait un être humain pour prendre une décision ou résoudre un problème.

III.3. Concepts de base de machine Learning (ML)

La machine learning ou l'apprentissage automatique (apprentissage-machine) est une sous-catégorie de l'intelligence artificielle qui consiste en une série de procédés permettant d'entraîner un système plutôt que de la programmer. L'objectif de base de la machine learning est "*d'apprendre à apprendre*" aux ordinateurs et par la suite, à agir et réagir comme le font les humains, en améliorant leur mode d'apprentissage et leurs connaissances de façon autonome sur la durée. Le machine learning utilise des programmes de développement qui s'ajustent chaque fois qu'ils sont exposés à différents types de données en entrée.

III.4. Les réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie est évidemment un réseau. Un réseau de neurone ne se programme pas, il est entraîné grâce à un mécanisme d'apprentissage. Les tâches particulièrement adaptées au traitement par réseau de neurones sont: l'association, la classification, la discrimination, la prévision ou l'estimation, et la commande de processus complexes. Les réseaux de neurones artificiels consistent en des modèles plus ou moins inspirés du fonctionnement cérébral de l'être humain en se basant principalement sur le concept de neurone.

III.4.1. Historique

- Jusqu'à la première moitié du XXIème siècle : il s'agit avant tout de construire les bases philosophiques et mathématiques sur lesquelles pourra se développer l'IA. À noter, quelques projets de « machines à penser », qui sont essentiellement des « machines à calculer » : projet de machine à calculer de Pascal au XVIIème siècle, projet « d'automate rationnel » de Leibnitz au début du XVIIIème, machine de Babbage au XXIème.
- Années 1940/50 : naissance de l'IA. Modèles mathématiques de Pitts et McCulloch en 1943; machine de Turing en 1950; théorie de l'information de Shannon.
- Années 50-60 : essor de l'IA : conférence de Darmouth en 1956 consacrant le terme d'Intelligence Artificielle ; développement des ordinateurs, des langages informatiques de type Lisp.
- Années 70 : nouveaux modèles de représentation et de traitement des connaissances. Systèmes experts, création du langage Prolog orienté vers le traitement de la langue naturelle en France au début des années 70.
- Années 80 : phase d'industrialisation : diffusion d'applications industrielles, commercialisation de progiciels.
- Depuis les années 90 : retour à des projets plus réalistes (on parle moins des systèmes experts par ex.). Nouveaux concepts (ex. Agents intelligents), développement des applications liées à la recherche de l'information (parallèlement au développement d'Internet), résurgence des concepts des réseaux neuronaux et d'algorithmes génétiques (Boisard, 2020).

III.4.2. Le neurone biologique

Le neurone biologique est une cellule vivante d'un être humain ou animal. Cette cellule peut prendre différentes formes (pyramidale, étoilée ou sphérique) définie par une membrane qui sépare l'intérieur du neurone de son extérieur. En effet, un neurone biologique est composé de:

- Soma : appelé aussi péricaryon, qui représente le corps du neurone.
- Dendrites (les afférences) : est la structure d'entrée du neurone permettant de récupérer les signaux transmis par d'autres neurones.
- Axone (l'efférence) : la structure de sortie du neurone, définie comme le prolongement unique pour diffuser le signal vers d'autres cellules.
- Synapses : sont les connexions ou les points de jonction entre l'axone du neurone émetteur et les dendrites du neurone récepteur. En d'autres termes, les synapses forment les connexions entre différents neurones (IDIR, , 2022)




Figure III.1. Neurone biologique

III.4.3. Le neurone formel

La première modélisation du neurone remonte aux années 40 où McCulloch et Pitts ont proposé le premier modèle de neurones formels. C'est un modèle mathématique qui réalise une somme pondérée des signaux qui lui parviennent et déclenche une réponse si cette somme dépasse un certain seuil. La [Figure III.20](#) à résume la chaîne de traitement développée par ce neurone. Ce modèle n'a pas possédé une règle d'apprentissage jusqu'à 1949 où Hebb a proposé un principe d'apprentissage sans avoir donné d'équations. La valeur de la sortie (y) résulte de la somme des entrées (x_i) pondérées par des coefficients (w_i) et du calcul d'une fonction d'activation (F) de cette somme pondérée. Il est à noter que cette modélisation simplifiée est loin de fournir une explication exacte concernant la complexité de fonctionnement des neurones biologique. Malgré cela, cette formalisation permet d'étudier les connexions entre ces neurones dans d'autres processus plus complexes comportant plusieurs neurones interconnectés ([NEMISSI, 2009](#))




Figure III.2. Le neurone formel : (a) Modèle de McCulloch et Pitts, (b) Modèle avec capacité d'apprentissage

III.4.4. Le neurone artificiel

La conception des réseaux de neurones artificiels (ANN) ou formels est inspirée des réseaux de neurones biologiques. Ainsi, un ANN est définie comme modèle connexionniste pour les machines apprenantes avec une adaptation rudimentaire des traitements synaptiques. La structure des réseaux de neurones artificiels est décrite par un graphe orienté, dont les nœuds sont les noyaux des neurones et les arcs leurs connexions.




Figure III.3. Graphe d'un réseau de neurones artificiels

Une couche d'un ANN est composée d'un ensemble de nœuds. Pour chaque couche les sorties de la couche $N-1$ deviennent les entrées de la couche N . Exceptionnellement, la couche d'entrées reçoit les valeurs de données de l'objet du traitement. Le schéma de la **Figure II.3** ci-dessus montre une modélisation d'un réseau de neurone artificiel avec les entrées (e_1, e_2, e_3, e_4), l'ensemble des connexions (les arcs du graphe), les nœuds intermédiaires du réseau et la sortie « S ». Les couches d'un réseau de neurones artificiels sont : Une couche d'entrées (Input layer), des couches cachées (Hidden layers), et une couche de sortie (Output layer)




Figure III.4. Similitude entre un neurone biologique et artificiel.

III.4.5. Le perceptron

Le perceptron est un neurone formel binaire. Cela signifie que son unique sortie est soit 0, soit 1, correspondant ainsi à deux classes prédictibles. L'ensemble de ses entrées est connecté à sa sortie. L'action d'un neurone sur ses entrées (x_i) correspond à une fonction d'agrégation, qui dans le cas du perceptron est une somme pondérée. Pour la calculer, des paramètres sont associés à chaque entrée (i), que nous appelons poids (w_i). Une fonction d'activation est alors appliquée sur z , dont le résultat est noté a . Elle permet de définir un seuil à partir duquel le neurone s'activera. La valeur de sortie du neurone est directement dépendante de son activation. Dans le cas du perceptron de Rosenblatt, pour une tâche de classification, la fonction non linéaire de Heaviside est appliquée. Cette fonction indique que la réponse du neurone sera 0 si le résultat est inférieur ou égal à 0 et sera 1 sinon. Il est tout à fait possible d'utiliser d'autres fonctions d'activation, par exemple la fonction sigmoïde (σ), pour une tâche de régression, qui est définie par $f(x)$. Nous représentons le perceptron à l'aide de la figure




Figure III.5. Schéma du perceptron de Rosenblatt

Les paramètres (poids), du perceptron sont initialisés aléatoirement et sont mis à jour à l'aide d'une règle d'apprentissage définie comme : W_0 valeur du poids i , W_i la valeur actuelle du poids i , α le taux d'apprentissage, Y_t la sortie attendue, Y la sortie réelle et X_i l'entrée i . La règle d'apprentissage permet ainsi d'optimiser les paramètres du neurone grâce à des données d'exemple, pour lesquelles nous connaissons la sortie attendue. Ces données doivent représenter un problème de classification (ou de régression), afin de laisser le perceptron trouver automatiquement la séparation linéaire applicable. Un dernier paramètre du perceptron correspond au biais (θ). Il s'agit du potentiel d'activation d'un neurone et est un poids pouvant être mis à jour. Il sera soustrait au résultat de la somme pondérée des entrées. De cette manière, la fonction d'activation sera appliquée sur le résultat de l'opération. En s'appliquant sur le résultat de la somme pondérée juste avant l'application de la fonction d'activation, le biais influe sur la capacité d'un neurone à s'activer. Il permet ainsi de rendre une unité neuronale plus flexible. (Caubriere,, 2021)

III.4.6. Le perceptron multicouche (MLPNN)

Le principe du perceptron multicouche (Multilayer Perceptron, MLP), est d'organiser en collaboration plusieurs perceptrons simples de manière à utiliser la sortie d'un neurone comme entrée d'un ou plusieurs autres. Plusieurs neurones peuvent être présents côte à côte, on parle ainsi de couche neuronale et ils peuvent être connectés à plusieurs neurones d'une couche suivante. Un perceptron multicouche est nécessairement doté d'une couche neuronale d'entrée et d'une couche de sortie. Il peut également être complété par une ou plusieurs couches intermédiaires, appelées couches cachées. Comme les sorties des unités neuronales sont connectées aux entrées des unités de la couche suivante, l'information se propagera obligatoirement de la couche d'entrée vers la couche de sortie. Les entrées d'une unité neuronale correspondent à l'ensemble des sorties des unités de la couche qui la précède.

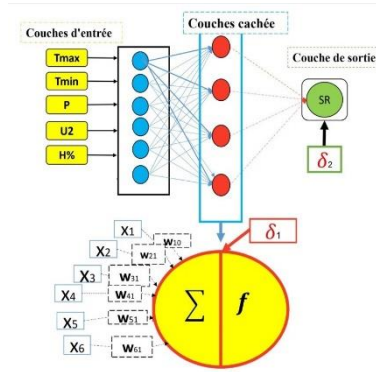


Figure III.6. L'architecture du MLPNN

III.4.7. Le Réseau de Neurone de Régression Généralisée (GRNN)

Un réseau de neurone de régression généralisée (GRNN) est un réseau basé sur les probabilités. Ce réseau est classé là où la variable cible est spécifique, tandis que les GRNN effectuent une régression où la variable cible est continue. Le réseau se compose des couches d'entrée, de masque et de sortie. La couche d'entrée contient un neurone pour chaque variable de prédicteur. Les neurones d'entrée unifient la plage de valeurs en soustrayant la médiane et en la divisant par la plage quartile (ouguissi, & ALMAOUI, 2020)




Figure III.7. La structure du réseau GRNN

III.5. La Régression linéaire multiple (MLR)

Elle repose sur l'hypothèse qu'il existe une relation linéaire entre une variable dépendante (à expliquer) Y , et une série de p variables indépendantes (explicatives) X_i (ici, les descripteurs) sous la forme suivante :

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$$

Cette équation est linéaire par rapport aux paramètres (coefficients de régression) $\beta_0, \beta_1, \dots, \beta_p$. La détermination de l'équation se fait alors à partir d'une base de données de n échantillons (observations) pour laquelle à la fois les variables indépendantes et la variable dépendante sont connues. (Yagoub al, 2021)

III.6. Apprentissage des réseaux de neurones

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. Toute l'information que peut contenir un réseau neuronal réside dans les poids synaptiques. L'apprentissage consiste donc à ajuster ces derniers de telle façon qu'il puisse générer correctement la sortie correspondante à chaque point de l'espace d'entrée. Il existe de nombreux types de règles d'apprentissage qui peuvent être regroupées en trois catégories: les règles d'apprentissage supervisé, non supervisé et renforcé. Mais l'objectif fondamental de l'apprentissage reste le même : soit la classification, l'approximation de fonction ou encore la prévision. (BEN YUCEF, 2020)

III.6.1. Apprentissage supervisé

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif. Ce genre d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties. La procédure usuelle dans le cadre de la prévision est l'apprentissage supervisé qui consiste à associer une réponse spécifique désirée à chaque signal d'entrée. La modification des poids s'effectue progressivement jusqu'à ce que l'erreur (ou l'écart) entre les sorties du réseau (ou résultats calculés) et les résultats désirés soient minimisés. (BEN YUCEF, 2020)

III.7. Répartition des données & apprentissage et validation

L'objectif fondamental de l'apprentissage-machine est de généraliser au-delà des instances de données utilisées pour former les modèles. Une stratégie courante consiste à prendre toutes les données étiquetées disponibles, et à les fractionner en sous-ensembles de formation et d'évaluation, généralement avec une proportionnel 70-80 % pour la formation (Training) et de 20-30 % pour l'évaluation (Validation). Le système d'apprentissage machine utilise les données de formation pour former les modèles à identifier des tendances, et utilise les données d'évaluation pour évaluer la qualité prédictive du modèle formé.

III.8. Développement des modèles sous la plateforme ANACONDA

Trois modèles mathématiques basés sur l'intelligence artificielle Machine Learning (ML) sous la plateforme ANACONDA ont été développés pour estimer le rayonnement solaire :

1. Perceptron multicouches (MLPNN)
2. Réseau neuronal de régression généralisée (GRNN)
3. Régression linéaire multiple (MLR)

Anaconda Navigator est une interface utilisateur graphique (GUI) conviviale incluse dans la distribution Anaconda. Elle permet aux utilisateurs de lancer des applications et de gérer facilement les paquets, environnements et canaux conda sans avoir recours à des commandes en ligne de commande. Navigator peut rechercher des paquets sur Anaconda Cloud ou dans un dépôt Anaconda local. Il est disponible pour Windows, MacOS et Linux. (Kamingu., 2023)



Figure III.8. Représentation de Logo d'Anaconda.

III.8.1. Présentation de la plateforme ANACONDA

Anaconda est une distribution libre pour les langages de programmation Python et R, dans les applications scientifiques. Dans cette distribution, on peut avoir accès à plusieurs autres applications qui peuvent être des IDE, des bibliothèques, etc. Par défaut, on a les applications suivantes : JupyterLab, Jupyter Notebook, Spyder, Glueviz, Orange, RStudio. (Kamingu., 2023)

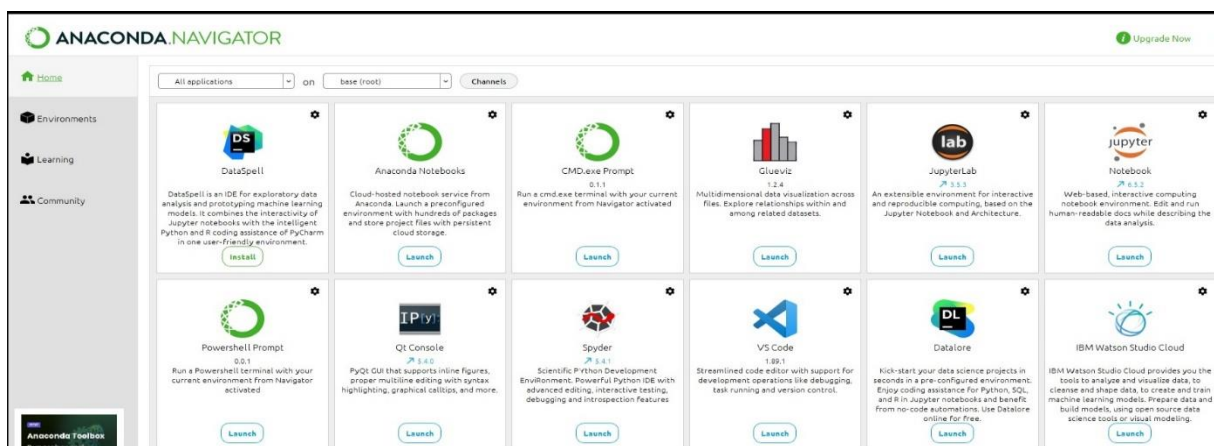


Figure III.9. Présentation du navigateur d'Anaconda.

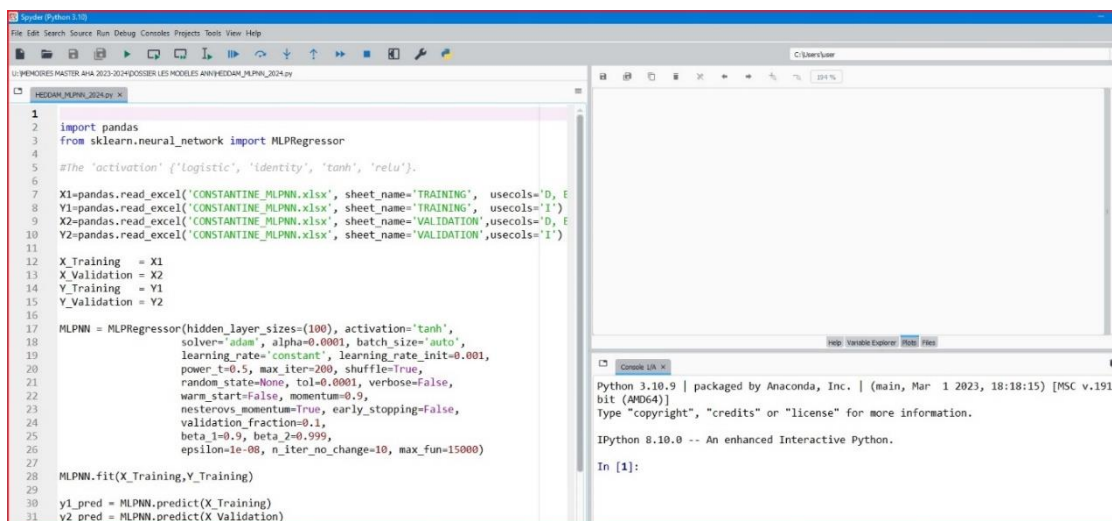
III.9. Présentation du langage Python

Python est un langage de programmation de haut niveau portable et gratuit, doté d'un typage dynamique fort, d'une gestion automatique de la mémoire et d'un système de gestion des exceptions. Python est développé depuis 1989 par Guido van Rossum et de nombreux contributeurs bénévoles (Swinnen 2012). Sa première version fut publiée le 20 février 1991 et sa dernière version date du 5 mai 2023. Python est un langage de programmation interprété, c'est-à-dire que les instructions qu'on lui envoie sont « traduites » en langage machine au fur et à mesure de leur lecture. La véritable valeur d'Anaconda réside dans sa capacité à servir de plateforme complète pour le calcul scientifique et l'analyse de données. Son intégration avec Python et R, couplée à sa vaste collection de bibliothèques et d'outils, permet aux chercheurs et aux data Scientists de s'attaquer à des tâches computationnelles complexes avec efficacité. (Kamingu, 2023)

II.7.2. Présentation de l'environnement de développement Spyder

Spyder est un environnement scientifique puissant écrit en Python, pour Python, et conçu par et pour des scientifiques, ingénieurs et analystes de données. Il offre une combinaison unique des fonctionnalités avancées d'édition, d'analyse, de débogage et de profilage d'un outil de développement complet avec l'exploration de données, l'exécution interactive, l'inspection approfondie et les belles capacités de visualisation d'un logiciel scientifique. Au-delà de ses nombreuses fonctionnalités intégrées, ses capacités peuvent être encore étendues grâce à son système de plugins et son API. De plus, Spyder peut également être utilisé comme bibliothèque d'extension, ce qui permet aux développeurs de s'appuyer sur ses fonctionnalités et d'intégrer ses composants, tels que la console interactive, dans leur propre logiciel PyQt . (Aib, , 2019)

Figure III.10. Fenêtre principale Spyder pour Python



Dans la présente mémoire nous avons utilisé le langage Python pour développer les deux modèles MLPNN et GRNN, alors que pour le modèle MLR, il est développé sous Excel. La Figure III.11 résume les étapes de la modélisation et le plan de travail général.

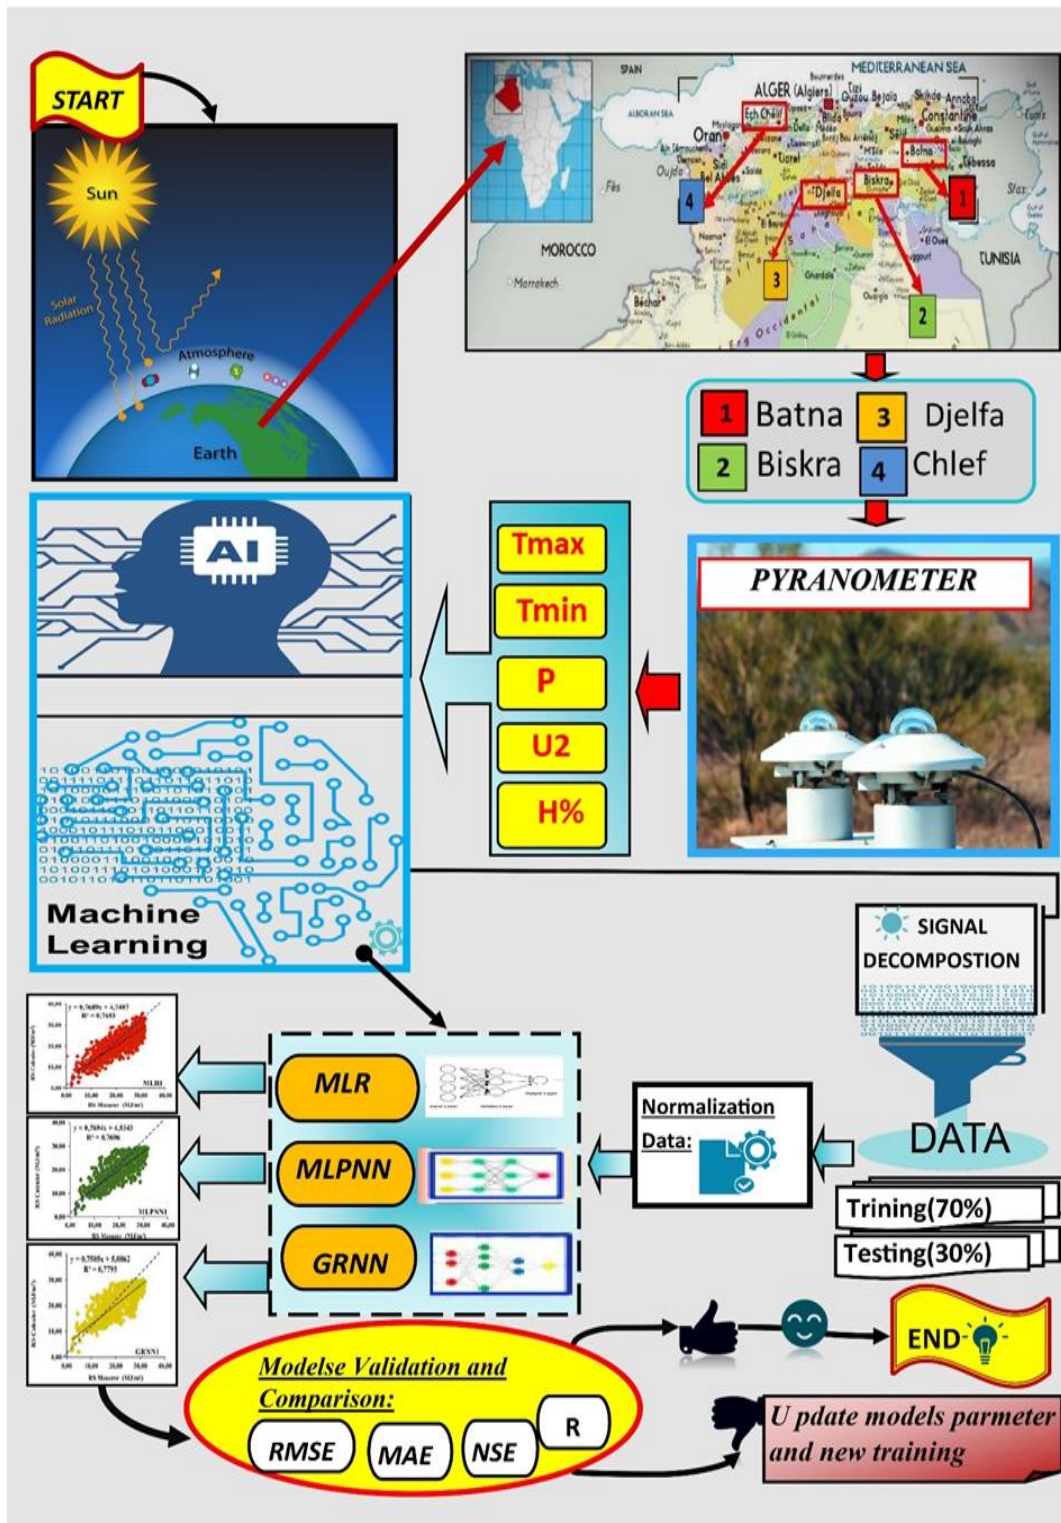


Figure III.11. Flowchart et synoptique générale de l'étude.

III.9. Conclusion

Le domaine de la prédiction des radiations solaires est devenu par le biais de l'intelligence artificielle (IA) et l'apprentissage automatique (ML) un domaine de recherche attractive. En exploitant de grandes quantités de données provenant de stations d'observation terrestres et spatiales, plusieurs modèles ont été développés. Elles peuvent prédire avec précision les valeurs de la radiation solaire avec des précisions très acceptable. Si l'IA et le ML recèlent un immense potentiel, leur développement continu est crucial pour affiner encore la précision des prévisions. La facilitation du partage de données entre les pays et les organisations, et un soutien accru à la recherche et au développement dans ce domaine unissant nos efforts et en investissant dans ces technologies prometteuses, nous pouvons façonner un avenir où l'énergie solaire éclaire nos vies de manière fiable et durable, pour le bien de tous.

Chapitre IV : Résultats et Interprétation

IV.1. Introduction

Les mesures directes de la radiation solaire sont généralement rares et imprécises dans le monde, en raison de leur coûts d'installation élevés et des difficultés d'entretien des instruments de mesure (Kisi et al. 2019 ; Bounoua et al. 2021). De plus, la prévision cohérente de la radiation solaire est un défi en raison de sa nature non linéaire. Les stratégies de prédiction basées sur l'utilisation des techniques d'intelligence artificielle (IA) et la régression linéaire pour prédire les paramètres climatiques a montré de nombreux succès qui ont été rapportés dans la littérature (Hussein et al. 2021). Dans ce chapitre nous comparons les résultats de modélisation de la radiation solaire obtenus par la technique de régression linéaire et deux modèles de réseaux de neurones artificielles, sous les abréviations (MLR, MLPNN et GRNN). Pour le développement des modèles, le langage de programmation Python a été utilisé. Les résultats sont présentés séparément pour chaque station dans les tableaux IV.1-4. En plus des résultats numériques, nous présenterons des résultats graphiques pour chaque station sous forme de courbes Scatterplots (Figures IV.1-12). Étant donné que la phase de validation est la plus importante, nous consacrons notre discussion sur les résultats obtenus par les différents modèles durant cette phase.

IV.2. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Batna

Pour la station de Batna (Tableau IV.1, Figures IV.1-3), d'une façon générale, les performances étaient faibles à moyenne, aucun modèle n'a permis d'obtenir un coefficient de corrélation (R) supérieur à 0.90. Les moyennes des valeurs de R et NSE pour les modèles MLR, MLPNN et GRNN sont de l'ordre de (0.779 et 0.593), (0.761 et 0.582) et (0.786 et 0.621), respectivement.

La meilleure combinaison des variables d'entrée pour les modèles MLR est la première combinaison (T_{\max} , T_{\min} , P, U_2 , H%) avec l'inclusion de tous les variables climatiques. Les indices numérique du modèle MLR1 sont de l'ordre de ($R \approx 0.84$, $NSE \approx 0.71$, $RMSE \approx 4.43$ et $MAE \approx 3.54$), suivi par les deux modèles MLR5 et MLR6 ($R \approx 0.84$, $NSE \approx 0.70$, $RMSE \approx 4.45$ et $MAE \approx 3.54$), ce qui explique l'effet négligeable des précipitations (P), et nous conduit à conclure que l'effet des deux variables U_2 et H% est similaire. Pour qui est des faibles performances, elles sont assurées par la dernière combinaison (T_{\min} , P) avec des indices numérique de ($R \approx 0.59$, $NSE \approx 0.34$, $RMSE \approx 6.62$ et $MAE \approx 5.42$), et avec un taux de dégradation de 42.373%, 108.824%, 33.082% et 34.686% en termes de R, NSE, RMSE et MAE, respectivement, par rapport au meilleur modèle (MLR1).

Pour les modèles MLPNN, le meilleur modèle est le MLPNN2 qui utilise la deuxième combinaison d'entrée (T_{\max} , T_{\min} , P , U_2), avec des indices numériques de ($R \approx 0.86$, $NSE \approx 0.73$, $RMSE \approx 4.24$ et $MAE \approx 3.42$), ce qui explique l'effet mineur de l'humidité relative ($H\%$). Les taux d'amélioration assurés par ce modèle par rapport au modèle qui utilise tous les variables climatiques (MLPNN1) sont de l'ordre de 8.861%, 17.742%, 15.873% et 16.176%, en termes de R , NSE , $RMSE$ et MAE , respectivement. Pour qui est des faibles performances, elles sont assurées par la dernière combinaison (T_{\min} , P) avec des indices numérique de ($R \approx 0.56$, $NSE \approx 0.31$, $RMSE \approx 6.80$ et $MAE \approx 5.50$), et avec un taux de dégradation de 53.571%, 135.484%, 37.647% et 37.818% en termes de R , NSE , $RMSE$ et MAE , respectivement, par rapport au meilleur modèle (MLPNN2).

Pour les modèles GRNN, les meilleures performances sont obtenues avec le modèle GRNN5 ($R \approx 0.85$, $NSE \approx 0.72$, $RMSE \approx 4.34$ et $MAE \approx 3.44$) qui utilise la cinquième combinaison (T_{\max} , T_{\min} , U_2), ce qui explique l'effet mineur des précipitations (P) et de l'humidité relative ($H\%$). Les taux d'amélioration assurés par ce modèle par rapport au modèle qui utilise tous les variables climatiques (GRNN1) sont de l'ordre de 1.190%, 1.408%, 1.587% et 1.714%, en termes de R , NSE , $RMSE$ et MAE , respectivement. Pour qui est des faibles performances, elles sont assurées par la douzième combinaison (T_{\min} , P) avec des indices numérique de ($R \approx 0.65$, $NSE \approx 0.42$, $RMSE \approx 6.23$ et $MAE \approx 5.18$), et avec des taux de dégradation de 30.769%, 71.429%, 30.337% et 33.591% en termes de R , NSE , $RMSE$ et MAE , respectivement, par rapport au meilleur modèle (GRNN5).

Les modèles proposés ont été comparés sur la base des représentations graphiques (Figures IV1, IV2 et IV3), les Scatterplots des valeurs calculées et observées de la radiation solaire durant la phase de validation montrent que le modèle MLPNN6 est le modèle qui donne les données les moins dispersées (forte corrélation). Par contre, la dernière combinaison a donné les données les plus dispersées (faible corrélation).

Table IV.1. Performances des différents modèles : Station de Batna

Modèles	Training				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLR1	0.84	0.71	4.35	3.43	0.84	0.71	4.43	3.54
MLR2	0.84	0.71	4.35	3.44	0.84	0.70	4.45	3.55
MLR3	0.82	0.48	4.59	3.66	0.82	0.46	4.68	3.76
MLR4	0.82	0.68	4.62	3.68	0.82	0.67	4.68	3.77
MLR5	0.84	0.71	4.37	3.45	0.84	0.70	4.45	3.54
MLR6	0.84	0.71	4.37	3.45	0.84	0.70	4.45	3.54
MLR7	0.82	0.68	4.60	3.67	0.82	0.67	4.68	3.76
MLR8	0.70	0.49	5.95	4.68	0.69	0.47	5.78	4.82
MLR9	0.75	0.56	5.36	4.26	0.75	0.56	5.42	4.29
MLR10	0.70	0.49	5.80	4.70	0.68	0.46	5.99	4.85
MLR11	0.82	0.67	4.64	3.69	0.82	0.67	4.68	3.76
MLR12	0.58	0.33	6.61	5.44	0.59	0.34	6.62	5.42
MLPNN1	0.79	0.63	4.96	3.99	0.79	0.62	5.04	4.08
MLPNN2	0.86	0.74	4.14	3.30	0.86	0.73	4.24	3.42
MLPNN3	0.83	0.69	4.50	3.58	0.82	0.67	4.68	3.74
MLPNN4	0.83	0.68	4.57	3.68	0.82	0.68	4.63	3.77
MLPNN5	0.79	0.62	4.98	4.02	0.79	0.62	5.07	4.12
MLPNN6	0.83	0.69	4.54	3.63	0.82	0.66	4.74	3.80
MLPNN7	0.65	0.41	6.22	5.19	0.63	0.39	6.39	5.39
MLPNN8	0.77	0.59	5.20	4.18	0.76	0.57	5.33	4.26
MLPNN9	0.71	0.51	5.69	4.63	0.71	0.50	5.78	4.75
MLPNN10	0.82	0.67	4.63	3.73	0.82	0.66	4.74	3.86
MLPNN11	0.76	0.58	5.25	4.21	0.75	0.57	5.39	4.30
MLPNN12	0.55	0.30	6.77	5.51	0.56	0.31	6.80	5.50
GRNN1	0.91	0.82	3.46	2.62	0.84	0.71	4.41	3.50
GRNN2	0.90	0.80	3.58	2.72	0.84	0.71	4.43	3.50
GRNN3	0.88	0.77	3.92	3.03	0.82	0.67	4.72	3.76
GRNN4	0.86	0.73	4.20	3.26	0.82	0.67	4.69	3.73
GRNN5	0.88	0.78	3.83	3.00	0.85	0.72	4.34	3.44
GRNN6	0.86	0.73	4.19	3.32	0.82	0.68	4.64	3.71
GRNN7	0.76	0.58	5.28	4.23	0.72	0.51	5.73	4.64
GRNN8	0.81	0.65	4.78	3.80	0.78	0.61	5.14	4.07
GRNN9	0.76	0.57	5.29	4.24	0.70	0.49	5.84	4.69
GRNN10	0.84	0.71	4.37	3.47	0.82	0.67	4.69	3.76
GRNN11	0.79	0.62	5.00	4.00	0.77	0.59	5.21	4.16
GRNN12	0.70	0.49	5.77	4.68	0.65	0.42	6.23	5.18




Figure IV.1. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Batna & modèles MLR

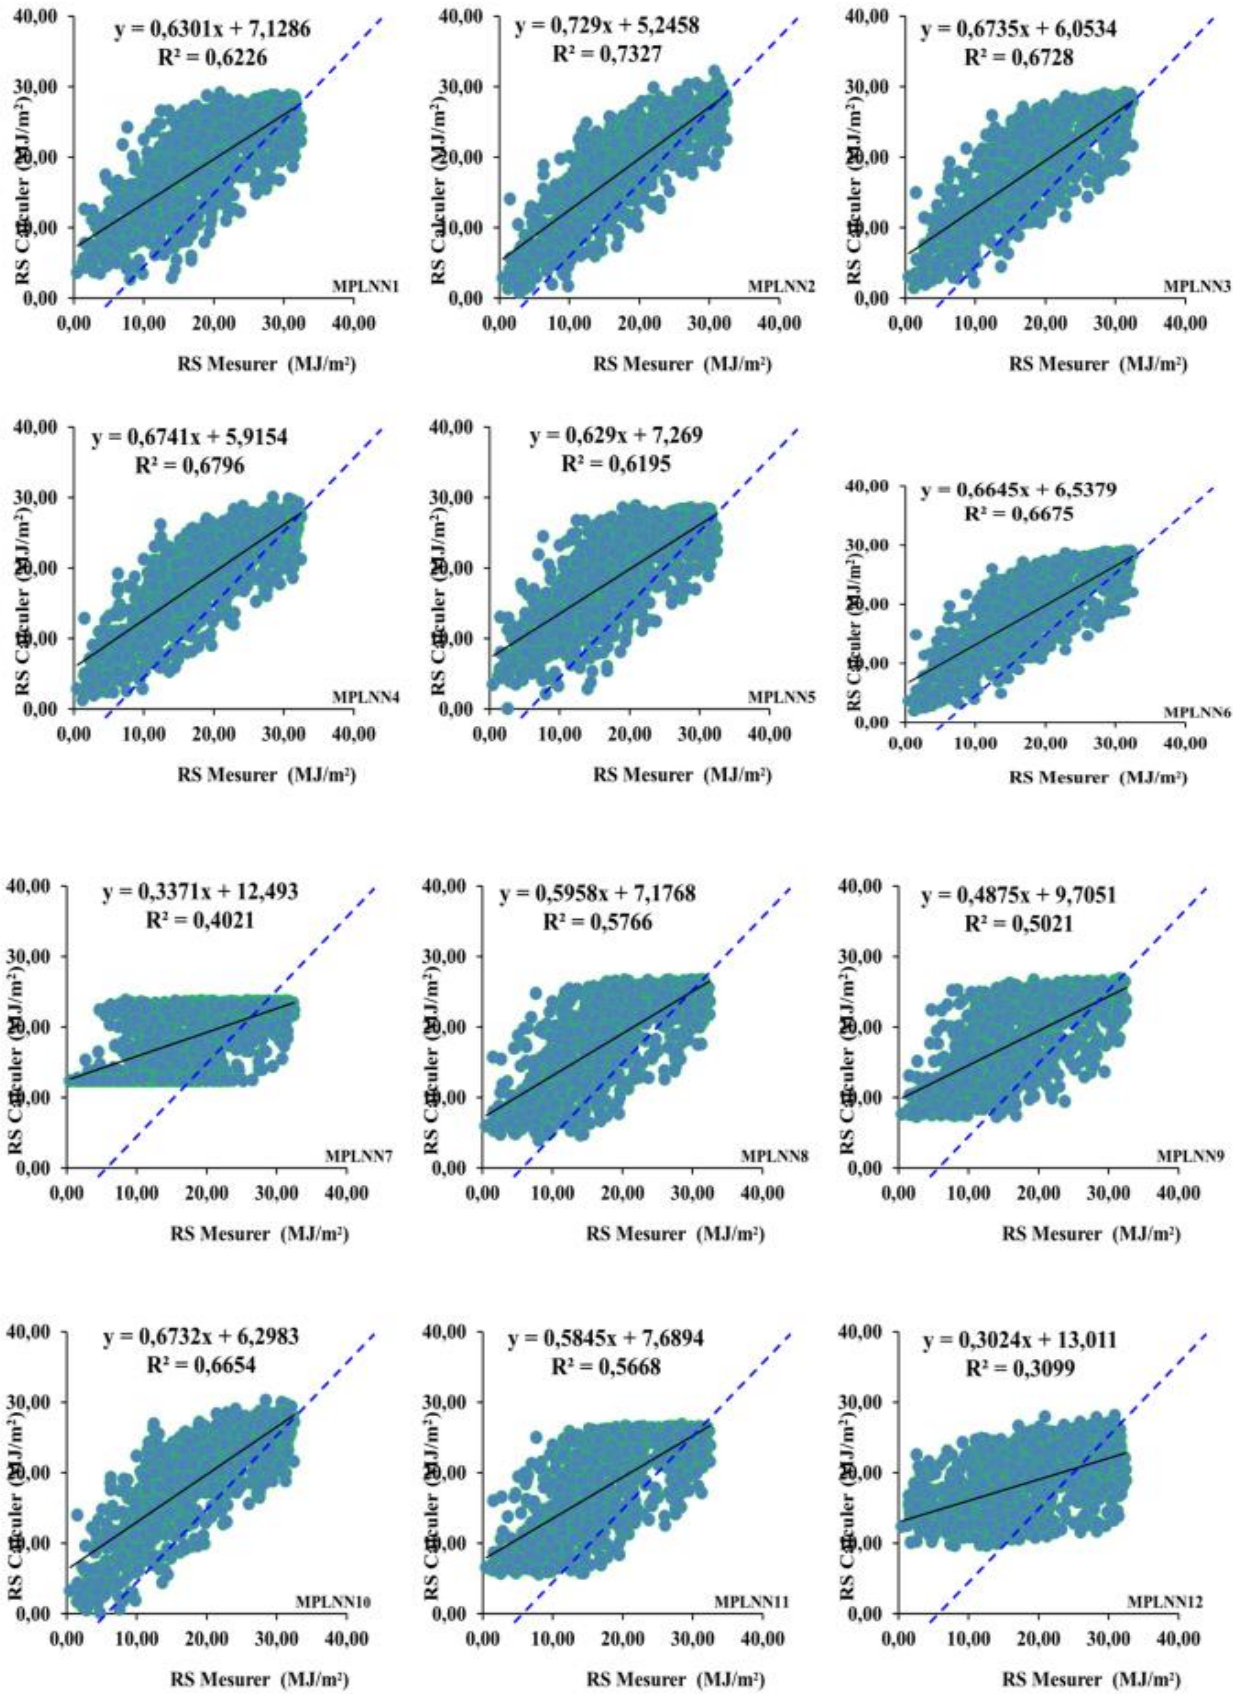


Figure IV.2. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Batna & modèles MLPNN

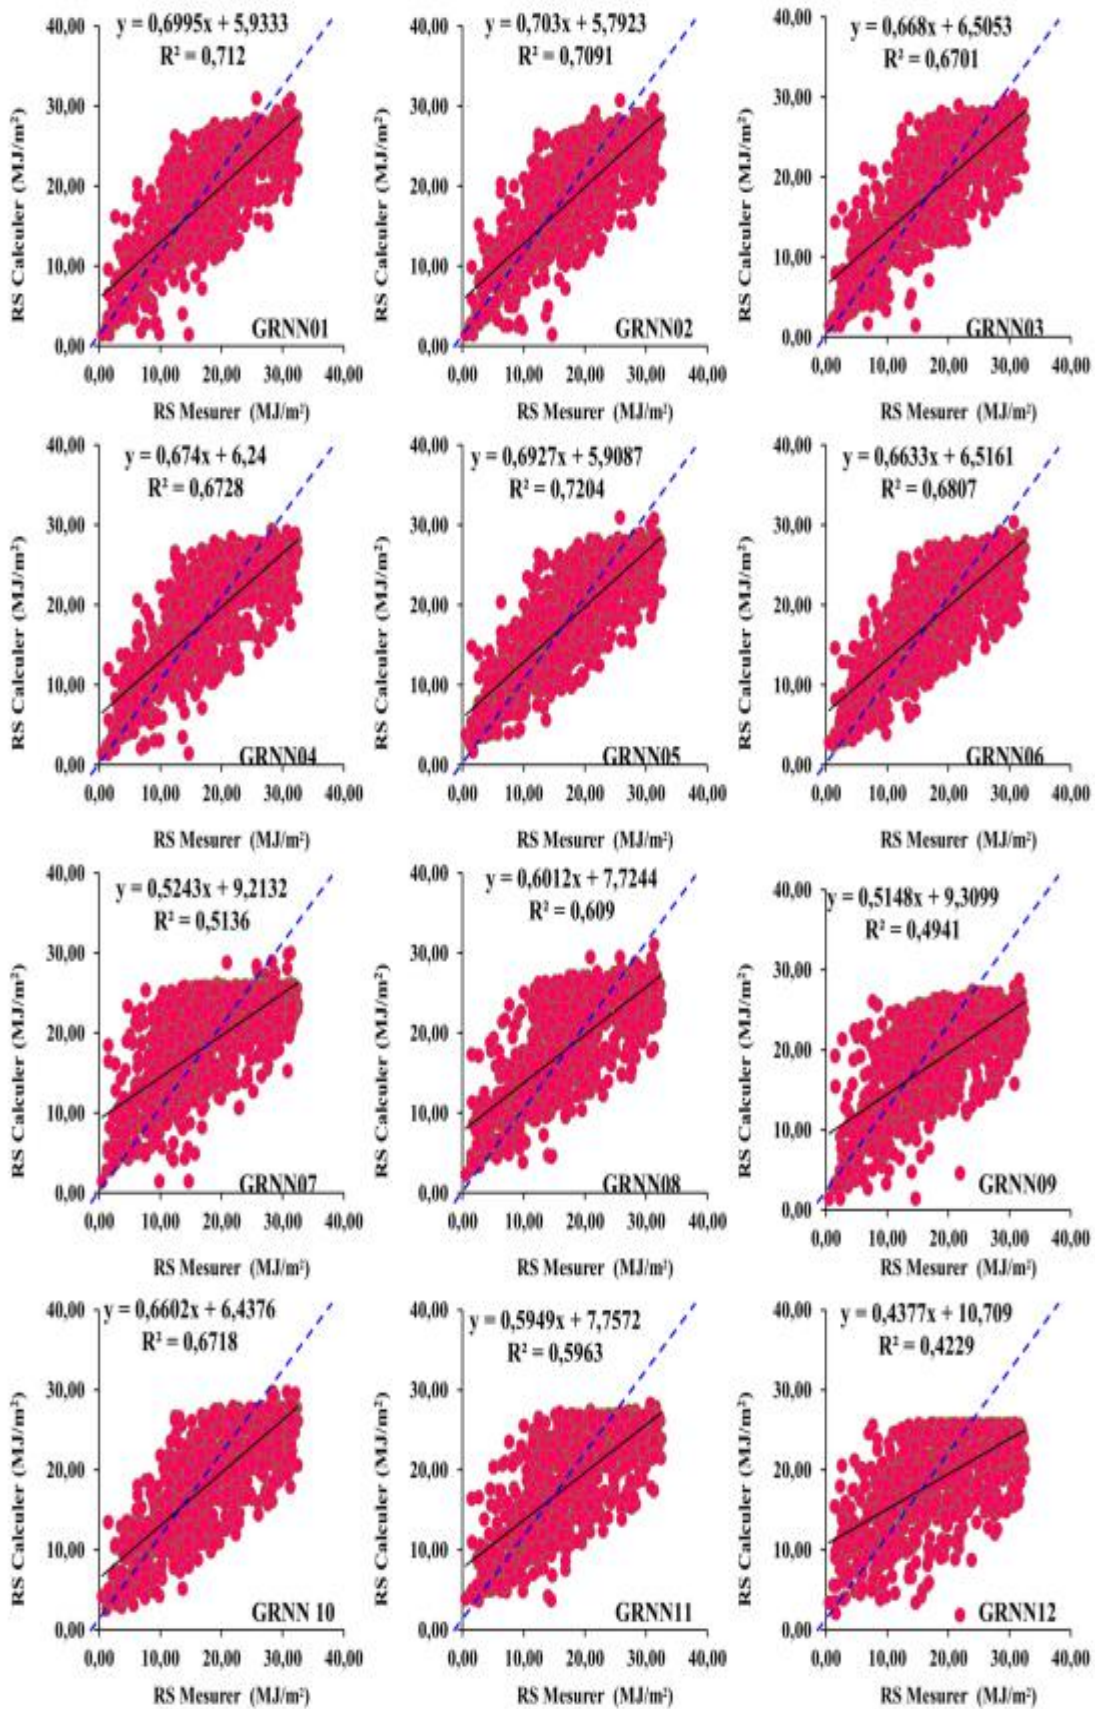


Figure IV.3. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Batna & modèles GRNN

IV.3. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Biskra

Au niveau de la station de Biskra (Tableau IV.2, Figures IV.4-6), les performances des modèles étaient meilleures par rapport à la station de Batna. Les moyennes des valeurs de R et NSE sont de l'ordre de (0.828 et 0.690), (0.838 et 0.702), (0.837 et 0.702), pour les modèles MLR, MLPNN et GRNN, respectivement.

La remarque la plus importante est l'effet des variables d'entrées des modèles: tous les modèles utilisant la première combinaison avec tous les variables climatiques (T_{\max} , T_{\min} , P, U_2 , H%) ont assuré les meilleures performances. Le meilleur modèle est le modèle GRNN1 avec les plus grands R et NSE (0.88, 0.78) et les plus faibles RMSE et MAE (3.52, 2.66), suivi par le modèle MLPNN1 ($R \approx 0.88$, $NSE \approx 0.77$, $RMSE \approx 3.61$, $MAE \approx 2.71$), suivi par le modèle MLR1 ($R \approx 0.87$, $NSE \approx 0.76$, $RMSE \approx 3.63$, $MAE \approx 2.84$).

Pour les modèles à quatre variables d'entrée, les meilleurs résultats sont obtenus avec les modèles utilisant la deuxième combinaison, et le GRNN2 assure les meilleurs performances ($R \approx 0.88$, $NSE \approx 0.77$, $RMSE \approx 3.59$, $MAE \approx 2.72$), suivi par le modèle MLPNN2 ($R \approx 0.88$, $NSE \approx 0.77$, $RMSE \approx 3.57$, $MAE \approx 2.82$), suivi par le modèle MLR2 ($R \approx 0.87$, $NSE \approx 0.76$, $RMSE \approx 3.65$, $MAE \approx 2.88$).

Avec la troisième combinaison, le modèle GRNN3 garantit les meilleurs performances ($R \approx 0.86$, $NSE \approx 0.74$, $RMSE \approx 3.80$, $MAE \approx 2.88$), suivi par le modèle MLPNN3 ($R \approx 0.86$, $NSE \approx 0.74$, $RMSE \approx 3.83$, $MAE \approx 2.93$), suivi par le modèle MLR3 ($R \approx 0.85$, $NSE \approx 0.72$, $RMSE \approx 3.94$, $MAE \approx 3.06$).

Pour les modèles à trois variables d'entrée (la quatrième à la neuvième combinaison), les moyennes des valeurs de R et NSE sont de (0.830 et 0.692), (0.838 et 0.702) et (0.838 et 0.702) pour le MLR, MLPNN et GRNN, respectivement.

Avec les modèles utilisant deux variables d'entrée (la dixième à la douzième), les résultats obtenus étaient faibles, surtout lorsqu'en utilisant la dernière combinaison, les modèles MLR12, MLPNN12 et GRNN12 assurent les faibles performances au niveau de la station, et les taux de réduction des performances du modèle MLR12 ($R \approx 0.71$, $NSE \approx 0.51$, $RMSE \approx 5.24$, $MAE \approx 4.26$) par rapport au meilleur modèle au niveau de la station (GRNN1) sont de l'ordre de 23.944%, 52.941%, 32.824%, et 37.559% , en termes de R, NSE, RMSE, et MAE, respectivement.

La représentation graphique (Figures IV.4, IV.5, et IV.6) montre la même tendance que les résultats numériques, l'utilisation de la première combinaison assurent les données les moins dispersées, Par contre, la dernière combinaison a donné les données les plus dispersées.

Table IV.2. Performances des différents modèles : Station de Biskra

<i>Modèles</i>	<i>Training</i>				<i>Validation</i>			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<i>MLR1</i>	0.87	0.76	3.65	2.88	0.87	0.76	3.63	2.84
<i>MLR2</i>	0.87	0.76	3.69	2.93	0.87	0.76	3.65	2.88
<i>MLR3</i>	0.85	0.72	3.93	3.06	0.85	0.72	3.94	3.06
<i>MLR4</i>	0.84	0.70	4.08	3.25	0.84	0.71	4.04	3.18
<i>MLR5</i>	0.87	0.75	3.70	2.93	0.87	0.76	3.66	2.88
<i>MLR6</i>	0.85	0.72	3.93	3.07	0.85	0.72	3.94	3.05
<i>MLR7</i>	0.81	0.65	4.41	3.42	0.80	0.64	4.50	3.47
<i>MLR8</i>	0.83	0.69	4.13	3.22	0.82	0.68	4.24	3.25
<i>MLR9</i>	0.81	0.66	4.36	3.37	0.80	0.64	4.48	3.43
<i>MLR10</i>	0.84	0.70	4.10	3.26	0.84	0.71	4.05	3.18
<i>MLR11</i>	0.83	0.69	4.19	3.24	0.82	0.67	4.30	3.28
<i>MLR12</i>	0.72	0.52	5.18	4.19	0.71	0.51	5.24	4.26
<i>MLPNN1</i>	0.88	0.78	3.53	2.71	0.88	0.77	3.61	2.71
<i>MLPNN2</i>	0.88	0.77	3.53	2.86	0.88	0.77	3.57	2.82
<i>MLPNN3</i>	0.86	0.75	3.76	2.91	0.86	0.74	3.83	2.93
<i>MLPNN4</i>	0.85	0.71	4.01	3.22	0.85	0.72	3.99	3.15
<i>MLPNN5</i>	0.88	0.77	3.57	2.85	0.88	0.77	3.56	2.81
<i>MLPNN6</i>	0.86	0.75	3.76	2.90	0.86	0.74	3.84	2.91
<i>MLPNN7</i>	0.80	0.63	4.51	3.53	0.80	0.64	4.52	3.54
<i>MLPNN8</i>	0.84	0.71	4.02	3.09	0.83	0.69	4.20	3.13
<i>MLPNN9</i>	0.82	0.67	4.30	3.30	0.81	0.65	4.43	3.37
<i>MLPNN10</i>	0.85	0.72	3.98	3.21	0.85	0.72	3.97	3.13
<i>MLPNN11</i>	0.83	0.70	4.11	3.17	0.82	0.67	4.28	3.22
<i>MLPNN12</i>	0.74	0.55	4.99	4.09	0.74	0.54	5.08	4.06
<i>GRNN1</i>	0.92	0.84	3.01	2.28	0.88	0.78	3.52	2.66
<i>GRNN2</i>	0.91	0.82	3.15	2.40	0.88	0.77	3.59	2.72
<i>GRNN3</i>	0.88	0.78	3.50	2.68	0.86	0.74	3.80	2.88
<i>GRNN4</i>	0.87	0.75	3.74	2.91	0.85	0.73	3.93	3.02
<i>GRNN5</i>	0.91	0.82	3.16	2.42	0.88	0.77	3.58	2.71
<i>GRNN6</i>	0.88	0.78	3.51	2.69	0.86	0.74	3.80	2.88
<i>GRNN7</i>	0.82	0.67	4.31	3.27	0.80	0.64	4.48	3.37
<i>GRNN8</i>	0.85	0.73	3.88	2.98	0.83	0.68	4.20	3.13
<i>GRNN9</i>	0.83	0.69	4.17	3.16	0.81	0.65	4.43	3.28
<i>GRNN10</i>	0.87	0.75	3.74	2.91	0.85	0.73	3.93	3.02
<i>GRNN11</i>	0.84	0.71	4.05	3.12	0.82	0.67	4.27	3.22
<i>GRNN12</i>	0.77	0.60	4.74	3.78	0.72	0.52	5.17	4.11

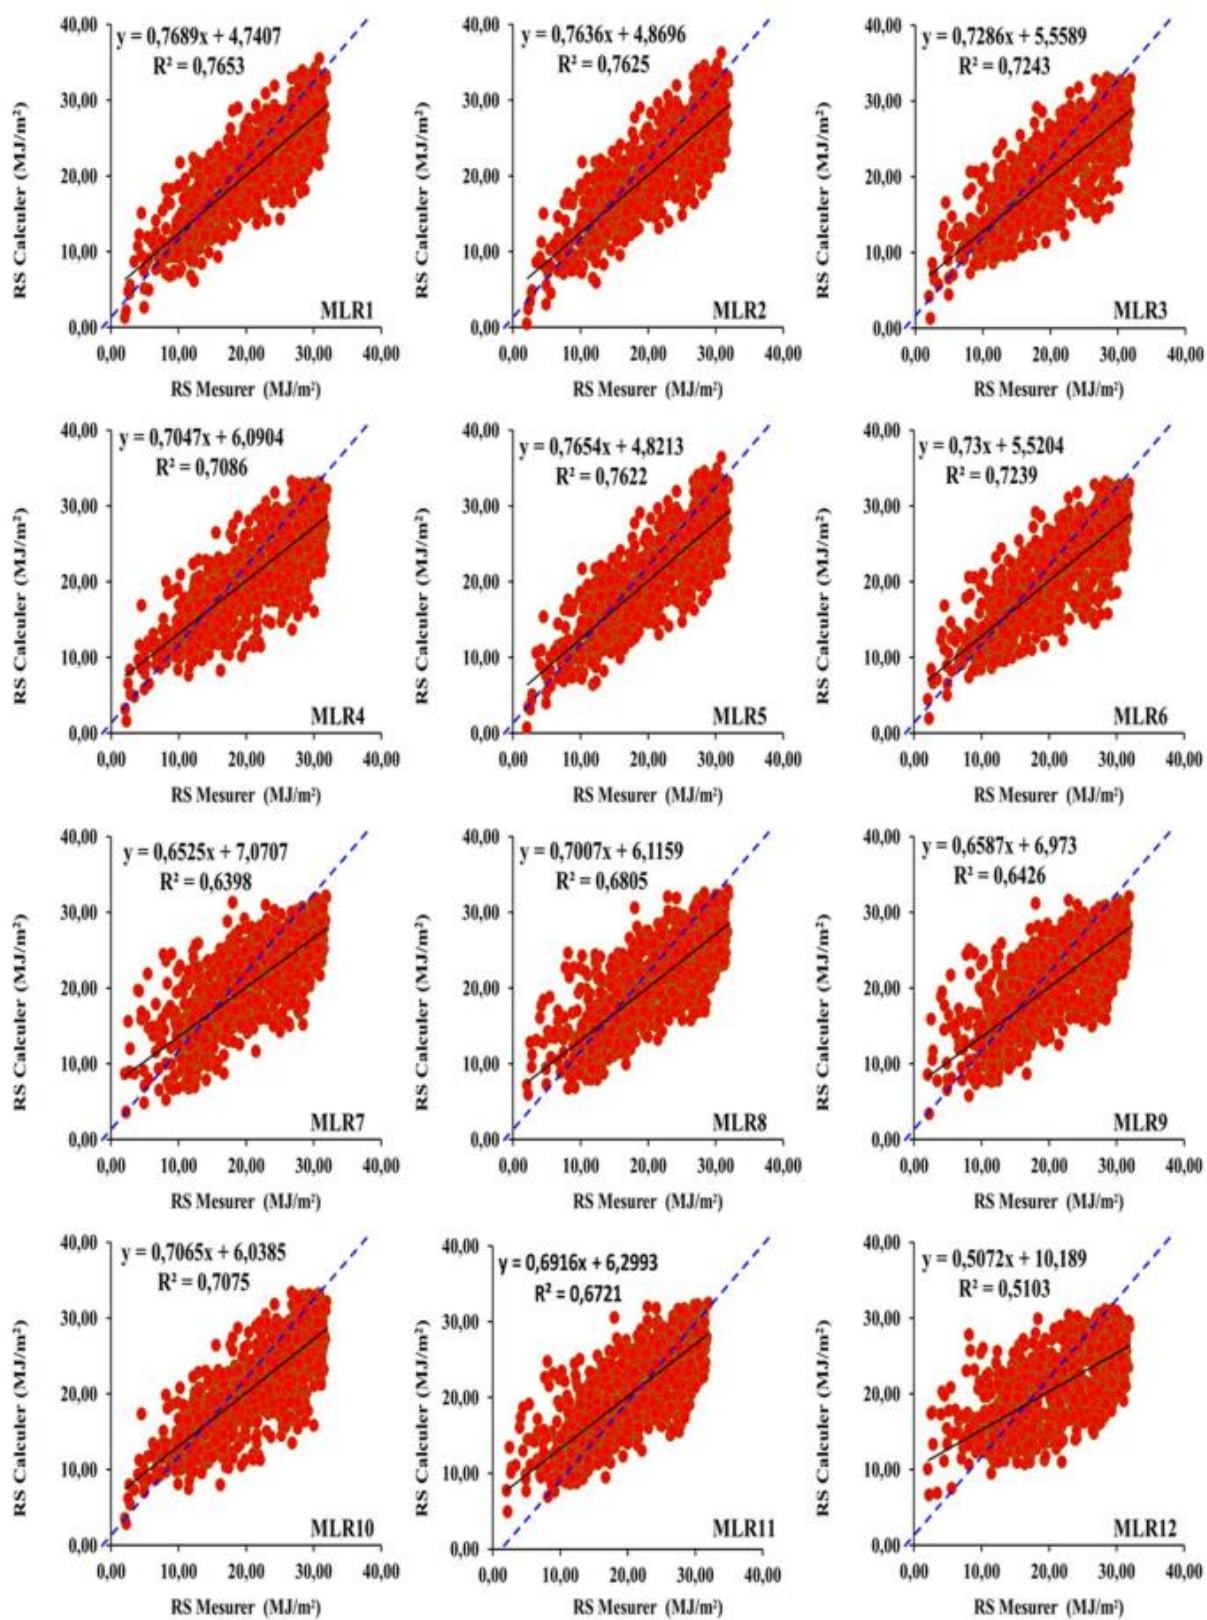


Figure IV.4. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Biskra & modèles MLR

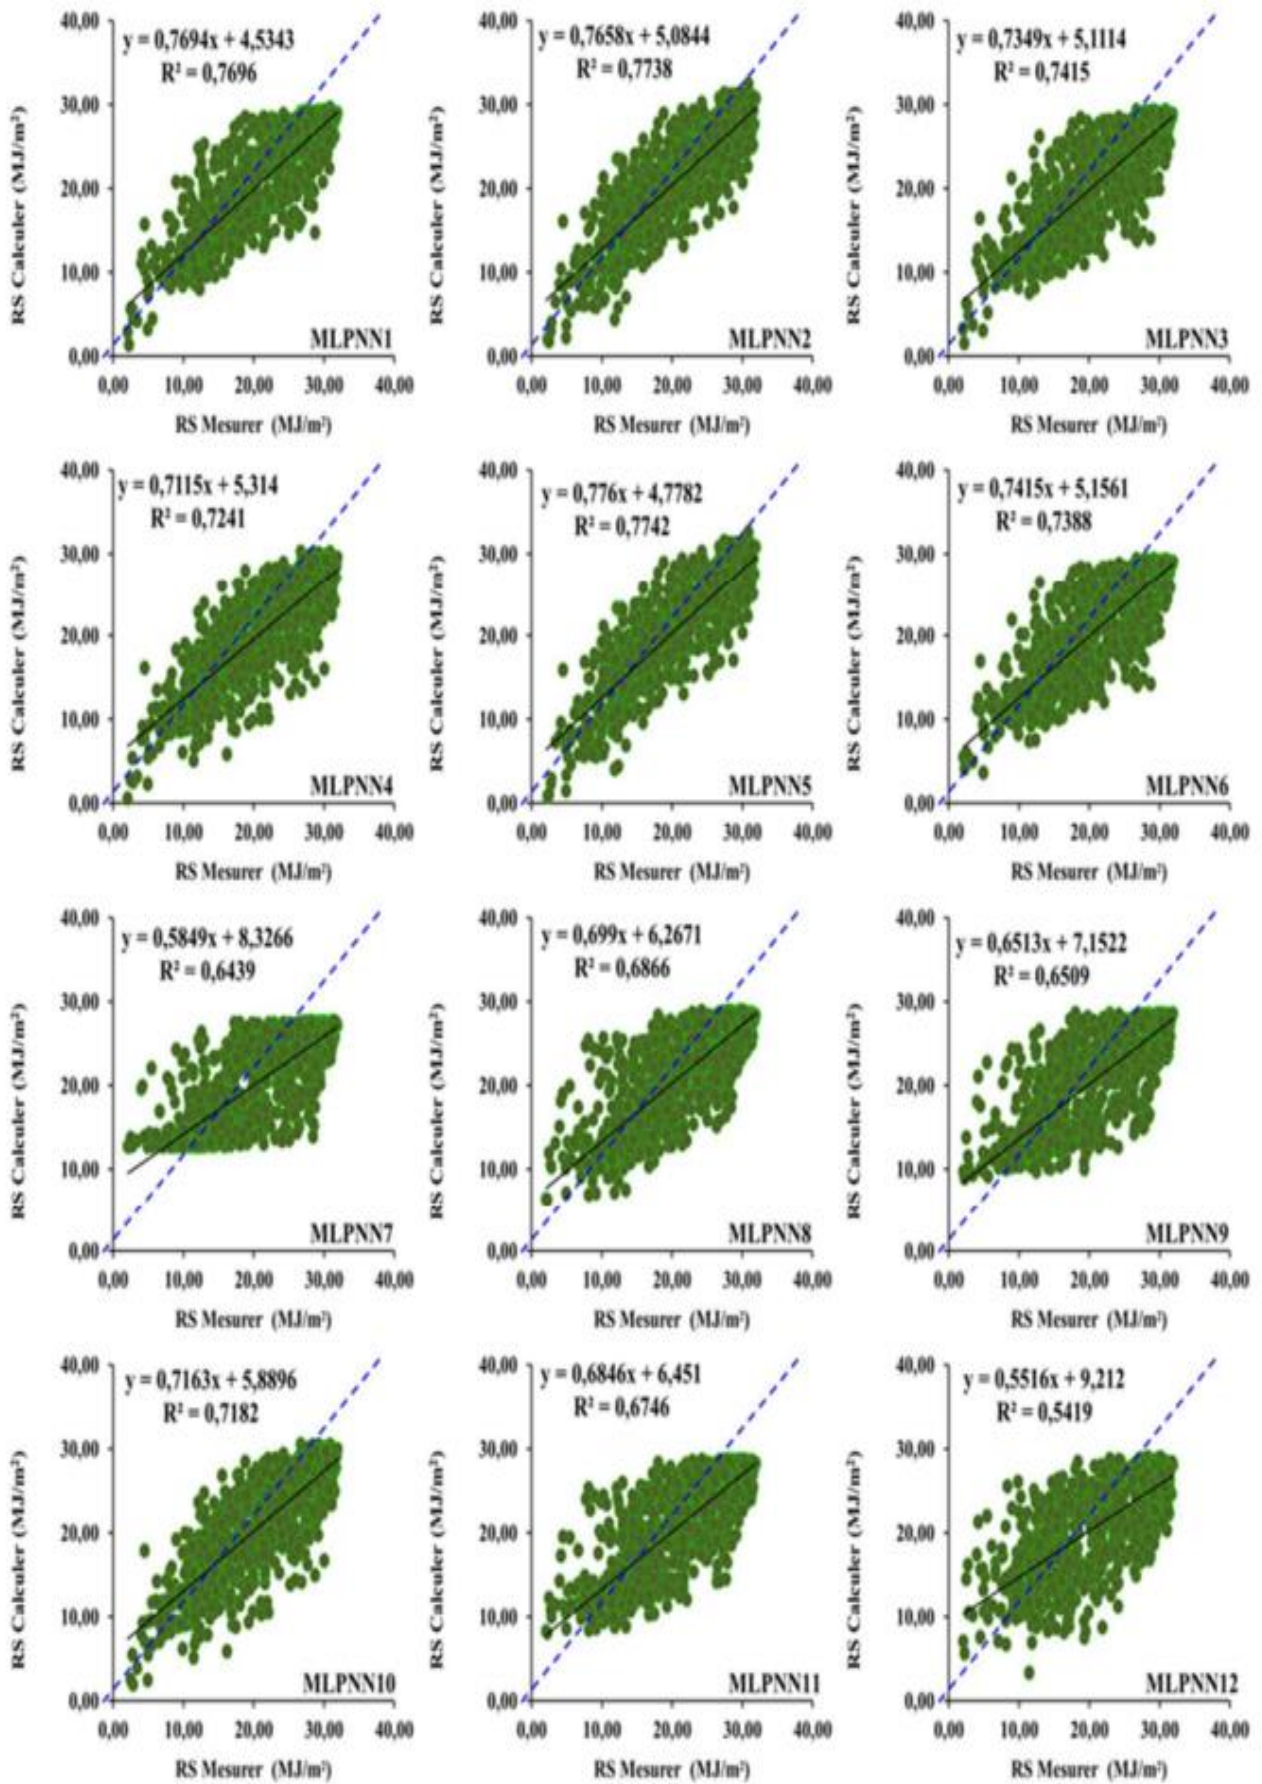


Figure IV.5. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Biskra & modèles MLPNN

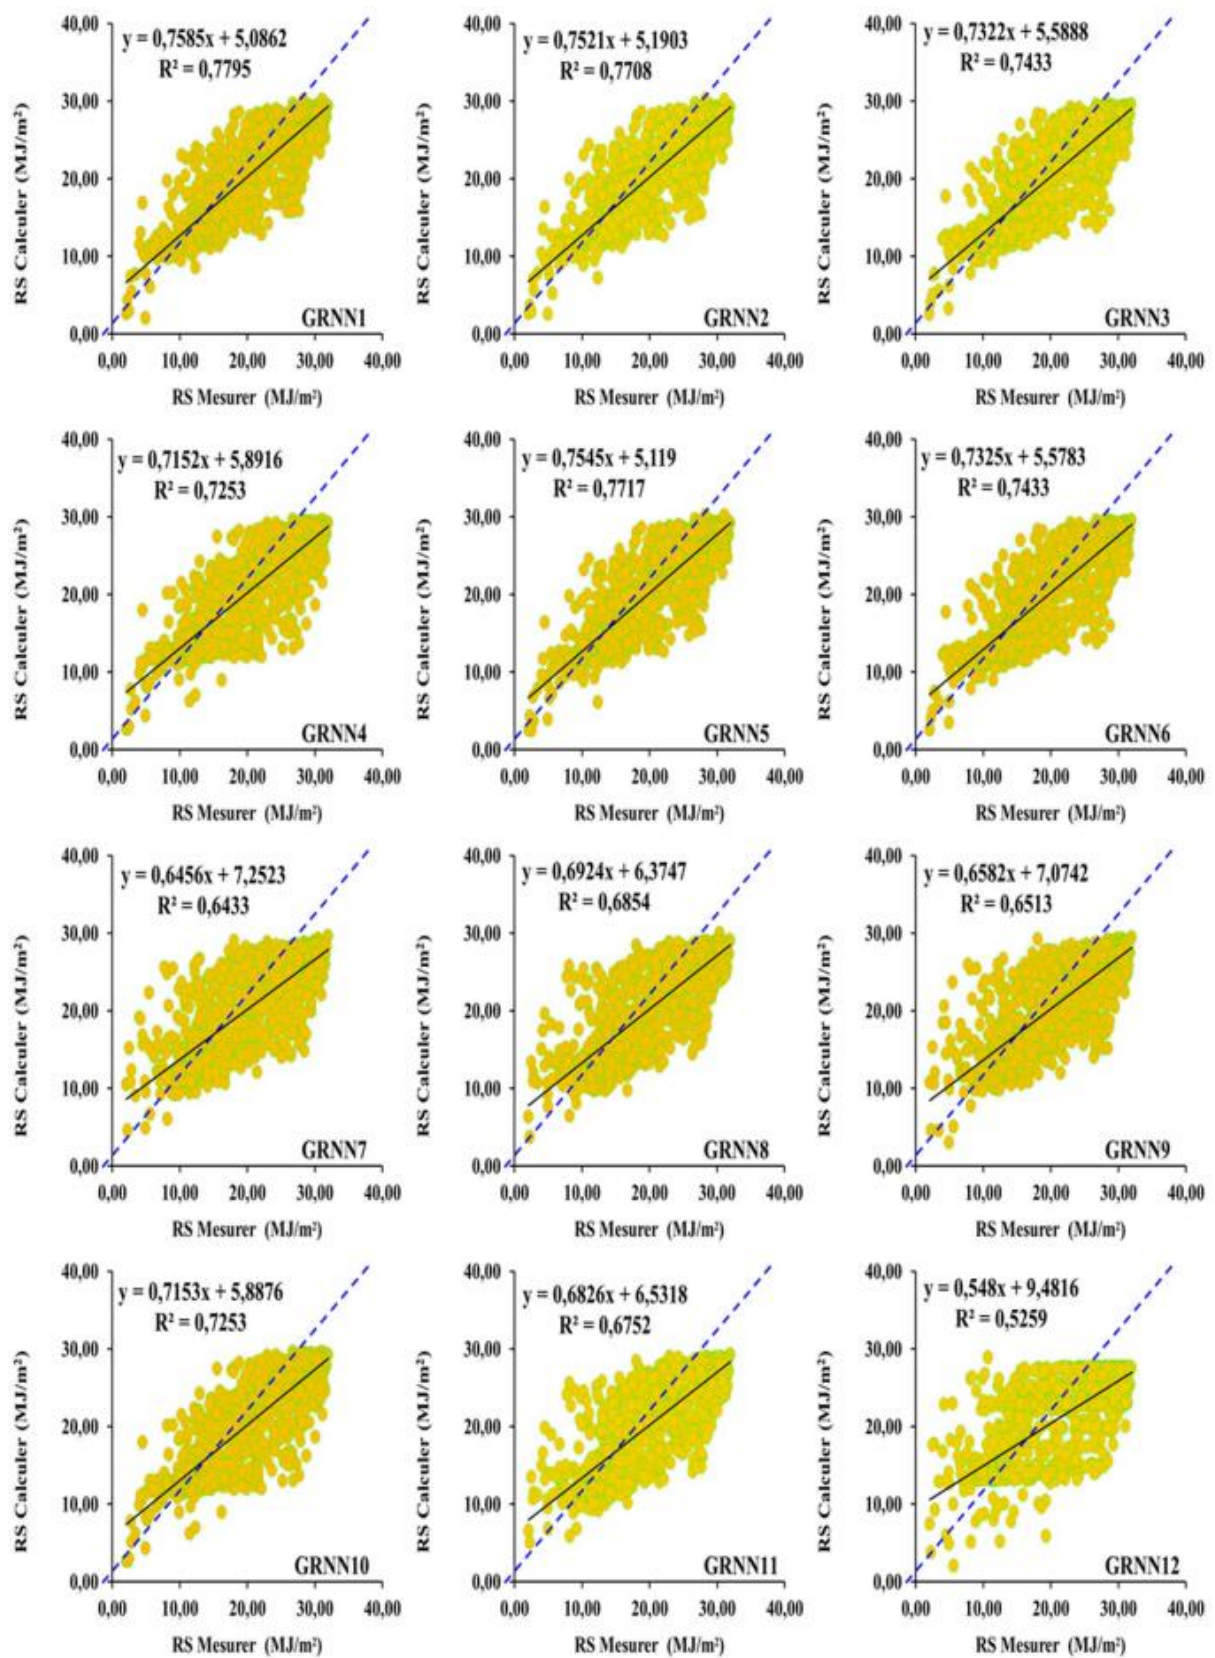


Figure IV.6. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Biskra & modèles GRNN

IV.4. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Djelfa

Pour la station de Djelfa (Tableau IV.3, Figures IV.7-9), d'une façon générale, les performances étaient faibles par rapport à la station de Biskra et similaire par rapport à la station Batna. Les modèles GRNN ont donnés des valeurs de R et NSE allant de ≈ 0.85 à ≈ 0.68 (moyenne ≈ 0.804), et ≈ 0.72 à ≈ 0.46 (moyenne ≈ 0.643), les modèles MLPNN ont donnés des valeurs de R et NSE allant de ≈ 0.86 à ≈ 0.68 (moyenne ≈ 0.790) et de ≈ 0.74 à ≈ 0.46 (moyenne ≈ 0.627), tandis que les valeurs obtenues à l'aide des modèles MLR allant de ≈ 0.83 à ≈ 0.59 (moyenne ≈ 0.770) et de ≈ 0.69 à ≈ 0.34 (moyenne ≈ 0.597).

Le modèle MLPNN2 qui utilise la deuxième combinaison avec quatre variables climatiques (T_{\max} , T_{\min} , P, U_2) est le plus performant au niveau de la station de Djelfa, avec des indices numériques de l'ordre de ($R \approx 0.86$, $NSE \approx 0.74$, $RMSE \approx 4.08$, $MAE \approx 3.25$), et avec l'inclusion de l'humidité relative (H%) (la première combinaison), les performances se dégradent, et nous obtenons des diminution en termes de R, NSE, RMSE et MAE avec des taux de l'ordre de 2.381%, 4.225%, 4.895% et 4.130%, respectivement, par rapport au modèle MLPNN1, ce qui nous permet de conclure que l'utilisation de l'H% comme entrée des différent modèles ne permet pas d'améliorer les Performances.

Le modèle le moins performant au niveau de la station est le modèle MLR6, avec des indices numériques de l'ordre de ($R \approx 0.59$, $NSE \approx 0.34$, $RMSE \approx 6.47$, $MAE \approx 5.29$), et avec des taux de réductions par rapport au meilleur modèle de la station (MLPNN2) de l'ordre de 45.763%, 117.647%, 36.940% et 38.563% en termes de R, NSE, RMSE et MAE, respectivement.

La remarque la plus importante est l'effet prédominant de la vitesse du vent (U_2), surtout lorsqu'il est combiné avec la température maximale (T_{\max}) et minimale (T_{\min}), les modèles utilisant la cinquième combinaison avec trois variables d'entrée (T_{\max} , T_{\min} , U_2) assure des performances similaires à celle obtenus par la première et la deuxième combinaison.

D'une façon générale, la dernière combinaison d'entrée (T_{\min} , P) assure les faibles résultats au niveau de la station, et les taux de réduction des performances des modèles MLR12, MLPNN12 et GRNN12 en termes de R, NSE, RMSE et MAE sont de l'ordre de (40.678%, 102.941%, 31.221%, 33.459%), (26.471%, 60.870%, 30.137%, 32.990) et (25.000%, 56.522%, 27.939%, 30.625%) par rapport aux meilleurs modèles (MLR2, MLPNN2 et GRNN1), respectivement.

Les modèles ont été comparés d'une façon graphique, comme le montrent les figures IV.7, IV.8, et IV.9. Les Scatterplots des valeurs calculées et mesurées de la radiation solaire durant la phase de validation pour tous les modèles, nous permet de conclure que les données

étaient moins dispersées (forte corrélation) en utilisant la deuxième combinaison d'entrée. Par contre, la dernière combinaison a donné les données les plus dispersées (faible corrélation).

Table IV.3. Performances des différents modèles : Station de Djelfa

<i>Models</i>	<i>Training</i>				<i>Validation</i>			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<i>MLR1</i>	0.83	0.69	4.45	3.54	0.83	0.69	4.45	3.52
<i>MLR2</i>	0.83	0.69	4.45	3.54	0.83	0.69	4.45	3.52
<i>MLR3</i>	0.83	0.69	4.45	3.54	0.81	0.66	4.68	3.73
<i>MLR4</i>	0.81	0.65	4.73	3.79	0.81	0.65	4.71	3.75
<i>MLR5</i>	0.83	0.69	4.48	3.56	0.83	0.68	4.50	3.55
<i>MLR6</i>	0.81	0.65	4.73	3.79	0.81	0.65	4.72	3.77
<i>MLR7</i>	0.72	0.52	5.51	4.43	0.73	0.53	5.49	4.46
<i>MLR8</i>	0.74	0.55	5.37	4.27	0.74	0.55	5.36	4.32
<i>MLR9</i>	0.72	0.53	5.51	4.43	0.72	0.53	5.50	4.46
<i>MLR10</i>	0.80	0.64	4.78	3.82	0.80	0.64	4.77	3.81
<i>MLR11</i>	0.74	0.55	5.37	4.27	0.74	0.55	5.36	4.32
<i>MLR12</i>	0.58	0.34	6.49	5.33	0.59	0.34	6.47	5.29
<i>MLPNN1</i>	0.85	0.72	4.23	3.35	0.84	0.71	4.29	3.39
<i>MLPNN2</i>	0.86	0.74	4.11	3.28	0.86	0.74	4.08	3.25
<i>MLPNN3</i>	0.83	0.69	4.47	3.57	0.82	0.68	4.52	3.59
<i>MLPNN4</i>	0.82	0.68	3.56	3.68	0.82	0.68	3.53	3.61
<i>MLPNN5</i>	0.85	0.72	4.24	3.38	0.85	0.72	4.21	3.35
<i>MLPNN6</i>	0.82	0.68	4.54	3.61	0.82	0.67	4.56	3.62
<i>MLPNN7</i>	0.72	0.52	5.52	4.46	0.71	0.50	5.63	4.56
<i>MLPNN8</i>	0.76	0.57	5.23	4.22	0.76	0.57	5.23	4.26
<i>MLPNN9</i>	0.76	0.57	5.24	4.20	0.75	0.56	5.30	4.29
<i>MLPNN10</i>	0.75	0.56	5.30	4.29	0.82	0.66	4.63	3.70
<i>MLPNN11</i>	0.75	0.56	5.28	4.25	0.75	0.57	5.24	4.29
<i>MLPNN12</i>	0.69	0.48	6.76	4.78	0.68	0.46	5.84	4.85
<i>GRNN1</i>	0.89	0.80	3.61	2.79	0.85	0.72	4.23	3.33
<i>GRNN2</i>	0.89	0.79	3.68	2.83	0.85	0.71	4.28	3.36
<i>GRNN3</i>	0.85	0.73	4.19	3.30	0.83	0.68	4.50	3.59
<i>GRNN4</i>	0.84	0.71	4.34	3.40	0.82	0.67	4.58	3.64
<i>GRNN5</i>	0.88	0.77	3.85	3.00	0.85	0.72	4.25	3.35
<i>GRNN6</i>	0.85	0.72	4.24	3.36	0.83	0.68	4.49	3.58
<i>GRNN7</i>	0.78	0.61	4.96	3.92	0.75	0.56	5.32	4.27
<i>GRNN8</i>	0.78	0.61	5.01	3.97	0.78	0.60	5.04	4.07
<i>GRNN9</i>	0.83	0.68	4.49	3.56	0.82	0.67	4.58	3.63
<i>GRNN10</i>	0.83	0.68	4.49	3.56	0.82	0.67	4.58	3.63
<i>GRNN11</i>	0.77	0.69	5.11	4.09	0.77	0.60	5.07	4.13
<i>GRNN12</i>	0.74	0.54	5.42	4.40	0.68	0.46	5.87	4.80

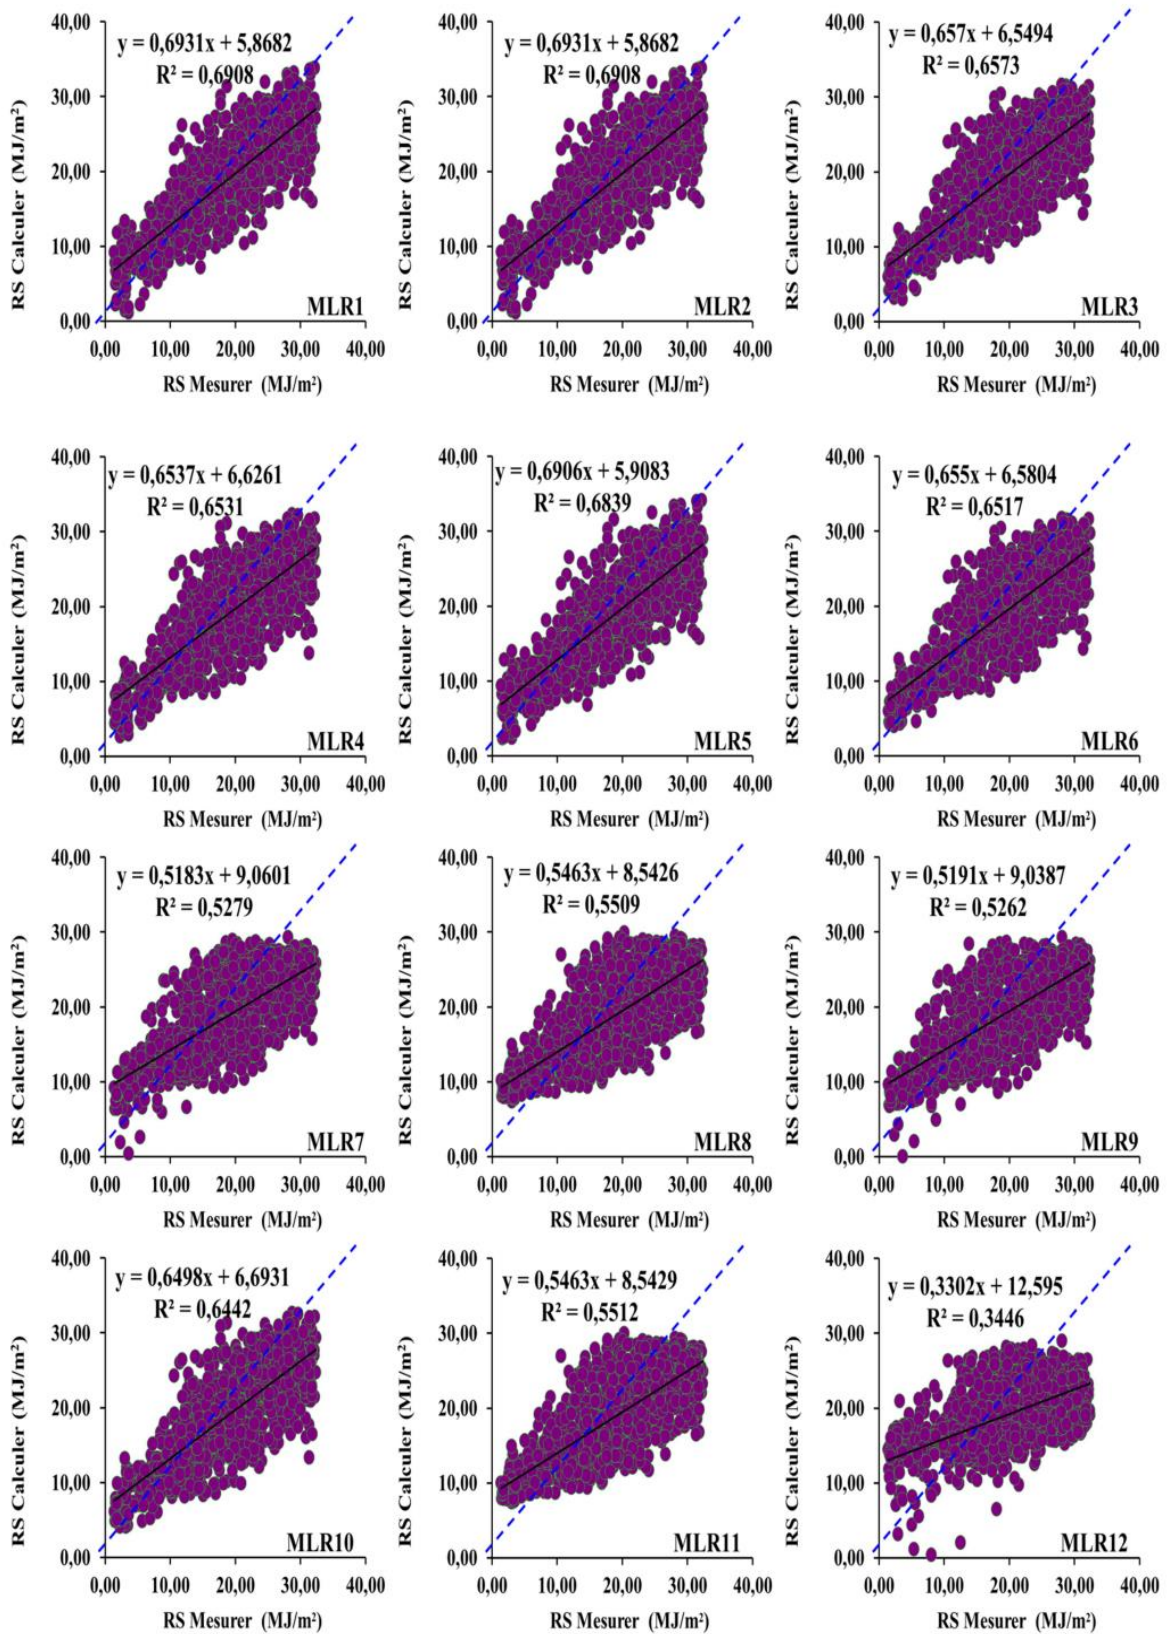


Figure IV.7. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Djelfa & modèles MLR

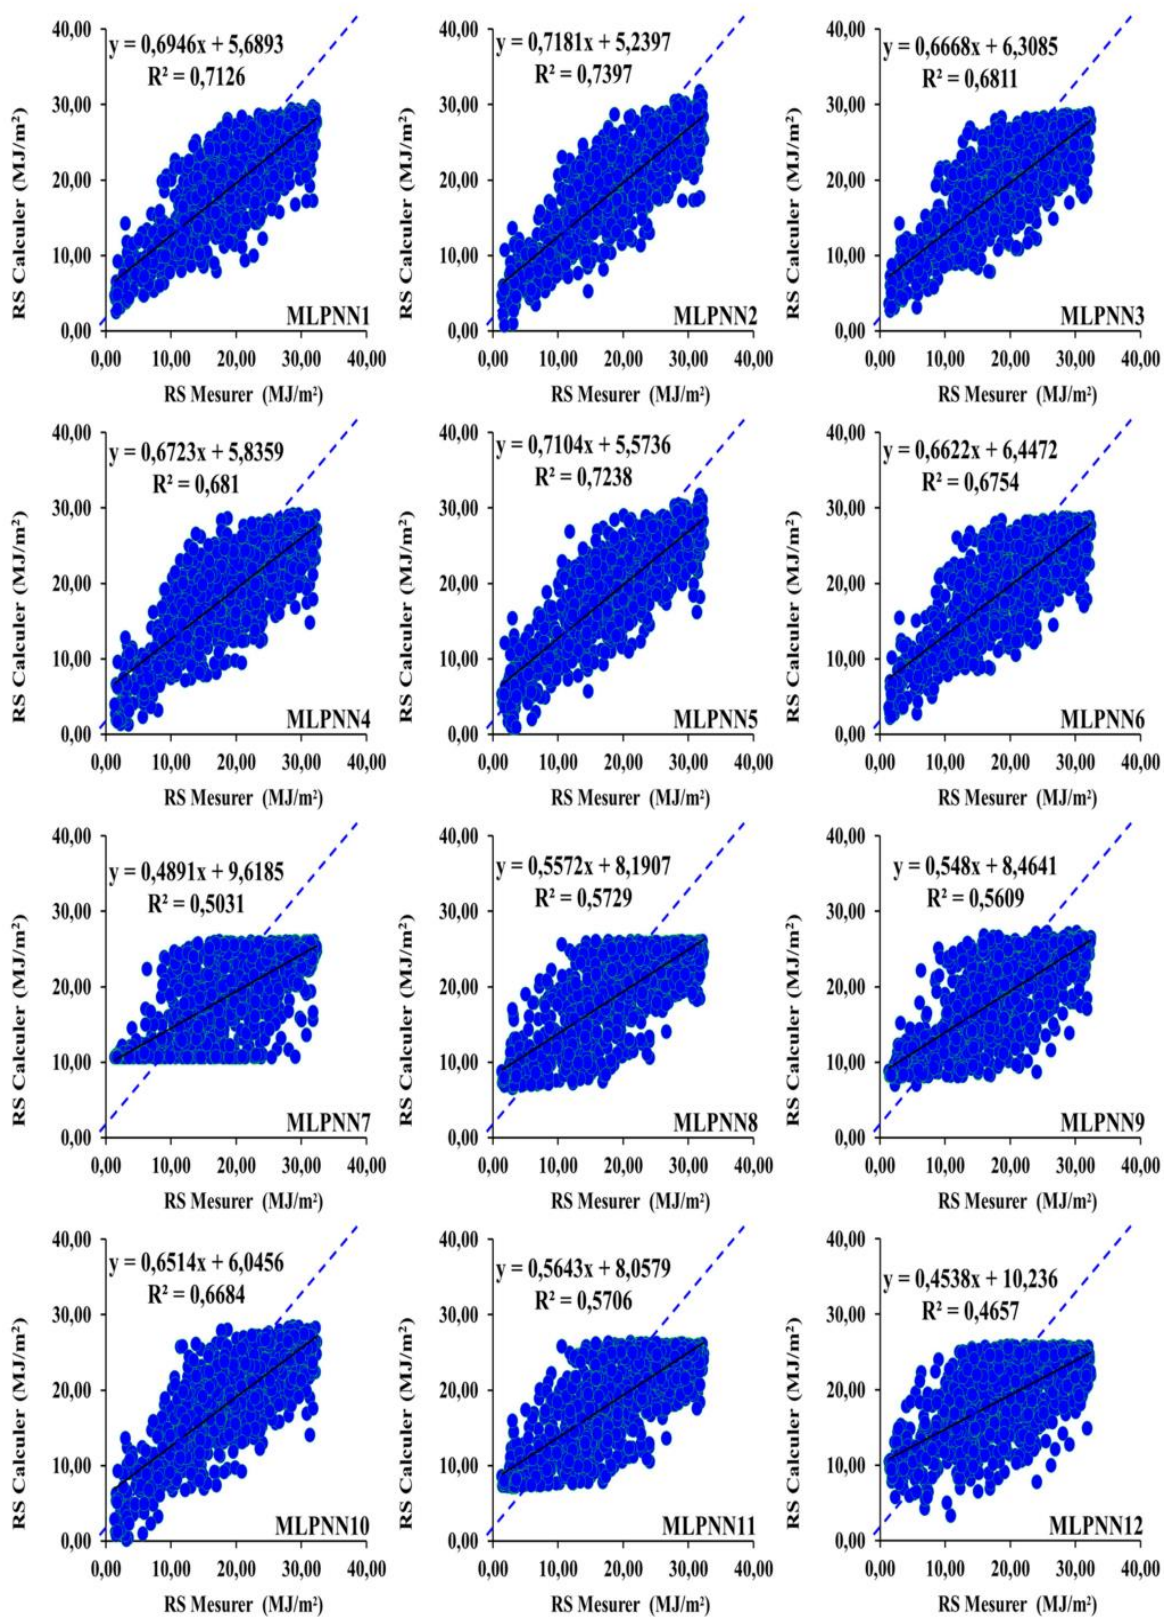


Figure IV.8. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Djelfa & modèles MLPNN




Figure IV.9. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation: Station de Djelfa & modèles GRNN

IV.5. Modélisation de la radiation solaire à Pas de Temps Journalière & Station de Chlef

Au niveau de la station de Chlef (Tableau IV.4, Figures IV.10-12), les performances des modèles étaient similaires par rapport à la station de Batna et Djelfa, et faible par rapport à la station de Biskra. L'utilisation de la deuxième combinaison avec quatre variables climatiques (T_{\max} , T_{\min} , P, U_2) garantit les meilleures performances pour les modèles MLPNN2 ($R \approx 0.85$, $NSE \approx 0.73$, $RMSE \approx 4.60$, $MAE \approx 3.68$) et GRNN2 ($R \approx 0.82$, $NSE \approx 0.67$, $RMSE \approx 5.04$, $MAE \approx 3.99$). Avec l'inclusion de l'humidité relative (la première combinaison), les performances se dégradent, et nous obtenons des diminutions en termes de RMSE avec des taux de l'ordre de 2.542% et 0.198% pour les modèles MLPNN2 et GRNN2, respectivement, ce qui nous permet de conclure que l'utilisation de la variable H% ne permet pas d'améliorer les performances des modèles. Par contre, pour les modèles GRNN, le modèle GRNN1 ($R \approx 0.85$, $NSE \approx 0.71$, $RMSE \approx 4.71$ et $MAE \approx 3.68$) qui utilise la première combinaison (T_{\max} , T_{\min} , P, U_2 , H%) assure les meilleures performances, et l'exclusion de l'H% (GRNN2) conduit à une dégradation des performances avec des taux de l'ordre de 1.190%, 0.000%, 1.050% et 0.809% en termes de R, NSE, RMSE et MAE, respectivement.

Les meilleures performances au niveau de la station sont obtenues par le modèle MLPNN2, avec des différences négligeables par rapport au modèle GRNN1 et MLPNN1, et avec des taux de réductions de l'ordre de (0.00%, 2.817%, 2.335% et 0.00%) et (0.00%, 2.817%, 2.542% et 2.902%) en termes de R, NSE, RMSE et MAE, respectivement.

Les faibles résultats au niveau de la station sont obtenus par les modèles MLR, et le MLR2 assure les meilleures performances avec des taux de réductions par rapport au meilleur modèle de la station (MLPNN2) de l'ordre de 3.659%, 8.955%, 8.730% et 7.769% en termes de R, NSE, RMSE et MAE, respectivement. Par contre, les faibles performances au niveau de la station sont obtenues par le modèle MLR12, avec les plus faibles R et NSE (0.66, 0.44) et les plus grands RMSE et MAE (6.63, 5.44), et avec des taux de réductions par rapport au meilleur modèle de la station (MLPNN2) de l'ordre de 28.788%, 65.909%, 30.618% et 32.353% en termes de R, NSE, RMSE et MAE, respectivement.

La comparaison graphique (Figures IV.10, IV.11 et IV.12) entre les différents modèles confirme les résultats numériques.

Table IV.4. Performances des différents modèles : Station de Chlef

<i>Modèles</i>	<i>Training</i>				<i>Validation</i>			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<i>MLR1</i>	0.81	0.66	5.02	4.01	0.82	0.67	5.05	3.99
<i>MLR2</i>	0.81	0.66	5.02	4.01	0.82	0.67	5.04	3.99
<i>MLR3</i>	0.80	0.65	5.15	4.17	0.81	0.66	5.14	4.09
<i>MLR4</i>	0.80	0.64	5.17	4.19	0.81	0.66	5.16	4.10
<i>MLR5</i>	0.81	0.66	5.07	4.05	0.81	0.66	5.15	4.07
<i>MLR6</i>	0.80	0.64	5.19	4.19	0.81	0.65	5.22	4.14
<i>MLR7</i>	0.71	0.50	6.09	5.01	0.73	0.54	6.02	4.87
<i>MLR8</i>	0.76	0.58	5.62	4.54	0.77	0.60	5.61	4.45
<i>MLR9</i>	0.71	0.50	6.09	4.98	0.73	0.53	6.04	4.84
<i>MLR10</i>	0.80	0.64	5.22	4.22	0.80	0.64	5.26	4.16
<i>MLR11</i>	0.76	0.58	5.62	4.54	0.77	0.59	5.62	4.45
<i>MLR12</i>	0.64	0.41	6.67	5.49	0.66	0.44	6.63	5.44
<i>MLPNN1</i>	0.83	0.69	4.82	3.84	0.85	0.71	4.72	3.79
<i>MLPNN2</i>	0.84	0.71	4.64	3.69	0.85	0.73	4.60	3.68
<i>MLPNN3</i>	0.82	0.68	4.91	3.92	0.84	0.70	4.80	3.86
<i>MLPNN4</i>	0.82	0.67	4.94	4.03	0.83	0.69	4.88	4.93
<i>MLPNN5</i>	0.84	0.69	4.82	3.84	0.85	0.71	4.76	3.79
<i>MLPNN6</i>	0.82	0.67	5.00	4.00	0.84	0.69	4.91	3.94
<i>MLPNN7</i>	0.71	0.50	6.13	5.08	0.74	0.54	5.95	4.96
<i>MLPNN8</i>	0.78	0.61	5.38	4.40	0.78	0.61	5.38	4.40
<i>MLPNN9</i>	0.80	0.63	5.23	4.25	0.80	0.63	5.23	4.25
<i>MLPNN10</i>	0.81	0.66	5.07	4.13	0.81	0.66	5.07	4.13
<i>MLPNN11</i>	0.69	0.47	6.28	5.06	0.69	0.47	6.28	5.06
<i>MLPNN12</i>	0.70	0.49	6.15	5.12	0.70	0.49	6.15	5.12
<i>GRNN1</i>	0.87	0.75	4.30	3.38	0.85	0.71	4.71	3.68
<i>GRNN2</i>	0.86	0.74	4.40	3.46	0.84	0.71	4.76	3.71
<i>GRNN3</i>	0.84	0.70	4.72	3.75	0.84	0.70	4.86	3.83
<i>GRNN4</i>	0.84	0.71	4.69	3.73	0.83	0.68	4.97	3.90
<i>GRNN5</i>	0.86	0.74	4.44	3.50	0.84	0.71	4.78	3.71
<i>GRNN6</i>	0.84	0.70	4.73	3.76	0.84	0.70	4.87	3.84
<i>GRNN7</i>	0.77	0.59	5.54	4.50	0.77	0.59	5.67	4.62
<i>GRNN8</i>	0.82	0.67	4.99	4.01	0.82	0.67	5.09	4.06
<i>GRNN9</i>	0.76	0.58	5.61	4.53	0.77	0.59	5.66	4.57
<i>GRNN10</i>	0.83	0.68	4.85	3.87	0.83	0.69	4.94	3.88
<i>GRNN11</i>	0.80	0.63	5.25	4.25	0.81	0.65	5.25	4.21
<i>GRNN12</i>	0.73	0.54	5.89	4.84	0.73	0.53	6.044	4.96

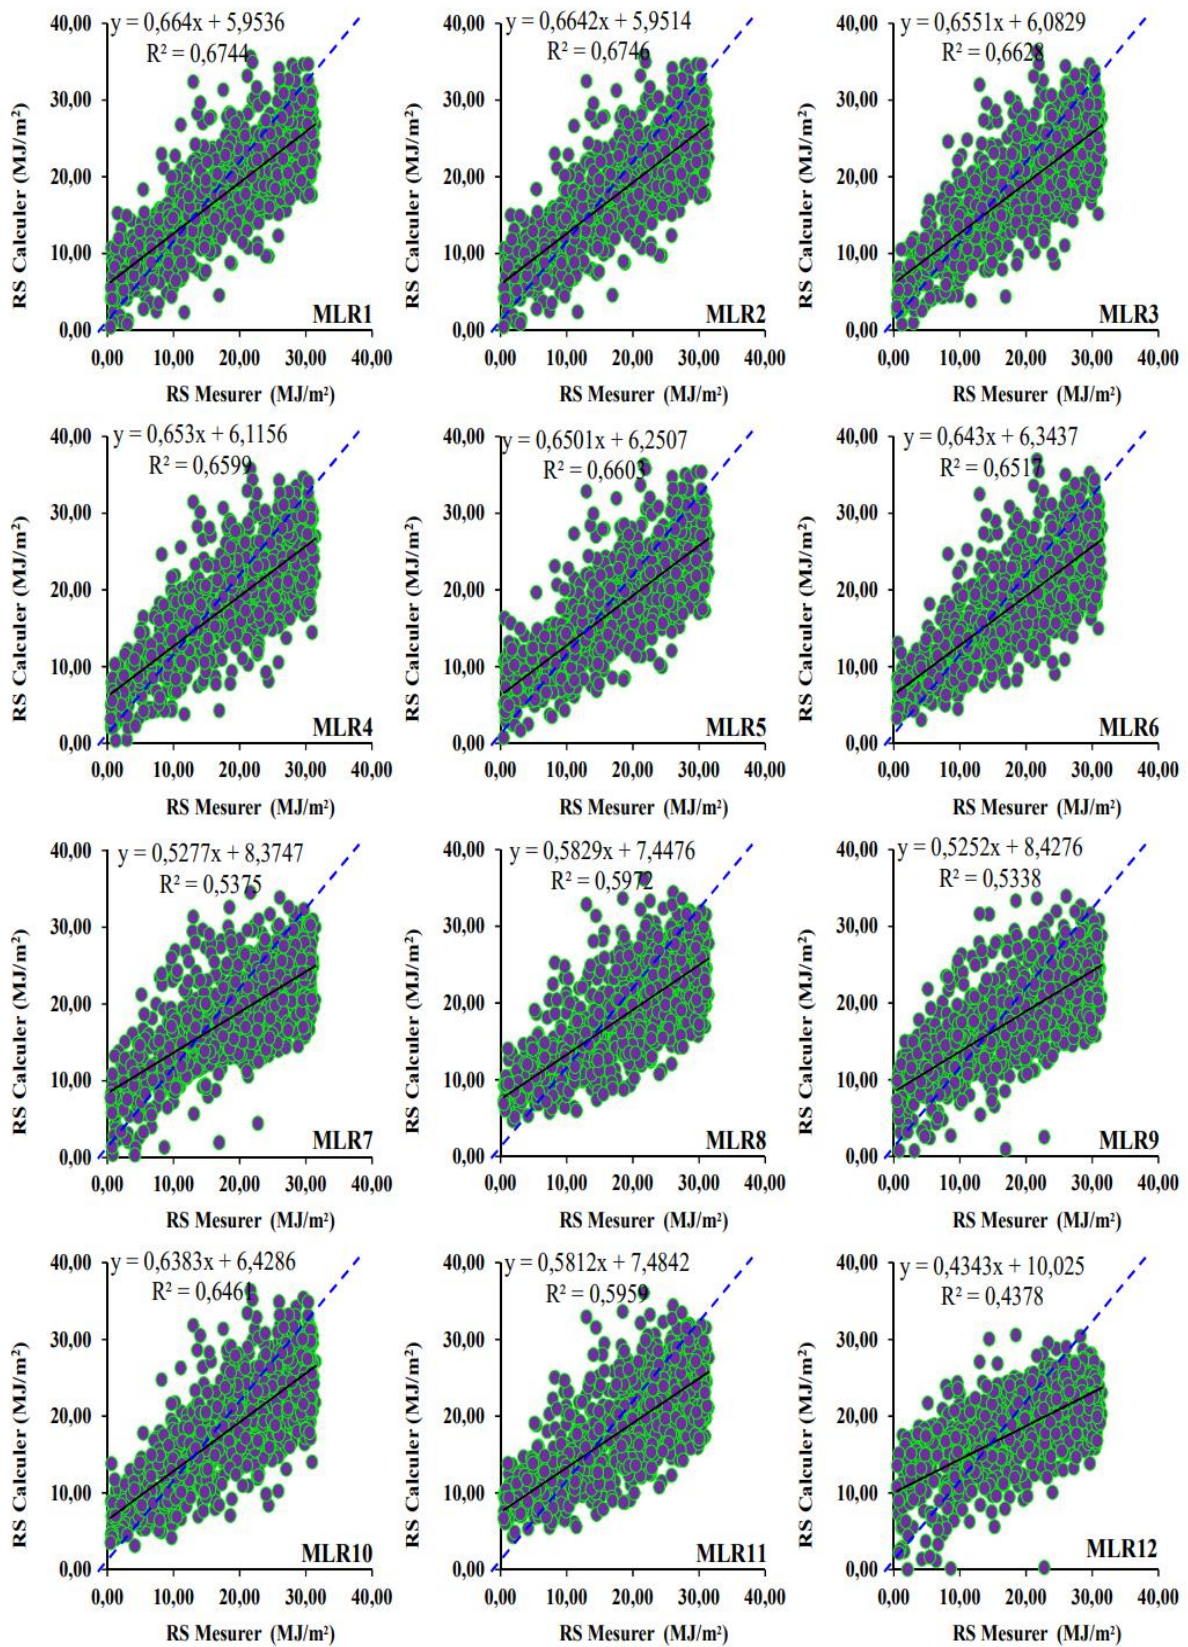


Figure IV.10. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Chlef & modèles MLR

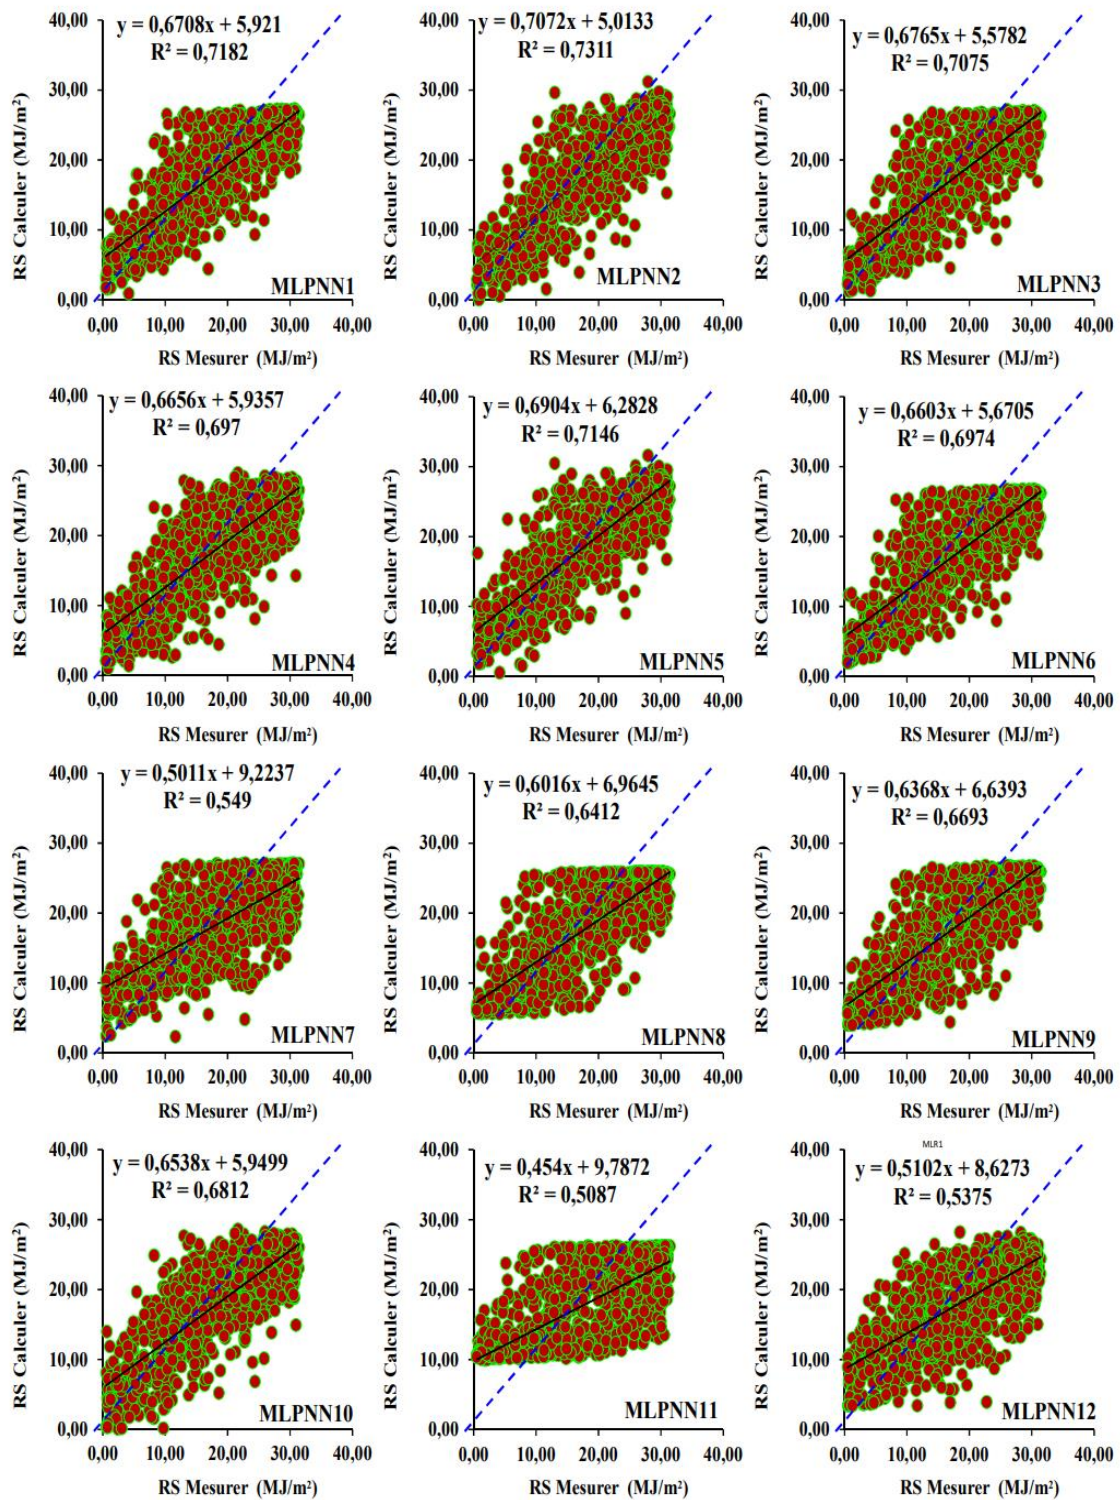


Figure IV.11. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Chlef & modèles MLPNN

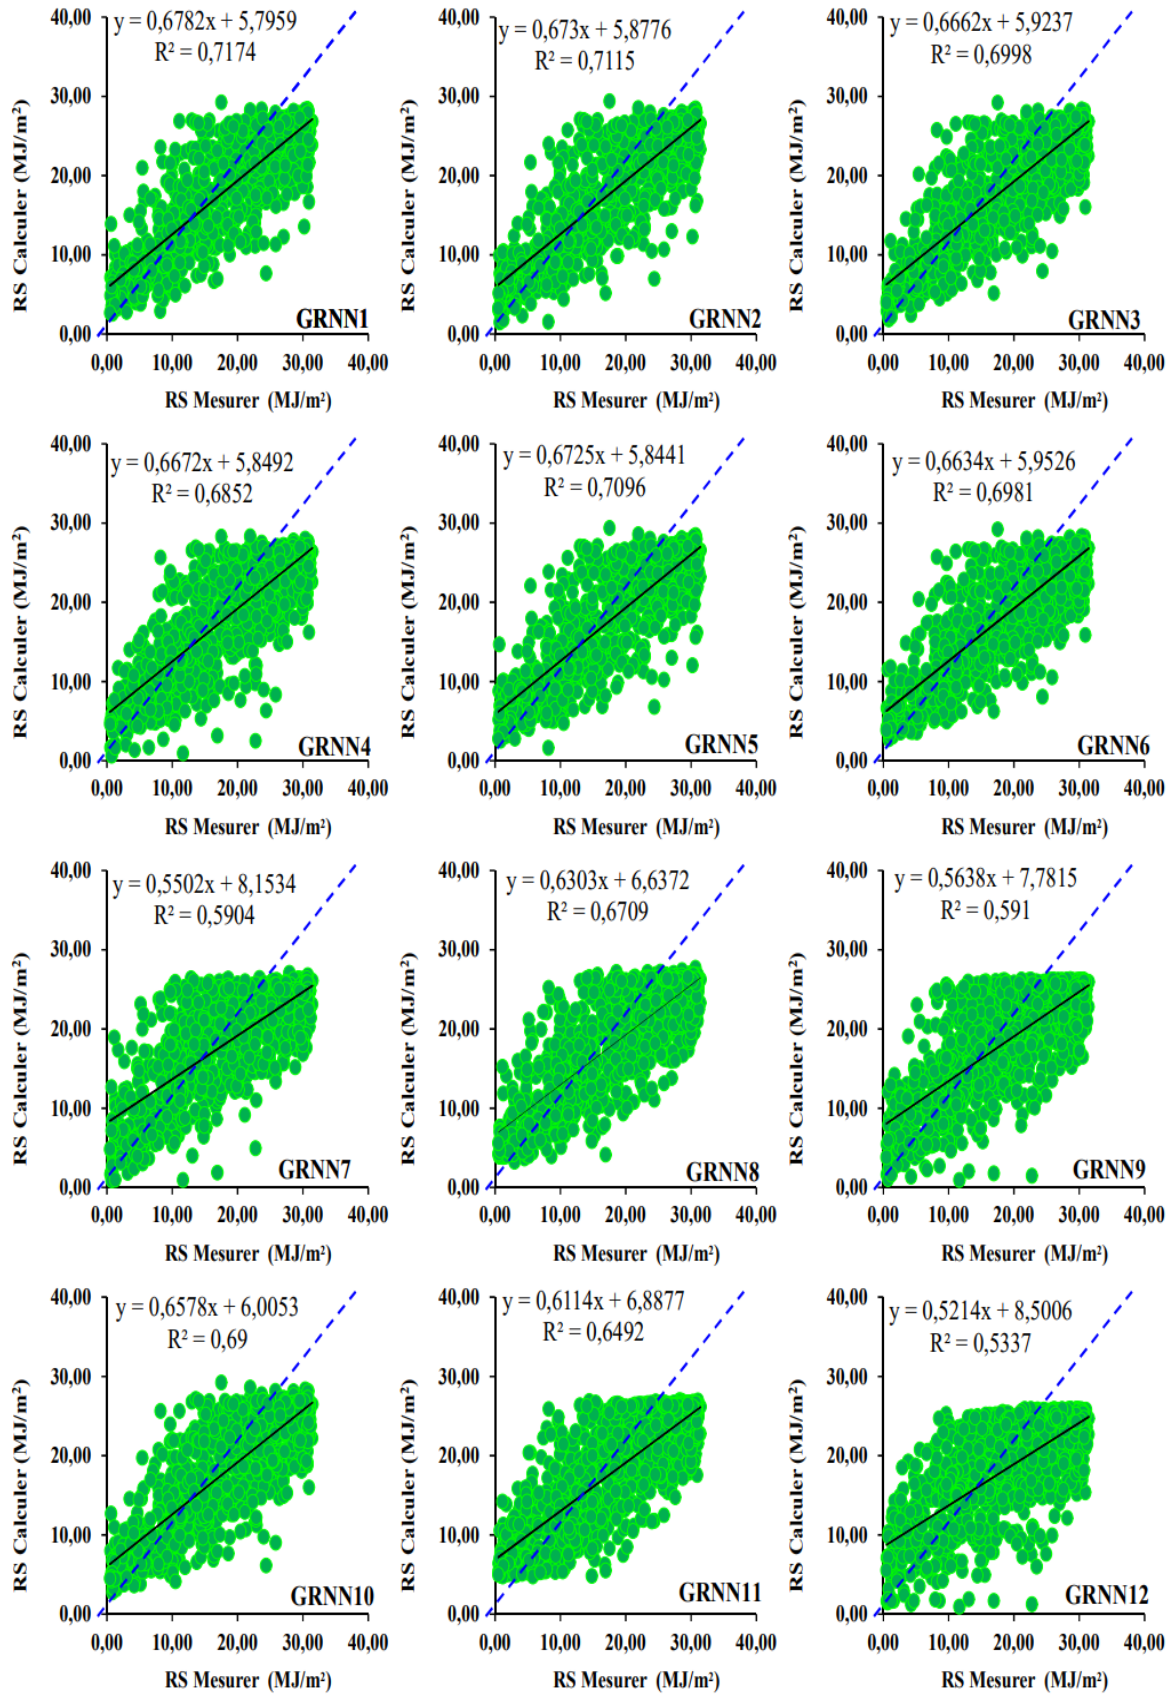


Figure IV.12. Scatterplots des valeurs mesurées et calculées de la RS en phase de validation : Station de Chlef & modèles GRNN

IV.4. Conclusion

Dans le présent chapitre, nous avons présenté et discuté les résultats de modélisation de la radiation solaire (SR) obtenus par la technique de régression linéaire et deux modèles des réseaux de neurones artificielles au niveau de quatre stations, à savoir: Batna, Biskra, Djelfa et Chlef. Nous avons comparé entre plusieurs combinaisons des variables climatiques et au total douze modèles ont été développés, ayant cinq, quatre, trois et deux variables d'entrées. À la lumière des résultats obtenus, on peut conclure ce qui suit:

- i-* Les résultats que nous avons obtenus fluctuent d'une station à l'autre, en générale ces résultats étaient faibles à moyennes.
- ii-* Il a été démontré que les modèles des réseaux de neurones artificielles (MLPNN et GRNN) étaient plus performants que le modèle de régression linéaire (MLR).
- iii-* On remarque aussi que la majorité des meilleurs modèles utilisent la première et la deuxième combinaison d'entrée.
- iv-* Il a été démontré aussi que, les températures minimales et maximales sont les principaux variables climatiques affectant la radiation solaire.

Conclusion Générale

Dans ce mémoire de fin d'étude de master II en Aménagement Hydro-Agricole, nous avons fixé pour objectif de prédire la radiation solaire journalière au niveau de quatre stations en Algérie, en utilisant la vitesse du vent, l'humidité relative, la température maximale et minimale et les précipitations, qui sont considérés comme étant celles qui affectent la radiation solaire à différent pas de temps et à travers les saisons. Les données journalières ont été divisées aléatoirement en deux parties, training et validation en respectant la ratio 70%/30%. Deux modèles à base de réseaux de neurones artificiels (GRNN et MLPNN), et un modèle de régression linéaire multiple (MLR) ont été utilisés. Quand on compare les indicateurs d'évaluation MAE, RMSE, R et NSE, les modèles GRNN et MLPNN ont affichés les meilleures performances prédictives par rapport aux modèles de régression linéaire multiple (MLR). Parmi les modèles de réseaux de neurones, le modèle MLPNN avait les meilleures performances, suivie par le GRNN, alors que les modèles MLR étaient les plus faibles.

Dans cette étude, la prédiction de la radiation solaire a été réalisée en utilisant des données journalières et trois modèles de machine learning, mais dans les études futures, d'autres données, l'ajout de nouvelles variables climatiques, ou l'application des modèles complexes d'apprentissage automatique peuvent être évalués. À mesure que l'intérêt pour la prévision de la radiation solaire augmente, l'importance de la modélisation augmente. Donc, cette étude a été proposée pour améliorer nos connaissances et le lancement de nouvelles voies de recherche. Des études plus approfondies des relations qui peuvent exister entre les variables climatiques et la radiation solaire sont nécessaires. Une diversité d'approche devrait être utilisée, en particulier l'utilisation de plusieurs types de modèles. La précision de la prédiction de la radiation solaire peut être améliorée grâce aux recherches futures qui doivent être proposées.

Références Bibliographiques

- Aidoudi L ;(2012) Etude du bilan hydrologique de la retenue du barrage de foug El Gherza (Wilaya de Biskra) Mémoire MASTER 141
- Aib, B. (Juillet 2019). Vers une détermination des vrais influenceurs sur. 44. Département d'Informatique.
[file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/AUFDRSD3/1/Python_vs_R_Une_Introduction%20\(1\)\[1\].pdf](file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/AUFDRSD3/1/Python_vs_R_Une_Introduction%20(1)[1].pdf)
- AIT IDIR J (2022) Les réseaux de neurones convolutifs pour la classification des tumeurs cérébrales. Mémoire de master IPSSI Paris – Ecole d'informatique et du numérique 87
- Allen, R. G., (1998). Crop evapotranspiration Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56 Fao, Rome, 300(9), D05109.
- Anil Kalyanpur, Marc-Etienne Mercadier, Philippe Blanc. (19 Aug 2015). Gisement solaire en France : caractérisation de la.
[file:///C:/Users/pc/AppData/Local/Microsoft/Windows/INetCache/IE/BUCE5YWY/Gisement-solaire-2013\[1\].pdf](file:///C:/Users/pc/AppData/Local/Microsoft/Windows/INetCache/IE/BUCE5YWY/Gisement-solaire-2013[1].pdf)
- Antoine C (2021) réseaux de neurones profonds appliqués à la compréhension de la parole thèse de doctorat UNIVERSITÉ DU MANS 190
- Bahaghighat, M. A. (2021). Using machine learning and computer vision to estimate the angular velocity of wind turbines in smargrids remotely. Energy Reports, 7, 8561-8576.
- BEN YUCEF Y. (2020). Simulation par les réseaux de neurones du comportement dynamique d'un réacteur continu parfaitement agité. Mémoire MASTER Université KASDI-MERBAH Ouargla p 10
[file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/AVQN8VC6/les_Réseaux_de_Neurones_fin_compressed\[1\].](file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/AVQN8VC6/les_Réseaux_de_Neurones_fin_compressed[1].)
- Boisard, O. (2020). , Brève histoire de l'Intelligence Artificielle . article
- Bounoua, Z., Chahidi, L. O., & Mechaqrane, A. (2021). Estimation of daily global solar radiation using empirical and machine-learning methods: A case study of five Moroccan locations. Sustainable Materials and Technologies, 28, e00261.
<https://doi.org/10.1016/j.susmat.2021.e00261>
- Caubriere, A. (2021). Réseaux de neurones profonds appliqués à la compréhension de la parole .
- .Duffie, J. &. (2013). Solar Engineering of Thermal Processes. John Wiley & Sons

Gueymard, C. A (2004) the sun's total and spectral irradiance for solar energy applications and solar radiation models". Solar Energy <https://doi.org/10.1016/j.solener.2003.08.039>

Hammadou. (2012). Etude de corrélation entre l'irradiation solaire et factures météorologiques mémoire de fin d'étude Université Abderrahmane MIRA BEJAÏA 63

Hussein, E.A., Ghaziasgar, M., Thron, C., Vaccari, M., & Bagula, A. (2021). Basic Statistical Estimation Outperforms Machine Learning in Monthly Prediction of Seasonal Climatic Parameters. Atmosphere, 12(5), 539. <https://doi.org/10.3390/atmos12050539>

Jahani. (2017). Evaluation and development of empirical models for estimating daily solar radiation. Renewable and Sustainable Energy Reviews <https://doi-org.snd11.arn.dz/10.1016/j.rser.2017.01.124>

Kamingu, G. L. (2 juin 2023). Python vs. R pour Data Scientists : Une introduction. Récupéré https://www.researchgate.net/publication/371780904_Python_vs_R_pour_Data_Scientists_Une_introduction?enrichId=rgreq-b0a2769fa37c68bcc3cd0ee7b8a22631-XXX&enrichSource=Y292ZXJQYWdlOzM3MTc4MDkwNDtBUzoxMTQzMTE4MTE2OTc2NTY0OUAxNjg3NDQ5MzM0MTAy&el=1_x_2&_esc=pu

Merabet, k. (2024). Modélisation des Variables Agro-Climatiques : Vers une Approche Globale Intégrée à Base d'Intelligence Artificielle. THESE Mémoire doctorat 207

Kisi, O., Haddam, S., & Yaseen, Z. M. (2019). The implementation of univariable scheme-based air temperature for solar radiation prediction: New development of dynamic evolving neural-fuzzy inference system model. Applied Energy, 241, 184-195. <https://doi.org/10.1016/j.apenergy.2019.03.089>

Madden, N. A., (2010) Absolute Radiometry of the Total Solar Irradiance Using Electrical Substitution Radiometers article https://www.researchgate.net/publication/295674813_Thermodynamic_temperature_by_primary_radiometry

Merabet, k. & remrem, k. (2019). Modélisation de l'Évapotranspiration de Référence (ET0) par les Systèmes d'Inférence Floue à Base de Réseaux université skikda mémoire master.101

NEMISSI M (2009) Classification et reconnaissance des formes par algorithmes hybrides thèse de doctorat Université de Guelma 146

Ouguissi, m. & ALMAOUI, a. (2019/2020). Prédiction de rayonnement solaire journalière par réseau de neurone.Mémoire master

Stephens, G. L. (2005). "Cloud Feedbacks in the Climate System: A Critical Review". Journal of Climate
<https://doi.org/10.1175/JCLI-3243.1>

Taiz, L. (2013). Physiologie des plantes. Liver

Trenberth, K. F. (2009). Earth's Global Energy Budget. Bulletin of the American Meteorological Society, 90(3), 311-324. Article

Yagoub Y Lakrouche M S Neguia S Edd. (2021). Application de la méthodologie QSAR à une série des composés organiques. Mémoire master p 9

[file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/UKXT3ERH/660-173\[1\].](file:///C:/Users/Tamasoft/AppData/Local/Microsoft/Windows/INetCache/IE/UKXT3ERH/660-173[1].)

<https://fac.umc.edu.dz/fst/fichiers/COURS%204%20HVP.>

[-https://amu.hal.science/hal01338010/file/Les_reseaux_de_neurones_artificie.pdf](https://amu.hal.science/hal01338010/file/Les_reseaux_de_neurones_artificie.pdf)

[-https://vincenttalloor.com/project/Memoire/Memoire_de_recherche_appliquee.pdf](https://vincenttalloor.com/project/Memoire/Memoire_de_recherche_appliquee.pdf)

[-https://www.vaisala.com/fr/blog/2019-10/quest-ce-que-le-point-de-rosee-et-comment-le-mesurer](https://www.vaisala.com/fr/blog/2019-10/quest-ce-que-le-point-de-rosee-et-comment-le-mesurer)

https://matheo.uliege.be/bitstream/2268.2/16936/6/s174654_Y%C3%9CKSEK_Gizem.pdf

[-https://docs.aws.amazon.com/fr_fr/machine-learning/latest/dg/splitting-the-data-into-training-and-evaluation-data.html](https://docs.aws.amazon.com/fr_fr/machine-learning/latest/dg/splitting-the-data-into-training-and-evaluation-data.html)

Nom et prénom : Ouatouat Sara

Nom et prénom : Boulemtafes Wissam

Nom et prénom : Bouleklouk Fatma Zohra

Nom et prénom : Meksen Maroua

Titre : *Modélisation de la Radiation Solaire (RS) par les Algorithms du Machine Learning: Développement Sur les plates Forme Anaconda & Spyder et R-Studio.*

Résumé

L'utilisation des modèles d'intelligence artificielle (IA) a considérablement augmenté ces dernières années, avec une expansion de leurs applications pour inclure divers aspects de la vie quotidienne. Dans le domaine de l'agriculture et des sciences agricoles, l'utilisation des modèles d'IA est devenue une nécessité incontournable pour développer des solutions efficaces et estimer précisément certaines variables notamment le rayonnement solaire. Cette étude entre dans le cadre de la préparation de mémoire de master en aménagement Hydro-Agricole, vise à appliquer des modèles d'IA et à proposer des solutions alternatives pour développer des modèles mathématiques pour calculer le rayonnement solaire. Nous avons utilisé deux modèles de réseaux de neurones artificiels : (i) le réseau de neurones multicouches (MLPNN), (ii) le réseau de neurones à régression généralisé (GRNN), ainsi que (iii) le modèle de régression linéaire multiple (MLR). Pour développer les modèles mathématiques, nous avons utilisé des données climatiques provenant de quatre stations : Batna, Biskra, Djelfa, and Chlef. Pour chaque station, nous avons collecté des données quotidiennes sur une période de dix ans (2004-2013) comprenant : (1) la température maximale (T_{max}), (2) la température minimale (T_{min}), (3) la vitesse du vent (U_2), (4) l'humidité relative ($H\%$), (5) les précipitations (P), et le rayonnement solaire (SR) qui a été utilisé comme variable à modéliser. La base de données a été divisée en deux parties : 70 % pour le développement et l'entraînement du modèle, et 30 % pour évaluer la capacité du modèle à prédire correctement le rayonnement solaire quotidien. Nous avons utilisé plusieurs critères de validation statistique, notamment le coefficient de corrélation (R), le coefficient de Nash-Sutcliffe efficacité (NSE), la moyenne des erreurs absolues (MAE), et la racine carrée de l'erreur quadratique moyenne ($RMSE$). Pour évaluer l'impact des différentes variables climatiques sur la réponse du modèle mathématique, nous avons comparé douze modèles avec différentes combinaisons de variables climatiques. Les modèles obtenus ont démontré la capacité des réseaux de neurones artificiels à calculer avec une excellente précision le rayonnement solaire, dépassant le modèle de régression linéaire. Les prévisions étaient hautement précises avec des coefficients R et des coefficients NSE atteignant respectivement 0.87 et 0.76 (meilleur modèle). Les résultats obtenus sont très encourageants et ouvrent des perspectives prometteuses pour l'avenir.

Mots-Clés : Rayonnement solaire, modèles d'intelligence artificielle, GRNN, MLPNN, MLR stations climatiques, variables climatiques, température, vitesse du vent, humidité relative, rayonnement solaire.

ملخص

ازداد الاعتماد على نماذج الذكاء الاصطناعي (ANN) بشكل ملحوظ في السنوات الأخيرة، حيث توسعت تطبيقاتها لتشمل مختلف جوانب الحياة اليومية. في مجال الري والعلوم الزراعية، بات استخدام نماذج الذكاء الاصطناعي ضرورة حتمية لتطوير حلول فعالة وتقدير إشعاع الشمس بدقة. تهدف هذه الدراسة التي تدخل ضمن إطار تحضير مذكرة تخرج في ماستر التهيئة المائية الفلاحية، إلى تطبيق نماذج الذكاء الاصطناعي واقتراح حلول بديلة لتطوير نماذج رياضية لحساب إشعاع الشمس. قمنا باستعمال نموذجان من الشبكات العصبية الاصطناعية وهما: (i) الشبكة العصبية المتعددة الطبقات (MLPNN)، (ii) شبكة الانحدار العصبي المعمم (GRNN) و (iii) نموذج الانحدار الخطي (MLR). من أجل تطوير النماذج الرياضية استعملنا معطيات مناخية تخص أربع محطات وهي: باتنة، بسكرة، الجلفة، الشلف وعلى مستوي كل محطة قمنا بجمع بيانات يومية تمتد على طول مرحلة عشر سنوات (2004-2013) وتحتوي على البيانات التالية: (1) درجة الحرارة القصوى (T_{max})، (2) درجة الحرارة الدنيا (T_{min})، (3) سرعة الرياح (U_2)، (4) الرطوبة النسبية ($H\%$)، (5) المطر (P)، والتي استعملت كمدخل لنمذجة الإشعاع الشمسي (SR). قسمت قاعدة البيانات الي قسمين: 70% من أجل تطوير وتدريب النموذج 30% من أجل تقييم قدرة النموذج على التنبؤ الصحيح بالإشعاع الشمسي اليومي. قمنا باستعمال مجموعة من معايير التحقق الاحصائي والتي هي: معامل الارتباط (R)، معامل كفاءة ناش (NSE)، متوسط الخطأ المطلق (MAE)، والجذر التربيعي لمربع الخطأ (RMSE). من أجل التعرف على تأثير مختلف المتغيرات المناخية على استجابة النموذج الرياضي، قمنا بالمقارنة ما بين 12 نموذج بتشكيلات مختلفة للمتغيرات المناخية. أثبتت النتائج المتحصل عليها قدرة الشبكات العصبية الاصطناعية على حساب الإشعاع الشمسي بدقة ممتازة وتجاوزت نموذج الانحدار الخطي وكانت الحسابات ذات دقة تنبؤيه عالية وصل معامل الارتباط R ومعامل كفاءة NSE 0,87 و 0,76 (أحسن نموذج). تعتبر النتائج المتحصل عليها جد مشجعة وتفتح آفاق مستقبلية واعدة.

الكلمات المفتاحية:

الإشعاع الشمسي ، نماذج الذكاء الاصطناعي، محطات مناخية، متغيرات مناخية، درجة الحرارة، سرعة الرياح، الرطوبة النسبية، الإشعاع الشمسي.