

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
الجمهورية الجزائرية الديمقراطية الشعبية  
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE  
وزارة التعليم العالي والبحث العلمي

جامعة 20 أوت 1955 - سطيف - جامعة 20 Août 1955-SKIKDA

Faculté des Sciences



Département des Sciences Agronomiques

## Thèse en vue de l'obtention du diplôme de Doctorat LMD

**Filière:** Sciences Agronomiques  
**Spécialité:** Aménagement Hydro-Agricole

**Par:** MERABET Khaled

### Thème

**Modélisation des Variables Agro-Climatiques: Vers une  
Approche Globale Intégrée à Base d'Intelligence Artificielle**

*Soutenue publiquement le 09/03/2024, devant le jury composé de:*

**Président:**

Mr. HEBAL Aziz M.C.A Univ 20 Août 1955, Skikda

**Rapporteur:**

Mr. HEDDAM Salim Prof Univ 20 Août 1955, Skikda

**Examineurs:**

Mr. KHELFAOUI Hakim M.C.A Univ 20 Août 1955, Skikda

Mr. LAOUACHERIA Fares M.C.A Univ Badji Mokhtar, Annaba

Mr. ZEGHADNIA Lotfi Prof Univ Mohamed Cherif Messaâdia, Souk-Ahras

Année Universitaire: 2023 – 2024

## Remerciements

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

Mes chaleureux remerciements vont à mon directeur de thèse, monsieur **HEDDAM Salim**, professeur de l'université du 20 Août 1955, Skikda, qui a toujours porté un intérêt particulier à mon travail: il a encadré et suivi de près et de loin, avec sa rigueur scientifique, toutes les étapes de cette étude. Ses conseils, ses remarques précises et ses fructueuses recommandations, ainsi que sa gentillesse m'ont encouragé pour poursuivre la réalisation de cette thèse.

Je voudrais remercier profondément les membres du jury pour m'avoir fait l'honneur d'accepter d'examiner ce travail de thèse :

**- Dr. HEBAL Aziz**

D'avoir accepté d'être président du jury. Je vous remercie infiniment de réagir avec nous et d'accepter d'abord cette responsabilité.

**- Dr. KHELFAOUI Hakim**

**- Dr. LAOUACHERIA Fares**

**- Pr. ZEGHADNIA Lotfi**

D'avoir consenti à être examinateurs dans mon jury de thèse.

Un merci particulier aux enseignants qui ont contribué à ma formation tout au long de mon cursus universitaire.

Enfin, mes gratitudes les plus profonds vont à mon épouse, mes chères enfants et à tous les membres de ma famille pour leurs soutiens inconditionnels et pour toutes les personnes qui ont participé de près ou de loin aux travaux que j'ai menés dans cette thèse.

## ملخص

يلعب التنبؤ بالرطوبة النسبية والإشعاع الشمسي دورا مهما جدا في عدة مجالات. في هذه الدراسة، قمنا بنمذجة هذين المتغيرين المناخيين باستخدام خمسة معطيات مناخية لكل متغير، تم جمعها من ثماني محطات تقع في الشمال والمنطقة شبه الجافة للجزائر، وهي: الجزائر العاصمة، عنابة، قسنطينة، سطيف، قالمة، جيجل، ميله، ووهران. تعتمد هذه النمذجة على استخدام ستة نماذج بسيطة للذكاء الاصطناعي، وهي: الشبكة العصبية متعددة الطبقات (MLPNN)، آلة التعلم المتطرف (ELM)، الشبكة العصبية التراجعية الشاملة (GRNN)، خطوط الانحدار التكيفية متعددة المتغيرات (MARS)، خوارزمية الغابات العشوائية (RFR)، وانحدار متجه الدعم (SVR). ولغرض تحسين الأداء التنبؤي لهذه النماذج الستة، قمنا باستخدام ثلاث خوارزميات لتحليل الإشارة (EMD, EWT, VMD). في البداية، قمنا باستخدام نماذج الذكاء الاصطناعي البسيطة للتنبؤ بالرطوبة النسبية والإشعاع الشمسي، ثم قمنا باستخدام خوارزميات تحليل الإشارة لتحليل المعطيات المناخية واستعمال نتائجها كمدخلات جديدة للنماذج الهجينة. توضح النتائج المتحصل عليها أن النماذج الهجينة توفر دقة تنبؤية عالية للرطوبة النسبية والإشعاع الشمسي، وقد تم إثبات فعالية تقنيات تحليل الإشارة في تحسين أداء نماذج الذكاء الاصطناعي البسيطة.

**الكلمات المفتاحية:** الرطوبة النسبية، الإشعاع الشمسي، نمذجة، نماذج الذكاء الاصطناعي البسيطة، النماذج الهجينة، تحليل الإشارة.

## Résumé

La prévision de l'humidité relative et la radiation solaire joue un rôle très important dans plusieurs domaines. Dans cette thèse, la modélisation de ces deux variables a été élaborée moyennant cinq données climatiques pour chaque variable. Ces données ont été collectées au niveau de huit stations situées au nord et dans la région semi-aride de l'Algérie, à savoir: Alger, Annaba, Constantine, Sétif, Guelma, Jijel, Mila et Oran. Cette modélisation est basée sur l'utilisation de la décomposition en mode empirique (EMD), la transformée en ondelettes empirique (EWT), et la décomposition en mode variationnel (VMD), combinées avec des modèles d'apprentissage automatique traditionnels pour améliorer leurs performances prédictives. Premièrement, six modèles traditionnels simples, à savoir: les réseaux de neurones à perceptron multicouche (MLPNN), les machines à apprentissage extrême (ELM), les réseaux de neurones à fonction de régression générale (GRNN), la régression multivariée par spline adaptative (MARS), les forêts aléatoires de régression (RFR), et la régression à vecteurs de support (SVR), ont été utilisés pour prédire l'humidité relative et la radiation solaire. Deuxièmement, les variables climatiques sont décomposées à l'aide des algorithmes de décomposition du signal et utilisées comme de nouvelles variables d'entrée dans les modèles hybrides. Les résultats obtenus démontrent que les nouvelles approches hybrides ont fourni des précisions prédictives élevées de l'humidité relative et la radiation solaire, et il a été conclu que l'efficacité de la décomposition du signal était démontrée et justifiée.

**Mots-clés:** Humidité relative, Radiation solaire, Modélisation, MLPNN, MARS, SVR, RFR, ELM, GRNN, VMD, EMD, EWT, Décomposition du signal.

## Abstract

The prediction of air relative humidity and solar radiation plays very important role in several fields. In this thesis, the modeling of these two variables was developed using five climatic data for each variable. These data were collected at eight stations located in the north and in the semi-arid region of Algeria, i.e., Algiers, Annaba, Constantine, Sétif, Guelma, Jijel, Mila and Oran. Our modeling strategy is based on the use of the empirical mode decomposition (EMD), empirical wavelet transform (EWT), and variational mode decomposition (VMD), combined with standalone machine learning models to improve their performance predictive. First, six standalone models, i.e., multilayer perceptron neural network (MLPNN), extreme learning machine (ELM), general regression neural network (GRNN), multivariate adaptive regression spline (MARS), random forest regression (RFR), and support vector regression (SVR), were used for predicting air relative humidity and solar radiation. Second, meteorological variables are decomposed using signal decomposition algorithms and used as new input variables to the hybrid models. The obtained results demonstrate that the new hybrid approaches provided high predictive accuracies of air relative humidity and solar radiation, and it was concluded that the effectiveness of signal decomposition was demonstrated and justified.

**Keywords:** Air relative humidity, solar radiation, modelling, MLPNN, MARS, SVR, RFR, ELM, GRNN, VMD, EMD, EWT, hybrid models, signal decomposition.

---



---

## *Table des matières*

---

Remerciements.....	I
الملخص.....	II
Résumé.....	III
Abstract.....	IV
Sommaire.....	V
Liste des tableaux.....	VIII
Liste des figures.....	X
Liste des abréviations.....	XIV
Introduction Générale.....	1

### *Chapitre I : État des Connaissances sur les Variables Climatiques*

I.1. Introduction.....	5
I.2. L'humidité relative.....	5
I.3. La radiation solaire.....	7
I.4. Les précipitations.....	8
I.5. La température.....	10
I.6. Le vent.....	11
I.7. Conclusion.....	12

### *Chapitre II : Modélisation de l'Humidité Relative (HR): Etat de l'Art*

II.1. Introduction.....	14
II.2. L'humidité relative: Etat de l'art .....	14
II.2.1. Application du modèle MLPNN pour la modélisation de l'HR.....	15
II.2.2. Application du Réseau ELM pour la modélisation de l'HR.....	19
II.2.3. Application du modèle GRNN pour la modélisation de l'HR.....	20
II.2.4. Application du modèle MARS pour la modélisation de l'HR.....	20
II.2.5. Application des forêts aléatoires (RFR) pour la modélisation de l'HR.....	20
II.2.6. Application du modèle SVR pour la modélisation de l'HR.....	22
II.2.7. Application d'autres modèles pour la modélisation de l'HR.....	23
II.3. Conclusion.....	27

### ***Chapitre III : Modélisation de la Radiation Solaire (RS): Etat de l'Art***

III.1. Introduction.....	29
III.2. Modélisation de la radiation solaire: Revue de Littérature .....	29
III.2.1. Application du modèle MLPNN pour la modélisation de la RS .....	30
III.2.2. Application du modèle ELM pour la modélisation de la RS.....	34
III.2.3. Application du modèle RFR pour la modélisation de la RS.....	35
III.2.4. Application du modèle SVR pour la modélisation de la RS.....	35
III.2.5. Application des techniques d'ondelettes pour la modélisation de la RS.....	35
III.2.6. Application d'autres modèles pour la modélisation de la RS.....	37
III.3. Conclusion.....	43

### ***Chapitre IV : Présentation de la zone d'étude et des données utilisées***

IV.1. Introduction.....	46
IV.2. Présentation et description des données utilisées .....	46
IV.2.1. Situation géographique des stations climatiques utilisées.....	46
IV.2.2. Statistiques descriptives.....	48
IV.3. Evaluation des performances des modèles.....	49
IV.4. Conclusion.....	50

### ***Chapitre V : Présentation des Modèles à Base d'Intelligence Artificielle***

V.1. Introduction.....	52
V.2. Les modèles d'apprentissage automatique .....	52
V.2.1. MLPNN.....	52
V.2.2. ELM.....	55
V.2.3. GRNN.....	57
V.2.4. MARS.....	59
V.2.5. RFR.....	61
V.2.6. SVR.....	63
V.3. Les techniques de décomposition du signal.....	64
V.3.1. La décomposition en mode empirique (EMD).....	65
V.3.2. La transformée en ondelettes empiriques (EWT).....	66
V.3.3. La décomposition en mode variationnel (VMD).....	67
V.4. Conclusion.....	68

## ***Chapitre VI : Modélisation de l'Humidité Relative (HR) par l'Intelligence Artificielle***

VI.1. Introduction.....	70
VI.2. Modélisation de l'HR par les modèles traditionnels .....	72
VI.3. Modélisation de l'HR par les modèles hybrides.....	85
VI.4. Conclusion.....	98

## ***Chapitre VII : Modélisation de la Radiation Solaire (RS) par l'Intelligence Artificielle***

VII.1. Introduction.....	101
VII.2. Modélisation de la RS par les modèles traditionnels .....	103
VII.3. Modélisation de la RS par les modèles hybrides.....	115
VII.4. Conclusion.....	127
<b>Conclusion Générale.....</b>	<b>130</b>
Références bibliographiques.....	133
Annexe A. Résultats détaillées obtenus par les modèles hybrides durant la modélisation de l'humidité relative.....	187
Annexe B. Résultats détaillées obtenus par les modèles hybrides durant la modélisation de la radiation solaire.....	199

---



---

## *Liste des tableaux*

---

Tableau II.1	Historique des modèles appliqués à la modélisation de l'HR.....	25
Tableau III.1	Historique des modèles appliqués à la modélisation de la RS.....	44
Tableau IV.1	Présentation des sites utilisés durant la modélisation de l'HR.....	47
Tableau IV.2	Présentation des sites utilisés durant la modélisation de la RS.....	47
Tableau IV.3	Paramètres statistiques de la base de données utilisée: modélisation de l'HR.....	48
Tableau IV.4	Paramètres statistiques de la base de données utilisée: modélisation de la RS.....	49
Tableau VI.1	Structure des modèles utilisés durant la modélisation de l'HR.....	71
Tableau VI.2	Résultats obtenus par les modèles traditionnels au niveau de la station d'Alger.....	74
Tableau VI.3	Résultats obtenus par les modèles traditionnels au niveau de la station d'Annaba.....	77
Tableau VI.4	Résultats obtenus par les modèles traditionnels au niveau de la station de Constantine.....	80
Tableau VI.5	Résultats obtenus par les modèles traditionnels au niveau de la station de Sétif.....	83
Tableau VI.6	Résultats obtenus par les meilleures modèles hybrides au niveau de la station d'Alger.....	86
Tableau VI.7	Résultats obtenus par les meilleures modèles hybrides au niveau de la station d'Annaba.....	89
Tableau VI.8	Résultats obtenus par les meilleures modèles hybrides au niveau de la station de Constantine.....	93
Tableau VI.9	Résultats obtenus par les meilleures modèles hybrides au niveau de la station de Sétif.....	96
Tableau VII.1	Structure des modèles utilisées durant la modélisation de la RS.....	101
Tableau VII.2	Résultats obtenus par les modèles traditionnels au niveau de la station de Guelma.....	104
Tableau VII.3	Résultats obtenus par les modèles traditionnels au niveau de la station de Jijel.....	107

Tableau VII.4	Résultats obtenus par les modèles traditionnels au niveau de la station de Mila.....	110
Tableau VII.5	Résultats obtenus par les modèles traditionnels au niveau de la station d'Oran.....	113
Tableau VII.6	Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Guelma.....	116
Tableau VII.7	Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Jijel.....	119
Tableau VII.8	Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Mila.....	122
Tableau VII.9	Résultats obtenus par les meilleurs modèles hybrides au niveau de la station d'Oran.....	125

---



---

## *Liste des figures*

---

Figure I.1	Hygromètre à cheveux.....	6
Figure I.2	Les instruments de mesure de la RS globale, directe et diffuse : (1) Pyranomètre pour mesurer la RS diffuse, (2) Pyranomètre pour mesurer la RS globale, (3) Périhéliomètre pour mesurer la RS directe, (4) La boule utilisée pour cacher définitivement le pyranomètre.....	8
Figure I.3	Exemple d'un pluviomètre.....	9
Figure I.4	Thermomètre.....	11
Figure I.5	Les instruments de mesure des paramètres du vent.....	12
Figure II.1	Nombre de publications en relation avec l'application des modèles à base d'IA pour la modélisation de l'HR.....	26
	Les modèles à base d'IA utilisées pour la modélisation de l'HR.....	26
Figure II.2		26
Figure II.3	Volume de publications par pays.....	27
Figure III.1	Nombre de publications en relation avec l'application des modèles à base d'IA pour la modélisation de la RS.....	42
	Les modèles à base d'IA utilisées pour la modélisation de la RS.....	42
Figure III.2		42
Figure III.3	Volume de publications par wilaya.....	43
Figure IV.1	Situation géographique des zones d'étude.....	47
Figure V.1	L'architecture du MLPNN.....	54
Figure V.2	La structure de l'ELM.....	57
Figure V.3	La structure du réseau GRNN.....	59
Figure V.4	La structure du modèle MARS.....	61
Figure V.5	L'architecture du modèle RFR.....	62
Figure V.6	La structure du réseau SVR.....	64
Figure V.7	Exemple de décomposition du signal des précipitations (P) pour la station d'Alger utilisant: (a) EMD, (b) EWT et (c) VMD.....	65
Figure VI.1	L'organigramme de modélisation de l'HR.....	71
Figure VI.2	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles traditionnels, station d'Alger.....	75

Figure VI.3	Comparaison graphique entre l'HR mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Alger.....	75
Figure VI.4	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles traditionnels, station d'Annaba.....	78
Figure VI.5	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Annaba.....	78
Figure VI.6	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles traditionnels, station de Constantine...	81
Figure VI.7	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Constantine.....	81
Figure VI.8	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles traditionnels, station de Sétif.....	84
Figure VI.9	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Sétif.....	84
Figure VI.10	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station d'Alger.....	87
Figure VI.11	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Alger.....	88
Figure VI.12	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station d'Annaba.....	90
Figure VI.13	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Annaba...	91
Figure VI.14	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station de Constantine.....	94

Figure VI.15	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Constantine.....	95
Figure VI.16	Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station de Sétif.....	97
Figure VI.17	Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Sétif.....	98
Figure VII.1	L'organigramme de modélisation de la RS.....	102
Figure VII.2	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Guelma.....	105
Figure VII.3	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Guelma.....	105
Figure VII.4	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Jijel.....	108
Figure VII.5	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels station de Jijel.....	108
Figure VII.6	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Mila.....	111
Figure VII.7	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Mila.....	111
Figure VII.8	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station d'Oran.....	114
Figure VII.9	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Oran.....	114

Figure VII.10	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station de Guelma.....	117
Figure VII.11	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Guelma.....	118
Figure VII.12	Scatterplots des valeurs calculées et observées de la RS durant la phase de validation: modèles hybrides, station de Jijel.....	120
Figure VII.13	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Jijel.....	121
Figure VII.14	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station de Mila.....	123
Figure VII.15	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Mila.....	124
Figure VII.16	Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station d'Oran.....	126
Figure VII.17	Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation :(a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Oran.....	127

## **Liste des abréviations**

ABC: Artificial bee colony algorithm

ANFIS: Adaptive neuro fuzzy inference system

ANN: Artificial neural networks

ARIMA: Autoregressive integrated moving average

ARMA: Autoregressive moving average

BDT: Boosted decision trees

BF: Basis function

BNN: Bayesian neural network

BPNN: Backpropagation neural network

CART: Classification and regression trees

CEEMDAN: Complete ensemble empirical mode decomposition with adaptive noise

CFNN: Cascade forward neural network

CFSR: Climate forecast system reanalysis

CNN: Convolutional neural network

CVNN: Complex valued neural network

CVWNN: Complex valued wavelet neural network

DFL: Distributed fusion LSTM network

DL: Deep learning

DT: Decision tree

DTR: Decision tree regression

ELM: Extreme learning machine

EMD: Empirical mode decomposition

ENN: Elman neural network

EPUNNs: Evolutionary product unit neural networks

ERNN: Elman recurrent neural network

ET<sub>0</sub>: Evapotranspiration de référence

EWT: Empirical wavelet transform

FCWN: Fully complex valued wavelet network

FL: Fuzzy logic

FLSTM: Fusion LSTM

GA: Genetic algorithm

GBT: Gradient boosting trees

GCV: Generalized cross validation

GEP: Genetic expression programming

GPR: Gaussian process regression

GRNN: General regression neural network

H<sub>0</sub>: Radiation solaire extraterrestre

HFM: Hopfield model

HR: Humidité relative

HR<sub>max</sub>: Humidité relative maximale

HR<sub>mean</sub>: Humidité relative moyenne

HR<sub>min</sub>: Humidité relative minimale

IA: Intelligence artificielle

IF: Iterative filtering

IMFs: Intrinsic mode functions

KI: Indice de clarté

KNN: K-Nearest neighbor

KNR: K-Neighbors regressor

LGC-GMDH: Local gravitational clustering-group method of data Handling

LR: Linear regression

LSM: Least squares method

LSSVM: Least squares support vector machine

LSTM: Long-short term memory

MAE: Mean absolute error

MAPE: Mean absolute percentage error

MARS: Multivariate adaptive regression spline

MBE: Mean bias error

MIMO: Multi-entrées sorties-unique

MISO: Multi-entrées multi-sorties

ML: Machine learning

MLPNN: Multilayer perceptron neural network

MLR: Multiple linear regression

MODWT: Maximum overlap discrete wavelet transform

MRA: Multiresolution analysis

MRE: Mean relative error

MSE: Mean square error

MTM: Markov transition matrix

NAR: Nonlinear autoregressive neural network

nMAE: Normalized mean absolute error

NNARX: Nonlinear autoregressive with external input

nRMSE: Normalized root mean square error

NSE: Nash-Sutcliffe efficiency

OB: Out of bag

P: Précipitation

P<sub>a</sub>: Pression atmosphérique

PNN: Polynomial neural network

P<sub>p</sub>: Pression partielle de la vapeur d'eau

PRNN: Probabilistic neural network

P<sub>s</sub>: Pression de saturation de la vapeur d'eau

QVNN: Quaternion valued neural networks

R: Coefficient de corrélation

R<sup>2</sup>: Coefficient de détermination

RBFNN: Radial basis function neural network

R<sub>dif</sub>: Radiation solaire diffuse

R<sub>dir</sub>: Radiation solaire directe

RFC: Random forest classification

RFR: Random forest regression

RGH: Radiation solaire globale horizontale

RMSE: Root mean square error

RNN: Recurrent neural network

rRMSE: Relative Square Error

RS: Radiation solaire

RVNN: Real valued neural network

SARIMA: Seasonal autoregressive integrated moving average

SLFN: Single hidden layer feedforward network

SS: Durée d'ensoleillement

SVM: Support vector machine

SVR: Support vector regression

SWT: Stationary wavelet transform

T<sub>a</sub>: Température de l'air

T<sub>Diff</sub>: Différence de température

T<sub>max</sub>: Température maximale

T<sub>mean</sub>: Température moyenne

T<sub>min</sub>: Température minimale

TOA: Top of atmosphere

T<sub>R</sub>: Rapport de température

$U_2$ : Vitesse du vent

VMD: Variational mode decomposition

WD: Direction du vent

WGPR: Weighted gaussian process regression

WPD: Wavelet packet decomposition

WRF: Weather research and forecasting model

WT: Wavelet transform

XGBoost: Extreme gradient boosting

$\alpha$ : Angle d'azimut

$\theta_z$ : Angle zénithal solaire

# *Introduction Générale*

---

## **Introduction Générale**

La prévision des variables météorologiques est actuellement considérée comme l'une des priorités les plus importantes en raison de son rôle cruciale dans de nombreux éléments de prise de décision liée à de nombreux domaines tels que l'agriculture, les affaires, le tourisme, la gestion de l'énergie, la santé humaine et animale, etc. (Mellit et al., 2013; Rasel et al., 2018; Fathi et al., 2022). Elle est souvent utilisée pour prédire et avertir des catastrophes naturelles causées par un changement brusque des conditions climatiques (Kaur et al., 2011; Bhawsar et al., 2021).

La mesure des variables climatiques, y compris l'humidité relative (HR) et la radiation solaire (RS), exige que des mesures étendues soient réalisées par un grand nombre de stations météorologiques couvrant les régions étudiées. Cependant, en raison des coûts des stations de mesure et de leur entretien, ces mesures ne sont pas disponibles pour la plupart de la surface terrestre. De plus, les processus météorologiques sont hautement non linéaires et suivant une tendance irrégulière, les techniques de l'intelligence artificielle (IA) sont des meilleures techniques pour prédire ces comportements, et pour analyser et identifier la relation entre les variables météorologiques (Mohd-Safar et al., 2018).

Le travail à réaliser dans la présente thèse est de proposer des modèles d'intelligence artificielle simples et hybrides pour la modélisation de l'humidité relative et la radiation solaire dans huit stations situées aux nord et dans la région semi-aride de l'Algérie, et l'évaluation de l'impact des algorithmes de décomposition du signal sur les performances de différents types de modèles.

La thèse s'organise alors comme suit:

Après une introduction générale, le premier chapitre présente l'état des connaissances sur les variables climatiques, diverses définitions sont présentées, ainsi que les méthodes et les instruments de mesure.

Le deuxième et le troisième chapitre exposent un état de l'art de la modélisation de l'HR et la RS, respectivement, par les différentes techniques de l'intelligence artificielle à travers une revue de littérature. Cette revue de littérature permet d'identifier plus facilement les lacunes dans l'ensemble de la littérature et les orientations futures de la recherche.

Le quatrième chapitre effectue une présentation et une description de la base de données utilisée issue des huit stations climatiques géographiquement situées aux nord et dans la région semi-aride de l'Algérie.

Dans le cinquième chapitre, nous exposons les modèles traditionnels d'apprentissage automatique ainsi que les méthodes de décomposition du signal, qui seront appliqués pour la modélisation de la radiation solaire et l'humidité relative.

Selon la variable climatique à modéliser, les chapitres six et sept présentent respectivement, les résultats de modélisation de l'HR et de la RS obtenus par les modèles traditionnels et hybrides déjà définis au chapitre précédent.

Enfin, une conclusion générale qui récapitule et compare l'essentiel des résultats obtenus précédents et quelques perspectives pour les recherches futures.

***Chapitre I***  
***État des Connaissances sur les Variables Climatiques***

---

## I.1. Introduction

La vie quotidienne est constamment sous l'influence des variables météorologiques; ces variables, y compris l'HR et la RS, affectent directement les environnements naturels et urbains, allant des problèmes de sécurité à la stabilité économique régionale, aux systèmes d'eau, à l'agriculture et à la gestion des systèmes d'énergie renouvelable (Krebs et al., 2009; Khatibi et al., 2013; Jian et al., 2014; Tai et al., 2016). Dans la plupart des applications spécialisées, les variables météorologiques servent normalement de variables d'entrée qui peuvent être prédites avec précision (Pour et al., 2020). La modélisation 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 (Bauer et al., 2015; Alley et al., 2019; Bayatvarkeshi et al., 2020). Dans ce premier chapitre, nous présenterons brièvement quelques notions de base sur les variables climatiques et leurs méthodes de mesures.

## I.2. L'humidité relative

L'humidité relative de l'air (HR) est l'une des variables météorologiques les plus critiques pour les études agronomiques, hydrologiques et climatiques. 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 (Mantri et al., 2021; Shad et al., 2022; Ozbek et al., 2022; Guo et al., 2023a), et elle a également été incluse dans diverses études sur le changement climatique (Gunawardhana et al., 2017; Adnan et al., 2021; Sein et al., 2022). 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 et al., 1998). Elle est importante pour le développement des plantes du fait que lorsque l'HR diminue, le taux de transpiration des plantes augmente. Lorsque l'eau absorbée par les racines ne correspond pas à l'eau perdue par la transpiration, les stomates des plantes se ferment et la transpiration diminue. Dans ce cas, les échanges gazeux nécessaires à la photosynthèse et à la respiration échouent et, par conséquent, la croissance de la plante ralentit ou s'arrête complètement (Cox et al., 2016; Kuzugudenli, 2018; Bayatvarkeshi et al., 2020). La température de l'air ( $T_a$ ) et l'HR sont considérées comme les facteurs les plus importants du confort environnemental thermique (Yasar et al., 2012; Kuang, 2020). L'HR est une variable météorologique très sensible qui

affecte plusieurs autres processus, en particulier les produits agroalimentaires et biologiques, et qui est fortement influencée par plusieurs autres variables météorologiques, en particulier la  $T_a$ , la RS, les précipitations (P), la vitesse du vent ( $U_2$ ), et la pression atmosphérique ( $P_a$ ) (Khatibi et al., 2013; Shrestha et al., 2019; Adnan et al., 2021). Une prévision précise de l'HR peut être très bénéfique pour plusieurs domaines (Hanoon et al., 2021; Tao et al., 2022).

L'HR est le rapport entre la quantité de vapeur d'eau disponible dans l'air et la quantité maximale de vapeur d'eau pouvant être retenue à la même température. En d'autres termes, l'HR est définie comme le rapport entre la pression partielle de la vapeur d'eau ( $P_p$ ) dans l'air et la pression de saturation de la vapeur d'eau ( $P_s$ ) à la même température (Equation I.1) (Shad et al., 2022; Tao et al., 2022; Ozbek et al., 2022; Merabet & Heddam, 2023).

$$HR (\%) = \frac{P_p}{P_s} \cdot 100 \quad (\text{I.1})$$

L'HR peut être mesurée à l'aide de différents instruments (Figure I.1), telles que les psychromètres, les capteurs de point de rosée, les hygromètres mécaniques et les sondes électroniques de l'HR. Les capteurs de ces sondes sont, dans la plupart des cas, capacitifs, résistifs ou optiques (Nilsson et al., 2018; Coimbra & Leal-Junior, 2022). Un examen approfondi concernant les principes, les mécanismes et les technologies de fabrication des capteurs d'humidité est présenté dans les références (Farahani et al., 2014; Fraden, 2016; Sonntag et al., 2021).




Figure I.1. Hygromètre à cheveux (Sonntag et al., 2021)

### I.3. La radiation solaire

La radiation solaire (RS) est défini comme la quantité d'énergie émise par le soleil sous forme d'ondes électromagnétiques qui atteint la surface de la terre (Jahani et al., 2017), elle est d'une importance fondamentale pour diverses applications, telles que la météorologie, l'hydrologie, l'écologie, l'agriculture, l'industrie, et en particulier pour la conception et l'utilisation de systèmes d'énergie renouvelable (Mirbolouki et al., 2022; Alizamir et al., 2023; Babatunde et al., 2023; Gürel et al., 2023). 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 (Stöckle et al., 2003; Yang et al., 2006; Castelli et al., 2014; Taki et al., 2021). La RS est également l'un des paramètres clés pour l'estimation de l'ET<sub>0</sub> (Aladenola & Madramootoo, 2014; Kisi et al., 2019). Elle dépend des conditions climatiques du lieu et des caractéristiques géographiques de la zone concernée (Guermoui et al., 2018a; 2018b).

La radiation globale reçu par le soleil (W/m<sup>2</sup>) sur une surface inclinée est la somme des trois composantes; directe, diffuse et réfléchi (Mousavi Maleki et al., 2017; Chikh et al., 2021; Gostein et al., 2022). La partie réfléchi a une valeur nulle sur une surface horizontale (Benatallah et al., 2019), la relation entre les trois radiations; globale horizontale (RGH), diffuse (R<sub>dif</sub>) et directe (R<sub>dir</sub>) est donnée par l'équation I.2 (Xu et al., 2016; Guermoui et al., 2018a; Ameen et al., 2019; Bellaoui et al., 2021):

$$RGH = R_{dir} \times \cos \theta_z + R_{dif} \quad (I.2)$$

Où  $\theta_z$  est l'angle zénithal solaire.

Chacune des composantes solaires citées précédemment sont mesurées avec un dispositif spécifique (Figure I.2); le pyranomètre, le pyranomètre avec ombrage, le pyréliomètre et l'albedomètre sont des instruments qui mesurent la RS globale, la RS diffuse, la RS directe et la radiation réfléchi, respectivement (Pazikadin et al., 2020; Karaman et al., 2021; Botero-Valencia et al., 2022; Gürel et al., 2023).



Figure I.2. Les instruments de mesure de la RS globale, directe et diffuse : (1) Pyranomètre pour mesurer la RS diffuse, (2) Pyranomètre pour mesurer la RS globale, (3) Périhéliomètre pour mesurer la RS directe, et (4) La boule utilisée pour cacher définitivement le pyranomètre (Rabehi et al., 2021)

Malheureusement, les mesures directes de la RS sont généralement rares et imprécises dans le monde; en particulier dans les pays en développement, il existe encore de vastes zones sans aucune observation de la RS 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; Taki et al., 2021; Zhou et al., 2021).

Une solution consiste à utiliser les observations satellitaires (Dahmani et al., 2016), de nombreuses méthodes ont été développées en vue d'estimer les RS à partir de ces observations depuis longtemps (Rigollier et al., 2004; Martins et al., 2007; Janjai, 2010; Rusen & Konuralp, 2020).

#### I.4. Les précipitations

Les précipitations (P) sont définies comme étant les produits liquides ou solides de la condensation de la vapeur d'eau tombant des nuages. La quantité totale des précipitations qui atteint le sol au cours d'une période donnée est exprimée en termes de profondeur verticale d'eau (mm) (ou d'équivalent en eau dans le cas des formes solides) à laquelle elle couvrirait une projection horizontale de la surface de la terre (WMO, 2018; Cauteruccio et al., 2021). Les précipitations jouent un rôle essentiel dans le maintien de la vie des hommes, des animaux et des plantes (Zerouali et al., 2023), 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. C'est l'une des composantes les plus étudiées en hydrologie et sciences du climat car elle affecte directement ou indirectement notre société (Mekanik et al., 2013; Babel et al., 2017; Duong et al., 2018; Danandeh Mehr et al., 2019). De plus, il possède une influence directe sur les écosystèmes, les ressources en eau, l'agriculture et la variabilité spatio-temporelle de la disponibilité de l'eau douce (Sharma & Goyal, 2015; Poornima & Pushpalatha, 2019; Salaeh et al., 2022; Dotse et al., 2023).

Une prévision précise des précipitations est nécessaire pour une estimation correcte du bilan hydrique ainsi que pour planifier, élaborer des stratégies, maintenir les options de stockage de l'eau pendant des conditions météorologiques extrêmes et concevoir des systèmes d'alerte aux inondations (Yaseen et al., 2018; Zambrano et al., 2018; Hammad et al., 2021; Vivas et al., 2023). La prévision des précipitations peut être considérée comme l'une des tâches pratiques les plus difficiles et complexes en raison des relations non linéaires entre les précipitations et les variables climatiques, telles que la température, le vent, l'humidité, la pression et d'autres facteurs (Danandeh Mehr et al., 2019; Chong et al., 2020; Ghamariadyan et al., 2021; Salaeh et al., 2022).

L'un des principaux facteurs limitant de la prévision des précipitations est très probablement la nature chaotique des précipitations, car cette incertitude doit être prise en compte lors de la prise de toute décision (Bushara & Abraham, 2013; Mishra, 2013; Pham et al., 2019). L'instrument de base de mesure des hauteurs de précipitations liquides ou solides est le pluviomètre (Tekleyohannes et al., 2021; Valík et al., 2021; Joseph et al., 2022; Choi et al., 2023) (Figure I.3). Plusieurs dispositifs et techniques sont également utilisés, et peuvent être trouvés dans la référence (Cauteruccio et al., 2021).



Figure I.3. Exemple d'un pluviomètre (Cauteruccio et al., 2021).

## I.5. La température

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 (Ahmadi et al., 2018; Nazeri Tahroudi et al., 2019). Elle joue un rôle important dans diverses applications, telles que les études hydrologiques, écologiques et environnementales (Stahl et al., 2006; Izadyet al., 2015; Sanikhani et al., 2018), les prévisions météorologiques (Christiansen, 2005; Kisi & Heddami, 2019; Kisi et al., 2019; Adnan et al., 2020), l'irrigation et l'agriculture (Webber et al., 2016; Curceac et al., 2019; Roy, 2020; Sekertekin et al., 2021), et le changement climatique (Lofgren et al., 2011; Lin et al., 2012; Ahmadi et al., 2018; Nazeri Tahroudi et al., 2019). Il est utilisé comme variable d'entrée clé et affecte directement la précision de ces applications (Izady et al., 2015).

La  $T_a$  varie selon les régions à la fois de façon saisonnière et annuelle en fonction de la latitude, de l'altitude, de l'évapotranspiration et de différentes caractéristiques géographiques (Jain & Kumar, 2012; Datta & Das, 2019). 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 (Ramesh & Anitha, 2014; Salcedo-Sanz et al., 2016; Shelia et al., 2019; Sekertekin et al., 2021). La  $T_a$  est mesurée en degrés Celsius ( $^{\circ}\text{C}$ ), kelvin (K) ou degrés Fahrenheit ( $^{\circ}\text{F}$ ), la relation entre les trois unités est donnée par les équations I.3 et I.4 (McRoberts, 2013; Bernstein, 2022):

$$T_{\text{Celsius}} (^{\circ}\text{C}) = T_{\text{kelvin}} - 273.16 \quad (\text{I.3})$$

$$T_{\text{Celsius}} (^{\circ}\text{C}) = \frac{5}{9} \cdot (T_{\text{Fahrenheit}} - 32) \quad (\text{I.4})$$

Les indicateurs les plus importants pour décrire la variation de la température sont la température maximale ( $T_{\text{max}}$ ) et minimale ( $T_{\text{min}}$ ), qui sont les températures les plus élevées et les plus basses, respectivement, au cours d'une période donnée.

Les techniques les plus utilisées pour mesurer la température de l'atmosphère comprennent de plusieurs types de thermomètres (Figure I.4). Plus de détails sur ces instruments et d'autres sont présentés dans la référence (Foken & Bange, 2021a).




Figure I.4. Thermomètre (Foken & Bange, 2021a)

## I.6. Le vent

Le vent, dans sa forme la plus simple, est le mouvement de l'air dans l'atmosphère terrestre (Krupar, 2020). Selon Davis (1982), Le vent est le mouvement horizontal de l'air, généralement généré par des gradients de pression barométrique. Le vent est un paramètre climatique très important, il a un impact énorme sur la climatologie, l'agriculture, la navigation, etc (Zhao et al., 2022). La surveillance des caractéristiques du vent, telles que la vitesse, la direction et la distribution, fournit des informations importantes qui sont cruciales pour diverses activités, allant des loisirs à l'industrie (Andrade et al., 2011; Bourassa et al., 2019; Ko et al., 2022).

Une estimation précise de la vitesse et de la direction du vent est importante pour de nombreux domaines d'application, notamment la prévision météorologique, l'énergie, le trafic, et la planification. Ces deux variables environnementales dépendent de plusieurs facteurs et sont liées entre elles (Zjavka, 2015; Krömer & Platoš, 2017). En tant que l'un des phénomènes naturels les plus fondamentaux, la modélisation du vent est le moteur le plus important qui aborde l'atmosphère (Gill & Shao, 2004). 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 et al., 2021; Chen et al., 2021a; Chen, 2022; Wang et al., 2022). 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 (Foken & Bange, 2021b). Les anémomètres (Figure I.5a) mesurent la vitesse du vent, et la girouette (Figure I.5b) indique sa direction. Ces instruments sont disponibles sous forme individuels ou peuvent être intégrés dans un seul système (Figure I.5c). Plusieurs types et formes de ces instruments sont présentées dans la référence (Foken & Bange, 2021b).




Figure I.5. Les instruments de mesure des paramètres du vent: (a) Anémomètres, (b) Girouette, (c) Combinaison d'un anémomètre avec une girouette (Foken & Bange, 2021b).

## I.7. Conclusion

Les variables climatiques, telles que l'humidité relative, la radiation solaire, les précipitations, la température, la vitesse et la direction du vent, etc., recueillies dans diverses stations météorologiques à partir des observations au sol, par radars, par satellites et par d'autres formes d'observation, montrent l'état actuel du climat. L'un des avantages les plus importants de la connaissance de ces variables est qu'il permet la prédiction d'une variable en fonction des autres. La prévision météorologique est l'une des attributs les plus importants pour les secteurs de l'agriculture et de nombreuses industries, en particulier pour prédire et avertir des catastrophes naturelles causées par des changements brusques des conditions du climat. Dans ce chapitre, nous avons présenté les principales variables climatiques qui sont utilisés dans la présente étude comme variables d'entrée pour la modélisation de l'humidité relative de l'air et la radiation solaire. Diverses définitions sont présentées, ainsi que les méthodes et les instruments de mesure.

***Chapitre II***

***Modélisation de l'Humidité Relative (HR): Etat de l'Art***

---

## II.1. Introduction

Une revue de littérature est la première étape dans le cadre des projets de recherche tels que les thèses de doctorat (Kraus et al., 2020). Elle est considérée comme un genre clé pour la préservation et le développement des connaissances (Gorman, 2016; Schryen & Sperling, 2023). De plus, elle joue un rôle important en tant que fondement de tous les types de recherche (Snyder, 2019), et permet aux chercheurs d'améliorer leur compréhension des travaux antérieurs dans leur domaine, et d'identifier plus facilement les lacunes dans l'ensemble de la littérature et les orientations futures de la recherche (Palmatier et al., 2018; Kraus et al., 2021; Kraus et al., 2022). Dans ce chapitre, nous avons essayé de donner un aperçu global sur les travaux de recherches publiées sur la modélisation de l'HR par l'outil de l'IA, et en fournissant un résumé et une analyse des résultats.

## II.2. L'humidité relative: Etat de l'art

Les techniques de l'IA ont été récemment utilisés comme outil de modélisation appropriée car leur application peut fournir une plate-forme pour l'analyse en temps réel ou simulée des paramètres météorologiques (Yaseen et al., 2019; Jing et al., 2019; Malik et al., 2020; Bounoua & Mechaqrane, 2023). Malgré que l'application des modèles à base de l'IA ait démontré une progression remarquable dans le domaine des processus hydrologiques, il a été observé que la modélisation de l'HR à l'aide de ces techniques est limitée (Adnan et al., 2021; Qadeer et al., 2021) par rapport à la modélisation des autres variables climatiques.

Nous passons en revue 51 applications de modèles basés sur l'IA liés à la modélisation de l'HR répertoriées dans la littérature (Tableau II.1, Figure II.1, II.2 et II.3). Certaines de ces études ont présentés une modélisation de l'HR dans les milieux extérieures, et d'autres études dans des milieux intérieures fermée, à savoir par exemple: les maisons d'essai (Lu & Viljanen, 2009); bâtiment d'enseignement (Özbalta et al., 2012); bâtiment expérimental (Shi et al., 2018); bâtiment intelligent (Mba et al., 2016; Wang et al., 2021; Kaligambe et al., 2022); bâtiments utilisés pour la préservation du patrimoine culturel (Boesgaard et al., 2022); usine intelligent (Prihatno et al., 2021); serre (Outanoute et al., 2015; Hamidane et al., 2021; Petrakis et al., 2022; El-Alaoui et al., 2022); les étables (Arulmozhi et al., 2021); et les tunnels (Peng et al., 2023).

De plus, Nous remarquons que la majorité des études ont porté sur l'estimation future de l'HR, et certaines d'autres ont été concentré sur la cartographie (Li & Zha, 2018; Chen et

al., 2023). Cependant, une étude récente a combiné entre les modèles autorégressifs saisonnière intégrés à moyennes mobiles (SARIMA) et les tests de tendances (Eymen & Köylü, 2019). Nous remarquons aussi que la majorité des chercheurs ont utilisé les techniques des réseaux de neurones artificiels (ANN) pour modéliser l'HR et qui ont montrés leur efficacité (He & Ma, 2010; Hasni et al., 2012; Outanoute et al., 2015; Çolak et al., 2022). Ceci est principalement dû à leur structure adaptative et à ses algorithmes de correction d'erreurs très puissants.

### II.2.1. Application du modèle MLPNN pour la modélisation de l'HR

Le **Tableau II.1** présente l'historique des méthodes appliquées à la modélisation de l'HR par l'IA. Il est clair que, la grande partie des articles publiés utilisent le modèle MLPNN pour la modélisation de l'HR. Nous discutons ci-après les différents travaux publiés.

Maqsood et al. (2004) furent les premiers à modéliser l'HR, ils ont utilisé les modèles MLPNN, le réseau de neurones à fonction radiale de base (RBFNN), le réseau de neurones récurrent Elman (ERNN) et le modèle de Hopfield (HFM, pour la prédiction de l'HR à pas de temps horaire. De très bons résultats ont été obtenus avec un coefficient de corrélation (R) supérieur à 0.99. Une année plus tard, Chaudhuri et Chattopadhyay (2005) ont conçu un MLPNN pour prédire l'HR et  $T_{\max}$  dans la ville de Calcutta en Inde. Les données de la  $T_{\max}$  et de l'HR maximale mesurées du 1<sup>er</sup> mars au 31 mai durant la période allant de 1994 à 1998 ont été utilisées. Les auteurs ont constaté que le modèle MLPNN est d'une grande utilité pour prévoir l'occurrence de systèmes météorologiques à petite échelle. Ils ont aussi observé que le remplissage des valeurs manquantes et l'extension des séries chronologiques sont possibles avec le modèle MLPNN. Dans le même pays, Paras et al. (2009) ont utilisé le modèle MLPNN pour prédire les paramètres météorologiques à savoir: la  $T_{\max}$ , la  $T_{\min}$  et l'HR. Deux cas ont été considérés; le premier utilise les  $T_{\max}$ ,  $T_{\min}$ , et les précipitations (P), alors que dans le second cas, l'HR est estimée à l'aide des données extraites de la série chronologique de l'HR elle-même, avec données enregistrées durant 03 années (Avril 1996 à Mars 1999). Les auteurs ont constaté que les résultats obtenus sont très encourageants. Pour l'HR, une valeur du coefficient de détermination ( $R^2$ ) de  $\approx 0.874$  a été obtenue. Le même modèle au même pays a été utilisé par Kaur et al. (2011) pour modélisé l'HR maximale et minimale avec des données de 10 ans (2000-2010). Les courbes de variations entre les valeurs observées et calculées montrent que l'HR maximale et minimale peut être prédite avec plus de précision en utilisant le MLPNN. Durant la même année, Khatib et al. (2011) ont testé un MLPNN pour

estimer la vitesse du vent ( $U_2$ ) et l'HR en Malaisie. Le modèle MLPNN développé pour la prédiction de l'HR utilise quatre entrées à savoir: le numéro du jour, l'heure, le taux d'ensoleillement et la couverture nuageuse. Sur la base des résultats obtenus, le modèle MLPNN proposé a donné de bonnes prédictions de l'HR horaire avec des valeurs du pourcentage de l'erreur absolu moyen (MAPE), la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur biais moyenne (MBE), de l'ordre de  $\approx 5.08\%$ ,  $\approx 5.8$  et  $\approx -0.041$ , respectivement. Alors que les valeurs de MAPE pour les prévisions journalières et mensuelles étaient de l'ordre de  $\approx 2.66\%$  et  $\approx 0.57\%$ , respectivement.

En Turquie, trois études ont été réalisées en comparant le modèle MLPNN et les modèles à base de régression linéaire multiple (MLR). La première étude a été conduite par [Yasar et al. \(2012\)](#). Ils ont modélisé l'HR mensuelle en utilisant cinq variables d'entrée, à savoir les précipitations mensuelles, la latitude, la longitude, l'altitude et le numéro du mois. Ils ont constaté que le MLPNN était plus performant et présentait des valeurs de R allant de  $\approx 0.96$  à  $\approx 0.99$ , et de  $\approx 0.73$  à  $\approx 0.94$  pour le MLPNN et le MLR, respectivement, tandis que le MAPE a été comprise entre  $\approx 1.56\%$  et  $\approx 3.32\%$  et entre  $\approx 3.88\%$  et  $\approx 8.56\%$ , respectivement, ce qui montre la forte contribution des informations topographiques à l'amélioration des performances de prévisions de l'HR mensuelle. La deuxième étude a été conduite par [Özbalta et al. \(2012\)](#). Ils ont développé plusieurs modèles pour prédire les valeurs moyennes journalières de la température ( $T_{\text{mean}}$ ) et de l'HR intérieure dans un bâtiment d'enseignement. Afin de prédire la  $T_{\text{mean}}$  et l'HR, les auteurs ont utilisé un ensemble de données d'entrées comprenant les conditions climatiques extérieures, le jour de l'année et les paramètres de confort thermique. Les résultats obtenus étaient très satisfaisantes, le modèle MLPNN a donné des meilleures performances avec des valeurs de  $R^2$  et RMSE de l'ordre de  $\approx 0.96$  et  $\approx 0.90$ , respectivement. La troisième étude a été conduite par [Kuzugudenli \(2018\)](#). Il a essayé de prédire l'HR en fonction de la  $T_{\text{mean}}$  mensuelle, les précipitations et les paramètres d'altitude obtenus à partir de 177 stations météorologiques pour une période de trente années (1987-2017). Lors de l'analyse, le modèle MLPNN avait un pouvoir prédictif plus important ( $R^2 \approx 0.84$ ) que le modèle MLR ( $R^2 \approx 0.76$ ).

Aux États-Unis, [Khatibi et al. \(2013\)](#) ont comparé entre le modèles MLPNN et la programmation génétique d'expression (GEP) pour la prédiction de l'HR en fonction des valeurs de  $T_{\text{mean}}$ ,  $U_2$  et  $P_a$ , en utilisant les données de deux stations. Les modèles proposés ont

donné des performances de prédiction acceptables, avec une valeur de  $R \approx 0.931$  pour le MLPNN, et  $\approx 0.917$  pour le GEP. Durant la même année, Mellit et al. (2013) ont comparé le modèle machine à vecteurs de support à base des moindres carrés (LSSVM) par des modèles à base des ANN, à savoir: MLPNN, RBFNN, le réseau de neurones probabiliste (PRNN) et le réseau de neurones récurrent (RNN), pour la prédiction à court terme de séries chronologiques météorologiques ( $RS$ ,  $T_{\text{mean}}$ ,  $HR$ ,  $U_2$  et  $P_a$ ). Les modèles ont été développés en fonction des données historiques des variables enregistrées dans la ville de Médine en Arabie saoudite. La comparaison a montré que le LSSVM a donné des résultats nettement meilleurs que les modèles ANN avec des valeurs de  $R^2$ , RMSE et MAPE de  $\approx 0.96$ ,  $\approx 1.65$  et  $\approx 0.27$ , respectivement, pour la prédiction de l'HR.

Le MLPNN a été également utilisé pour l'estimation de  $T_a$  et de l'HR intérieur d'une serre expérimentale située à la faculté des sciences de Meknès (Maroc) par Outanoute et al. (2015). Ils ont utilisé les données de la  $T_a$  et l'HR externe et interne, collectées avec un intervalle de temps d'échantillonnage de 10 secondes. Une comparaison des données mesurées et simulées pour la  $T_a$  et l'HR sous serre a montré que les modèles élaborés étaient capables de prédire les conditions à l'intérieur de la serre. De plus, les auteurs ont constaté que ce modèle pourrait être utile pour développer un système de contrôle automatique. D'autre étude similaire conduite par Mba et al. (2016) en utilisant le modèle MLPNN pour prédire la  $T_a$  et l'HR horaire intérieurs d'un bâtiment moderne situé dans la ville de Douala, en Cameroun. Les auteurs ont utilisé le MLPNN avec 48 variables d'entrée (les 12 dernières valeurs des  $T_a$  et d'HR intérieur et extérieur). Les résultats obtenus étaient très satisfaisants, avec un  $R$  de l'ordre de  $\approx 0.985$  pour l'HR. Shi et al. (2018) ont utilisé le MLPNN pour la prédiction de la  $T_{\text{mean}}$  et de l'HR à 6 heures, 24 heures et 72 heures à l'avance, dans un bâtiment expérimental à Chongqing, en Chine. Les résultats expérimentaux ont montré que les prédictions de l'HR ont de fortes corrélations avec les données réelles avec des valeurs de  $R^2$  de  $\approx 0.977$ , et les auteurs ont conclu que le modèle MLPNN fournissait des meilleures prédictions pour la  $T_a$  intérieure et l'HR.

Durant la même année, Mohd-Safar et al. (2018) ont utilisé des modèles MLPNN pour la prévision horaire des variables météorologiques ( $P_a$ ,  $T_{\text{mean}}$  et  $HR$ ). Des données météorologiques horaires de la  $P_a$ , la température du bulbe sec, le point de rosée, l'humidité, la vitesse et la direction du vent, la hauteur et l'intensité des précipitations, mesurées durant

trois années (2012 à 2014) en Malaisie ont été utilisées. Pour l'HR, une valeur de R de l'ordre de  $\approx 0.959$  a été obtenue. En Colombie, la seule étude est conduite par [Molano-Jimenez et al. \(2018\)](#) qui ont proposé quatre modèles ANN pour prédire l'HR et la  $T_{\text{mean}}$  en fonction de trois variables à savoir la température intérieure et extérieure et la concentration du  $\text{CO}_2$ . Pour comparer les résultats, les auteurs ont utilisé deux critères de mesure de l'erreur; l'erreur quadratique moyenne (MSE) et l'erreur absolue moyenne (MAE), et ont observé que les modèles utilisés sont adaptés à la prédiction de l'HR dans les étables non équipées de capteurs d'humidité. Un an plus tard, [Rajendra et al. \(2019\)](#) ont conduit une étude comparative entre le modèle MLPNN, RBFNN et MLR pour prédire les données météorologiques horaires et mensuelles de deux sites en Inde. Les données de la  $T_{\text{mean}}$ , l'HR et la température du sol ont été utilisées. Pour l'HR, la valeur de R est de l'ordre de  $\approx 0.91$  pour le RBFNN et le MLPNN. En revanche, le MLR présentait une valeur de  $\approx 0.76$ , inférieure à celle obtenue par les ANN. Deux ans plus tard, [Mantri et al. \(2021\)](#), ont développé un modèle hybride basé sur les ANN pour prédire la  $T_{\text{mean}}$  et l'HR. Les données d'entrée comprenaient la température du point de rosée, la visibilité, la vitesse et la direction du vent, enregistrées à Delhi en Inde durant six années (2011-2016). Les résultats du modèle de prédiction ont montré la grande capacité des modèles à prédire l'HR.

[Ghadiri et al. \(2021\)](#) ont conduit une étude comparative entre le MLPNN, le LSSVM, le RBFNN et le système d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS) pour estimer l'HR en fonction de la dépression du bulbe humide et de la température du bulbe sec. Les valeurs obtenues de  $R^2$ , RMSE et MSE étaient ( $\approx 0.9997$ ,  $\approx 0.366$  et  $\approx 0.134$ ), ( $\approx 0.998$ ,  $\approx 0.999$  et  $\approx 0.999$ ), ( $\approx 0.9996$ ,  $\approx 0.4393$  et  $\approx 0.193$ ), ( $\approx 0.999$ ,  $\approx 0.25$  et  $\approx 0.132$ ) pour les modèles RBFNN, MLPNN, ANFIS et LSSVM, respectivement. Sur la base des résultats obtenus, les auteurs à conclure que la capacité des méthodes proposées a été confirmée de manière significative. [Petraakis et al. \(2022\)](#) ont modélisé la température et l'HR intérieures d'une serre agricole en Grèce. Les variables d'entrées sont la  $T_a$  externe, l'HR externe,  $U_2$  et la RS, ainsi que la  $T_a$  et l'HR internes. Les résultats étaient très satisfaisants avec un  $R^2$  de  $\approx 0.999$  pour les deux variables. [El-Alaoui et al. \(2022\)](#) ont utilisé un ANN multicouche pour la prédiction de la  $T_a$  interne et de l'HR d'une serre située près d'Agadir, au Maroc. Dans un premier temps, les auteurs ont fait une analyse des corrélations entre les entrées et les sorties afin de sélectionner les variables d'entrée adéquats. La  $T_a$  extérieure, l'HR et la RS sont les variables qui ont le coefficient de corrélation le plus élevé avec les sorties. Les résultats ont été très

satisfaisants avec un R de l'ordre  $\approx 0.996$ . Durant la même année, [Shad et al. \(2022\)](#) ont tenté de mettre en œuvre deux modèles à savoir: le MLPNN et SARIMA pour prévoir l'HR mensuelle à Delhi, en Inde. Les données mensuelles moyennes de l'HR pour la période 2000-2016 ont été utilisées pour réaliser les objectifs de l'étude proposée. Les performances des modèles ont été mesurées à l'aide de RMSE et MAE. Les résultats ont montré que le modèle MLPNN (RMSE $\approx 4.65$  et MAE $\approx 3.42$ ) était plus fiable pour prédire l'HR que le modèle SARIMA (RMSE $\approx 6.04$  et MAE  $\approx 4.56$ ). [Wu et al. \(2022\)](#) ont comparé entre le MLPNN et le modèle à base d'apprentissage profond (Deep learning) dite Mémoire longue à court terme (LSTM) pour prédire un ensemble de données de microclimat urbain constitués de la  $T_{\text{mean}}$ , l'HR et la RS. Les données utilisées sont collectées à partir d'une station de microclimat installée sur le toit d'un bâtiment de sept étages en Chine, durant la période de 2017 à 2019 avec une résolution de 5 minutes, et l'ensemble de données de janvier à avril 2020 ont été utilisées comme données de validation. Les résultats obtenus ont montrés que les deux modèles MLPNN et LSTM assurent des meilleures performances pour l'HR avec un R de l'ordre de  $\approx 0.99$ .

## II.2.2. Application du Réseau ELM pour la modélisation de l'HR

La seule étude dans la littérature qui parle de l'utilisation du modèle des machines à apprentissage extrême (ELM) pour modéliser l'HR est conduite par [Merabet et Heddam \(2023\)](#), cette recherche a proposé une nouvelle stratégie de modélisation de l'HR par l'utilisation de la décomposition en mode empirique (EMD), la décomposition en mode variationnel (VMD) et la transformée en ondelettes empiriques (EWT), combinées aux trois modèles d'apprentissage automatique simple à savoir: MLPNN, ELM et la régression de forêt aléatoire (RFR). Premièrement, les modèles simples ont été utilisés pour prédire l'HR journalière à l'aide de diverses variables météorologiques, à savoir: les  $T_{\text{min}}$ ,  $T_{\text{max}}$ , P, RS et la  $U_2$ , mesurée à deux stations météorologiques situées en Algérie. Deuxièmement, les variables météorologiques ont été décomposées en plusieurs fonctions de mode intrinsèque (IMFs) et utilisées comme de nouvelles variables d'entrée aux modèles hybrides. Les résultats obtenus par les modèles simples montrent que le MLPNN donne des meilleures performances avec des valeurs de R, le critère d'efficacité de Nash-Sutcliffe (NSE), RMSE et MAE de l'ordre de  $\approx 0.939$ ,  $\approx 0.882$ ,  $\approx 7.44$  et  $\approx 5.62$  pour la station de Constantine, et  $\approx 0.943$ ,  $\approx 0.887$ ,  $\approx 7.72$  et  $\approx 5.93$  pour la station de Sétif, respectivement. Les modèles hybrides ont montré des

performances élevées avec un R, NSE, RMSE et MAE de l'ordre de  $\approx 0.950$ ,  $\approx 0.902$ ,  $\approx 6.79$  et  $\approx 5.24$  pour la station de Constantine, et  $\approx 0.955$ ,  $\approx 0.912$ ,  $\approx 6.82$  et  $\approx 5.29$  pour la station de Sétif. Les auteurs ont montré que les nouvelles approches hybrides ont fourni des performances plus, mettant en évidence l'importance des techniques de décomposition (EMD, VMD et EWT).

### II.2.3. Application du modèle GRNN pour la modélisation de l'HR

Pour le modèle des réseaux de neurones à fonction de régression générale (GRNN), une seule étude menée par [Białobrzewski \(2008\)](#) a été publiée. Les deux modèles GRNN et MLPNN ont été comparés pour l'estimation et la prédiction de l'HR. Les données expérimentales sont les résultats des mesures des variables météorologiques de la ville d'Olsztyn (Nord-Est de la Pologne). Les auteurs ont utilisé un intervalle de prévision de 3 heures. La prévision a été étendue à 48 h en réintroduisant une valeur nouvellement estimée en entrée. Les résultats obtenus étaient satisfaisants et le modèle MLPNN assure des valeurs de R et d'erreur relative moyenne (MRE) de l'ordre de  $\approx 0.972$  et  $\approx 2.1\%$ , respectivement. Avec le modèle GRNN, Lorsque 100 % des données ont été introduites, ces modèles ont estimé l'HR avec un coefficient de corrélation parfait ( $R \approx 0.999$ ).

### II.2.4. Application du modèle MARS pour la modélisation de l'HR

Le modèle de régression multivariée par Spline adaptative (MARS) a été utilisé dans une seule étude conduite par [Adnan et al. \(2021\)](#). Ils ont comparé ce modèle par le modèle M5Tree pour prédire l'HR journalière en fonction des P, RS et la  $T_{\text{mean}}$ , mesurés dans le bassin de la rivière Hunza, au Pakistan. Les résultats obtenus ont révélé que le modèle MARS était plus performant que le modèle M5Tree, avec un RMSE, MAE et  $R^2$  allant de  $\approx 5.86\%$  à  $\approx 6.58\%$ ,  $\approx 4.97\%$  à  $\approx 5.43\%$  et  $\approx 0.806$  à  $\approx 0.815$ , respectivement, par rapport à la valeur de  $\approx 6.08\%$  à  $\approx 6.19\%$ ,  $\approx 5.46\%$  à  $\approx 5.58\%$  et  $\approx 0.762$  à  $\approx 0.783$  obtenus avec le M5Tree.

### II.2.5. Application des forêts aléatoires (RFR) pour la modélisation de l'HR

Pour la première fois, [Li et Zha \(2018\)](#) ont présenté une méthodologie pour cartographier l'HR, la  $T_{\text{mean}}$  et extrême en été chaud en Chine en utilisant les modèles à base de forêt aléatoire (RFR). Plusieurs données en tant que variables explicatives ont été exploitées pour prédire l'HR et les températures. Les auteurs ont démontré la capacité des modèles de régression RFR à générer des cartes d'HR et des températures avec des gradients

plus fins en été chaud dans la Chine ( $RMSE \approx 7.4\%$ ,  $MAE \approx 5.6\%$ ), par rapport à la technologie d'interpolation et aux méthodes statistiques. Trois ans plus tard, [Hanoon et al. \(2021\)](#) ont comparé le RFR, le MLPNN, le RBFNN, l'arbre de renforcement de gradient (GBT) et la régression linéaire (LR), pour prédire l'HR journalière et mensuelle en Malaisie. D'après les résultats obtenus, il a été constaté que: (i) à l'échelle journalière, le MLPNN était plus performant et assurait des valeurs de R, RMSE et MAE d'environ  $\approx 0.634$ ,  $\approx 2.6\%$  et  $\approx 3.9\%$ , et (ii) à l'échelle mensuelle, le RBFNN était le plus performant avec des valeurs de R, RMSE et MAE d'environ  $\approx 0.713$ ,  $\approx 1.6\%$  et  $\approx 2\%$ , respectivement. Durant la même année, [Hussein et al. \(2021\)](#) ont comparé entre cinq modèles d'apprentissage automatique, à savoir: les RFR, MLPNN, MLR, l'algorithme d'extrême gradient Boosting (XGBoost) et l'algorithme des K plus proches voisins (KNN) pour estimer cinq variables climatiques à savoir: l'HR, les P, l'évaporation, la  $T_{mean}$ , et  $U_2$  en Madagascar à l'aide de données d'image mensuelles. Les données d'images collectées et utilisées étaient disponibles dans les archives de données GESDISC de la NASA. D'après les résultats obtenus, il a été constaté que les modèles proposés étaient capables d'estimer l'HR avec un  $R^2$  de  $\approx 0.99$ . [Park et al. \(2021\)](#) ont modélisé l'HR de surface à l'aide du modèle RFR et XGBoost au Japon et en Corée du Sud. Les auteurs ont utilisé la combinaison des données satellitaires dans des conditions sans nuages, et des données dans des conditions de ciel nuageux. Les résultats ont montré que le XGBoost ( $R^2 \approx 0.72$ ,  $MAE \approx 7.88\%$  et  $RMSE \approx 10.61\%$ ) assure une précision légèrement supérieure au modèle RFR. [Prihatno et al. \(2021\)](#) ont utilisé les RFR pour la prédiction de l'HR dans l'environnement d'une usine intelligente. À la lumière de la valeur de MAPE entre les valeurs observées et estimées, les auteurs ont obtenu un pourcentage de 82.49 %, ce qui est considéré comme une excellente précision. De plus, des faibles valeurs des indices statistiques en relation avec l'erreur de prédiction ont été obtenus ( $MAE \approx 0.0837$ ,  $MSE \approx 0.0367$  et  $RMSE \approx 0.1918$ ). En 2022, pour la première fois, une étude propose l'utilisation des forêts aléatoires de classification (RFC) et XGBoost pour la prédiction de l'HR. C'est l'étude de [Boesgaard et al. \(2022\)](#), qui ont étudié l'utilisabilité des deux méthodes d'apprentissage automatique supervisé pour prédire l'HR de 24 h à l'avance à l'intérieur des bâtiments utilisés pour la préservation du patrimoine culturel en Danemark. Les données utilisées sont des enregistrements horaires de l'HR et la  $T_a$  intérieurs et extérieurs. Les auteurs ont obtenus des bons résultats de prévision. Un an plus tard, en 2023, une étude propose une technique pour cartographier l'HR, c'est l'étude de [Chen et al. \(2023\)](#) qui ont exploité le RFR pour effectuer une cartographie horaire de l'environnement thermique dans la ville de Hong Kong, en Chine,

à une résolution de 100 m, y compris la  $T_a$ , l'HR et la température effective nette, pour la saison estivale (mai à septembre) de 2008 à 2018, en tenant compte des facteurs météorologiques, de la topographie et des facteurs paysagers basés sur la zone climatique locale. Les résultats obtenus étaient satisfaisante avec des valeurs moyennes de  $R^2$ , RMSE et MAE de l'ordre de  $\approx 0.797$ ,  $\approx 5.381\%$  et  $\approx 3.864\%$ , respectivement.

## II.2.6. Application du modèle SVR pour la modélisation de l'HR

Le modèle SVR a été utilisé pour la modélisation de l'HR par certains chercheurs. [Suradhaniwar et al. \(2021\)](#) ont développé des modèles de prévision de l'HR et la  $T_a$  en Inde. Ils ont appliqué le SVR, MLPNN, LSTM, SARIMA et RNN. La base de données utilisée est constituée de six paramètres à savoir: l'HR, la  $T_{\text{mean}}$ , les P, la RS,  $U_2$  et la  $P_a$ . Sur la base des valeurs du RMSE, il a été constaté que les modèles SVR (RMSE  $\approx 1.96$  et  $\approx 11.31$ ) et SARIMA (RMSE  $\approx 1.87$  et  $\approx 11.31$ ) étaient plus performant que le MLPNN (RMSE  $\approx 2.83$  et  $\approx 18.11$ ) et les deux modèles d'apprentissages profonds; LSTM (RMSE  $\approx 2.12$  et  $\approx 12.02$ ) et RNN (RMSE  $\approx 2.13$  et  $\approx 14.74$ ). Durant la même année, [Wang et al. \(2021\)](#) ont comparé entre le SVR et trois réseaux LSTM à savoir: DFL (Distributed Fusion LSTM network), FLSTM (Fusion LSTM) et LSTM classique, pour la prédiction de la  $T_{\text{mean}}$  et de l'HR dans un bâtiment intelligent de sept étages et de 11700 m<sup>2</sup> à Bangkok, en Thaïlande. Les données d'entrées des modèles sont la température, l'humidité, la lumière, la charge HVAC (chauffage, ventilation et climatisation) et la date. Les résultats de prédiction de l'HR montrent que le DFL (MAE  $\approx 0.884$ , MSE  $\approx 1.679$ ) est plus performant par rapport aux autres méthodes de prévision, notamment SVR (MAE  $\approx 1.395$ , MSE  $\approx 9.638$ ), FLSTM (MAE  $\approx 1.895$ , MSE  $\approx 8.367$ ) et LSTM classique (MAE  $\approx 1.356$ , MSE  $\approx 2.864$ ). [Qadeer et al. \(2021\)](#) ont comparé entre le modèle SVR et RFR pour modéliser l'HR en fonction de deux prédicteurs, à savoir: la température du bulbe sec et la température du bulbe humide, les auteurs ont signalé une différence négligeable entre les deux modèles. [Arulmozhi et al. \(2021\)](#) ont comparé entre plusieurs modèles, i.e., SVR, MLPNN, RFR, MLR et la régression à arbre de décision (DTR) pour prédire l'HR intérieur et la  $T_a$  intérieure dans une étable située à l'université nationale de Gyeongsang, Jinju-Si, République de Corée. D'après les résultats obtenus, le RFR est le modèle le plus performant avec des valeurs de  $R^2$ , RMSE et MAE de  $\approx 0.954$ ,  $\approx 2.429\%$  et  $\approx 1.470\%$ , respectivement. [Tao et al. \(2022\)](#) ont comparé les modèles SVR, RFR et MARS pour la modélisation de l'HR mensuelle. Les auteurs ont utilisé le modèle XGBoost pour une meilleure sélection des variables d'entrée. Plusieurs variables

climatiques collectées à deux stations météorologiques en Irak, à savoir: les deux températures  $T_{\max}$  et  $T_{\min}$ ,  $ET_0$ , les heures d'ensoleillement (SS) et  $U_2$ . Le modèle RFR était le plus performant à la station de Kut, présentant des valeurs de RMSE, MAE et NSE d'environ  $\approx 4.92\%$ ,  $\approx 3.89\%$  et  $\approx 0.916$ , respectivement, tandis qu'à la station de Mossoul, le modèle MARS était le plus performant avec des valeurs RMSE, MAE et NSE de  $\approx 3.80\%$ ,  $\approx 2.86\%$  et  $\approx 0.967$ , respectivement.

### II.2.7. Application d'autres modèles pour la modélisation de l'HR

Dans la littérature, d'autres modèles ont été utilisés pour modéliser l'HR. [Lu et Viljanen \(2009\)](#) ont utilisé pour la première fois le modèle non linéaire Autorégressif avec entrée exogène (NNARX) et l'algorithme génétique (GA) pour estimer l'HR dans une maison d'essai. Les résultats de prédiction de l'HR ont montré une performance prédictive élevée avec une valeur de R d'environ  $\approx 0.99$ . [Mellit et al. \(2010a\)](#) ont appliqué un modèle hybride (PNN-GA) basé sur l'utilisation d'un réseau de neurones PNN (Polynomial Neural Network) combiné à un algorithme génétique (GA) pour la prédiction de séries temporelles météorologiques ( $RS$ ,  $T_a$ , HR et  $U_2$ ), par l'utilisation des données historiques de chaque variable. Ces données journalières sont enregistrées pendant cinq ans (1996-2000) à Alger par l'Office National de Météorologie (ONM). Les résultats obtenus pour la prédiction de l'HR est très satisfaisantes, la valeur de R est de l'ordre de  $\approx 0.9832$ . Les auteurs ont montré que le modèle proposé fournit des résultats plus performants que les autres techniques, ANN (MLPNN, RBFNN et RNN), réseau d'ondelettes et ANFIS.

[Thapliyal et al. \(2014\)](#) ont utilisé un modèle de régression linéaire (LR) pour l'extraction de l'HR en Inde, ce modèle montre une bonne performance prédictive avec une valeur R d'environ  $\approx 0.91$ . [Li et al. \(2019a\)](#) ont comparé les modèles autorégressifs intégrés et à moyenne mobile (ARIMA) et les modèles LSTM. [Abayomi-Alli et al. \(2019\)](#) ont utilisé le LSTM pour prédire l'HR en utilisant des données satellitaires comprenant: la date, la longitude, la latitude, l'altitude, la  $T_{\max}$ , la  $T_{\min}$ , les P, la  $U_2$ , l'HR, la RS et l'ozone troposphérique. De très bons résultats ont été obtenus avec une valeur de R de  $\approx 0.98$ . Un an plus tard, [Hutapea et al. \(2020\)](#) ont observé que le modèle LSTM est capable de prédire l'HR dans la région de Medan, en Indonésie. [Ma et al. \(2020\)](#) ont utilisé l'algorithme XGBoost pour prédire la température et l'humidité extérieures à l'aide de données acquises à Shenzhen, en Chine. Le modèle XGBoost a donné des excellents résultats avec  $R^2 \approx 0.81$  et  $RMSE \approx 6.33$ . [Li et al. \(2020\)](#) ont utilisé trois modèles; Holt-Winters, SARIMA et XGBoost, pour prédire

l'HR dans la ville de Ya'an, en Chine. Les résultats obtenus ont montré que parmi les trois modèles, le modèle XGBoost (MAE $\approx$ 2.29, MSE $\approx$ 9.17 et MAPE $\approx$ 2.99%) était meilleure. Un an plus tard, [Hamidane et al. \(2021\)](#) ont utilisé le modèle ANFIS pour prédire l'HR interne. Les résultats obtenus étaient satisfaisants, avec R<sup>2</sup> et RMSE de l'ordre de  $\approx$ 0.886 et  $\approx$ 0.633, respectivement. [Ho et al. \(2021\)](#) ont utilisé le modèle LSTM pour la prévision de l'HR dans les États-Unis. Dans une autre étude, des données météorologiques historiques de l'HR de huit ans dans des différentes régions climatiques de Turquie (Ankara, Erzurum, Samsun, Diyarbakır, Antalya et Bilecik) ont été exploitées par [Ozbek et al. \(2022\)](#) pour prédire l'HR un jour à l'avance par l'utilisation de deux algorithmes d'apprentissage automatique; LSTM et ANFIS. Les résultats obtenus indiquent que les modèles LSTM et ANFIS ont donné des performances presque identiques et satisfaisantes pour la prédiction de l'HR journalière avec une certaine supériorité du modèle LSTM.

Tableau II.1. Historique des modèles appliqués à la modélisation de l'HR

N°	Auteurs	Année	pays	Modèles
01	Maqsood et al	2004	Canada	MLPNN, RBFNN, ERNN et HFM
02	Chaudhuri et Chattopadhyay	2005	Inde	MLPNN
03	Bialobrzewski	2008	Pologne	MLPNN et GRNN
04	Paras et al	2009	Inde	MLPNN
05	Lu et Viljanen	2009	Finlande	NNARX et GA
06	Mellit et al	2010a	Algérie	PNN-GA, Ondelettes, RBFNN, MLPNN, RNN, ANFIS
07	Kaur et al	2011	Inde	MLPNN
08	Khatib et al	2011	Malaisie	MLPNN
09	Yasar et al	2012	Turquie	MLPNN et MLR
10	Özbalta et al	2012	Turquie	MLPNN et MLR
11	Khatibi et al	2013	USA	MLPNN et GEP
12	Mellit et al	2013	Arabie saoudite	LSSVM, RNN, MLPNN, RBFNN et PNN
13	Thapliyal et al	2014	Inde	LR
14	Outanoute et al	2015	Maroc	MLPNN
15	Mba et al	2016	Cameroun	MLPNN
16	Shi et al	2018	Chine	MLPNN
17	Mohd-Safar et al	2018	Malaisie	MLPNN
18	Kuzugudenli	2018	Turquie	MLPNN et MLR
19	Li et Zha	2018	Chine	RFR
20	Molano-Jimenez et al	2018	Colombie	MLPNN
21	Rajendra et al	2019	Inde	MLPNN, RBFNN et MLR
22	Li et al	2019a	Chine	ARIMA et LSTM
23	Abayomi-Alli et al	2019	Nigeria	LSTM
24	Eymen et Köylü	2019	Turquie	ARIMA et le test de Mann-Kendall
25	Hutapea et al	2020	Indonésie	LSTM
26	Ma et al	2020	Chine	XGBoost
27	Li et al	2020	Chine	Holt-Winters, SARIMA et XGBoost
28	Mantri et al	2021	Inde	MLPNN
29	Suradhaniwar et al	2021	Inde	RNN, LSTM, SVR, SARIMA et MLPNN
30	Hanoon et al	2021	Malaisie	RFR, GBT, LR, MLPNN et RBFNN
31	Hussein et al	2021	Madagascar	RFR, MLPNN, MLR, XGBoost et KNN
32	Adnan et al	2021	Pakistan	MARS et M5Tree
33	Wang et al	2021	Thaïlande	DFLSTM, FLSTM, LSTM et SVR
34	Hamidane et al	2021	Maroc	ANFIS
35	Park et al	2021	Japon et Corée du sud	RFR et XGBoost
36	Ghadiri et al	2021	-	LSSVM, MLPNN, RBFNN et ANFIS
37	Ho et al	2021	USA	LSTM
38	Qadeer et al	2021	-	RFR et SVR
39	Prihatno et al	2021	Corée du sud	RFR
40	Arulmozhi et al	2021	Corée	MLR, MLPNN, RFR, SVR et DTR
41	Ozbek et al	2022	Turquie	LSTM et ANFIS
42	Wu et al	2022	Chine	MLPNN et LSTM
43	Tao et al	2022	Irak	XGBoost, SVR, RFR et MARS
44	Shad et al	2022	Inde	SARIMA et MLPNN
45	El-Alaoui et al	2022	Maroc	MLPNN
46	Petrakis et al	2022	Grèce	MLPNN
47	Kaligambe et al	2022	Japon	XGBoost
48	Boesgaard et al	2022	Danemark	RFC et XGBoost
49	Peng et al	2023	Chine	LSTM-RNN
50	Chen et al	2023	Chine	RFR
51	Merabet et Heddami	2023	Algérie	MLPNN, ELM, RFR, EMD, EWT et VMD

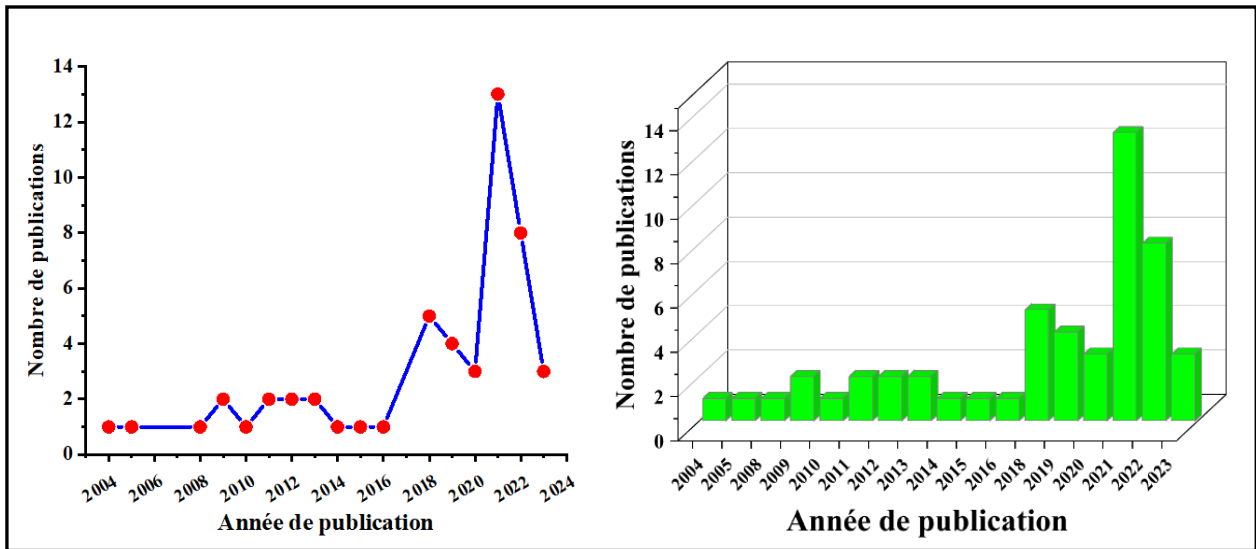


Figure II.1. Nombre de publications en relation avec l'application des modèles à base d'IA pour la modélisation de l'HR

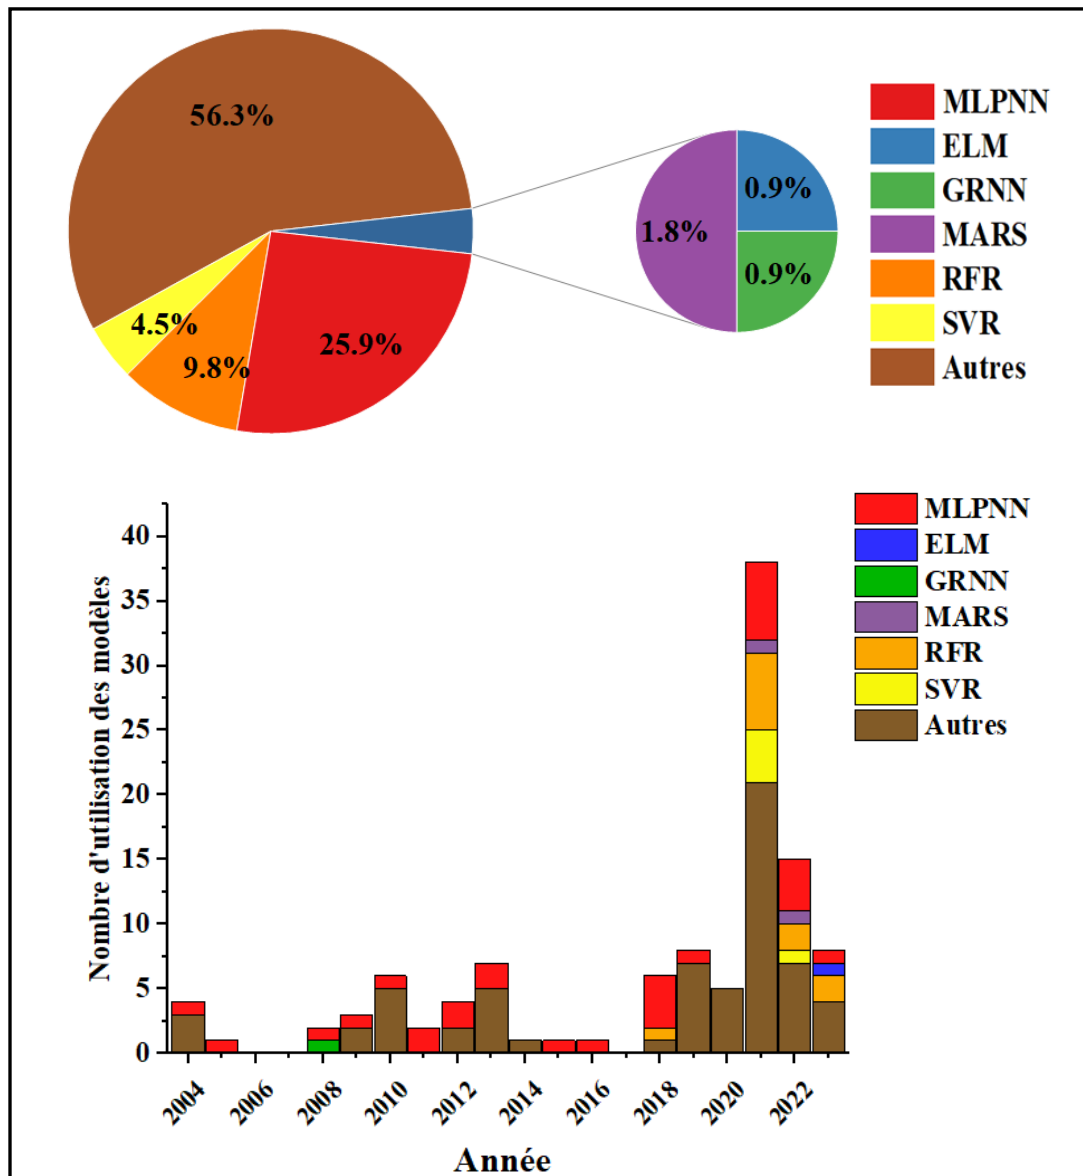


Figure II.2. Les modèles à base d'IA utilisés pour la modélisation de l'HR

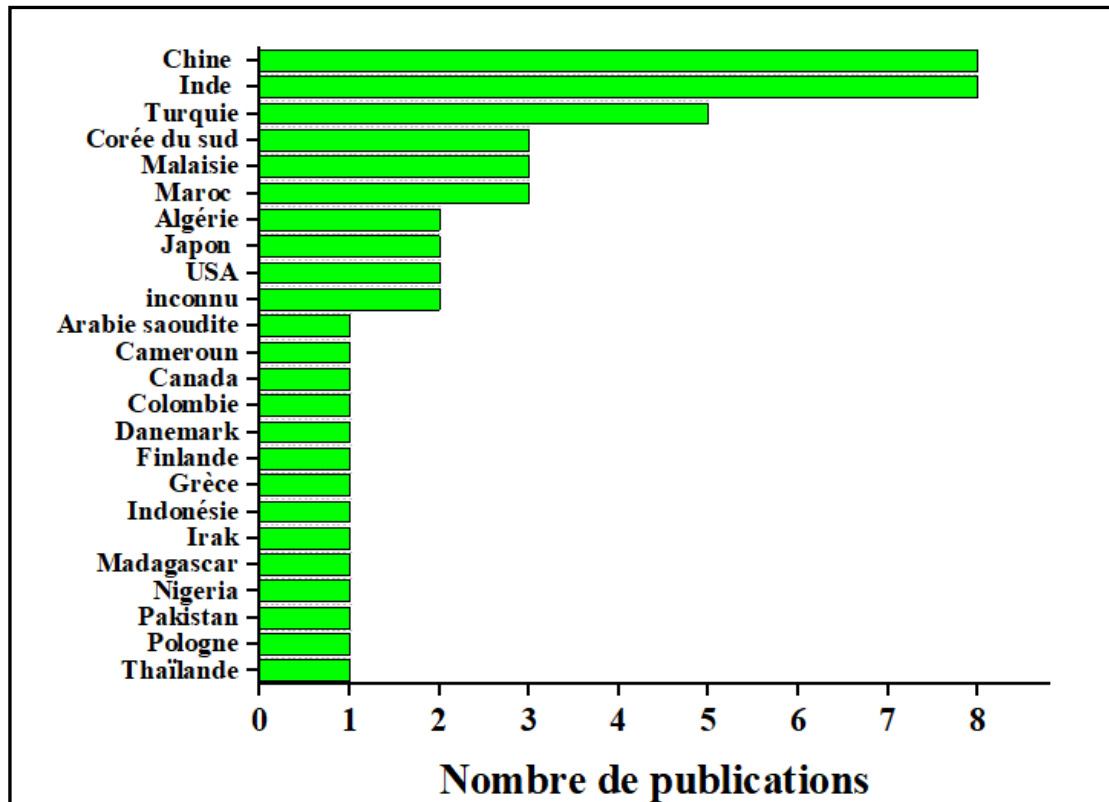


Figure II.3. Volume de publications par pays

### II.3. Conclusion

Dans ce chapitre, nous avons passé en revue la littérature en relation avec la modélisation de l'HR par les techniques à base d'IA sous de nombreuses formes et variantes. Par conséquent, la comparaison des performances de différents modèles est très compliquée, en raison des différentes régions et lieux d'intérêt, la disponibilité des données d'entrée-sortie, la variation des conditions climatiques, l'horizon temporel et l'utilisation de divers types de modèles. Les résultats montrent que la performance des modèles de prédiction dépend de plusieurs aspects :

- i.* Phase de prétraitement et procédures de sélection des entrées utilisées;
- ii.* Sélection de l'architecture et du type de modèle utilisé;
- iii.* Pas de temps de prévision souhaité qui peut conduire à des précisions plus élevées pour des horizons très courts;
- iv.* Le type de climat du lieu d'intérêt.

Nous avons remarqué que, pour la majorité des cas, l'utilisation des données de la Température comme variables d'entrées conduit à des résultats significatifs. Il est clair que la grande partie des publications utilisent le MLPNN pour modéliser l'HR, malgré ça, cette variable climatique n'a pas reçu l'attention qu'elle mérite par rapport à la modélisation des autres variables climatiques.

***Chapitre III***  
***Modélisation de la Radiation Solaire (RS): Etat de l'Art***

---

### III.1. Introduction

Contrairement à la modélisation de l'HR, la littérature en relation avec la modélisation de la RS est très disponible, d'après [Demir et Citakoglu \(2023\)](#), plus de 400 articles ont été trouvés dans la base de données 'Scopus' pour l'approche d'apprentissage automatique (ML) pour la modélisation de la RS. [El-Amarty et al. \(2023\)](#) ont compté 457 articles basés sur les ANN à partir des bibliothèques numériques telles que: IEEE, Science direct, Researchgate, Elsevier et Google Scholar publiés entre 2015 et 2022.

### III.2. Modélisation de la radiation solaire: Revue de Littérature

Plusieurs chercheurs ont passé en revue les modèles en relation avec l'estimation et la prévision de la RS ([Diagne et al., 2013](#); [Tolabi et al., 2014](#); [Yadav & Chandel, 2014](#); [Mohanty et al., 2016](#); [Voyant et al., 2017](#); [Zhang et al., 2017](#); [Hassan et al., 2018](#); [Guermoui et al., 2020](#); [Singla et al., 2021](#); [Zhou et al., 2021](#); [Attar et al., 2022](#); [Gürel et al., 2023](#); [El-Amarty et al., 2023](#)). Au cours des deux dernières décennies, les techniques d'IA ont été utilisées avec succès pour la prévision de la RS ([Amiri et al., 2021](#); [Voyant et al., 2017](#)), dans la littérature, de nombreuses publications s'appuient sur ces techniques pour l'estimation et la prévision de la RS à l'aide des modèles simples tels que le MLPNN ([Dorvlo et al., 2002](#); [Hontoria et al., 2005](#); [Elminir et al., 2007](#); [Azadeh et al., 2009](#); [Behrang et al., 2010](#); [Mellit et al., 2010b](#); [Paoli et al., 2010](#); [Asl et al., 2011](#); [Voyant et al., 2012](#); [Kaushika et al., 2014](#); [Ahmad et al., 2015](#); [Ihya et al., 2015](#); [Ghofrani et al., 2016](#); [Kumar & Kaur, 2016](#); [Feng et al., 2017](#); [Hassan et al., 2017](#); [Marzo et al., 2017](#); [Jadidi et al., 2018](#); [Pang et al., 2020](#)), le modèle ELM ([Salcedo-Sanz et al., 2013](#); [Salcedo-Sanz et al., 2014](#); [Şahin et al., 2014](#); [Shamshirband et al., 2015](#); [Urraca et al., 2015](#); [Aybar-Ruiz et al., 2016](#); [Burianek & Misak, 2016](#); [Nazhad et al., 2017](#); [Salcedo-Sanz et al., 2017](#); [Behera et al., 2018](#); [Ghimire et al., 2018](#); [Cornejo-Bueno et al., 2019](#)), le modèle GRNN ([Şenkal, 2010](#); [Şenkal et al., 2010](#); [Celik & Muneer, 2013](#); [Wang et al., 2016](#); [Feng et al., 2017](#); [Heng et al., 2017](#); [Lotfinejad et al., 2018](#); [Fan et al., 2019](#); [Bellido-Jiménez et al., 2021](#)), le modèle MARS ([Deo et al., 2017](#); [Salcedo-Sanz et al., 2018](#); [Keshtegar et al., 2018](#); [Kisi et al., 2019](#); [Li et al., 2019b](#); [Srivastava et al., 2019](#); [Huynh et al., 2021](#); [Liu et al., 2022a](#); [Goliatt & Yaseen, 2023](#)), le modèle RFR ([Huang et al., 2014](#); [Ibrahim & Khatib, 2017](#); [Fouilloy et al., 2018](#); [Benali et al., 2019](#); [Karasu & Altan, 2019](#); [Fan et al., 2020](#); [Ağbulut et al., 2021](#); [Alrashidi et al., 2021](#); [Bounoua et al., 2021](#); [Chen et al., 2021b](#); [Obiora et al., 2021](#); [Zhou et al., 2022](#); [Bounoua & Mechaqrane, 2023](#); [Mishra et al., 2023](#)), le modèle SVR ([Chen et al., 2011](#); [Chen & Li, 2014](#); [Ramedani et al., 2014](#); [Antonanzas et al., 2015](#); [Mohammadi et al., 2015](#); [Gala et al., 2016](#); [Deo et al., 2016](#); [Halabi et al., 2018](#);

Khosravi et al., 2018; Basaran et al., 2019; Bhola & Bhardwaj, 2019; Ghimire et al., 2019a; Torres-Barrán et al., 2019; Mohammadi & Aghashariatmadari, 2020; Bamisile et al., 2022), ou des modèles hybrides basées sur des algorithmes de décomposition du signal tels que la transformée en ondelettes (WT) (Cao & Cao, 2006; Yadav & Behera, 2014; Shamshirband et al., 2016; Sharma et al., 2016; Ghimire et al., 2019b; Huang et al., 2019; Rezaie-Balf et al., 2021; Alizamir et al., 2023), l'algorithme EMD (Barnhart & Eichinger, 2011; Calif et al., 2013; Wang & Wu 2016; Monjoly et al., 2017; Li et al., 2018; Wang et al., 2018a; Wang et al., 2018b; Prasad et al., 2020; Aghmadi et al., 2021), l'algorithme VMD (Majumder et al., 2018; Ali et al., 2021; Sibtain et al., 2021) et l'algorithme EWT (Dash et al., 2020; Dash et al., 2021; Jamei et al., 2023). En Algérie, nous avons trouvé 82 publications utilisant les techniques d'IA pour la modélisation de la RS (Tableau III.1, Figure III.1, III.2 et III.3).

### III.2.1. Application du modèle MLPNN pour la modélisation de la RS

Le Tableau (III.1) présente l'historique des méthodes d'IA utilisées pour la modélisation de la RS en Algérie. Il est clair que la plupart des modèles de prédiction pour différentes régions et différentes échelles de temps sont basés sur les réseaux de neurones artificiels et en particulier le MLPNN, qui a été utilisé pour la première fois par Mellit et al. (2005a). Ils ont utilisés un modèle hybride (MLPNN-MTM) basé sur les ANN et une matrice de transition de Markov (MTM) pour prédire la RS globale journalière, en utilisant un minimum de données d'entrée (latitude, longitude et altitude), dans les sites isolés. Une prédiction très précise a été obtenue avec une RMSE  $\approx 8\%$  et un R compris entre  $\approx 0.9$  et  $\approx 0.92$ .

Deux ans plus tard, en 2007, deux études comparatives utilisant les modèles MLPNN, ANFIS, RBFNN et RNN ont été conduits par Mellit et al. (2007a, 2007b). La première a pour but de prédire la RS globale en fonction de la durée d'ensoleillement moyenne journalière et de la  $T_a$ . Les données d'une période de 10 ans entre 1981 et 1990 ont été utilisées. Les résultats ont montré que le modèle ANFIS donne de bons résultats par rapport aux autres modèles ANN (MLPNN, RBFNN et RNN). Un R de 0.98 et une erreur relative moyenne (MRE) ne dépassant pas 1% ont été obtenus. La deuxième a pour but de prédire la RS globale journalière en fonction de coordonnées géographiques (latitude, longitude et altitude) de 60 localités en Algérie. Un total de 56 localités a été utilisé pour l'apprentissage du modèle et quatre pour le tester. Les résultats ont montré la supériorité du modèle ANFIS avec un  $R^2$  de 0.97, RMSE compris entre 0.0215 et 0.0235 et MAPE inférieure à 2.2 %. Un an plus tard, Mellit et al. (2008) ont conduit une étude similaire et ont trouvé les mêmes résultats.

Asradj et Alkama (2014) ont modélisé la RS globale en fonction de quatre variables météorologiques à savoir:  $T_a$ ,  $P_a$ , HR et P, enregistrées tous les huit minutes en 2010 dans la région de Bejaïa. La comparaison avec des modèles empiriques a montré la supériorité du modèle MLPNN ( $R \approx 0.8952$  et  $RMSE \approx 0.015$  MJ/m<sup>2</sup>/jour). Assas et al. (2014) ont utilisé le modèle MLPNN pour prédire la RS globale journalière sur une surface horizontale en fonction de données météorologiques (L'intensité de la RS extraterrestre journalière moyenne, les heures d'ensoleillement maximales possibles, l'HR journalière moyenne, la  $T_{mean}$  journalière, la  $P_a$  journalière moyenne et la  $U_2$ ), enregistrées durant une période de cinq années (2001-2005) à Djelfa. Il a été constaté que l'inclusion de l'HR conduit à des améliorations des performances (RMSE de 0.1273 avec HR et 0.1323 sans HR). Dahmani et al. (2014) ont développé un modèle MLPNN pour estimer la RS globale inclinée à partir de la RS horizontale à pas de temps de 5 min à Bouzaréah (Alger). Les données utilisées pour tester et valider le modèle correspondent à la période d'Avril 2011 avec 75674 données enregistré tous les 5 minutes. Ils ont constaté que l'addition de l'angle d'azimut ( $\alpha$ ) n'apporte aucune amélioration significative. Des indices numériques de  $R^2 \approx 0.994$ ,  $MAE \approx 2.41$  Wh.m<sup>-2</sup>, sa valeur normalisée  $nMAE \approx 6.63\%$ , et  $RMSE \approx 3.21$  Wh.m<sup>-2</sup> ont été obtenues, ce qui est une bonne précision pour un pas de temps court.

Un an plus tard, Asradj et Alkama (2015) ont comparé quatre modèles de régression linéaire avec un modèle MLPNN pour estimer la RS globale enregistrée toutes les 8 minutes sur le site de Béjaïa. Les auteurs ont constaté que le modèle MLPNN assure de meilleures performances avec une valeur de R de  $\approx 0.895$  et une RMSE de  $\approx 0.015$ . Miloudi et Acheli (2015) et Miloudi et al. (2017) ont proposé deux types de modèles ANN (MLPNN et RBFNN) pour estimer la RS globale. En utilisant 700 données enregistrées toutes les 15 min en 2012 sur le site de Boumerdes. Les R obtenus étaient très satisfaisants pour les deux modèles ANN, avec une valeur de l'ordre de  $\approx 0.997$  et  $\approx 0.998$  pour le MLPNN et le RBFNN, respectivement.

En 2016, le modèle MLPNN a été utilisé dans six études. Belaid et Mellit (2016) ont comparé le modèle MLPNN avec les SVM (Support Vector Machine) pour prédire la RS globale horizontale journalière et mensuelle. Ils ont utilisé 42 combinaisons de six variables. L'introduction de différentes températures mesurées ( $T_{max}$ ,  $T_{min}$ ,  $T_{mean}$  et la différence de température  $T_{diff}$ ), la durée d'ensoleillement maximale (SS) et la RS extraterrestre ( $H_0$ ) ont amélioré les prédictions des données horaires. Les résultats de prévision journalière ont

montré une amélioration significative des performances en introduisant  $H_0$  ou SS avec les températures mesurées comme entrées. Les tests statistiques ont indiqué que les valeurs de RMSE normalisé (nRMSE) sont comprises entre 13.163% et 13.305%, la MAPE est de 10.403% à 10.503% et R varie entre 0.894 et 0.896. Pour la prédiction mensuelle, les résultats ont obtenue étaient un nRMSE $\approx$ 7.442 %, MAPE $\approx$  8.940 % et R proche de 0.986. La deuxième étude en 2016 est conduite par [Benkaciali et al. \(2016\)](#) dans la région de Ghardaïa. Ils ont utilisé le MLPNN pour estimer la RS globale horizontale avec quatre variables d'entrées, à savoir:  $T_{\text{mean}}$ , HR, SS et la déclinaison solaire. Les résultats ont montré que le modèle MLPNN offre des meilleures performances par rapport aux modèles empiriques. Les valeurs de nRMSE et  $R^2$  étaient de 4.422% et 0.98 pour le MLPNN et de 5.5381 % et 0.9722 pour le modèle empirique. De plus, il a été prouvé que la durée d'ensoleillement (SS) est un paramètre important pour prédire la RS globale. La troisième étude est conduite par [Dahmani et al. \(2016\)](#) qui ont estimé la RS globale horizontale à pas de temps horaire et de 5 min à l'aide de réseau MLPNN. Sept paramètres météorologiques ( $T_a$ , HR,  $U_2$ , P,  $P_a$ , direction du vent WD et SS) et 3 variables calculés (Angle zénithal  $\theta_z$ , déclinaison solaire  $\delta$  et radiation extraterrestre  $H_0$ ) ont été enregistrés dans la station de Bouzaréah durant la période d'avril 2011 à décembre 2013 (33 mois de données de 5 min). Premièrement, pour la prévision horaire: les indices statistiques du meilleur modèle à 6 entrées ( $T_a$ , HR, p,  $U_2$ , SS et  $H_0$ ) sont (nMAE $\approx$ 13.28 % et  $R^2\approx$ 0.979) par rapport aux (nMAE $\approx$ 12.72 % et  $R^2\approx$ 0.9812) pour le modèle à 10 entrées. Deuxièmement, pour la prévision de 5 min, le meilleur modèle à 6 entrées a donné des valeurs de: nMAE $\approx$ 16.18% et  $R^2\approx$ 0.9633.

Dans la même année, [Guermoui et al. \(2016\)](#) ont développé un modèle MLPNN pour estimer la RS globale horizontale journalière dans la ville de Ghardaïa. Les données de trois années de mesure (2005-2008) à savoir:  $T_a$ , HR et SS, ont été utilisées comme variables climatiques d'entrée, tandis que la RS globale journalière était la seule sortie du modèle. Les auteurs ont constaté que le MLPNN basé sur la SS et la  $T_a$  donne des meilleurs résultats en termes de R et RMSE. Les valeurs obtenues de ces indices sont respectivement de  $\approx$ 98.19% et  $\approx$ 1.28 MJ/m<sup>2</sup>. La dernière recherche qui utilise le MLPNN en 2016 est publiée par [Rezrazi et al. \(2016\)](#) qui ont utilisé la  $T_a$ , l'HR, le nombre de jours et le temps local, enregistrées en 2007 à Ghardaïa, pour prédire la RS directe, la RS diffus (90°), la RS globale (90°) et la RS globale (30°). D'excellentes performances ont été obtenues avec des R et RMSE de (0.972 et 9.22%),

(0.975 et 20.27%), (0.992 et 7.03%), (0.992 et 19.73%) pour la RS directe, diffus ( $90^\circ$ ), globale ( $90^\circ$ ) et globale ( $30^\circ$ ), respectivement.

Une année plus tard, [Laidi et al. \(2017\)](#) ont utilisé un modèle MLPNN pour prédire la RS sur des surfaces inclinées en fonction de 8 paramètres à savoir: la latitude, la  $T_{\text{mean}}$ , l'HR moyenne, le facteur de trouble de Linke, le coefficient d'Angstrom, la  $H_0$ , la RS horizontale et l'angle  $\theta_z$ . Les données expérimentales de la RS enregistrées autour de l'année 2004 de 13 stations réparties dans toute l'Algérie (Béjaïa, Mostaganem, Tebessa, Batna, Tiaret, Tlemcen, Ouargla, Ghardaïa, Bechar, In Salah, Adrar, Tamanrasset et In Guezzam) ont été utilisées pour l'apprentissage et la validation du modèle, tandis que les données d'une station (Tindouf) ont été utilisées dans l'interpolation. La configuration 5 entrées, 35 neurones dans la couche cachée et 1 sortie a donné la meilleure précision avec un  $R^2$  de 0.99 et une RMSE de 5.75 Wh/m<sup>2</sup>.

Le modèle MLPNN a été utilisé aussi par [El-Mghouchi et al. \(2019\)](#) pour prédire la RS globale journalière. Les données de 35 sites (27 villes marocaines, 2 villes espagnoles, 4 villes mauritaniennes et 2 villes algériennes: Bechar et Tindouf) comprennent l'altitude, la longitude, la latitude, la déclinaison du soleil  $\delta$ , la durée du jour, le numéro du jour, l'indice de clarté (KI), la radiation TOA (Top Of Atmosphere), la  $T_{\text{mean}}$ , la  $T_{\text{max}}$ , la  $T_{\text{min}}$ , la  $T_{\text{Diff}}$ , le rapport de température ( $T_R$ ), l'HR et la  $U_2$  moyenne, ont été collectées à partir de plusieurs sources à savoir: la Direction Nationale de la Météorologie, du Laboratoire d'Energie Solaire de la Faculté des Sciences de Tétouan (depuis le 05/11/2008), du Laboratoire d'Energie Solaire de la Faculté des Sciences de Rabat (années 2005 et 2014) et des sites internet: [www.rp5.ru](http://www.rp5.ru) (depuis le 01/02/2005) et [www.ogimet.com/gsynres.phtml](http://www.ogimet.com/gsynres.phtml) (depuis le 15/09/1999). Des meilleurs performance ont été obtenus, les valeurs de  $R^2$ , MBE, RMSE, nRMSE et MAPE sont de l'ordre de 0.992, -0.203, 0.302, 0.055 et 0.002, respectivement.

Durant l'année 2020, trois études utilisant le MLPNN ont été publiés, la première a réalisée à Adrar par [Benatiallah et al. \(2020\)](#) qui ont estimé la RS globale horaire en fonction des données météorologiques ( $T_a$ , HR,  $U_2$ , et  $P_a$ ), astronomiques (déclinaison, angle de la hauteur solaire, SS, et  $H_0$ ) et la périodicité (numéro de jour de l'année et numéro d'heure du jour) collecté durant six ans (2013 - 2018) de 07h00 jusqu'à 18h00. Des meilleurs résultats ont été obtenus avec une valeur de R dépasse 0.98. La deuxième et la troisième étude ont été appliquées dans la région de Ghardaïa. [Khelifi et al. \(2020\)](#) ont utilisé deux modèles ANN à savoir: le MLPNN et le RBFNN pour la prévision journalière de la RS globale et directe en utilisant un ensemble de paramètres météorologiques mesurés durant 3 ans (2014 et 2016). Les résultats montrent que les deux modèles fonctionnent bien pour les prévisions à trois

étapes à l'avance avec une légère amélioration des modèles MLPNN. [Rabehi et al. \(2020a\)](#) ont présenté une étude comparative entre différents modèles de prédiction à savoir: le MLPNN, les arbres de décision boostés (BDT) et une nouvelle combinaison de ces modèles avec la régression linéaire (LR) pour la prédiction de la RS globale journalière. Les résultats obtenus montrent que le modèle MLPNN est plus performant que les autres modèles en termes d'indicateurs statistiques: nRMSE (0.033) et  $R^2$  (0.977).

Un an plus tard, [Rabehi et al. \(2021\)](#) ont évalué les performances des modèles MLPNN, LSSVM, BDT et la régression par processus gaussien (GPR), et leurs hybridations avec un modèle de régression linéaire pour estimer des composantes de la RS, en utilisant uniquement les données de la RS globale journalière mesurée durant la période de mai 2013 à décembre 2015 à Ghardaïa. Les résultats obtenus montrent que le modèle GPR et LSSVM offrent une performance élevée par rapport aux autres modèles étudiés, un RMSE de 0.074, 0.075 et 0.093, 0.093 pour les modèles GPR et LSSVM respectivement, pour l'estimation de la RS directe et diffuse.

Les dernières applications du modèle MLPNN en Algérie ont été réalisées en [2022](#). [Gairaa et al. \(2022\)](#) ont estimé la RS globale horaire de h+1 à h+6 en utilisant deux modèles: MLPNN et MLR. Plusieurs données d'entrées enregistrées à deux sites; Alger (20/06/2011 à 21/06/2014) et Ghardaïa (01/01/2013 à 31/12/2016) ont été utilisées. [Benmouiza \(2022\)](#) a testé un modèle hybride appelé LGC-GMDH (Local Gravitational Clustering-Group Method of Data Handling) pour la prévision de la RS à 1 heure d'avance à Ghardaïa. D'excellent résultats ont été obtenus avec un RMSE de 43.7268 W/m<sup>2</sup> et un  $R^2$  de 0.9887.

### III.2.2. Application du modèle ELM pour la modélisation de la RS

Le modèle ELM a été utilisé par [Guermoui et al. \(2022a; 2023\)](#). Dans la première étude, ils ont comparé le modèle ELM avec le réseau de neurones convolutif (CNN), GPR et LSSVM, pour la prévision de la RS globale horaire. Les données de la RS globale et des principaux paramètres météorologiques, tels que l'HR, la  $T_a$ , la  $P_a$ , la WD et la  $U_2$ , ont été collectés avec des intervalles de 5 minutes et d'une heure à partir de deux sites: Alger et Ghardaïa. Les résultats ont montré l'efficacité du modèle ELM. La deuxième étude sera présentée lors de la discussion des études liées à l'utilisation des techniques d'ondelettes pour la modélisation de la RS en Algérie.

### III.2.3. Application du modèle RFR pour la modélisation de la RS

Le modèle RFR a été utilisé dans deux recherches publiées en 2022, la première est conduite par [Djaafari et al. \(2022\)](#) qui ont utilisé plusieurs modèles à savoir le LSTM hybride, RFR, MLPNN, K-Neighbors Regressor (KNR) et SVR pour prédire la RS directe horaire à trois sites, à savoir: Tamanrasset, Adrar et Ghardaïa, en fonction d'ensembles de données météorologiques mesurées pendant 1 à 2 ans qui incluent l'HR, la  $T_a$  et la RS globale horaire. D'excellentes performances ont été obtenues, avec des RMSE inférieurs à 2.07 % et des R supérieurs à 0.99. La deuxième étude est menée par [Takilalte et al. \(2022\)](#). Ils ont testé trois techniques d'apprentissage automatique supervisé: le réseau de neurones non linéaire autorégressif (NAR), RFR et SVR, pour prédire la RS globale de 5 min, 1 heure et un horizon d'un jour, dans deux régions: Alger et Ghardaïa. Les résultats ont montré que le RFR était meilleur, notamment pour les prévisions horaires avec des valeurs de nRMSE de 20.04%, 20.42% et 21.37% pour le modèle RFR, SVR et NAR, respectivement.

### III.2.4. Application du modèle SVR pour la modélisation de la RS

En plus des deux études présentées ci-dessus, le modèle SVR a été utilisé aussi par [Guermoui et al. \(2018a\)](#). Ils ont appliqué le SVR pour estimer la RS globale journalière horizontale dans la ville de Ghardaïa, en fonction uniquement du taux d'ensoleillement comme entrée. Le modèle SVR a été développé et testé à l'aide d'un ensemble de données enregistrées sur trois ans (2005-2007). Les valeurs mesurées et estimées ont été comparées statistiquement durant la phase de test en utilisant le RMSE, le RMSE relative (rRMSE) et le  $R^2$ . Les valeurs de ces indices étaient 1.59 MJ/m<sup>2</sup>, 8.46 et 97.4 %, respectivement. De même, le modèle SVR ont été utilisés par [Zemouri et Bouzgou \(2018\)](#) pour prédire la RS globale horizontale dans quatre sites à savoir: Alger, M'sila, Batna et Bechar à partir des données enregistrées durant deux années (2004 et 2005). Des meilleures performances ont été obtenues avec un  $R^2$  supérieur à 0.999 pour les quatre sites. Dans la région de Ghardaïa, [Guermoui et al. \(2022b\)](#) ont utilisé deux modèles SVR, le premier pour estimer la RS globale horizontale en utilisant uniquement la  $T_a$  de trois ans (2013-2015), tandis que le second modèle SVR est utilisé pour estimer l'erreur produite par le premier modèle.

### III.2.5. Application des techniques d'ondelettes pour la modélisation de la RS

Dans la littérature en relation avec la modélisation de la RS en Algérie par les techniques d'ondelettes, onze études ont été publiées. [Mellit et al. \(2006\)](#) furent les premiers à utiliser ces techniques pour prédire la RS globale journalière. À cet effet, des données

journalières de la RS globale correspondant à la période de 1981 à 2001 de la région d'Alger. Les résultats obtenus étaient de l'ordre de:  $R \approx 0.97$ ,  $MRE \approx 5\%$  et  $MAPE$  inférieure à  $6\%$ . De même, [Mellit et al. \(2010a\)](#) ont appliqué un modèle hybride (PNN-GA) basé sur l'utilisation d'un réseau de neurones PNN combiné à un algorithme génétique (GA) pour prédire la RS globale, en utilisant des données allant de 1996 à 2000 enregistrés dans la région d'Alger. Une valeur de  $R$  de l'ordre de  $\approx 0.9821$  a été obtenue, et il a été démontré que le modèle PNN-GA était plus précise que le MLPNN, RBFNN, RNN, le réseau d'ondelettes et l'ANFIS.

Cinq ans plus tard, [Saoud et al. \(2015a\)](#) ont utilisé le modèle CVWNN (Complex-Valued Wavelet Neural Network) pour prédire la RS globale journalière de 6 capitales du Maghreb qui sont Tripoli (Libye), Tunis (Tunisie), Alger (Algérie), Rabat (Maroc), El Ayoun (Sahara Occidental) et Nouakchott (Mauritanie). Les deux stratégies, multi-entrées sorties-unicques (MIMO) et multi-entrées multi-sorties (MISO) ont été utilisées. Pour la ville d'Alger, une valeur de  $nRMSE$  de l'ordre de  $26.96\%$  a été obtenue. En 2017, Les même auteurs ([Saoud et al., 2017](#)) ont proposé un réseau d'ondelettes nommé: the Fully Complex Valued Wavelet Network (FCWN) pour prédire la RS globale horaire et journalière. Les deux stratégies MISO et MIMO ont été utilisées. Les données météorologiques mesurées dans la ville de Tamanrasset ont été exploitées pour valider le modèle développé. Selon les résultats obtenus, les auteurs ont constaté que le FCWN est une technique prometteuse pour prévoir la RS horaire et journalière. Premièrement, pour le pas de temps journalier, des valeurs de  $MAE \approx 5.21\%$ ,  $nRMSE \approx 8.69\%$  et  $R^2 \approx 99.20\%$  ont été obtenus. Pour l'estimation de la RS globale horaire, le modèle utilisé assure des valeurs de  $MAE \approx 3.32\%$ ,  $nRMSE \approx 23.44\%$  et  $R^2 \approx 97.21\%$ .

Durant l'année 2021, deux études ont été publiés. [Ferkous et al. \(2021a\)](#) ont développé un modèle hybride composé du modèle GPR et des ondelettes (W-GPR), pour prédire la RS globale journalière à Ghardaïa. Des données de température ( $T_{max}$ ,  $T_{min}$  et  $T_{mean}$ ), humidité relative ( $HR_{max}$ ,  $HR_{min}$  et  $HR_{mean}$ ) et du RS globale enregistrées durant une période de quatre ans (2013-2016) ont été utilisé. Les auteurs ont comparé leurs performances du modèle W-GPR avec le modèle GPR classique, les résultats ont montré une amélioration significative des performances du modèle W-GPR avec des valeurs de  $R^2 \approx 0.960$ ,  $MAE \approx 1.02 \text{ MJ/m}^2$ ,  $MSE \approx 5.25 \text{ MJ/m}^2$ ,  $RMSE \approx 1.81 \text{ MJ/m}^2$  et  $rRMSE \approx 11.21\%$ . [Ferkous et al. \(2021b\)](#) ont utilisé la même approche avec les mêmes entrées mais les résultats été inférieure, avec des valeurs de  $R^2 \approx 0.923$ ,  $MAE \approx 1.625 \text{ MJ/m}^2$ ,  $MSE \approx 5.852 \text{ MJ/m}^2$  et  $RMSE \approx 2.4191$ . Un an plus tard, [Ferkous et al. \(2022a\)](#) ont exploité les données enregistrées à Ghardaïa entre 2013 et 2016

pour estimer la RS journalière, ils ont combiné le modèle GPR avec les ondelettes et la technique de décomposition en paquets d'ondelettes (WPD). Le modèle hybride WPD-GPR a donné d'excellents résultats en termes de ( $RMSE \approx 0.58 MJ/m^2$ ), ( $rRMSE \approx 2.83\%$ ), ( $MSE \approx 0.34 MJ/m^2$ ) et ( $R^2 \approx 0.995$ ). Un autre modèle hybride (CEEMDAN-GPR) qui combine l'algorithme de décomposition du signal CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) avec le GPR, a été proposé par [Ferkous et al. \(2022b\)](#). Les résultats ont montré la supériorité du modèle hybride CEEMDAN-GPR avec des critères de validation de:  $R^2 \approx 0.955$ ,  $rRMSE \approx 8.80\%$ ,  $MSE \approx 3.23 MJ/m^2/jour$  et  $RMSE \approx 1.80 MJ/m^2/jour$ .

Durant la même année, [Saoud et Al Marzouqi \(2022\)](#) ont proposé un modèle hybride (SWT-QVNN) pour prédire la RS dans les villes d'Abou Dhabi, en UAE, et Tamanrasset, en Algérie, combinant la transformation en ondelettes stationnaire (SWT) et le réseau de neurones à valeurs quaternions (QVNN). La méthode développée est comparée à d'autres modèles qui sont le réseau de neurones à valeurs réelles (RVNN), le réseau de neurones à valeurs complexes (CVNN) et le QVNN. Pour la ville de Tamanrasset, les résultats obtenus ont montré la supériorité du modèle hybride avec des indices statistiques de  $nMAE \approx 5.04\%$ ,  $nRMSE \approx 8.16\%$  et  $R^2 \approx 0.996$ . [Guermoui et al. \(2022c\)](#) ont proposé un nouveau modèle hybride (IF-GPR) basé sur un algorithme de décomposition du signal nommé Iterative Filtering (IF) utilisé comme étape de prétraitement des données historiques de la RS horaire, combiné avec le modèle GPR pour estimer la RS globale de plusieurs heures à l'avance dans trois sites en Algérie (Bouzaréah, Ghardaïa et Adrar). Les résultats de prévision étaient très encourageants avec des indices de performances très acceptables. En fin, [Guermoui et al. \(2023\)](#) ont proposé une nouvelle technique hybride basée sur l'algorithme de décomposition du signal EMD et le modèle ELM pour la prévision de la RS globale horaire, en utilisant des données climatiques recueillies à trois régions climatiques; Bouzaréah (Jan 2014 à Déc 2015), Ghardaïa (Jan 2014 à Déc 2015) et Tamanrasset (Jan 2019 à Juin 2021). Les résultats de prévision du modèle hybride proposé étaient d'une grande précision par rapport aux modèles ELM-CEEMDAN et ELM classique, avec des valeurs de  $nRMSE$  inférieur à  $8.3\%$  et un  $R$  supérieur à  $0.98$ .

### III.2.6. Application d'autres modèles pour la modélisation de la RS

En plus des modèles mentionnés ci-dessus, de nombreux autres modèles ont été proposés par les chercheurs pour modéliser la RS en Algérie. [Drif et Chikh \(2000\)](#) furent les premiers à modéliser la RS en Algérie en utilisant un algorithme basé sur les concepts de la logique floue (FL). [Mellit et al. \(2005b\)](#) ont utilisé le modèle RBFNN pour prédire la RS

globale journalière en fonction de la SS et la  $T_a$ . [Hasni et al. \(2012\)](#) ont utilisé les ANN pour estimer la RS globale journalière horizontale horaire à Bechar. Durant l'année 2013, trois recherches ont modélisé la RS en Algérie, la première est conduite par [Benmouiza et Cheknane \(2013\)](#) qui ont proposé un modèle combinant l'algorithme de clustering K-means et NAR. La deuxième étude est menée par [Laidi et al. \(2013\)](#) qui ont utilisé un ANN pour estimer la RS globale de 5 min sur une surface inclinée à l'aide de données mesurées en 2011 à partir de la station météorologique située à l'intérieur de l'université de Blida. La troisième étude en 2013 est celle de [Saoud et al. \(2013\)](#), ils ont utilisé le modèle CVNN pour prévoir la RS journalière et horaire. Les ANN sont utilisées aussi pour prédire la RS en Algérie par [Laidi et al. \(2014a; 2014b\)](#). [Ouali et Alkama \(2014\)](#) furent les premiers à utiliser un modèle MLR pour modéliser la RS globale en fonction de cinq paramètres météorologiques enregistrés tous les huit minutes du site de Béjaïa durant quatre ans, de 2010 à 2013 ( $SS$ ,  $T_a$ ,  $P_a$ , HR et P). [Saoud et al. \(2014\)](#) ont utilisé le modèle CVNN pour prédire la RS globale journalière de 6 capitales du Maghreb, qui sont Tripoli (Libye), Tunis (Tunisie), Alger (Algérie), Rabat (Maroc), El Ayoun (Sahara Occidental) et Nouakchott (Mauritanie) en fonction des données satellitaires obtenues à partir du site officiel de la NASA.

[Yacef et al. \(2014\)](#) ont utilisé six modèles empiriques et un modèle de réseau de neurones bayésien (BNN) pour estimer la RS globale journalière sur une surface horizontale à Ghardaïa. Un an plus tard, [Gairaa et al. \(2015\)](#) ont présenté une méthode de prévision de la RS basée sur le modèle NAR. Les données de trois années (2012-2014) de séries temporelles de la RS globale pour le site de Ghardaïa ont été utilisées pour développer le modèle. De même, et toujours pour le site de Ghardaïa, [Rabehi et al. \(2015\)](#) ont proposé un modèle simple basé sur le RBFNN pour estimer la RS globale journalière à partir des données enregistrées du 01/01/2012 au 28/10/2014 à Ghardaïa. [Saoud et al., \(2015b; 2015c\)](#) ont modélisé la RS, par un réseau de neurones QVNN et la logique floue.

Dans un travail similaire, [Gairaa et al. \(2016\)](#) ont combiné entre les ANN et le modèle ARMA pour prédire la RS globale journalière, en utilisant des données enregistrées entre 2012 et 2013 à Bouzaréah et Ghardaïa. Durant la même année, [Benmouiza et Cheknane \(2016\)](#) ont introduit un modèle hybride basé sur le modèle ARMA (Autoregressive moving average) et NAR pour prédire la RS globale horizontale à petite échelle. [Boualit et Mellit \(2016\)](#) ont utilisé un modèle hybride qui combine le modèle SARIMA et SVM pour prédire la RS globale journalière à partir des prévisions de l'indice de clarté (KI). Un an plus tard, et au même site, [Benkaciali et al. \(2017\)](#) ont testé l'influence des variables d'entrée sur les performances du modèle RBFNN pour estimer la RS globale journalière sur une surface

horizontale en fonction de sept combinaisons de 12 variables météorologiques et géographiques d'entrée. Durant la même année, à la même région, avec le même modèle, [Rabehi et al. \(2017\)](#) ont estimé la RS directe et la RS diffuse en fonction de différentes variables climatiques. Toujours à la même région, [Chaba-Mouna et al. \(2017\)](#) ont utilisé un modèle ANN pour prédire la RS globale reçu sur une surface horizontale à Ghardaïa. Dans la région de Bejaïa, et par l'utilisation de l'algorithme génétique, [Asradj et al. \(2017\)](#) ont modélisé la RS en fonction de quatre variables ( $SS$ ,  $T_a$ ,  $P_a$  et  $HR$ ) enregistrées durant quatre ans (2010-2013).

Finalement on peut citer brièvement d'autres études conduites dans différentes régions à savoir: le modèle GPR ([Guermoui et al., 2018b](#)), le modèle Weighted Gaussian Process Regression (WGPR) ([Guermoui et al., 2018c](#)), les SVM ([Belaid et al., 2018](#)), le modèle QVNN ([Saoud et al., 2018](#)), Evolutionary Product Unit Neural Networks (EPUNNs) ([Amiri et al., 2019](#)), le modèle ANFIS ayant différentes méthodes de partitionnement (Grid partition, Subtractive clustering, et Fuzzy C-Mean clustering) ([Benmouiza & Cheknane, 2019](#)), le modèle ANFIS ([Babahadj et al., 2020](#)), deux types de modèles ANFIS à savoir: ANFIS-FCM et Subtractive Clustering ([Abdeljabar et al., 2020](#)), GPR et LSSVM ([Guermoui et Rabehi, 2020](#)), le modèle RBFNN ([Rabehi et al., 2020b](#)), le modèle ARIMA ([Mebrouk et al., 2020](#)), le modèle hybride combinant le modèle Weather Research and Forecasting (WRF) et ANN (WRF-ANN) ([Bouchouicha et al., 2021](#)), le modèle MLR ([Abdelhafidi et al., 2021](#)), le réseau de neurones en Cascade (CFNN) et le réseau de neurones Elman (ENN) ([Benatiallah et al., 2021a](#)), le modèle ANFIS ([Benatiallah et al., 2021b](#)), le modèle ABC (Artificial Bee Colony algorithm) combiné avec le LSSVM (ABS-LSSVM) ([Guermoui et al., 2021](#)), le modèle SVM ([Belaid et al., 2022](#)). En fin, Durant l'année 2023, trois recherches ont utilisé des modèles que nous n'avons pas utilisés dans notre travail, la première recherche est conduite par [Benmouiza \(2023\)](#) qui a utilisé trois types de modèles ANFIS ayant différentes méthodes de partitionnement (Grid partition, Subtractive clustering, et Fuzzy C-Mean clustering) pour estimer la RS horaire. La deuxième recherche est menée par [Dahmani et al. \(2023\)](#), qui ont comparé entre deux modèles ANN pour prédire la RS globale horaire. La troisième recherche est réalisée par [Djeldjli et al. \(2023\)](#), ils ont utilisé quatre modèles basés sur les ANN utilisant différents algorithmes d'apprentissage pour estimer la RS globale journalière dans la ville de Béchar, les données de six ans ont été utilisées. Des résultats significatifs ont été obtenus avec des indices de ( $R \approx 0.9198$  et  $MAPE \approx 7.57$ ).

Tableau III.1. Historique des modèles appliqués à la modélisation de la RS

N°	Auteurs	Année	Régions	Modèles
01	Drif et Chikh	2000	Bouzaréah	FL
02	Mellit et al	2005a	60 localités en Algérie	MLPNN-MTM
03	Mellit et al	2005b	Alger	RBFNN
04	Mellit et al	2006	Alger	Réseaux d'ondelettes, AR, ARMA, MTM, MLPNN, RNN et RBFNN
05	Mellit et al	2007a	Alger	ANFIS, MLPNN, RBFNN et RNN
06	Mellit et al	2007b	60 localités en Algérie	ANFIS, MLPNN, RBFNN et RNN
07	Mellit et al	2008	60 localités en Algérie	ANFIS, MLPNN, RBFNN et RNN
08	Mellit et al	2010a	Alger	PNN-GA, Ondelettes, MLPNN, RBFNN, ANFIS et RNN
09	Hasni et al	2012	Bechar	ANN
10	Benmouiza et Cheknane	2013	Oran	K-means, NAR et ARMA
11	Laidi et al	2013	Blida	ANN
12	Saoud et al	2013	Tamanrasset	CVNN
13	Asradj et Alkama	2014	Béjaïa	MLPNN
14	Assas et al	2014	Djelfa	MLPNN
15	Dahmani et al	2014	Bouzaréah	MLPNN
16	Laidi et al	2014a	Bouzaréah	ANN
17	Laidi et al	2014b	Blida	ANN
18	Ouali et Alkama	2014	Béjaïa	MLR
19	Saoud et al	2014	Tripoli, Tunis, Alger, Rabat, El Ayoun et Nouakchott	CVNN
20	Yacef et al	2014	Ghardaïa	BNN
21	Asradj et Alkama	2015	Bejaïa	MLPNN et LR
22	Gairaa et al	2015	Ghardaïa	NAR et ARMA
23	Miloudi et Acheli	2015	Boumerdes	MLPNN et RBFNN
24	Rabehi et al	2015	Ghardaïa	RBFNN
25	Saoud et al	2015a	Tripoli, Tunis, Alger, Rabat, El Ayoun et Nouakchott	CVWNN
26	Saoud et al	2015b	Tamanrasset	QVNN
27	Saoud et al	2015c	Tamanrasset	FL
28	Belaid et Mellit	2016	Ghardaïa	SVM et MLPNN
29	Benkaciali et al	2016	Ghardaïa	MLPNN
30	Benmouiza et Cheknane	2016	Ghardaïa et Oran en Algérie, Londres en Angleterre, Almería en Espagne	NAR et ARMA
31	Boualit et Mellit	2016	Ghardaïa	SARIMA et SARIMA-SVM
32	Dahmani et al	2016	Bouzaréah	MLPNN
33	Gairaa et al	2016	Bouzaréah et Ghardaïa	ARMA et ANN
34	Guermoui et al	2016	Ghardaïa	MLPNN
35	Rezrazi et al	2016	Ghardaïa	MLPNN
36	Asradj et al	2017	Béjaïa	GA
37	Benkaciali et al	2017	Ghardaïa	RBFNN
38	Chaba-Mouna et al	2017	Ghardaïa	ANN
39	Laidi et al	2017	Bejaïa, Mostaganem, Tebessa, Batna, Tiaret, Tlemcen, Ouargla, Ghardaïa, Bechar, In Salah, Adrar, Tamanrasset, Tindouf et In Guezzam)	MLPNN
40	Miloudi et al	2017	Boumerdes	MLPNN et RBFNN
41	Rabehi et al	2017	Ghardaïa	RBFNN

42	Saoud et al	2017	Tamanrasset	FCWN
43	Belaïd et al	2018	Ghardaïa	SVM
44	Guermoui et al	2018a	Ghardaïa	SVR
45	Guermoui et al	2018b	Ghardaïa	GPR
46	Guermoui et al	2018c	Ghardaïa	WGPR
47	Saoud et al	2018	Tamanrasset	QVNN
48	Zemouri et Bouzgou	2018	Alger, Msila, Batna et Bechar	SVR
49	Amiri et al	2019	Bouzaréah	EPUNN
50	Benmouiza et Cheknane	2019	Ghardaïa	ANFIS
51	El-Mghouchi et al	2019	27 villes marocaines, 2 villes espagnoles, 4 villes mauritaniennes et 2 villes algériennes: Bechar et Tindouf	MLPNN
52	Abdeljabar et al	2020	Adrar	ANFIS
53	Babahadj et al	2020	Adrar, Timimoun et Bordj Badji Mokhtar	ANFIS
54	Benatallah et al	2020	Adrar	MLPNN
55	Guermoui et Rabehi	2020	Ghardaïa	GPR et LSSVM
56	Khelifi et al	2020	Ghardaïa	MLPNN et RBFNN
57	Mebrouk et al	2020	Adrar	ARIMA
58	Rabehi et al	2020a	Ghardaïa	MLPNN, BDT et LR
59	Rabehi et al	2020b	Ghardaïa	RBFNN
60	Abdelhafidi et al	2021	Oran	MLR et PCA
61	Benatallah et al	2021a	Béchar, Naâma et Tindouf	CFNN, FFNN et ENN
62	Benatallah et al	2021b	Adrar, Khenchela, El-Bayadh et El-Menia	ANFIS
63	Bouchouicha et al	2021	Adrar	WRF-ANN
64	Ferkous et al	2021a	Ghardaïa	GPR et W-GPR
65	Ferkous et al	2021b	Ghardaïa	GPR, SVM, W-GPR et W-SVM
66	Guermoui et al	2021	Ghardaïa	ABC-LSSVM
67	Rabehi et al	2021	Ghardaïa	MLPNN, LSSVM, GPR, BDT et LR
68	Belaïd et al	2022	Ghardaïa	SVM, ARMA, NARX et AR
69	Benmouiza	2022	Ghardaïa et Denver (USA)	LGC-GMDH, MLPNN, RNN-MLPNN, LSTM-MLPNN, WPD-CNN-LSTM-MLPNN et ANFIS
70	Djaafari et al	2022	Tamanrasset, Adrar et Ghardaïa	BDSCA-LSTM, LSTM, MLPNN, SVR, RFR et KNR
71	Ferkous et al	2022a	Ghardaïa	GPR, WPD-GPR et W-GPR
72	Ferkous et al	2022b	Ghardaïa	GPR, WPD-GPR, W-GPR et CEEMDAN-GPR
73	Gairaa et al	2022	Alger, Ghardaïa	MLPNN et MLR
74	Guermoui et al	2022a	Alger et Ghardaïa	CNN, GPR, LSSVM et ELM
75	Guermoui et al	2022b	Ghardaïa	SVR
76	Guermoui et al	2022c	Bouzaréah, Ghardaïa et Adrar	IF-GPR, GPR, CEEMDAN-GPR et SP
77	Saoud et AlMarzouqi	2022	Tamanrasset et Abou Dhabi	QVNN, RVNN, CVNN, SWT-QVNN
78	Takilalte et al	2022	Alger et Ghardaïa	NAR, SVR et RFR
79	Benmouiza	2023	Ghardaïa	ANFIS
80	Dahmani et al	2023	Bouzaréah	ANN
81	Djeldji et al	2023	Béchar	ANN
82	Guermoui et al	2023	Bouzaréah, Ghardaïa, Tamanrasset	ELM-EMD, ELM-CEEMDAN et ELM

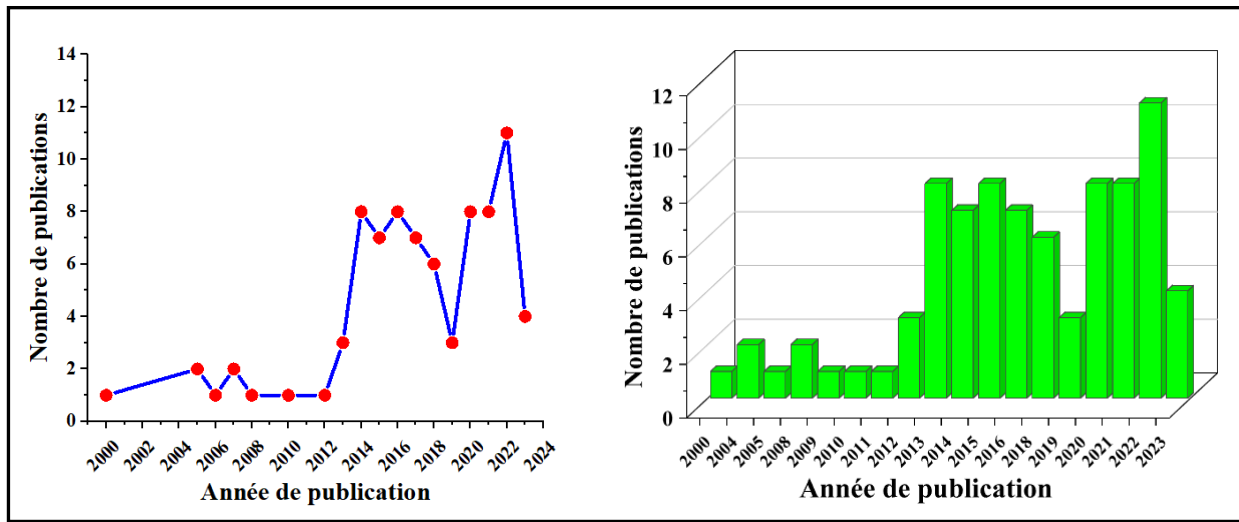


Figure III.1. Nombre de publications en relation avec l'application des modèles à base d'IA pour la modélisation de La RS

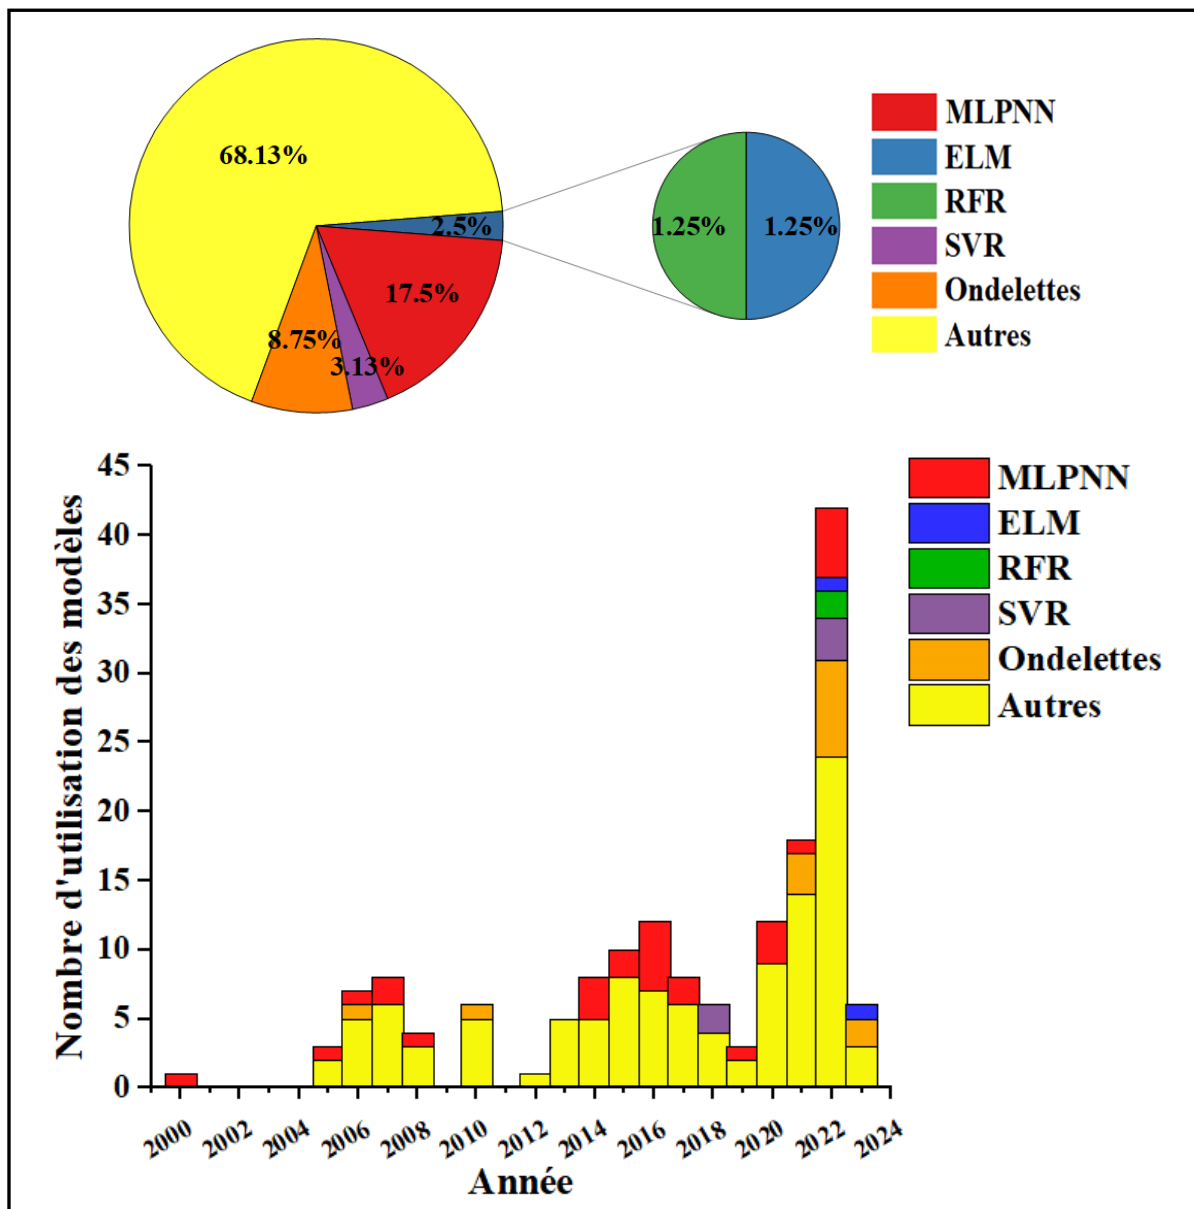


Figure III.2. Les modèles à base d'IA utilisés pour la modélisation de la RS

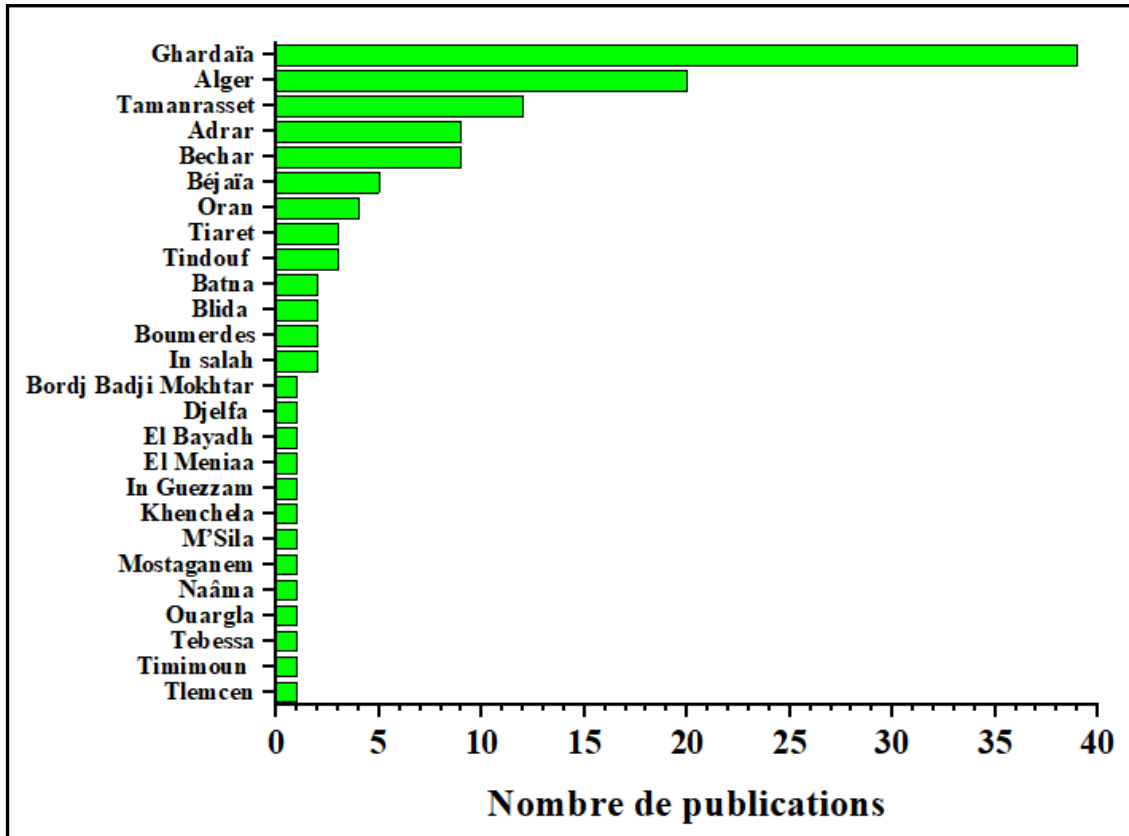


Figure III.3. Volume de publications par wilaya

### III.3. Conclusion

Dans le présent chapitre, une revue sur la littérature en relation avec la prévision et l'estimation de la radiation solaire en Algérie a été réalisée.

A la lumière de cette présentation on peut conclure ce qui suit:

- i.* La plupart des chercheurs ont formé des algorithmes d'IA en utilisant une grande variété de paramètres d'entrée et ont généralement rapporté des résultats satisfaisants.
- ii.* La radiation solaire journalière est la plus étudiée en raison de sa facilité à le traiter car il s'agit d'une fonction continue contrairement à la radiation solaire horaire dont les heures de nuit représentent un grand obstacle.
- iii.* Il est possible de conclure qu'il ne serait pas correct de dire que n'importe quel algorithme d'IA donne les meilleurs résultats pour toutes les régions. En d'autres termes, il a été bien observé que si un algorithme d'IA a donné la meilleure estimation des résultats de la RS pour une région, il a donné le pire résultat pour une autre région.
- iv.* Les paramètres les plus importants affectant les résultats de prédiction de la RS sont la durée d'ensoleillement et la température pour la majorité des cas.

- v. Il est clair de noter que la région de Ghardaïa a reçu la plus grande part de la recherche, en raison des potentiels solaires élevés ainsi que la disponibilité des données.
- vi. Aucune étude, à notre connaissance, n'a rapporté l'application des modèles GRNN et MARS et des techniques de décomposition EWT et VMD pour l'estimation et la prévision de la RS en Algérie. De plus, aucune étude à modéliser la RS dans les régions de Guelma, Jijel et Mila.

***Chapitre IV***

***Présentation de la zone d'Étude et des Données Utilisées***

---

## IV.1. Introduction

L'acquisition des données est une phase essentielle pour toute recherche appliquée, et la qualité des données conditionne la qualité de toute étude. En modélisation, les données servent non seulement à élaborer un modèle mais aussi à tester sa capacité de généralisation. Sans données en quantité et qualité suffisantes, le modèle aura donc peu de chances d'être performant et opérationnel (Donatelli et al., 2004; Coakley et al., 2014; Gairaa et al., 2022). Selon Bellocchi et al. (2011), la précision d'un modèle est déterminée d'une part par l'adéquation des algorithmes décrivant les processus du système réel et d'autre part par la qualité des données d'entrée et d'évaluation. L'objectif de notre travail est la modélisation de l'humidité relative (HR:%) et la radiation solaire (RS: MJ/m<sup>2</sup>) en fonction des variables climatiques. Nous disposons pour la modélisation de l'HR cinq variables climatiques: la température maximale ( $T_{\max}$ : °C), la température minimale ( $T_{\min}$ : °C), les précipitations (P: mm), la vitesse du vent ( $U_2$ : m/s), et la radiation solaire (RS: MJ/m<sup>2</sup>). Pour la modélisation de la radiation solaire nous utilisons cinq variables: la température maximale ( $T_{\max}$ : °C), la température minimale ( $T_{\min}$ : °C), les précipitations (P: mm), la vitesse du vent ( $U_2$ : m/s), et l'humidité relative (HR: %).

## IV.2. Présentation et description des données utilisées

### IV.2.1. Situation géographique des stations climatiques utilisées

La modélisation de l'humidité relative (HR) et la radiation solaire (RS) reporté dans le cadre de cette thèse au nord et dans la région semi-aride de l'Algérie, est réalisée par un vaste échantillon de données, comptant huit sites (stations), pour chaque branche de modélisation (i.e., RH ou HR) nous utilisons deux stations au nord et deux stations dans la région semi-aride de l'Algérie (Figure IV.1). Pour ce travail, nous avons utilisé des données climatiques de réanalyse du système de prévision climatique de la NOAA (CFSR: Climate Forecast System Reanalysis). Ces données du CFSR sont disponibles gratuitement en ligne pour la période de 1979-2014 (<https://swat.tamu.edu/data/cfsr>). La méthode de réanalyse CFSR a prouvé leur efficacité pour générer des données climatiques fiables par plusieurs chercheurs (Dile & Srinivasan, 2014; Fuka et al., 2014; Essou et al., 2017; Hu et al., 2017; Tolera et al., 2018; Alfaro et al., 2020; Bui et al., 2021; Al-Kakey et al., 2023). Généralement, les techniques satellitaires sont actuellement les plus adaptées pour obtenir des informations sur la distribution des paramètres météorologiques à l'échelle régionale à continentale, elles sont couramment utilisées en l'absence de données (Linares-Rodriguez et al., 2013; Ruiz-Arias et

al., 2015; Xu et al., 2016; Pfenninger & Staffell, 2016; Amjad et al., 2021; dos Santos et al., 2021; Liu et al., 2022b). Les tableaux IV.1, IV.2 présentent les coordonnées géographiques des sites et la taille de la base de données utilisées.

Tableau IV.1. Présentation des sites utilisés durant la modélisation de l'HR

Stations	Longitude (°)	Latitude (°)	Altitude (m)	Périodes	Durée (ans)	Jours
Alger	3.217	36.683	29	1990-2014	25	8978
Annaba	7.817	36.833	04	1990-2014	25	8978
Constantine	6.562	36.374	698	1990-2014	25	8978
Sétif	5.312	36.374	1094	1990-2014	25	8978

Tableau IV.2. Présentation des sites utilisés durant la modélisation de la RS

Stations	Longitude (°)	Latitude (°)	Altitude (m)	Périodes	Durée (ans)	Jours
Guelma	7.5	36.3746	314	1990-2014	25	8978
Jijel	5.883	36.800	10	1990-2014	25	8978
Mila	6.25	36.3746	1003	1990-2014	25	8978
Oran	-0.3125	35.7501	131	1990-2014	25	8978

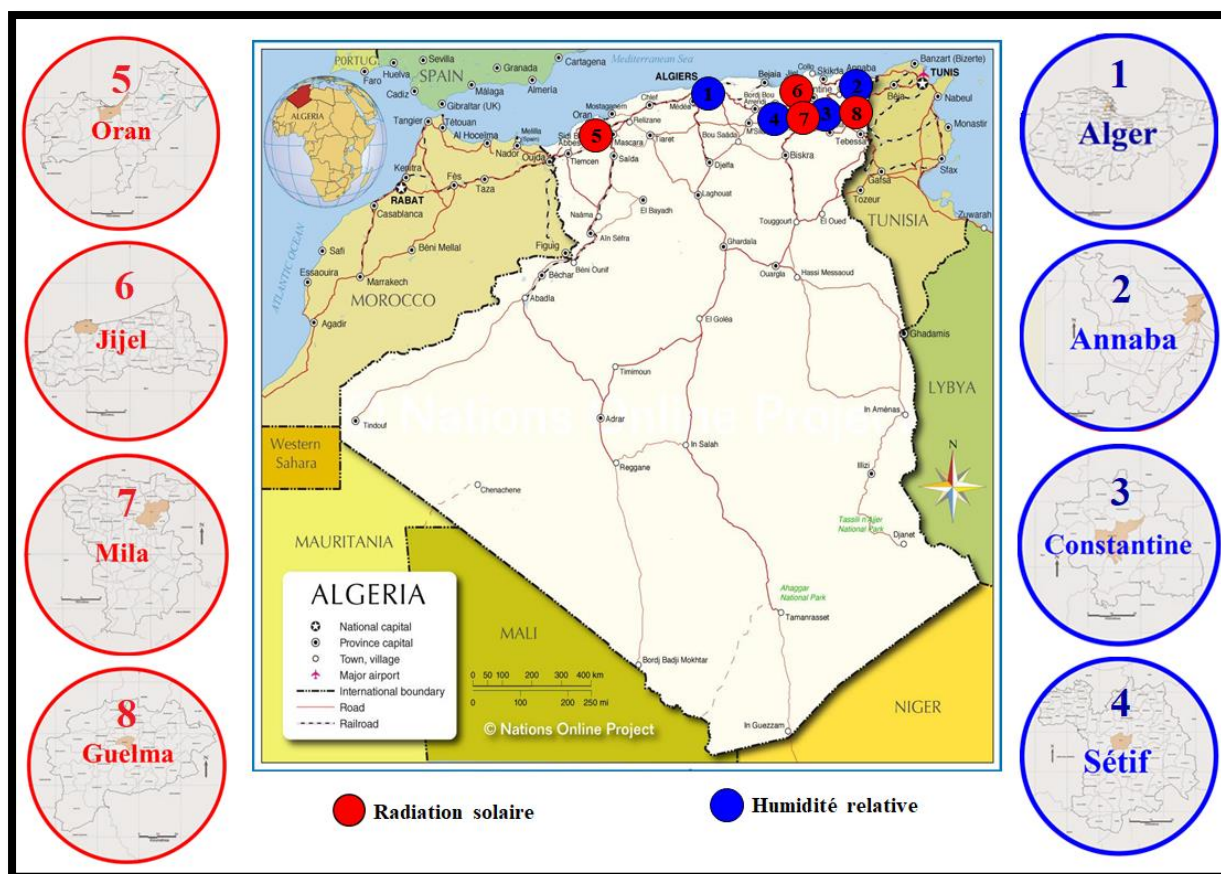


Figure IV.1. Situation géographique des zones d'étude

## IV.2.2. Statistiques descriptives

Dans le présent travail, nous avons calculé les paramètres statistiques pour les différentes variables climatiques, les tableaux IV.3 et IV.4 présentent les résultats obtenus.

- ✓ La valeur maximale ( $X_{\max}$ ) qui est la valeur la plus élevée de la série et qui correspond à la borne supérieure;
- ✓ La valeur moyenne ( $X_{\text{mean}}$ ) qui est égale à la somme des valeurs divisée par leur nombre;
- ✓ La valeur minimale ( $X_{\min}$ ) qui est la valeur la plus faible de la série et qui constitue la borne inférieure;
- ✓ L'écart type ( $S_x$ ) qui représente la caractéristique de dispersion la plus usuelle;
- ✓ Le coefficient de corrélation linéaire ( $R$ ), permet d'illustrer la relation entre la variable climatique et l'humidité relative ou la radiation solaire.
- ✓ Le coefficient de variation ( $C_v$ ) est le rapport de l'écart-type à la moyenne. Plus la valeur de coefficient de variation est élevée plus la dispersion autour de la moyenne est grande.

Tableau IV.3. Paramètres statistiques de la base de données utilisée: modélisation de l'HR

Modélisation de l'humidité relative								
Stations	Variables	Unité	$X_{\text{mean}}$	$X_{\max}$	$X_{\min}$	$S_x$	$C_v$	$R$
Alger	$T_{\max}$	°C	23.590	47.689	3.718	7.488	0.317	-0.787
	$T_{\min}$	°C	13.131	31.972	-4.805	5.765	0.439	-0.667
	P	mm	1.420	79.397	0.000	4.328	3.047	0.353
	$U_2$	m/s	3.555	12.072	0.914	1.378	0.388	0.019
	RS	MJ/m <sup>2</sup>	18.795	32.099	0.537	8.173	0.435	-0.540
	HR	%	63.793	99.605	10.764	14.859	0.233	1.000
Annaba	$T_{\max}$	°C	21.318	39.277	7.269	5.675	0.266	-0.512
	$T_{\min}$	°C	16.721	30.160	4.375	4.940	0.295	-0.386
	P	mm	2.006	69.094	0.000	4.939	2.462	0.389
	$U_2$	m/s	4.655	18.977	1.337	2.189	0.470	0.149
	RS	MJ/m <sup>2</sup>	18.448	31.636	0.712	8.470	0.459	-0.321
	HR	%	69.376	95.474	30.511	8.366	0.121	1.000
Constantine	$T_{\max}$	°C	22.424	45.108	0.071	9.528	0.425	-0.887
	$T_{\min}$	°C	9.331	31.886	-10.133	6.625	0.710	-0.728
	P	mm	2.021	78.827	0.000	5.150	2.548	0.400
	$U_2$	m/s	1.910	6.757	0.512	0.582	0.305	-0.205
	RS	MJ/m <sup>2</sup>	17.605	32.476	0.320	8.835	0.502	-0.676
	HR	%	65.737	100.064	8.581	21.283	0.324	1.000
Sétif	$T_{\max}$	°C	20.519	42.902	-2.737	9.670	0.471	-0.890
	$T_{\min}$	°C	8.079	30.216	-8.398	6.645	0.823	-0.714
	P	mm	2.696	80.125	0.000	6.046	2.242	0.403
	$U_2$	m/s	1.798	6.256	0.463	0.595	0.331	-0.132
	RS	MJ/m <sup>2</sup>	17.078	32.709	0.377	9.003	0.527	-0.687
	HR	%	66.877	100.647	9.743	22.524	0.337	1.000

Le coefficient de corrélation linéaire entre les variables climatiques et l'humidité relative montre que la variable à modéliser est négativement corrélée avec la température minimale et maximale et avec la radiation solaire, ce qui indique que, plus ces variables

augmentent, plus l'HR diminue. Par contre l'humidité relative est faiblement corrélée à la vitesse du vent et les précipitations.

Tableau IV.4. Paramètres statistiques de la base de données utilisée: modélisation de la RS

Modélisation de la radiation solaire								
Stations	Variabes	Unité	$X_{\text{mean}}$	$X_{\text{max}}$	$X_{\text{min}}$	$S_x$	$C_v$	R
Guelma	$T_{\text{max}}$	°C	22.764	48.762	1.419	9.667	0.425	0.731
	$T_{\text{min}}$	°C	9.787	29.458	-6.088	6.204	0.634	0.450
	P	mm	2.662	83.723	0.000	6.106	2.294	-0.423
	$U_2$	m/s	2.694	10.603	0.756	0.953	0.354	-0.249
	HR	%	66.261	99.706	8.767	20.050	0.303	-0.639
	RS	MJ/m <sup>2</sup>	16.926	32.223	0.283	8.994	0.531	1.000
Jijel	$T_{\text{max}}$	°C	21.559	44.585	0.876	8.037	0.373	0.710
	$T_{\text{min}}$	°C	10.874	30.808	-5.932	5.933	0.546	0.430
	P	mm	2.534	83.328	0.000	6.320	2.495	-0.436
	$U_2$	m/s	2.318	9.206	0.761	0.801	0.346	-0.215
	HR	%	68.451	100.203	12.849	17.971	0.263	-0.618
	RS	MJ/m <sup>2</sup>	17.834	32.194	0.352	8.740	0.490	1.000
Mila	$T_{\text{max}}$	°C	22.347	45.709	-0.519	9.578	0.429	0.746
	$T_{\text{min}}$	°C	9.256	31.970	-9.896	6.696	0.723	0.456
	P	mm	1.910	79.349	0.000	4.944	2.589	-0.393
	$U_2$	m/s	1.817	6.288	0.493	0.548	0.302	0.079
	HR	%	65.205	99.805	8.654	21.517	0.330	-0.675
	RS	MJ/m <sup>2</sup>	17.667	32.503	0.317	8.755	0.496	1.000
Oran	$T_{\text{max}}$	°C	24.351	47.215	6.663	7.029	0.289	0.668
	$T_{\text{min}}$	°C	14.493	29.756	-0.478	5.498	0.379	0.487
	P	mm	1.218	100.427	0.000	3.974	3.261	-0.332
	$U_2$	m/s	4.037	20.046	0.978	2.032	0.503	-0.195
	HR	%	63.162	97.473	14.680	12.715	0.201	-0.472
	RS	MJ/m <sup>2</sup>	18.716	31.174	0.380	7.960	0.425	1.000

Une relation linéaire positive existe entre la radiation solaire et les deux températures, plus le paramètre à modéliser augmente, plus les températures  $T_{\text{max}}$  et  $T_{\text{min}}$  augmentent. Par contre, la RS est négativement corrélée à l'humidité relative. De plus, le paramètre le plus corrélé à la RS est la température maximale, tandis que, la vitesse du vent est la plus faiblement corrélée.

### IV.3. Évaluation des performances des modèles

En général, il est nécessaire d'examiner les performances des modèles de prédiction développés et de comparer les performances obtenues à l'aide des indices statistiques particuliers. Toutefois, il est essentiel d'utiliser plusieurs indices statistiques car il est possible que deux ou plusieurs modèles atteignent des valeurs similaires ou proches pour un indice statistique particulier, et il est donc difficile de confirmer quel modèle est plus performant que les autres. Il convient de noter ici que chaque indice statistique évalue le modèle sous l'angle unique de l'adéquation entre les résultats du modèle et les valeurs mesurées. Par conséquent, il est conseillé d'examiner le modèle par rapport à plusieurs indices statistiques afin d'évaluer

pleinement les performances de chaque modèle individuellement et d'effectuer une analyse comparative solide entre eux afin d'obtenir une confirmation solide de la méthode de modélisation la plus appropriée (Hanoon et al., 2021).

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). Pour les deux premiers critères (RMSE et MAE), des valeurs plus faibles indiquent une grande performance du modèle, alors que pour les deux autres indices (R et NSE), des valeurs élevées indiquent une performance supérieure (Moriassi et al., 2007; Adnan et al., 2023; Babatunde et al., 2023; Kim et al., 2023). Mathématiquement, R, NSE, RMSE et MAE peut être écrit comme (Heddami, 2023; Merabet et Heddami, 2023; Alizamir et al., 2023):

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

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

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

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

$\overline{X_{obs}}$  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).

## IV.4. Conclusion

Nous avons présentés dans ce quatrième chapitre la base de données utilisées, et qui concerne huit stations: quatre pour la modélisation de l'HR, à savoir: Alger, Annaba, Constantine et Sétif, et quatre pour la modélisation de la RS, à savoir: Guelma, Jijel, Mila et Oran. Pour chaque station, les données s'étalent sur une période de vingt-cinq années, allant de Janvier 1990 jusqu'au Juillet 2014, contenant les paramètres climatiques suivants: pour la modélisation de l'HR; la température (maximale et minimale), les précipitations, la vitesse du vent, et la radiation solaire, et pour la modélisation de la RS; la température (maximale et minimale), les précipitations, la vitesse du vent et l'humidité relative.

***Chapitre V:***  
***Présentation des Modèles à Base d'Intelligence Artificielle***

---

## V.1. Introduction

Au cours des dernières années, l'application des modèles à base d'intelligence artificielle pour l'estimation et la prédiction des variables climatiques a reçu une grande importance dans la littérature, en raison de sa capacité à faire face aux problèmes mal définis et complexes dans plusieurs domaines scientifiques. Ce chapitre présente les différents modèles et techniques basés sur l'IA qui sont utilisées dans le cadre de la modélisation de l'HR et la RS.

## V.2. Les modèles d'apprentissage automatique

### V.2.1. MLPNN

Les réseaux de neurones artificiels (ANN) sont des modèles mathématiques inspirés du fonctionnement du cerveau humain. Ce sont des modèles non linéaires et appartiennent à la catégorie des techniques d'IA, généralement appelées modèles boîte noire (Heddam, 2016). L'une des architectures ANN les plus rapportées dans la littérature est le réseau de neurones à perceptron multicouche (MLPNN) (Rumelhart et al., 1986a). En raison de sa forte capacité de généralisation, il est principalement utilisé pour les problèmes de prédiction et d'approximation; et considéré comme un approximateur universel (Hornik et al., 1989; Hornik, 1991). Le MLPNN se compose de trois types de couches: une couche d'entrée qui contient les variables explicatives, une couche de sortie qui contient la variable à modéliser, et une ou plusieurs couches cachées. Les poids et les biais sont les paramètres du modèle MLPNN. L'apprentissage du MLPNN se fait avec des paramètres initiaux aléatoires. Le processus d'apprentissage est répété plusieurs fois, afin de déterminer le meilleur modèle ayant l'erreur quadratique moyenne (MSE) la plus faible entre la variable à modéliser mesuré et calculé (Heddam, 2016).

Le MLPNN utilisé dans cette étude est un réseau de neurones avec une fonction d'activation sigmoïde dans la couche cachée et une fonction d'activation linéaire dans la couche de sortie. La structure du MLPNN développé est illustrée à la figure V.1. Selon la figure V.1, la couche d'entrée contient les variables indépendantes ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$  et HR ou RS), la couche cachée contient les neurones de traitement et la troisième couche contient uniquement un seul neurone: HR ou RS.

La formulation mathématique du MLPNN est illustrée comme suit: De la couche d'entrée à la couche cachée, chaque neurone caché ( $I$ ) calcule la somme pondérée de toutes les variables d'entrée ( $x_i$ ) plus un biais ( $\delta_j$ ):

$$I_j = \delta_j + \sum_{i=1}^n x_i w_{ij} \quad \text{V.1}$$

Où  $x_i$  est la variable d'entrée,  $w_{ij}$  est le poids entre l'entrée  $i$  et le neurone caché  $j$ ,  $I_j$  est le niveau d'activité interne du neurone  $j$  dans la couche cachée et  $\delta_j$  est le biais associé au neurone caché  $j$ .

Une fonction d'activation ( $f$ ) appartenant à la couche cachée est appliquée à la somme des résultats :

$$E_j = f_1(I_j) \quad \text{V.2}$$

$E_j$  est la sortie du neurone  $j$  dans la couche cachée et  $f_1$  la fonction d'activation, généralement la fonction sigmoïde, représentée par l'équation V.3:

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad \text{V.3}$$

Les sorties des neurones cachés sont utilisées comme entrées dans la couche de sortie :

$$O = \delta_0 + \sum_{j=1}^n E_j w_{jk} \quad \text{V.4}$$

$w_{jk}$  est le poids de connexion du neurone  $j$  dans la couche cachée au neurone unique  $k$  dans la couche de sortie;  $O$  est l'entrée du neurone de sortie  $k$  et  $\delta_0$  est le biais du neurone de sortie  $k$ .

Enfin, la sortie du neurone  $k$  dans la couche de sortie est calculée à l'aide d'une fonction d'activation linéaire  $f_0$  :

$$Y = f_2(O) \quad \text{V.5}$$

La sortie du modèle MLPNN a été calculée selon [Jin et al. \(2016\)](#):

$$Y = f^2[W^2 f^1(W^1 X + b^1) + b^2] \quad \text{V.6}$$

où  $Y$  est le vecteur de sortie (HR ou SR prédite);  $X$  est le vecteur d'entrée (cinq variables climatiques);  $f^1$  et  $f^2$  sont des fonctions de transfert des couches cachée et de sortie, sigmoïde et linéaire, respectivement;  $b^1$  et  $b^2$  sont respectivement les biais des couches cachée et de sortie; et  $W^1$  et  $W^2$  sont respectivement les poids des couches d'entrée et cachée ([Jin et al., 2016](#)).

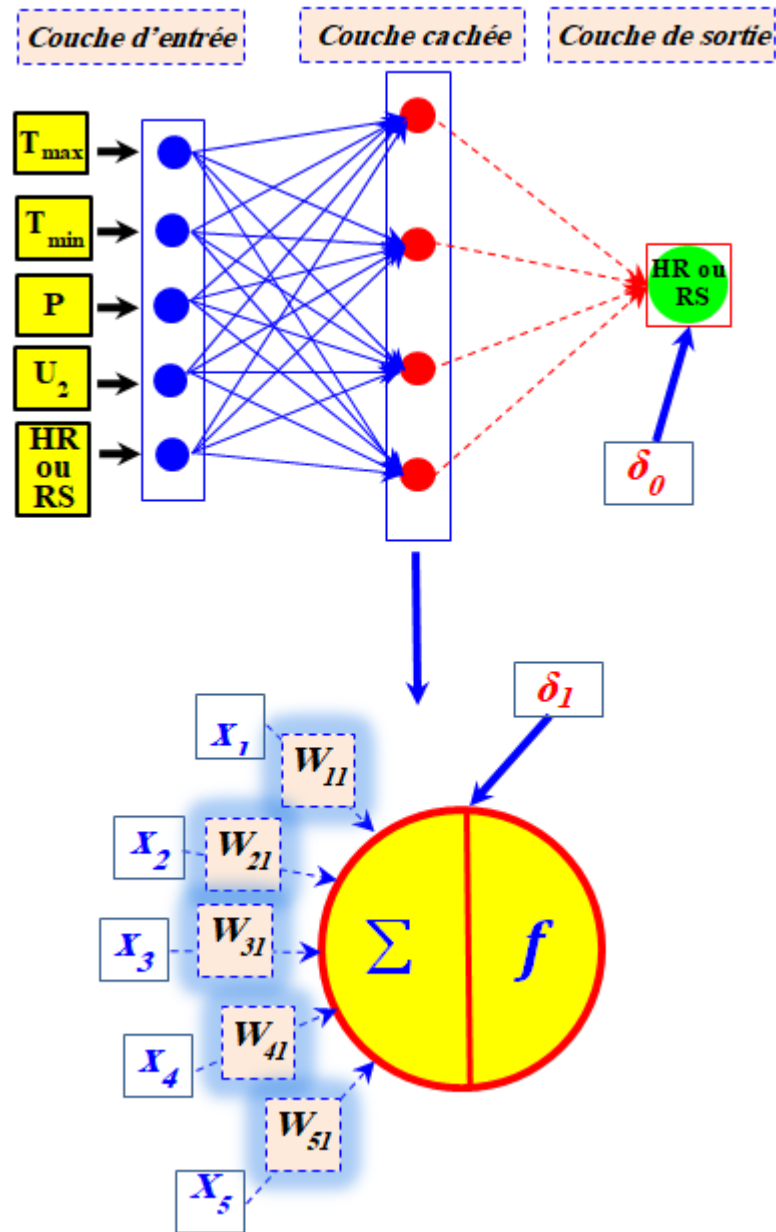


Figure V.1. L'architecture du MLPNN (Merabet & Heddami, 2023)

L'apprentissage du MLPNN s'effectue à l'aide d'un algorithme d'apprentissage supervisé, le plus connu est l'algorithme de rétropropagation du gradient (LeCun, 1985; Rumelhart et al., 1986a; 1986b), qui nécessite un ensemble d'entrées et de sortie désirée. L'objectif de l'algorithme d'apprentissage est de trouver les valeurs optimal de poids et de biais, qui fournit l'erreur minimale entre le résultat désirée et la sortie actuelle du modèle (Haykin, 1999).

## V.2.2. ELM

L'algorithme ELM a été proposé par [Huang et al. \(2006a, 2006b\)](#) en tant qu'algorithme d'apprentissage pour les réseaux de neurones de type feed-forward à couche cachée unique (SLFN).

Pour l'ANN standard décrit dans la section précédente, tous les paramètres du modèle (poids et biais) depuis la couche d'entrée jusqu'à la couche de sortie ont été améliorés pendant la phase d'apprentissage.

Dans certains cas, notamment lorsqu'il s'agit d'une grande base de données, le processus d'apprentissage devient une tâche difficile, prend beaucoup de temps et ne converge pas vers le meilleur ensemble optimal de paramètres, et par conséquent la capacité de généralisation du modèle peut être affectée ([Zhu et al., 2019](#)).

[Huang et al. \(2006a, 2006b\)](#) ont proposé une reformulation du processus d'apprentissage pour lequel les poids de la couche d'entrée à la couche cachée ont été choisis d'une façon aléatoire et les poids entre la couche cachée et la couche de sortie sont déterminés analytiquement dans la procédure d'apprentissage par la méthode des moindres carrés (LSM) ([Huang et al., 2012](#)). Plusieurs fonctions d'activation telles que la fonction sigmoïde, sinus et la fonction radiale de base peuvent être utilisées, et les neurones de sortie ont une fonction d'activation linéaire ([Huang et al., 2006a, 2006b](#)). Les détails de la formulation mathématique de l'ELM peuvent être résumés comme suit ([Figure V.2](#)):

En supposant que l'architecture du modèle SLFN est composée de  $L$  neurones cachés, une couche d'entrée; chaque neurone caché utilise une fonction d'activation  $f(x)$  et un neurone unique dans la couche de sortie. Tous les neurones ont un biais ( $b$ ).

L'apprentissage du SLFN s'effectue à l'aide d'un ensemble de données composé de  $N$  échantillons d'apprentissage arbitraires représentés par  $(X_i, Y_i)$ , où  $x_i = [x_{i1}, x_{i2}, \dots, x_{iD}]^T \in \mathbb{R}^D$  et  $y_i = [y_{i1}, y_{i2}, \dots, y_{iD}]^T \in \mathbb{R}^D$ .

SLFN est mathématiquement présenté comme ([Huang et al., 2006a, 2006b](#)):

$$\sum_{i=1}^L \beta_i f_i(x_j) = \sum_{i=1}^L \beta_i f_i(w_i x_j + b_i) = O_K \quad \text{V.7}$$

Avec  $w_i = [w_{i1}, w_{i2}, \dots, w_{iD}]^T$  est le vecteur de poids qui relie le  $i^{\text{ème}}$  neurone caché et les neurones d'entrée,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  est le vecteur de poids reliant le  $i^{\text{ème}}$  neurone caché et les neurones de sortie,  $O_K = [O_{K1}, O_{K2}, \dots, O_{Km}]^T$  est le  $K^{\text{ème}}$  vecteur de sortie du SLFN, et  $b_i$  est le biais du  $i^{\text{ème}}$  neurone caché.  $f_i(\cdot)$  est la sortie du  $j^{\text{ème}}$  neurone caché, et  $f$  est la fonction d'activation du

neurone caché (Huang et al., 2006a, 2006b, 2015; Huang et Chen, 2008). L'équation non linéaire V.7 pour un SLFN peut s'écrire sous forme matricielle comme:

$$H\beta = T \quad \text{V.8}$$

Avec:

$$H = \begin{bmatrix} f_1(w_1x_1 + b_1) & \cdots & f_L(w_Lx_1 + b_L) \\ \vdots & \vdots & \vdots \\ f_1(w_1x_N + b_1) & \cdots & f_L(w_Lx_N + b_L) \end{bmatrix} \quad \text{V.9}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix} \quad \text{V.10}$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_L^T \end{bmatrix} \quad \text{V.11}$$

Avec  $H$  est la matrice de sortie de la couche cachée du réseau.

Les poids de sortie entre la couche cachée et la couche de sortie sont donnés par:

$$\hat{\beta} = H^+ T \quad \text{V.12}$$

Avec  $H^+$  est l'inverse généralisé de Moore – Penrose de la matrice  $H$  (Huang et al., 2015).

Selon Huang et al. (2006a, 2006b), ELM est développé en trois étapes: (i) la génération aléatoire des paramètres de nœuds cachés  $w_i$  et le biais  $b_i$  en fonction du nombre de neurones cachés et du nombre de variables d'entrée basées sur une fonction de densité de probabilité continue (Vasu & Lee, 2016), (ii) le calcul de la matrice de sortie de la couche cachée  $H$  selon l'équation V.9 et (iii) le calcul du poids de sortie  $\hat{\beta}$  à l'aide de la méthode de l'inverse généralisé de Moore – Penrose.




Figure V.2. La structure de l'ELM (Huang, 2015)

### V.2.3. GRNN

Le modèle GRNN a été introduit pour la première fois par Donald F. Specht (Specht, 1991). Contrairement au réseau de neurones artificiels de rétropropagation (BPNN), qui a un processus d'apprentissage relativement compliqué et nécessite l'optimisation de nombreux paramètres, GRNN n'a qu'un seul paramètre qui doit être optimisé, le facteur spread ( $\sigma$ ) (Heddiam, 2017).

La base théorique du GRNN est l'analyse de régression non linéaire (Zhang et al., 2023).

Supposons que  $f(x, y)$  représente la fonction de densité de probabilité des variables aléatoires  $x$  et  $y$ . Soit  $X$  une valeur mesurée particulière de la variable aléatoire  $x$ . La moyenne conditionnelle de  $y$  étant donné  $X$  (également appelée régression de  $y$  sur  $X$ ) est donnée par Specht (1991):

$$\hat{Y} = \frac{\int_{-\infty}^{+\infty} y f(X, y) dy}{\int_{-\infty}^{+\infty} f(X, y) dy} \quad \text{V.13}$$

Où  $\hat{Y}$  représente le résultat prédit et  $f(X, y)$  est la fonction de densité de probabilité.

En utilisant une estimation non paramétrique, la fonction de densité  $\hat{f}(X, y)$  peut être estimée à partir de la base de données (Park & Kim, 2017),

$$\hat{f}(X, y) = \frac{1}{n(2\pi)^{\frac{(p+1)}{2}} \sigma^{p+1}} \sum_{i=1}^n f_X f_Y \quad \text{V.14}$$

Où

$$f_X = \exp \left[ -\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \quad \text{V.15}$$

Et

$$f_Y = \exp \left[ -\frac{(Y - Y_i)^2}{2\sigma^2} \right] \quad \text{V.16}$$

Où  $n$  et  $p$  sont respectivement le nombre d'observations de l'échantillon et la dimension de la variable  $x$ .  $\sigma$  est un facteur (appelé en anglais SPREAD).  $X_i$  et  $Y_i$  sont les valeurs de  $x$  et  $y$ , respectivement.

En remplaçant l'équation V.14 dans l'équation V.13 puis en échangeant l'ordre d'intégration et d'addition (Wang & Peng, 2018) nous pouvons obtenir la formule suivante:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n \exp \left[ -\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \int_{-\infty}^{+\infty} y \exp \left[ -\frac{(y - Y_i)^2}{2\sigma^2} \right] dy}{\sum_{i=1}^n \exp \left[ -\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \int_{-\infty}^{+\infty} \exp \left[ -\frac{(y - Y_i)^2}{2\sigma^2} \right] dy} \quad \text{V.17}$$

Effectuant le calcul intégral

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y_i \exp \left[ -\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[ -\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right]} \quad \text{V.18}$$

Où, la fonction scalaire  $D_i^2$  est donnée par:

$$D_i^2 = (X - X_i)^T (X - X_i) \quad \text{V.19}$$

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y_i \exp \left[ -\frac{D_i^2}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[ -\frac{D_i^2}{2\sigma^2} \right]} \quad \text{V.20}$$

L'architecture du GRNN est représentée dans la figure V.3. Comme le montre la figure V.3, le GRNN se compose de quatre couches (Cao & Zhang, 2021), comprenant la couche d'entrée, la couche du modèle, la couche de sommation et la couche de sortie. La première couche est entièrement connectée à la seconde. Le nombre de neurones de la couche d'entrée est proportionnel au nombre de variables explicatives ( $X_i$ ).

Chaque neurone de la couche du modèle est connecté aux deux neurones de la couche de sommation: le premier est appelé: Numérateur ( $N^S$ ), le deuxième neurone est appelé: Dénominateur ( $D^S$ ). Le neurone de sommation  $N^S$  calcule la somme pondérée des sorties de la couche du modèle, tandis que le neurone de sommation  $D^S$  calcule les sorties non pondérées des neurones de la couche du modèle (Specht, 1991). Finalement, et dans notre cas, la couche de sortie contient uniquement un seul neurone qui divise simplement la sortie du neurone  $N^S$  par la sortie du neurone  $D^S$  ( $N^S/D^S$ ) pour fournir le résultat finale du réseau de neurone GRNN.

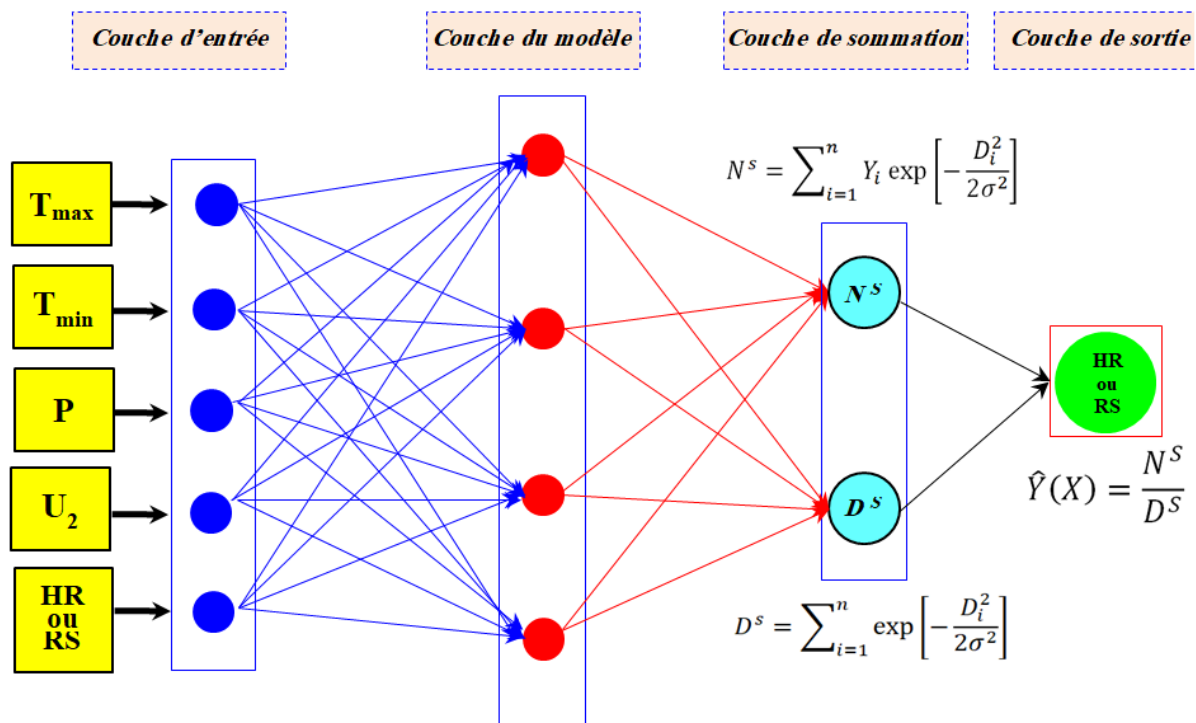


Figure V.3. La structure du réseau GRNN (Heddiam, 2017)

## V.2.4. MARS

Le modèle MARS a été développé par Friedman (1991). Il recherche toute relation non linéaire et non paramétrique possible qui peut exister et peut être construite entre un ensemble de variables d'entrée et de sortie (Adnan et al., 2021). MARS est utilisé pour tenter d'identifier et d'établir automatiquement l'éventuelle équation de régression entre les variables

explicatives et les variables dépendantes de manière progressive; un autre avantage important du modèle MARS est sa capacité à fournir la part de la contribution de chaque prédicteur à la variable dépendante, et à la fin de la procédure d'apprentissage, il fournit le classement final des régresseurs individuellement sur la base de leur rang (Friedman, 1991). Avec le modèle MARS, l'espace des régresseurs est divisé en plusieurs sous-espaces appelés nœuds, chacun ayant sa propre fonction et des splines (segments) qui servent à relier tous ces nœuds, et toutes les splines sont regroupées pour former une fonction de base (BF). Ainsi, le modèle MARS est basé sur trois grands composants: les nœuds, les splines et le BF.

Les idées principales du modèle MARS sont les suivantes: d'une part, la relation entre les variables indépendantes et dépendantes ne doit pas nécessairement être bien connue; d'autre part, l'information disponible dans l'espace des variables indépendantes est divisée en diverses régions appelées nœuds, et pour chaque nœud un modèle de régression est développé à l'aide d'une fonction spline, elle-même composée d'un ou plusieurs BF qui remplacent les prédicteurs originaux (Kisi & Heddam, 2019). La valeur prédite du modèle MARS est basée sur une combinaison linéaire des composantes BF impliquées dans l'espace des prédicteurs et se résume comme suit :

$$Y = f(x) = \beta_0 + \sum_{m=1}^M \beta_m BF_m(x) \quad \text{V.21}$$

où  $\beta_m$  sont les coefficients inconnus du modèle déterminés au cours du processus itératif,  $Y$  est la variable prédite (HR ou RS), BF sont les fonctions de base utilisées pour ajuster le modèle MARS et composées des prédicteurs d'origine, i.e.  $x_i$  (variables météorologiques), et  $M$  est le nombre total de BF (Friedman, 1991; Ghasemzadeh & Ahmed, 2018).

Le développement du modèle se fait en deux phases (Figure V.4): forward et backward. Dans la première phase, un modèle est construit qui contient les nœuds choisis et leur BF correspondant. Durant la deuxième phase, le BF qui contribue le moins à la diminution de l'erreur est élagué à l'aide de la méthode de validation croisée généralisée (GCV: Generalized Cross-Validation) (Kuter et al., 2018).

$$GCV(M) = \frac{\frac{1}{N} \sum_{i=1}^N (y_i - f(x_i))^2}{\left(1 - \frac{c(M)}{N}\right)^2} \quad \text{V.22}$$

où  $N$  est le nombre de données,  $y_i$  est la valeur souhaitée (HR ou RS mesurée),  $f(x_i)$  est la valeur calculée,  $c(M)$  est le facteur de pénalité (Lokuge et al., 2018; Yilmaz et al., 2018)

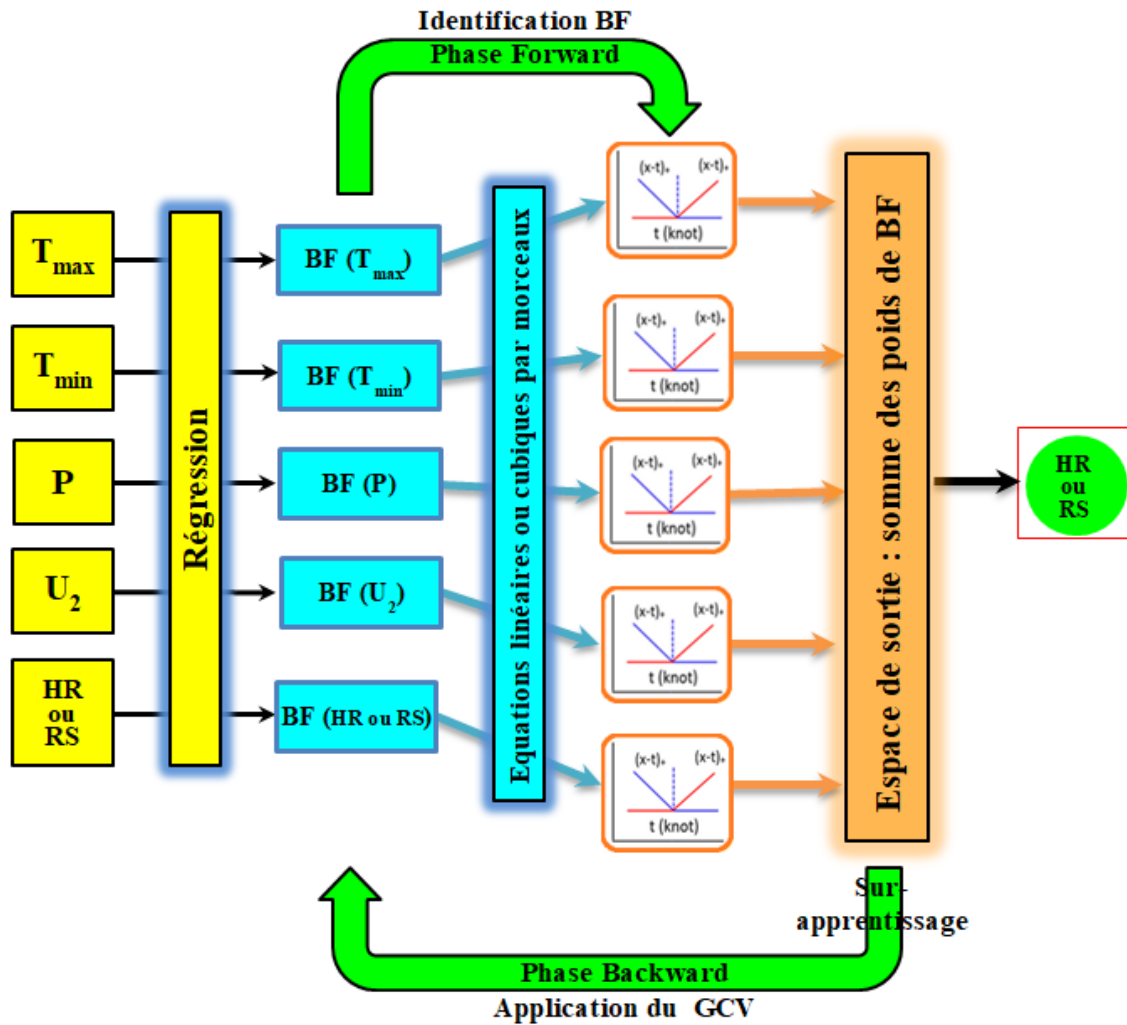


Figure V.4. La structure du modèle MARS (Kisi & Heddami, 2019)

### V.2.5. RFR

Les forêts aléatoires (RF) est un modèle d'apprentissage automatique proposé par Breiman (2001). Il est basé sur les arbres de décision (DT), et utilise l'algorithme CART (Classification And Regression Trees) pour résoudre les problèmes de régression (Heddami et al., 2020). Dans l'apprentissage des RFR, plusieurs sous-ensembles de données sont générés à l'aide de la méthode bootstrap. Le processus aléatoire de RFR comporte les deux étapes suivantes (Guo et al., 2023b): Premièrement, RFR crée chaque sous-ensemble  $S_m = \{(x_1, y_1), \dots, (x_m, y_m)\}$  en ré-échantillonnant aléatoirement un certain pourcentage de la base de données totale  $S_n = \{(x_1, y_1), \dots, (x_n, y_n)\}$ , Où  $x_n = [x_{n1}, x_{n2}, \dots, x_{ni}]$  et  $y_n = [y_{n1}, y_{n2}, \dots, y_{ni}]$  sont les vecteurs d'entrée et de sortie, respectivement. Deuxièmement, lors de l'apprentissage de chaque DT, RFR sélectionne de manière aléatoire  $P$  ( $P < M$ ) entrées parmi  $M$  entrées disponibles. Ces deux étapes assurent la diversité des DT dans la forêt. Après l'apprentissage, la fonction de sortie du  $k^{\text{ième}}$  arbre de

décision peut être décrite comme  $f(x, S_m^k)$  et le résultat de prédiction moyen du RFR constitué de k DT est obtenu comme suit (Guo et al., 2023b):

$$\hat{y}_{rf} = \frac{1}{k} \sum_{i=1}^k f(x, S_m^k)$$

V.23

Où  $\hat{y}_{rf}$ , est le résultat prédit du modèle.

Le principe structurel de la forêt aléatoire de régression (RFR) susmentionnée est représenté sur la figure V.5.

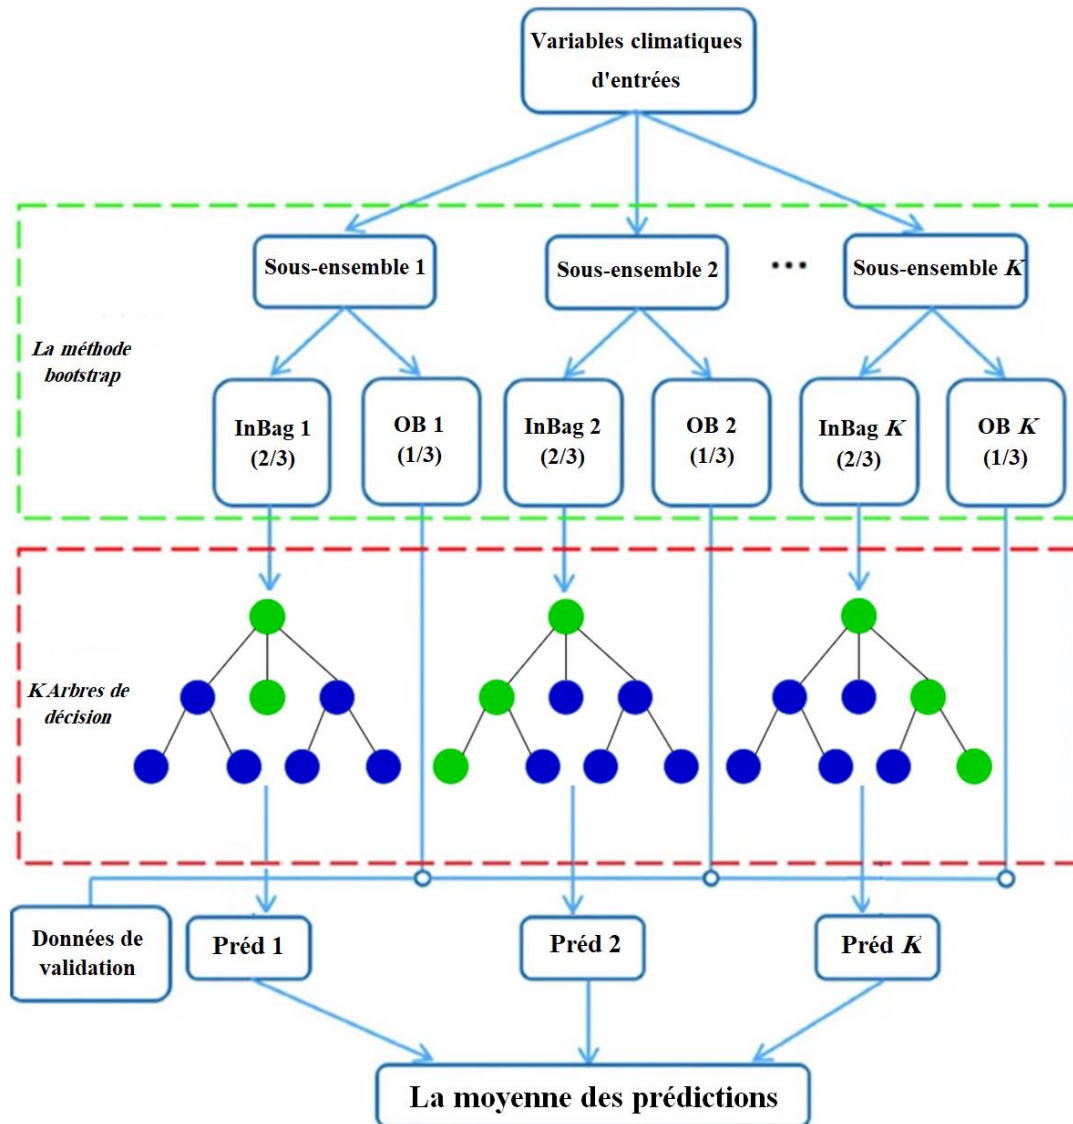


Figure V.5. L'architecture du modèle RFR (Zhang & Wu, 2020)

En raison de l'utilisation de la méthode bootstrap pour le ré-échantillonnage, environ un tiers des données d'apprentissage de chaque sous-ensemble de données est séparé, et ces données sont appelées Out-of-Bag (OB), et les deux tiers de chaque sous-ensemble de données sont appelées données In-Bag.

En utilisant les données OB fournies, le modèle RFR effectue une analyse des erreurs de prédiction (Equation V.24) (Guo et al., 2023b):

$$MSE_{OB} = \frac{1}{K} \sum_{i=1}^K (\hat{y}_i^{OB} - y_i)^2 \quad V.24$$

Où  $MSE_{OB}$ , représente l'erreur quadratique moyenne de la prédiction des données OB,  $y_i$  est la valeur observée,  $\hat{y}_i^{OB}$  est la valeur prédite de l'observation  $y_i$  dans les données OB, et  $k$  est le nombre de DT dans la forêt.

## V.2.6. SVR

Le modèle SVR est un type de machine à vecteurs de support (SVM) avec des fonctions de régression développées par Smola (1996). La version originale du modèle SVM a été introduite par Vapnik (1995) en s'appuyant sur la règle de minimisation des risques structurels. Le modèle SVR a été créé pour résoudre les problèmes de régression et de prévision dans les domaines de l'ingénierie, des tâches statistiques et de la prédiction (Tikhmarine et al., 2020). L'idée principale du modèle SVR est de trouver une fonction de dépendance  $f(x)$  qui utilise toutes les données avec la précision la plus minimale possible (Smola, 1996). La fonction de régression du modèle SVR peut être exprimée comme suit:

$$f(x) = w \phi(x) + b \quad V.25$$

Où  $f$  est la fonction de régression,  $\phi$  est la fonction de transfert, et  $w$  et  $b$  sont respectivement le poids et le biais. Le problème de régression peut être formulé comme suit (Tikhmarine et al., 2020):

$$\text{Minimizer : } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad V.26$$

$$\text{Sous les contraintes : } \begin{cases} y_i - f(x) \leq \varepsilon + \xi_i \\ f(x) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, 3, \dots, N \end{cases} \quad V.27$$

Où  $C$  est le paramètre de pénalité,  $\xi_i$  et  $\xi_i^*$  sont les variables de ressort (Slack variables en anglais), et  $\varepsilon$  est la valeur de frontière.

En utilisant les multiplicateurs de Lagrange, le problème d'optimisation se convertit en programmation quadratique et une solution de fonction de régression non linéaire peut être exprimée comme suit :

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad V.28$$

Où  $K(x, x_i)$  est la fonction Kernel et  $\alpha_i, \alpha_i^*$  sont les variables duales. Les fonctions Kernel représentent le cœur du modèle SVR; il existe plusieurs fonctions Kernel tels que la fonction gaussienne, linéaire, sigmoïde, polynomial et la fonction de base radiale. Dans notre travail de modélisation, la fonction gaussienne a été utilisée, cette fonction peut être formulée comme suit (Keshtegar et al., 2019):

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad \text{V.29}$$

Où  $\sigma$  est le paramètre du Kernel qui assure le lissage de la fonction.

L'architecture du modèle SVR est représentée dans la figure V.6.




Figure V.6. La structure du réseau SVR (Keshtegar et al., 2019)

### V.3. Les techniques de décomposition du signal

Dans cette étude, trois algorithmes de décomposition du signal ont été utilisés, à savoir (i) la décomposition en mode empirique (EMD), (ii) la transformée en ondelettes empiriques (EWT), et (iii) la décomposition en mode variationnel (VMD). La transformée en ondelettes a déjà été utilisée efficacement dans un plusieurs domaines pour décomposer des séries de données non stationnaires. Les algorithmes EMD, EWT et VMD décomposent les variables climatiques explicatives en plusieurs composants d'analyse multirésolution (MRA: Multiresolution Analysis), qui ont été utilisés comme nouvelles variables d'entrée (Heddad et

al., 2023). Un exemple d'application des trois algorithmes sur les données des précipitations pour la station d'Alger est représenté dans la figure V.7.

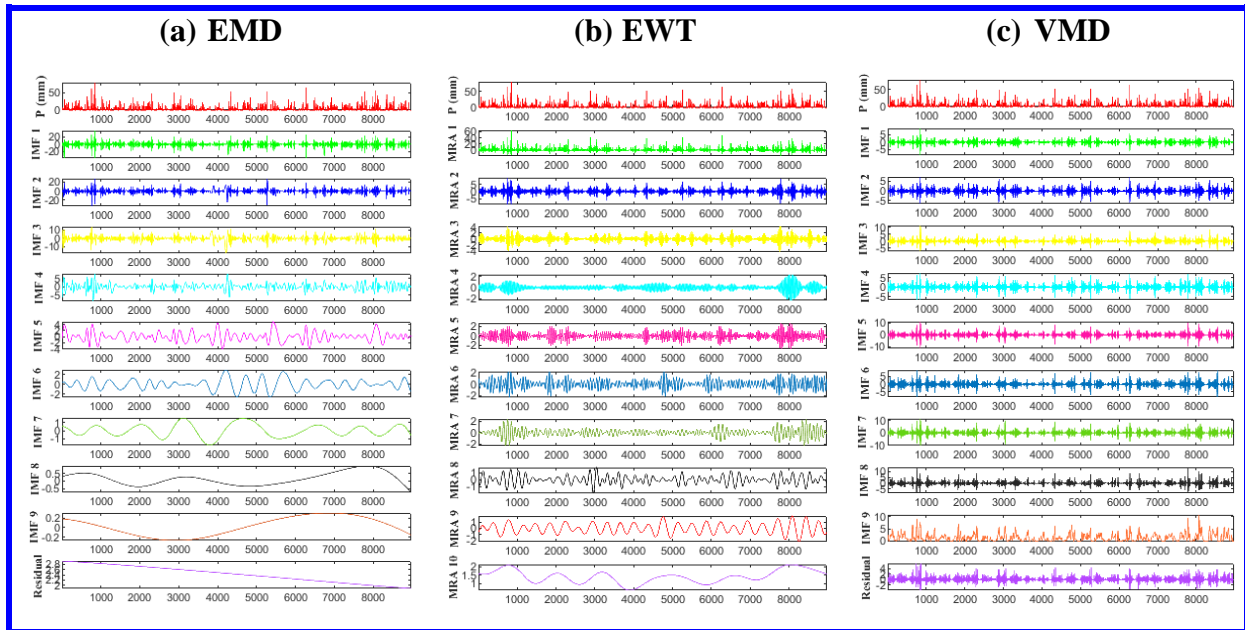


Figure V.7. Exemple de décomposition du signal des précipitations (P) pour la station d'Alger utilisant: (a) EMD, (b) EWT et (c) VMD

### V.3.1. La décomposition en mode empirique (EMD)

L'algorithme EMD a été proposé par Huang et al. (1998). La décomposition du signal par cette algorithme est une étape de prétraitement, principalement utilisée pour filtrer tout signal non linéaire et le transformer en une série de sous-signaux appelés fonctions modes intrinsèques (IMFs) (Merabet & Heddami, 2023).

Afin d'être une composante oscillatoire de l'IMF, certaines conditions doivent être respectées car la phase et l'amplitude de chacun changent lentement: (i) l'IMF entre deux extrêmes consécutifs n'a qu'une seule valeur zéro et (ii) la « moyenne locale » de l'IMF doit être nulle (Alaodolehei et al., 2020; Abdulhay et al., 2020).

La décomposition du signal non linéaire à l'aide de l'EMD, i.e., le processus de tamisage, implique plusieurs étapes, qui peuvent être résumées comme suit (Abdollahpoor & Lotfivand, 2020):

1. Les IMF calculés doivent être classés de l'échelle inférieure à l'échelle supérieure.
2. Le processus d'extraction de l'IMF commence par le calcul des maxima et minima locaux du signal  $x(t)$ .

3. Les maxima et minima locaux obtenus sont utilisés par la courbe spline cubique pour définir les enveloppes supérieures et inférieure, et leur valeur moyenne, i.e.,  $m_1(t)$ , est ensuite calculée.
4. Calcule de la première composante, i.e.,  $C_1(t)$  comme suit:

$$C_1(t) = x(t) - C_1(t) \quad \text{V.30}$$

5. Ce processus (i.e., tamisage) est itératif et se poursuit jusqu'à ce que la première IMF soit extraite.
6. Bien que le processus soit itératif, il existe un paramètre d'arrêt pour stopper le processus de tamisage, i.e., l'écart type ( $S_x$ ) calculé comme suit (Abdollahpoor & Lotfivand, 2020):

$$S_x = \sum_{t=0}^T \left[ \frac{|h_{k-1}(t) - h_k(t)|^2}{h_{k-1}^2(t)} \right] \quad \text{V.31}$$

7. Enfin, le signal original  $x(t)$  peut être reformulé comme suit :

$$x(t) = \sum_{i=1}^N IMF_i(t) + R_N(t) \quad \text{V.32}$$

Où  $N$  est le nombre du IMF et le  $R_N$  est appelé le résidu (El Bouny et al., 2019).

### V.3.2. La transformée en ondelettes empiriques (EWT)

L'EWT a été introduite par Jerome Gilles (Gilles, 2013). elle a été formulée sur la base de l'hypothèse selon laquelle un signal  $x(t)$  résulte de la somme des sous-composantes individuelles caractérisées par un support compact dans le spectre de Fourier (Liu et al., 2020; Merabet & Heddami, 2023). L'EWT est utilisé pour fournir une série de sous-signaux (MRA) (Wang et Hu 2015). Elle utilise deux fonctions distinctes, à savoir: (i) la fonction d'échelle empirique ( $\hat{\varphi}_n(\omega)$ ), et (ii) les fonctions d'ondelettes empiriques  $\hat{\psi}_n(\omega)$ . Les deux fonctions sont définies par les équations (V.33) et (V.34), respectivement (Hu et al., 2015; Si et al., 2019):

$$\left( \hat{\varphi}_n(\omega) \right) = \begin{cases} 1 & \text{si } |\omega| \leq \omega_n - \tau_n \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_n} |\omega| - \omega_n + \tau_n \right) \right] & \text{si } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{sinon} \end{cases} \quad \text{V.33}$$

et

$$\hat{\phi}_n(\omega) = \begin{cases} 1 & \text{si } \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n-1} \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_{n+1}} |\omega| - \omega_{n+1} + \tau_{n+1} \right) \right] & \text{si } \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_n} |\omega| - \omega_n + \tau_n \right) \right] & \text{si } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{sinon} \end{cases} \quad \text{V.34}$$

Pour les deux équations ci-dessus,  $(\omega)$  est le  $n^{\text{ième}}$  maxima du spectre de Fourier. La sélection de la meilleure valeur  $(\tau)$  doit être proportionnelle à  $(\omega_n)$  pour laquelle  $(\tau_n = \gamma \cdot \omega_n)$  où  $(0 < \gamma < 1)$ . La fonction  $\beta(x) \in C^k([0, 1])$  est une fonction arbitraire et exprimée comme suit (Liu et al., 2020; Hu et al., 2015; Si et al., 2019):

$$\beta(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ 1 & \text{si } x \geq 1 \end{cases} \text{ et } \beta(x) + \beta(1-x) = 1 \quad \forall x \in [0,1] \quad \text{V.35}$$

### V.3.3. La décomposition en mode variationnel (VMD)

Dragomiretskiy et Zosso (2013) proposent l'algorithme VMD pour la décomposition du signal. Le VMD utilise un processus de décomposition adaptative pour extraire une série IMF caractérisées par des propriétés spécifiques (Li et al., 2022; Merabet & Heddami, 2023). Le VMD estime les modes, i.e., les IMF et leurs fréquences centrales respectives à l'aide d'un algorithme adaptatif et concurrent (Peng et al., 2020). Chaque mode calculé à l'aide du VMD pourrait être formulé comme suit :

$$u_k(t) = A_k(t) \cos[\phi_k(t)] \quad \text{V.36}$$

Où  $u_k(t)$  est la  $k^{\text{ième}}$  composante de mode,  $A_k(t)$  est une enveloppe non-négative, et  $\phi_k(t)$  est la phase instantanée (Li et al., 2022). En utilisant le VMD, nous supposons que chaque mode calculé correspond à un IMF ayant une bande finie et une fréquence centrale, qui ont été déterminés à l'aide d'un processus de recherche itératif pour une solution optimale (Zhang et al., 2020). Étant donné tout signal  $f(t)$  non linéaire et non stationnaire, le VMD peut être considéré comme une minimisation d'un problème d'optimisation contraint et le VMD peut être construit comme suit:

$$\begin{cases} \min_{u_k, w_k} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \otimes u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{Sous contrainte } \sum_{k=1}^K u_k = f(t) \end{cases} \quad \text{V.37}$$

où  $u_k$  ( $k = 1, 2, 3, \dots, K$ ) représente les  $K$  IMF utilisant VMD,  $w_k$  est les fréquences centrales correspondantes de chaque IMF,  $t$  est le script de temps,  $K$  représente le nombre total de sous-signaux,  $\delta(t)$  est la distribution de Dirac,  $j$  est l'unité imaginaire, et  $\otimes$  est l'opérateur de

convolution, et enfin l'expression  $\left(\delta(t) + \frac{j}{\pi t}\right)$  correspond à la transformée de Hilbert de  $u_k(t)$  (Liu et al., 2021; Li et al., 2022; Peng et al., 2020).

## V.4. Conclusion

En raison de l'indisponibilité des données climatiques dans de nombreux cas, le recours aux techniques d'IA pour estimer et prédire ces données est inévitable. Dans le présent chapitre, nous avons exposé brièvement les techniques appliquées dans les chapitres suivants, pour la modélisation de l'HR et la RS, à savoir: les réseaux de neurones à perceptron multicouche (MLPNN), les machines à apprentissage extrême (ELM), les réseaux de neurones à fonction de régression générale (GRNN), Le modèle de régression multivariée par spline adaptative (MARS), les forêts aléatoires de régression (RFR), la régression à vecteurs de support (SVR), et les techniques de décomposition du signal, à savoir: la décomposition en mode empirique (EMD), la transformée en ondelettes empiriques (EWT), et la décomposition en mode variationnel (VMD).

**Chapitre VI**  
**Modélisation de l'Humidité Relative (HR) par l'Intelligence Artificielle**

---

## VI.1. Introduction

La prévision précise et cohérente de l'HR est un défi en raison de sa nature non linéaire (Qadeer et al., 2021; Ozbek et al., 2022). Les stratégies de prédiction basées sur l'utilisation des techniques d'intelligence artificielle (IA) pour prédire les paramètres agroclimatiques a montré de nombreux succès qui ont été rapportés dans la littérature (Hussein et al., 2021). Dans ce chapitre nous comparons les résultats obtenus par les modèles traditionnels simples d'IA qui appliquent la modélisation directement sur les données climatiques sous les abréviations (MLPNN, ELM, GRNN, MARS, RFR et SVR), et des modèles d'IA hybrides basés sur le prétraitement par la décomposition du signal. Pour chaque modèles hybride, nous avons utilisés trois techniques de décomposition sous les abréviations (EMD, EWT, VMD), Ainsi, les modèles hybrides ont été désignés ci-après par MLPNN\_EMD, MLPNN\_VMD et MLPNN\_EWT, et ceci est identique aux modèles ELM, GRNN, MARS, RFR et SVR. Nous discuterons les résultats obtenus au niveau des quatre stations dans le littorale et la région semi-aride de l'Algérie. Pour le développement des modèles, le logiciel **Matlab** a été utilisé comme outil de programmation.

Le choix des données d'entrées adéquates est la base de toutes modélisations. Le choix idéal contribue à améliorer la précision de l'algorithme, la compréhensibilité et l'effort de calcul de la simulation (Czarnecki & Podolak, 2013; Liu et al., 2017; Schmidt et al., 2019; Arulmozhi et al., 2021). Pour cela, et pour avoir des conclusions solides sur la qualité de la modélisation, et pour pouvoir comparer la robustesse des modèles simples et hybrides, et à la base de l'analyse des corrélations entre les entrées et la sortie, nous avons testé six combinaisons, ayant chacune différentes variables climatique d'entrée (inputs) (**Tableau VI.1**). Les six scénarios sont:(i) les modèles qui utilisent cinq variable climatique (un seul modèle), (ii) les modèles qui utilisent quatre variables climatiques (deux modèles), (iii) les modèles qui utilisent trois variables climatiques (deux modèles) et (iv) les modèles qui utilisent deux variables climatiques (un seul modèle). La base de données a été divisée d'une façon aléatoire en deux parties: une première partie dite d'apprentissage (70%), et une deuxième partie dite de validation (30%). Les performances des modèles sont évaluées en utilisant quatre critères: RMSE, MAE, R, et le critère de NSE. Les différents modèles utilisés possèdent différent type de paramètres à optimiser durant la phase d'apprentissage. L'organigramme qui synthétise la modélisation proposée est illustré à **la figure VI.1**.

Tableau VI.1. Structure des modèles utilisés durant la modélisation de l'HR

Modèles						Variables d'entrées (inputs)	Output
MLPNN1	ELM1	GRNN1	MARS1	RFR1	SVR1	$T_{max}$ , $T_{min}$ , P, $U_2$ , RS	HR
MLPNN2	ELM2	GRNN2	MARS2	RFR2	SVR2	$T_{max}$ , $T_{min}$ , $U_2$ , RS	HR
MLPNN3	ELM3	GRNN3	MARS3	RFR3	SVR3	$T_{max}$ , P, $U_2$ , RS	HR
MLPNN4	ELM4	GRNN4	MARS4	RFR4	SVR4	$T_{max}$ , P, $U_2$	HR
MLPNN5	ELM5	GRNN5	MARS5	RFR5	SVR5	$T_{max}$ , P, RS	HR
MLPNN6	ELM6	GRNN6	MARS6	RFR6	SVR6	$T_{max}$ , P	HR

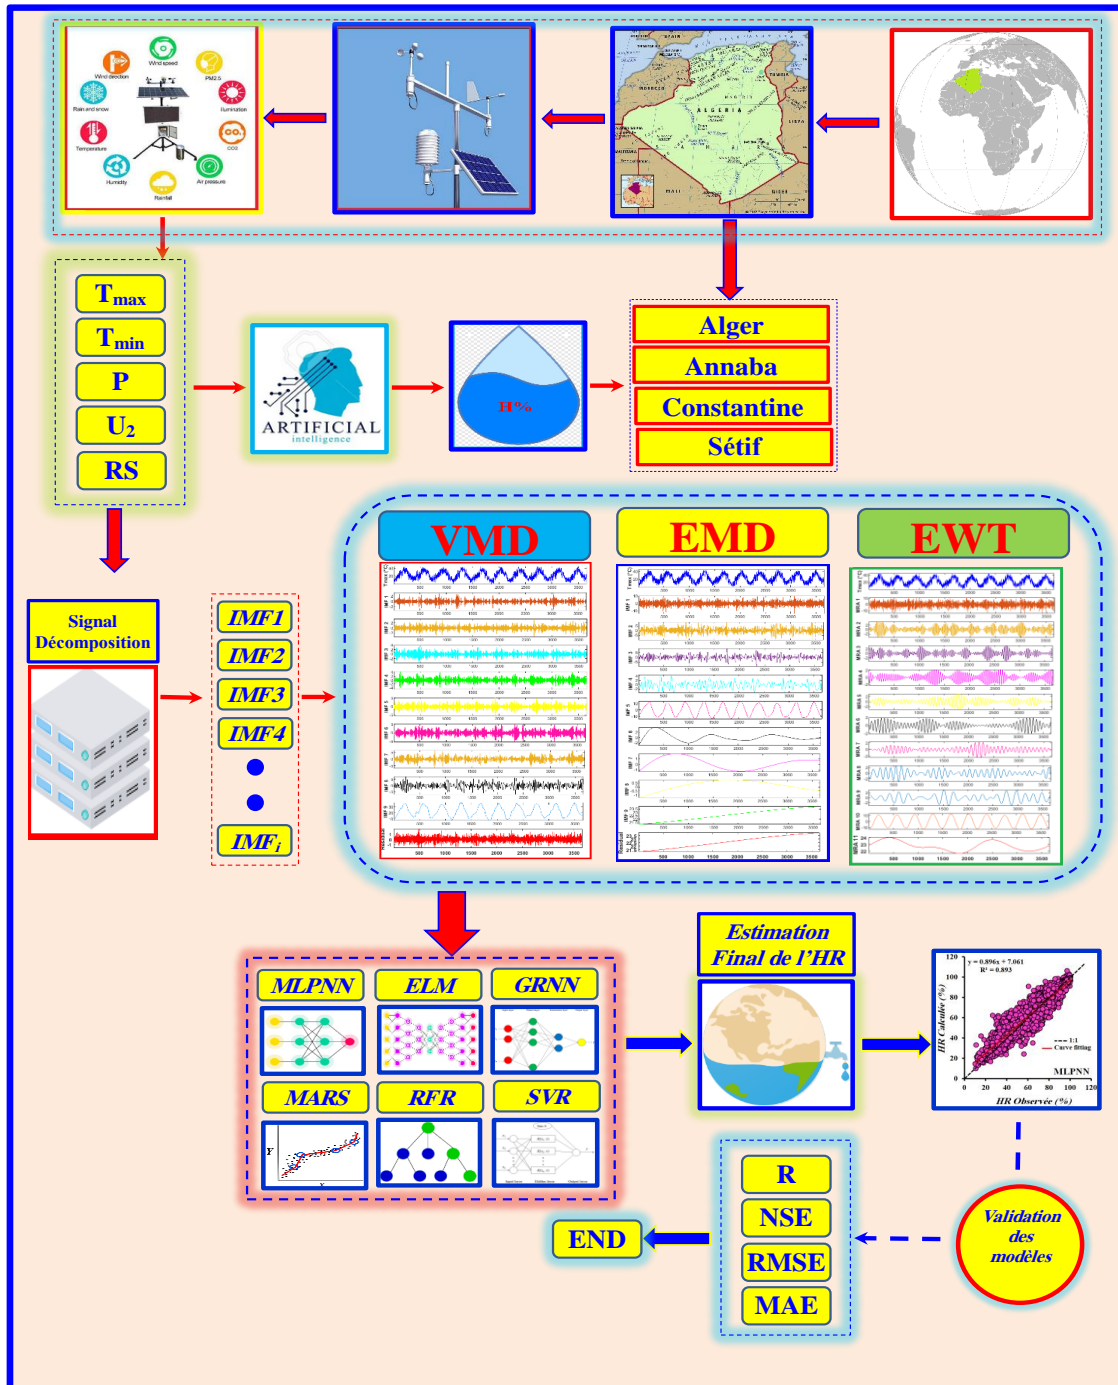


Figure VI.1. L'organigramme de modélisation de l'HR

## VI.2. Modélisation de l'HR par les modèles traditionnels

Pour la première partie, les six modèles traditionnels (MLPNN, ELM, GRNN, MARS, RFR et SVR) utilisent les mêmes entrées. Les résultats sont présentés séparément pour chaque station dans les tableaux VI.2-5. En plus des résultats numériques, nous présenterons des résultats graphiques pour chaque station sous forme de courbes Scatterplots, boxplots, violin plots, et diagramme de Taylor (Figures VI.2-9). 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.

Pour la station d'Alger (Tableau VI.2, Figures VI.2-3), les performances des modèles sont faibles à moyennes. Les moyennes des valeurs des R et NSE pour les six modèles sont rangés entre (0.859, 0.737) pour le meilleur modèle qui est le MLPNN et (0.830, 0.678) pour le plus faible modèle qui est le GRNN. Les meilleurs résultats avec les modèles MLPNN sont obtenus avec le modèle MLPNN1 qui utilise toutes les variables climatiques ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$  et RS) avec des indices de l'ordre de ( $R \approx 0.889$ ,  $NSE \approx 0.790$ ,  $RMSE \approx 6.779$ ,  $MAE \approx 5.397$ ), par contre les faibles performances sont obtenues par le modèle MLPNN6 qui utilise deux variables climatiques ( $T_{\max}$  et P) avec des indices de l'ordre de ( $R \approx 0.823$ ,  $NSE \approx 0.677$ ,  $RMSE \approx 8.404$ ,  $MAE \approx 6.687$ ). Les faibles résultats au niveau de la station d'Alger sont obtenus avec les modèles GRNN, les performances se sont dégradées par des taux de l'ordre de (9.814% et 10.669%) en termes des moyennes des RMSE et MAE entre les meilleurs modèles (MLPNN) et les modèles GRNN. Les autres modèles (ELM, MARS, RFR et SVR) ont donnés des résultats similaires entre eux, les meilleures performances sont obtenues avec le modèle RFR1 ( $R \approx 0.885$ ,  $NSE \approx 0.782$ ,  $RMSE \approx 6.905$ ,  $MAE \approx 5.489$ ), suivie par le modèle MARS1 ( $R \approx 0.879$ ,  $NSE \approx 0.772$ ,  $RMSE \approx 7.058$ ,  $MAE \approx 5.654$ ), suivie par le modèle SVR1 ( $R \approx 0.875$ ,  $NSE \approx 0.766$ ,  $RMSE \approx 7.148$ ,  $MAE \approx 5.612$ ), et enfin le modèle ELM2 qui utilise quatre variables climatiques ( $T_{\max}$ ,  $T_{\min}$ ,  $U_2$  et SR) garantie les meilleures performances avec des indices de l'ordre de ( $R \approx 0.867$ ,  $NSE \approx 0.752$ ,  $RMSE \approx 7.366$ ,  $MAE \approx 5.828$ ). Pour les modèles à quatre variables climatiques (la deuxième et la troisième combinaison), ils ont donné des résultats proches à celle des résultats obtenus par les meilleurs modèles, et cela nous conduit à conclure que les deux variables (P,  $T_{\min}$ ) jouent un rôle négligeable. Si en utilisant uniquement trois variables climatiques (la quatrième et la cinquième combinaison), les performances des modèles se dégradent d'une façon remarquable, surtout si on compare entre la première et la cinquième combinaisons, cette dégradation atteint (20.238%, 21.462%) en terme des RMSE et MAE entre RFR1 et RFR6. Enfin, les performances les plus faibles

parmi tous les modèles proposés ont été obtenus par les modèles à deux variables d'entrée, pour lesquelles les RMSE et le MAE ont été significativement augmentés et les valeurs de R et NSE ont été considérablement diminuées par rapport aux autres modèles, et le modèle GRNN6 assure les faibles performances au niveau de la station d'Alger avec des indices de ( $R \approx 0.810$ ,  $NSE \approx 0.645$ ,  $RMSE \approx 8.813$ ,  $MAE \approx 7.119$ ).

Les modèles ont été comparés d'une façon graphique, comme le montrent les figures VI.2 et VI.3. Dans la figure VI.2, nous avons tracé les Scatterplots des valeurs calculées et observées de l'HR durant la phase de validation pour les meilleurs modèles, ce qui nous permet de conclure que les données étaient moins dispersées (forte corrélation) en utilisant les modèles MLPNN et RFR. Par contre, le modèle GRNN a donné les données les plus dispersées (faible corrélation).

D'après les boxplots (Figure VI.3a) qui utilise quelques indicateurs de position des données de l'HR, telles que la médiane, le minimum, le maximum, l'étendue et les quartiles, et le violin plot (Figure VI.3b) qui est semblable à boxplot, mais il affiche également la densité de probabilité des données pour différentes valeurs, les modèles MLPNN et RFR montrent des grandes similitudes avec les données mesurées. Toutefois, selon le diagramme de Taylor (Figure VI.3c) qui applique trois mesures statistiques spécifiques; R, RMSE et l'écart-type pour représenter graphiquement les valeurs de l'HR observées et prédites, le modèle GRNN est le moins performant de tous les modèles proposés.

Tableau VI.2. Résultats obtenus par les modèles traditionnels au niveau de la station d'Alger

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.896</b>	<b>0.803</b>	<b>6.614</b>	<b>5.179</b>	<b>0.889</b>	<b>0.790</b>	<b>6.779</b>	<b>5.397</b>
MLPNN2	0.878	0.771	7.120	5.572	0.875	0.766	7.148	5.662
MLPNN3	0.873	0.760	7.300	5.721	0.869	0.754	7.341	5.852
MLPNN4	0.863	0.744	7.527	5.891	0.857	0.734	7.632	6.063
MLPNN5	0.846	0.715	7.942	6.296	0.838	0.703	8.058	6.451
MLPNN6	0.828	0.686	8.346	6.611	0.823	0.677	8.404	6.687
ELM 1	0.867	0.752	7.417	5.856	0.866	0.750	7.395	5.940
<b>ELM2</b>	<b>0.865</b>	<b>0.749</b>	<b>7.463</b>	<b>5.869</b>	<b>0.867</b>	<b>0.752</b>	<b>7.366</b>	<b>5.828</b>
ELM3	0.854	0.728	7.758	6.122	0.852	0.726	7.738	6.193
ELM4	0.855	0.731	7.717	6.059	0.853	0.727	7.725	6.137
ELM5	0.833	0.694	8.232	6.524	0.831	0.690	8.228	6.585
ELM6	0.827	0.684	8.372	6.633	0.822	0.676	8.414	6.695
GRNN1	0.855	0.720	7.880	6.167	0.841	0.700	8.104	6.465
GRNN2	0.835	0.684	8.368	6.634	0.831	0.678	8.392	6.735
<b>GRNN3</b>	<b>0.853</b>	<b>0.714</b>	<b>7.965</b>	<b>6.275</b>	<b>0.844</b>	<b>0.701</b>	<b>8.090</b>	<b>6.501</b>
GRNN4	0.849	0.705	8.085	6.408	0.841	0.695	8.167	6.569
GRNN5	0.819	0.658	8.700	6.941	0.814	0.651	8.732	7.036
GRNN6	0.815	0.652	8.781	7.021	0.810	0.645	8.813	7.119
<b>MARS1</b>	<b>0.880</b>	<b>0.638</b>	<b>7.074</b>	<b>5.570</b>	<b>0.879</b>	<b>0.772</b>	<b>7.058</b>	<b>5.654</b>
MARS2	0.867	0.752	7.411	5.813	0.867	0.752	7.364	5.831
MARS3	0.866	0.749	7.457	5.859	0.865	0.748	7.422	5.906
MARS4	0.861	0.741	7.573	5.923	0.858	0.736	7.602	6.020
MARS5	0.833	0.694	8.235	6.533	0.829	0.686	8.278	6.621
MARS6	0.825	0.681	8.414	6.673	0.822	0.631	8.985	7.234
<b>RFR1</b>	<b>0.954</b>	<b>0.847</b>	<b>4.593</b>	<b>3.548</b>	<b>0.885</b>	<b>0.782</b>	<b>6.905</b>	<b>5.489</b>
RFR2	0.949	0.895	4.820	3.710	0.871	0.758	7.272	5.741
RFR3	0.947	0.893	4.859	3.746	0.873	0.761	7.224	5.713
RFR4	0.901	0.800	6.652	5.147	0.856	0.726	7.735	6.213
RFR5	0.889	0.777	7.027	5.536	0.834	0.690	8.235	6.648
RFR6	0.866	0.739	7.608	5.959	0.813	0.657	8.657	6.989
<b>SVR1</b>	<b>0.901</b>	<b>0.812</b>	<b>6.456</b>	<b>4.951</b>	<b>0.875</b>	<b>0.766</b>	<b>7.148</b>	<b>5.612</b>
SVR2	0.887	0.786	6.885	5.320	0.869	0.755	7.320	5.747
SVR3	0.879	0.772	7.102	5.425	0.862	0.742	7.510	5.900
SVR4	0.866	0.748	7.468	5.753	0.852	0.726	7.746	6.068
SVR5	0.845	0.713	7.977	6.273	0.837	0.701	8.089	6.431
SVR6	0.828	0.685	8.360	6.569	0.820	0.671	8.474	6.678

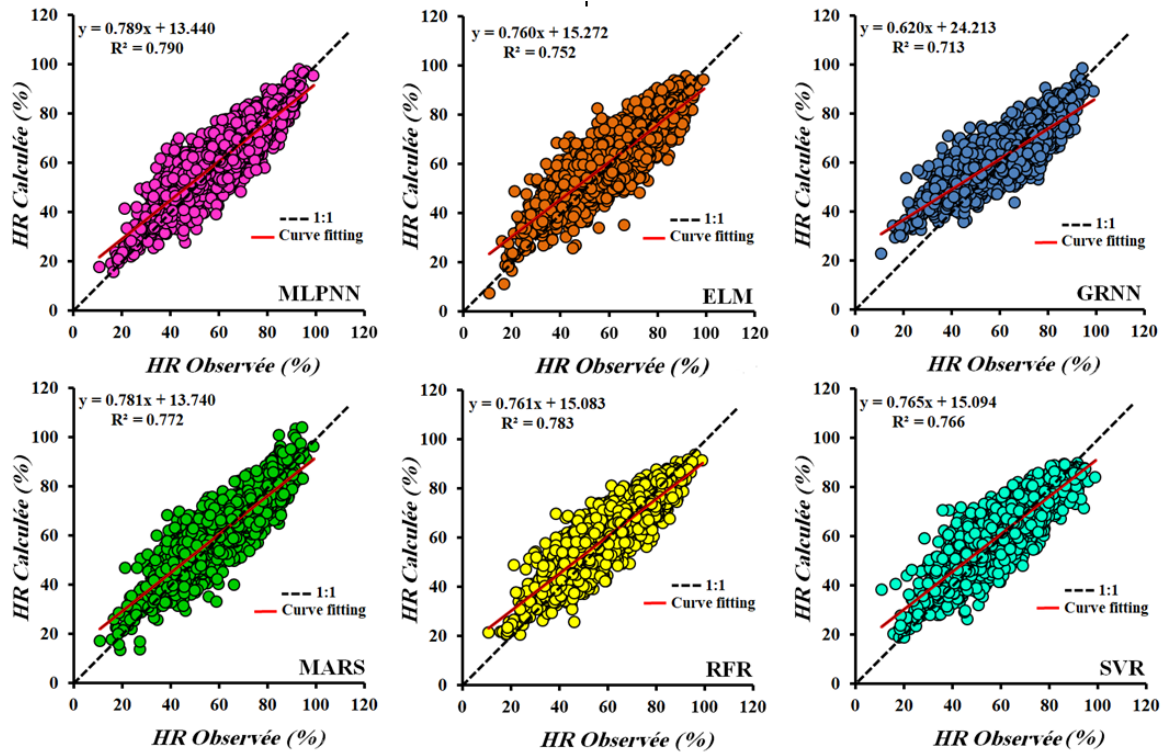


Figure VI.2. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles traditionnels, station d'Alger.

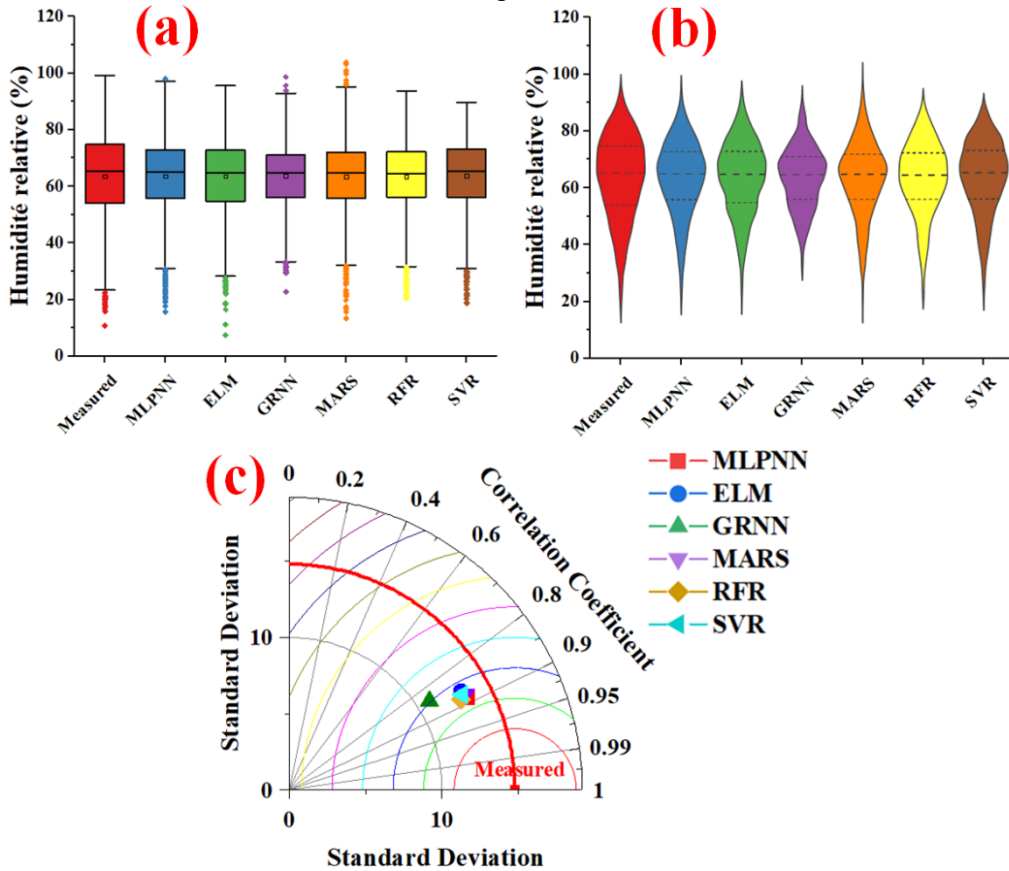


Figure VI.3. Comparaison graphique entre l'HR mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Alger

Au niveau de la station d'Annaba (Tableau VI.3, Figure VI.4-5), les performances des modèles étaient faibles par rapport à la station d'Alger. 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,  $U_2$  et RS) ont assurés les meilleurs performances avec des R et NSE rangés entre 0.672 et 0.754, 0.430 et 0.560, respectivement, et le modèle MLPNN1 était le meilleur modèle avec les plus grands R et NSE (0.754, 0.560) et les plus faibles RMSE et MAE (5.444, 4.317). On remarque aussi que l'exclusion de la précipitation (modèle MLPNN2) conduit à une réduction des performances, et les R et NSE se dégradent légèrement pour atteindre des valeurs de l'ordre de 0.660 et 0.428, respectivement, alors que les RMSE et MAE deviennent plus grandes importante et s'augmentent avec des taux de l'ordre de 12.349% et 12.594%, respectivement. La même remarque se fait ressentie lors de la comparaison entre la première et la deuxième combinaison. Pour qui est des faibles performances, elles sont assurées par les modèles GRNN, avec la moyenne des R et NSE de 0.638 et 0.390, mais le modèle MARS6 qui utilise la dernière combinaison assure les plus faibles performances au niveau de la station d'Annaba, avec les plus petits R et NSE (0.605, -0.290) et les plus grands RMSE et MAE (9.326, 7.537). D'une façon générale, les performances au niveau de la station d'Annaba sont faibles et non satisfaisantes.

La représentation graphique (Figure VI.4 et VI.5) montre la même tendance que les résultats numériques.

Tableau VI.3. Résultats obtenus par les modèles traditionnels au niveau de la station d'Annaba

Modélés	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.775</b>	<b>0.601</b>	<b>5.328</b>	<b>4.148</b>	<b>0.754</b>	<b>0.560</b>	<b>5.444</b>	<b>4.317</b>
MLPNN2	0.694	0.478	6.094	4.803	0.660	0.428	6.211	4.939
MLPNN3	0.709	0.501	5.953	4.654	0.691	0.476	5.943	4.667
MLPNN4	0.691	0.476	6.102	4.773	0.673	0.452	6.076	4.748
MLPNN5	0.685	0.468	6.151	4.821	0.670	0.447	6.106	4.813
MLPNN6	0.657	0.431	6.360	4.990	0.647	0.417	6.266	4.905
<b>ELM1</b>	<b>0.721</b>	<b>0.520</b>	<b>5.838</b>	<b>4.580</b>	<b>0.712</b>	<b>0.507</b>	<b>5.766</b>	<b>4.538</b>
ELM2	0.667	0.445	6.283	4.926	0.646	0.417	6.266	4.927
ELM3	0.650	0.423	6.404	5.046	0.634	0.402	6.347	4.984
ELM4	0.667	0.444	6.284	4.938	0.657	0.431	6.191	4.836
ELM5	0.663	0.440	6.312	4.972	0.655	0.429	6.203	4.881
ELM6	0.654	0.427	6.380	5.010	0.643	0.412	6.293	4.926
<b>GRNN1</b>	<b>0.709</b>	<b>0.476</b>	<b>6.101</b>	<b>4.724</b>	<b>0.672</b>	<b>0.430</b>	<b>6.196</b>	<b>4.806</b>
GRNN2	0.646	0.385	6.610	5.194	0.618	0.352	6.607	5.160
GRNN3	0.683	0.446	6.274	4.870	0.655	0.413	6.287	4.891
GRNN4	0.653	0.411	6.468	5.044	0.633	0.389	6.419	4.987
GRNN5	0.648	0.405	6.502	5.087	0.637	0.391	6.407	4.992
GRNN6	0.622	0.377	6.654	5.213	0.613	0.366	6.537	5.080
<b>MARS1</b>	<b>0.729</b>	<b>0.532</b>	<b>5.770</b>	<b>4.520</b>	<b>0.710</b>	<b>0.504</b>	<b>5.783</b>	<b>4.535</b>
MARS2	0.696	0.485	6.053	4.724	0.673	0.452	6.076	4.789
MARS3	0.718	0.515	5.870	4.623	0.673	0.166	7.497	5.889
MARS4	0.697	0.486	6.044	4.760	0.648	-0.482	9.993	8.051
MARS5	0.684	0.469	6.146	4.856	0.664	0.266	7.032	5.573
MARS6	0.667	0.444	6.285	4.945	0.605	-0.290	9.326	7.537
<b>RFR1</b>	<b>0.912</b>	<b>0.814</b>	<b>3.640</b>	<b>2.785</b>	<b>0.748</b>	<b>0.558</b>	<b>5.459</b>	<b>4.291</b>
RFR2	0.895	0.777	3.977	3.020	0.680	0.462	6.022	4.722
RFR3	0.897	0.789	3.877	2.969	0.715	0.510	5.747	4.522
RFR4	0.813	0.645	5.021	3.872	0.679	0.459	6.037	4.754
RFR5	0.811	0.643	5.038	3.884	0.679	0.459	6.036	4.753
RFR6	0.764	0.575	5.495	4.242	0.642	0.411	6.300	4.957
<b>SVR1</b>	<b>0.790</b>	<b>0.622</b>	<b>5.182</b>	<b>3.921</b>	<b>0.737</b>	<b>0.544</b>	<b>5.544</b>	<b>4.382</b>
SVR2	0.729	0.531	5.771	4.424	0.682	0.464	6.011	4.745
SVR3	0.742	0.550	5.657	4.333	0.702	0.492	5.850	4.596
SVR4	0.698	0.487	6.039	4.686	0.672	0.452	6.077	4.770
SVR5	0.703	0.494	5.997	4.673	0.681	0.464	6.011	4.733
SVR6	0.657	0.430	6.364	4.975	0.646	0.417	6.270	4.889

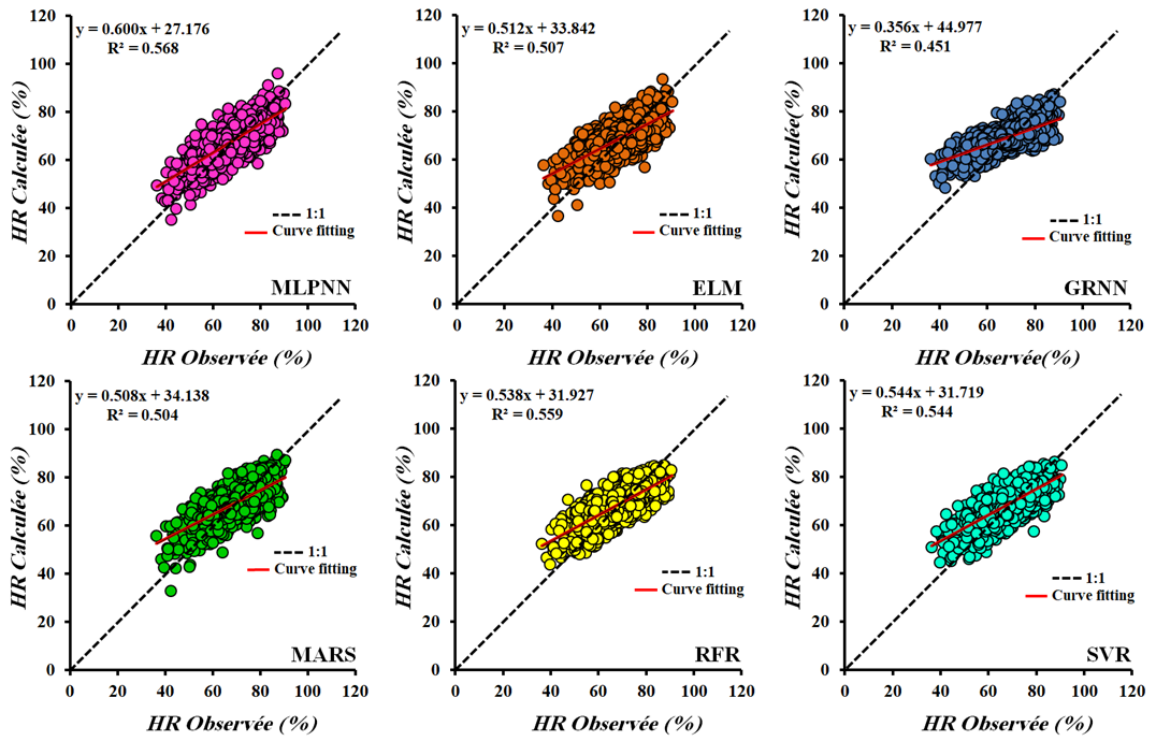


Figure VI.4.Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation:modèles traditionnels, station d'Annaba.

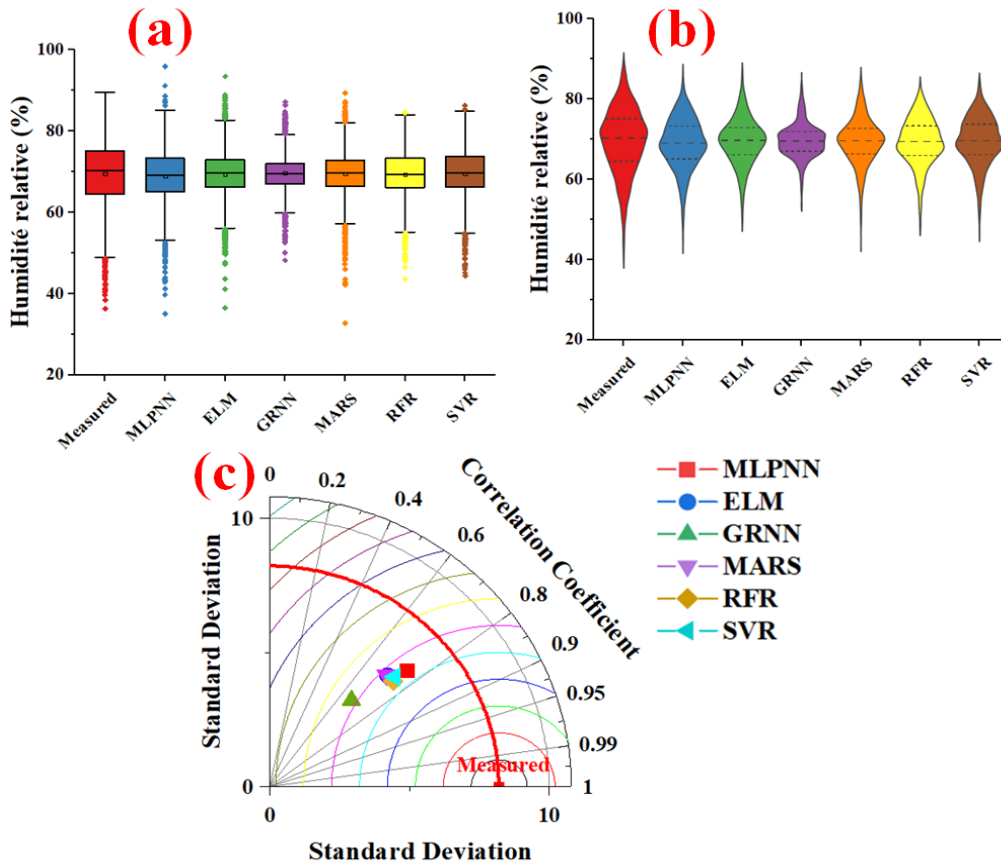


Figure VI.5.Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Annaba.

Au niveau de la station de Constantine (Tableau VI.4, Figure VI.6-7), d'une façon générale, avec tous les modèles, les performances varient entre bonnes à excellentes, le modèle MLPNN donne de meilleure performance pour toutes les combinaisons d'entrées, légèrement supérieure à celles des autres modèles (ELM, GRNN, MARS, RFR, SVR). Premièrement, en utilisant les cinq variables d'entrées, le modèle MLPNN1 donne les meilleures valeurs des R ( $\approx 0.944$ ), NSE ( $\approx 0.890$ ), RMSE ( $\approx 6.952$ ) et MAE ( $\approx 5.234$ ). Les modèles ELM1, GRNN1, MARS1, RFR1 et SVR1 ont donné des performances légèrement inférieures au MLPNN1. En termes de valeurs moyennes, les modèles MLPNN donnent des valeurs moyennes de R ( $\approx 0.928$ ) et NSE ( $\approx 0.860$ ), qui sont les plus élevées, et les valeurs moyennes de RMSE ( $\approx 7.835$ ) et MAE ( $\approx 5.957$ ), qui sont les plus faibles, suivis par les modèles RFR, SVR, ELM, MARS et GRNN, respectivement. En termes de moyenne des RMSE et MAE, la plus grande amélioration parmi tous les modèles est obtenue en utilisant les modèles MLPNN avec 43.345 % et 43.675 % par rapport aux modèles MARS, 12.543 % et 15.490 % par rapport aux modèles GRNN, 4.01 % et 4.711 % par rapport aux modèles ELM, 2.357 % et 1.374 % par rapport aux modèles SVR, et 1.878 % et 2.745 % par rapport aux modèles RFR.

Pour les modèles basés sur quatre variables d'entrées (la deuxième et la troisième combinaison), ils ont donné des performances légèrement inférieures à celle de la première combinaison, et il est clair que l'inclusion des précipitations (P) ou la température minimale ( $T_{\min}$ ) jouent un rôle mineur dans l'amélioration des performances des modèles. De plus, en n'utilisant que trois variables d'entrées, (la quatrième et la cinquième combinaison), il est clair que les performances des modèles se sont dégradées de telle sorte que, entre la première et la cinquième combinaison, on enregistre une chute des performances en terme des RMSE et MAE de (64.793%, 65.211%), (17.777%, 19.956%), (16.961%, 18.295%), (16.159%, 18.725%), (10.702%, 12.184%) et (9.478%, 11.517%) pour les modèles MARS, ELM, MLPNN, RFR, SVR et GRNN, respectivement. Enfin, les performances les plus faibles parmi tous les modèles proposés ont été assurées en utilisant les modèles n'ayant que deux variables d'entrée, pour lesquelles les RMSE et MAE ont été significativement améliorées et les valeurs des R et NSE ont été considérablement dégradées, à l'exception de deux modèles, GRNN6 et MARS6 qui sont plus performants par rapport aux modèles GRNN5 et MARS5, ce dernier (i.e., MARS5) est le modèle qui donne les plus faibles performances ( $R \approx 0.855$ ,  $NSE \approx -0.029$ ,  $RMSE \approx 21.308$ ,  $MAE \approx 16.583$ ) au niveau de la station de Constantine.

Pour les indices graphiques, les figures VI.6 et VI.7 ont montré que tous les modèles ont donné des bons résultats, à l'exception du modèle GRNN qui est moins performant par rapport aux autres.

Tableau VI.4. Résultats obtenus par les modèles traditionnels au niveau de la station de Constantine

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.950</b>	<b>0.903</b>	<b>6.658</b>	<b>5.019</b>	<b>0.944</b>	<b>0.890</b>	<b>6.952</b>	<b>5.234</b>
MLPNN2	0.936	0.877	7.510	5.642	0.931	0.867	7.651	5.752
MLPNN3	0.938	0.880	7.415	5.627	0.934	0.871	7.547	5.738
MLPNN4	0.936	0.876	7.550	5.769	0.930	0.864	7.735	5.863
MLPNN5	0.922	0.850	8.291	6.358	0.917	0.841	8.372	6.406
MLPNN6	0.914	0.836	8.677	6.692	0.909	0.826	8.754	6.748
<b>ELM1</b>	<b>0.946</b>	<b>0.894</b>	<b>6.962</b>	<b>5.284</b>	<b>0.939</b>	<b>0.882</b>	<b>7.211</b>	<b>5.459</b>
ELM2	0.929	0.864	7.895	6.005	0.922	0.850	8.125	6.120
ELM3	0.931	0.866	7.834	6.063	0.923	0.852	8.068	6.185
ELM4	0.931	0.867	7.796	5.992	0.925	0.855	7.992	6.111
ELM5	0.913	0.834	8.721	6.764	0.909	0.826	8.770	6.820
ELM6	0.914	0.836	8.670	6.727	0.908	0.824	8.809	6.813
GRNN1	0.926	0.854	8.171	6.335	0.914	0.833	8.586	6.661
GRNN2	0.914	0.830	8.816	6.902	0.905	0.814	9.053	7.042
GRNN3	0.926	0.851	8.255	6.496	0.915	0.831	8.625	6.759
<b>GRNN4</b>	<b>0.925</b>	<b>0.847</b>	<b>8.365</b>	<b>6.642</b>	<b>0.917</b>	<b>0.833</b>	<b>8.575</b>	<b>6.768</b>
GRNN5	0.903	0.809	9.341	7.417	0.896	0.796	9.485	7.528
GRNN6	0.904	0.807	9.393	7.531	0.899	0.798	9.429	7.534
<b>MARS1</b>	<b>0.940</b>	<b>0.884</b>	<b>7.275</b>	<b>5.617</b>	<b>0.935</b>	<b>0.872</b>	<b>7.502</b>	<b>5.769</b>
MARS2	0.932	0.868	7.775	5.893	0.926	0.857	7.944	5.989
MARS3	0.936	0.877	7.507	5.821	0.932	0.867	7.651	5.897
MARS4	0.937	0.879	7.451	5.726	0.886	0.370	16.674	12.921
MARS5	0.916	0.840	8.564	6.628	0.855	-0.029	21.308	16.583
MARS6	0.917	0.840	8.551	6.609	0.873	-0.087	21.899	16.296
<b>RFR1</b>	<b>0.977</b>	<b>0.953</b>	<b>4.640</b>	<b>3.474</b>	<b>0.941</b>	<b>0.885</b>	<b>7.129</b>	<b>5.382</b>
RFR2	0.972	0.943	5.120	3.780	0.926	0.858	7.924	5.943
RFR3	0.975	0.949	4.835	3.608	0.936	0.876	7.402	5.582
RFR4	0.959	0.916	6.220	4.750	0.926	0.855	7.992	6.203
RFR5	0.950	0.900	6.781	5.188	0.915	0.836	8.503	6.622
RFR6	0.938	0.878	7.488	5.731	0.905	0.818	8.961	7.021
<b>SVR1</b>	<b>0.953</b>	<b>0.908</b>	<b>6.491</b>	<b>4.912</b>	<b>0.934</b>	<b>0.872</b>	<b>7.501</b>	<b>5.586</b>
SVR2	0.941	0.885	7.267	5.427	0.926	0.857	7.950	5.881
SVR3	0.944	0.891	7.065	5.356	0.931	0.866	7.689	5.777
SVR4	0.937	0.878	7.460	5.675	0.926	0.858	7.919	5.996
SVR5	0.922	0.849	8.320	6.312	0.917	0.840	8.400	6.361
SVR6	0.915	0.837	8.632	6.588	0.911	0.829	8.687	6.638

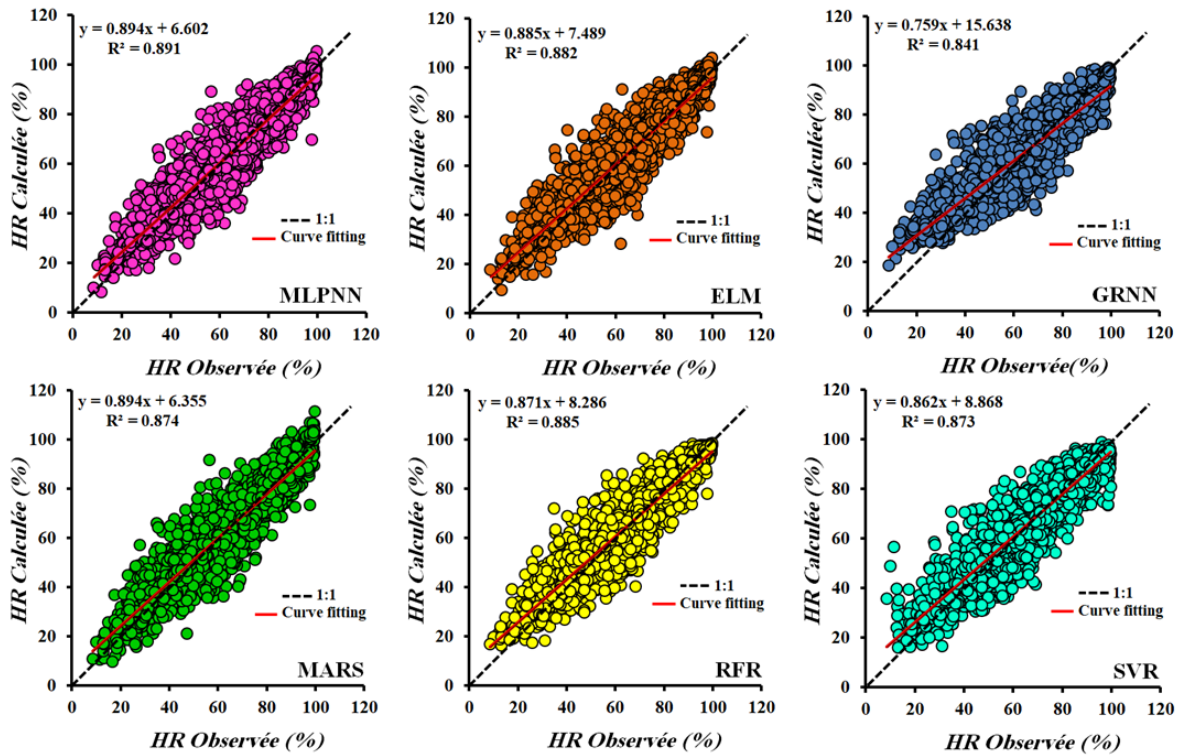


Figure VI.6. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation:modèles traditionnels, station de Constantine.

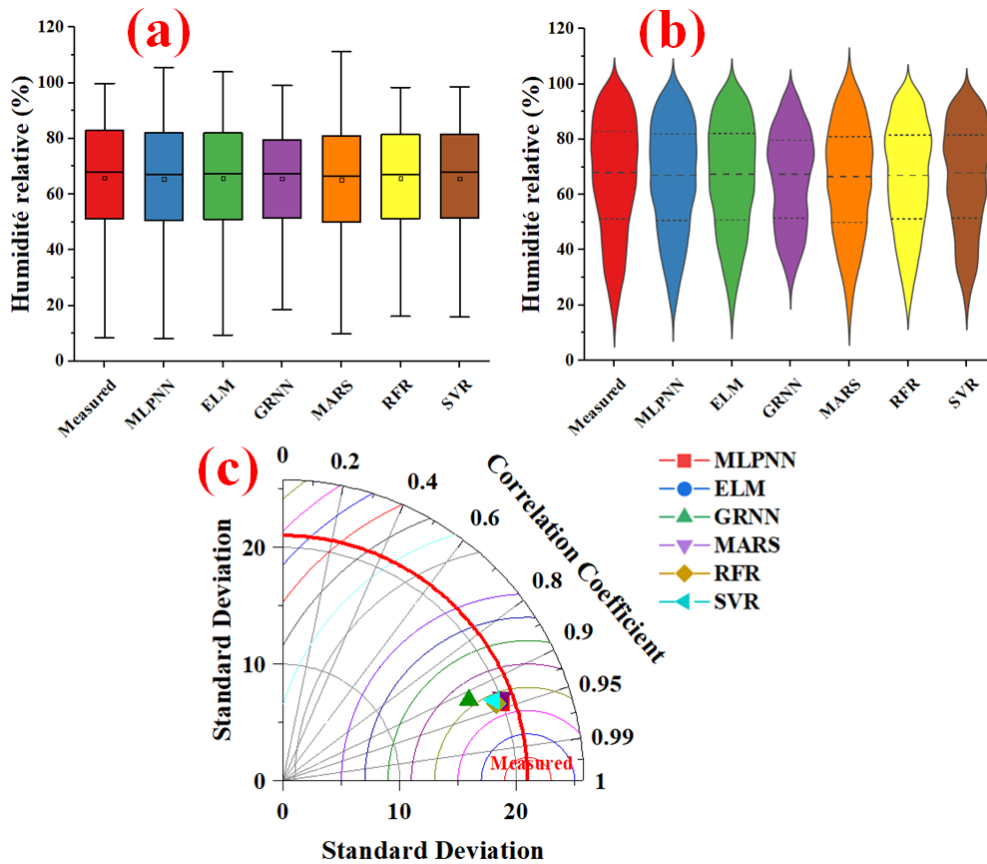


Figure VI.7. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Constantine.

Au niveau de la station de Sétif (Tableau VI.5, Figure VI.8-9), les performances des modèles étaient meilleures par rapport à celles obtenues au niveau des stations d'Alger et Annaba et similaire à celle de la station de Constantine.

Les modèles RFR ont donné des valeurs de R et NSE de  $\approx 0.914$  à  $\approx 0.941$  (moyenne  $\approx 0.927$ ), et  $\approx 0.835$  à  $\approx 0.885$  (moyenne  $\approx 0.861$ ), les modèles SVR ont donné des valeurs de R et NSE allant de  $\approx 0.913$  à  $\approx 0.942$  (moyenne  $\approx 0.927$ ) et de  $\approx 0.833$  à  $\approx 0.887$  (moyenne  $\approx 0.86$ ), les modèles ELM ont donné des valeurs R et NSE allant de  $\approx 0.911$  à  $\approx 0.93$  (moyenne  $\approx 0.921$ ) et de  $\approx 0.83$  à  $\approx 0.865$  (moyenne  $\approx 0.848$ ), les modèles MLPNN ont donné des valeurs R et NSE allant de  $\approx 0,874$  à  $\approx 0,945$  (moyenne  $\approx 0,917$ ) et de  $\approx 0,764$  à  $\approx 0,893$  (moyenne  $\approx 0.841$ ), les modèles MARS ont donné des valeurs R et NSE allant de  $\approx 0.885$  à  $\approx 0.938$  (moyenne  $\approx 0.91$ ) et de  $\approx 0.694$  à  $\approx 0.88$  (moyenne  $\approx 0.741$ ), tandis que les valeurs obtenues à l'aide des modèles GRNN allaient de  $\approx 0.90$  à  $\approx 0.916$  (moyenne  $\approx 0.908$ ) et  $\approx 0.805$  à  $\approx 0.833$  (moyenne  $\approx 0.819$ ).

Le modèle MLPNN1 est le plus performant au niveau de la station de Sétif avec des indices de l'ordre de (R $\approx 0.945$ , NSE $\approx 0.893$ , RMSE $\approx 7.424$ , MAE $\approx 5.592$ ), suivie par le SVR1 (R $\approx 0.942$ , NSE $\approx 0.887$ , RMSE $\approx 7.623$ , MAE $\approx 5.764$ ), le RFR1 (R $\approx 0.941$ , NSE $\approx 0.885$ , RMSE $\approx 7.691$ , MAE $\approx 5.798$ ), et par le modèle MARS1 (R $\approx 0.938$ , NSE $\approx 0.880$ , RMSE $\approx 7.870$ , MAE $\approx 6.011$ ). Le meilleur modèle ELM est ELM1 (R $\approx 0.930$ , NSE $\approx 0.865$ , RMSE $\approx 8.359$ , MAE $\approx 6.55$ ) qui est en dixième position, alors que pour les modèles GRNN, le modèle GRNN4 était le meilleur (R $\approx 0.916$ , NSE $\approx 0.833$ , RMSE $\approx 9.278$ , MAE $\approx 7.309$ ), mais il est moins performant que le meilleur modèle MLPNN1 avec des taux de l'ordre de 19.983%, et 23.492%, en termes des RMSE et MAE, respectivement.

Les résultats graphiques ont confirmé les résultats numériques, les Scatterplots (Figure VI.8) présentent des faibles dispersions des données pour tous les modèles, le boxplot (Figure VI.9a), le violin plot (Figure VI.9b) et le diagramme de Taylor (Figure VI.9c), montrent que le modèle GRNN était le moins performant.

Tableau VI.5. Résultats obtenus par les modèles traditionnels au niveau de la station de Sétif

Modelés	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.947</b>	<b>0.896</b>	<b>7.248</b>	<b>5.401</b>	<b>0.945</b>	<b>0.893</b>	<b>7.424</b>	<b>5.592</b>
MLPNN2	0.939	0.881	7.737	5.738	0.933	0.870	8.184	6.087
MLPNN3	0.920	0.847	8.780	6.597	0.917	0.841	9.045	6.885
MLPNN4	0.918	0.844	8.884	6.592	0.915	0.837	9.163	6.922
MLPNN5	0.920	0.845	8.834	6.635	0.917	0.839	9.118	6.912
MLPNN6	0.886	0.785	10.413	7.932	0.874	0.764	11.046	8.316
<b>ELM1</b>	<b>0.933</b>	<b>0.870</b>	<b>8.087</b>	<b>6.236</b>	<b>0.930</b>	<b>0.865</b>	<b>8.359</b>	<b>6.550</b>
ELM2	0.932	0.868	8.150	6.171	0.926	0.858	8.565	6.478
ELM3	0.925	0.855	8.563	6.612	0.919	0.845	8.931	6.818
ELM4	0.928	0.861	8.382	6.369	0.922	0.851	8.782	6.613
ELM5	0.918	0.843	8.905	6.706	0.915	0.837	9.176	6.962
ELM6	0.916	0.839	9.024	6.855	0.911	0.830	9.375	7.148
GRNN1	0.924	0.852	8.652	6.564	0.912	0.831	9.347	7.125
GRNN2	0.914	0.832	9.216	7.080	0.900	0.808	9.960	7.618
GRNN3	0.924	0.848	8.762	6.755	0.914	0.831	9.333	7.240
<b>GRNN4</b>	<b>0.923</b>	<b>0.843</b>	<b>8.892</b>	<b>6.968</b>	<b>0.916</b>	<b>0.833</b>	<b>9.278</b>	<b>7.309</b>
GRNN5	0.906	0.816	9.648	7.498	0.900	0.805	10.042	7.878
GRNN6	0.907	0.815	9.675	7.620	0.903	0.807	9.969	7.904
<b>MARS1</b>	<b>0.940</b>	<b>0.883</b>	<b>7.678</b>	<b>5.799</b>	<b>0.938</b>	<b>0.880</b>	<b>7.870</b>	<b>6.011</b>
MARS2	0.934	0.872	8.050	6.028	0.929	0.862	8.433	6.331
MARS3	0.934	0.872	8.033	6.125	0.902	0.678	12.888	9.560
MARS4	0.932	0.869	8.119	6.157	0.904	0.634	13.747	10.526
MARS5	0.919	0.844	8.878	6.719	0.902	0.699	12.466	9.602
MARS6	0.919	0.844	8.882	6.747	0.885	0.694	12.558	9.252
<b>RFR1</b>	<b>0.976</b>	<b>0.951</b>	<b>4.969</b>	<b>3.659</b>	<b>0.941</b>	<b>0.885</b>	<b>7.691</b>	<b>5.798</b>
RFR2	0.973	0.945	5.255	3.825	0.930	0.865	8.351	6.231
RFR3	0.973	0.946	5.237	3.853	0.935	0.874	8.050	6.040
RFR4	0.959	0.918	6.441	4.823	0.929	0.863	8.420	6.446
RFR5	0.953	0.906	6.879	5.135	0.920	0.846	8.914	6.820
RFR6	0.943	0.889	7.495	5.567	0.914	0.835	9.226	7.158
<b>SVR1</b>	<b>0.952</b>	<b>0.905</b>	<b>6.924</b>	<b>5.211</b>	<b>0.942</b>	<b>0.887</b>	<b>7.623</b>	<b>5.764</b>
SVR2	0.943	0.889	7.498	5.578	0.933	0.870	8.182	6.089
SVR3	0.939	0.881	7.738	5.768	0.930	0.866	8.326	6.204
SVR4	0.933	0.870	8.099	6.086	0.927	0.859	8.526	6.407
SVR5	0.920	0.846	8.827	6.561	0.918	0.842	9.022	6.753
SVR6	0.916	0.837	9.060	6.783	0.913	0.833	9.276	6.989

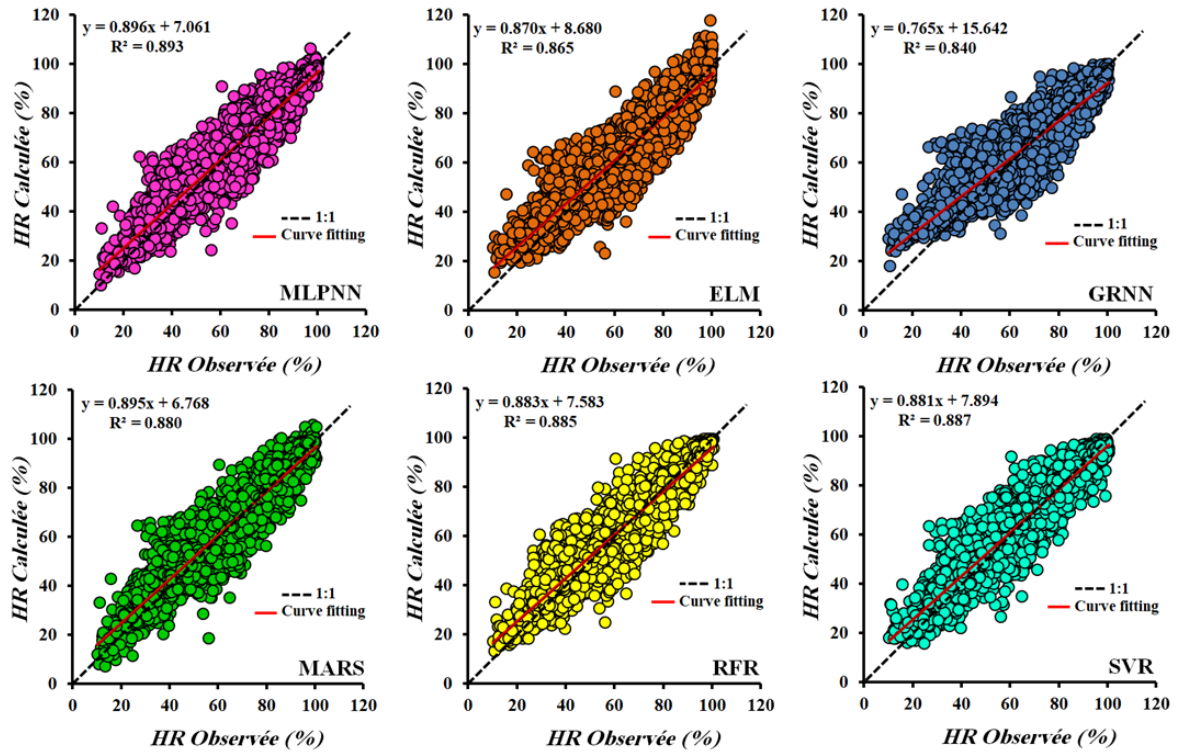


Figure VI.8. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation:modèles traditionnels, station de Sétif.

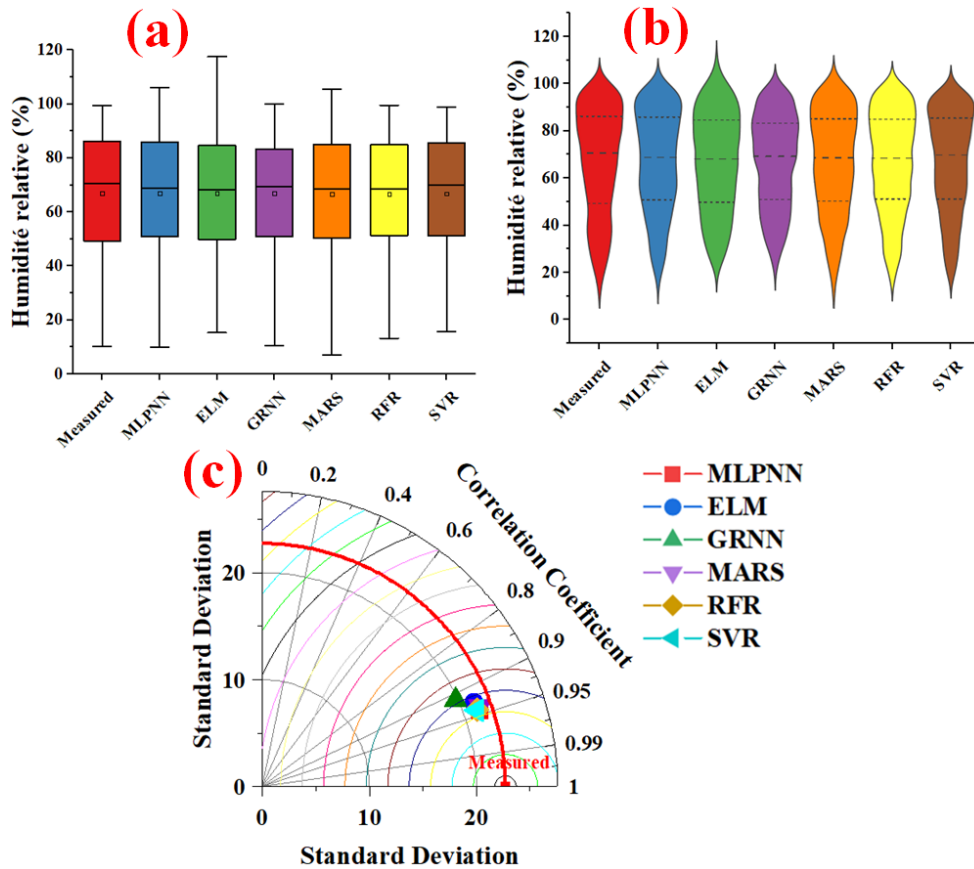


Figure VI.9. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Sétif.

### VI.3. Modélisation de l'HR par les modèles hybrides

Dans la deuxième partie de travail, nous avons essayé d'améliorer les performances prédictives de l'HR en appliquant la décomposition du signal, et au total trois algorithmes ont été comparés, à savoir l'EMD, l'EWT et le VMD. Les résultats obtenus sont représentés dans les tableaux VI.6-9 et les figures VI.10-17. Nous consacrons notre discussion aux meilleurs modèles pour chaque station, les résultats détaillés de la modélisation sont présentés en ANNEX A. Une discussion plus approfondie des différences entre les modèles avec et sans décomposition du signal est présentée ci-après.

Pour la station d'Alger (Tableau VI.6, Figures VI.10-11), les performances des modèles sont faibles à moyennes, la plupart des algorithmes de décompositions donnent des faibles performances par rapport aux modèles simples, uniquement six modèles ont donné des résultats légèrement supérieurs à celle des modèles traditionnels (MLPNN\_EMD3, MLPNN\_EWT1, MLPNN\_VMD1, ELM\_EWT2, GRNN\_EWT6 et RFR\_EWT1). Pour les modèles MLPNN, les trois algorithmes de décompositions assurent des améliorations des performances, et le modèle MLPNN\_EWT1 qui utilise toutes les variables climatiques ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$  et RS) donne les meilleurs résultats au niveau de la station d'Alger, avec des taux de 1.80%, 3.544%, 5.473% et 6.115% en terme de R, NSE, RMSE et MAE, respectivement, par rapport au meilleur modèle simple (MLPNN1).

Pour les modèles ELM, RFR et GRNN, les performances s'améliorent lorsque en utilise l'algorithme de décomposition EWT, et les valeurs de R et NSE se passent des valeurs 0.867 et 0.752 du ELM2 aux valeurs 0.869 et 0.753 du ELM\_EWT2, et passent des valeurs 0.844 et 0.701 du GRNN3 aux valeurs 0.85 et 0.717 du GRNN\_EWT6, et passent des valeurs 0.885 et 0.782 du RFR1 aux valeurs 0.895 et 0.795 du RFR\_EWT1, par contre avec l'utilisation des algorithmes EMD et VMD, les performances se sont dégradés.

Pour les modèles MARS et SVR, aucune algorithmes de décomposition n'a permis d'obtenir des performances meilleures que les modèles simples, avec le modèle SVR\_VMD6 qui utilise deux variables climatiques ( $T_{\max}$  et P), on obtient de très faibles performances au niveau de la station d'Alger ( $R \approx 0.334$ ,  $NSE \approx 0.065$ ,  $RMSE \approx 14.483$ ,  $MAE \approx 11.658$ ), avec des réductions des taux en termes de RMSE et MAE de l'ordre de 55.755%, 56.536%, respectivement, par rapport au meilleur modèle.

La comparaison sur la base des résultats graphiques ont montré la supériorité des modèles MLPNN combiné avec les EWT. Les Scatterplots (Figure VI.10) ont présenté des données plus dispersées en utilisant le modèle SVR (faible corrélation). Les boxplots (Figure VI.11a) et les violin plots (Figure VI.11b) montrent moins de similarité entre les données prédites par les trois modèles SVR hybrides et celles mesurées. Le digramme de Taylor (Figure VI.11c) a confirmé les faibles performances des modèles SVR, et il est clair que le modèle GRNN\_VMD a également donné de faibles résultats.

Tableau VI.6. Résultats obtenus par les meilleures modèles hybrides au niveau de la station d'Alger

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD3	0.927	0.858	5.602	4.417	0.892	0.794	6.704	5.328
MLPNN_EWT1	0.927	0.857	5.583	4.411	0.905	0.818	6.408	5.067
MLPNN_VMD1	0.931	0.865	5.440	4.308	0.894	0.800	6.706	5.257
ELM_EMD4	0.905	0.819	6.334	5.032	0.863	0.741	7.523	5.988
ELM_EWT2	0.904	0.817	6.328	4.991	0.869	0.753	7.466	5.932
ELM_VMD1	0.891	0.793	6.732	5.375	0.844	0.709	8.081	6.497
GRNN_EMD6	0.993	0.985	1.797	1.009	0.826	0.676	8.413	6.538
GRNN_EWT6	0.988	0.976	2.299	1.437	0.850	0.717	7.991	6.217
GRNN_VMD6	1.000	1.000	0.067	0.008	0.694	0.427	11.340	8.935
MARS_EMD1	0.820	0.673	8.517	6.831	0.817	0.668	8.520	6.881
MARS_EWT1	0.857	0.735	7.607	6.041	0.862	0.743	7.623	6.062
MARS_VMD1	0.854	0.729	7.704	6.141	0.847	0.718	7.956	6.373
RFR_EMD1	0.973	0.927	4.009	3.136	0.861	0.720	7.818	6.300
RFR_EWT1	0.974	0.939	3.659	2.848	0.895	0.795	6.809	5.438
RFR_VMD1	0.972	0.923	4.109	3.197	0.839	0.687	8.384	6.733
SVR_EMD6	0.974	0.903	4.647	3.490	0.709	0.440	11.067	8.448
SVR_EWT6	0.971	0.903	4.616	3.472	0.753	0.507	10.548	8.071
SVR_VMD6	0.970	0.848	5.776	4.079	0.334	0.065	14.483	11.658

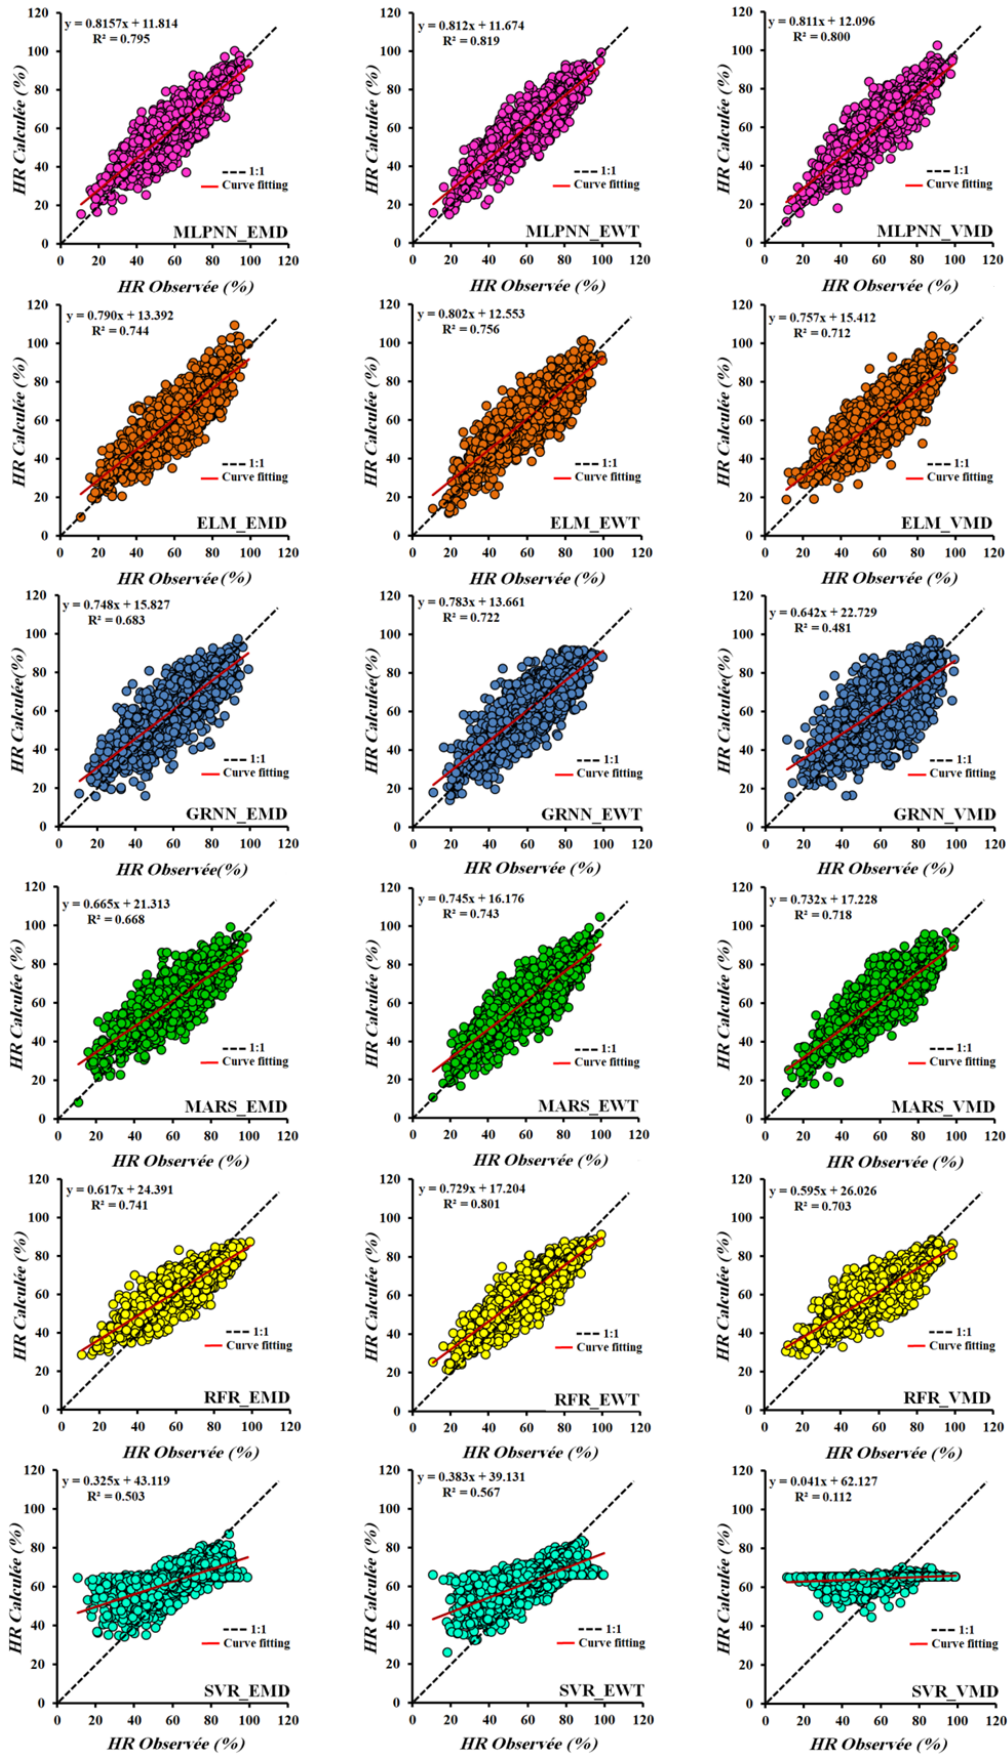


Figure VI.10. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station d'Alger.

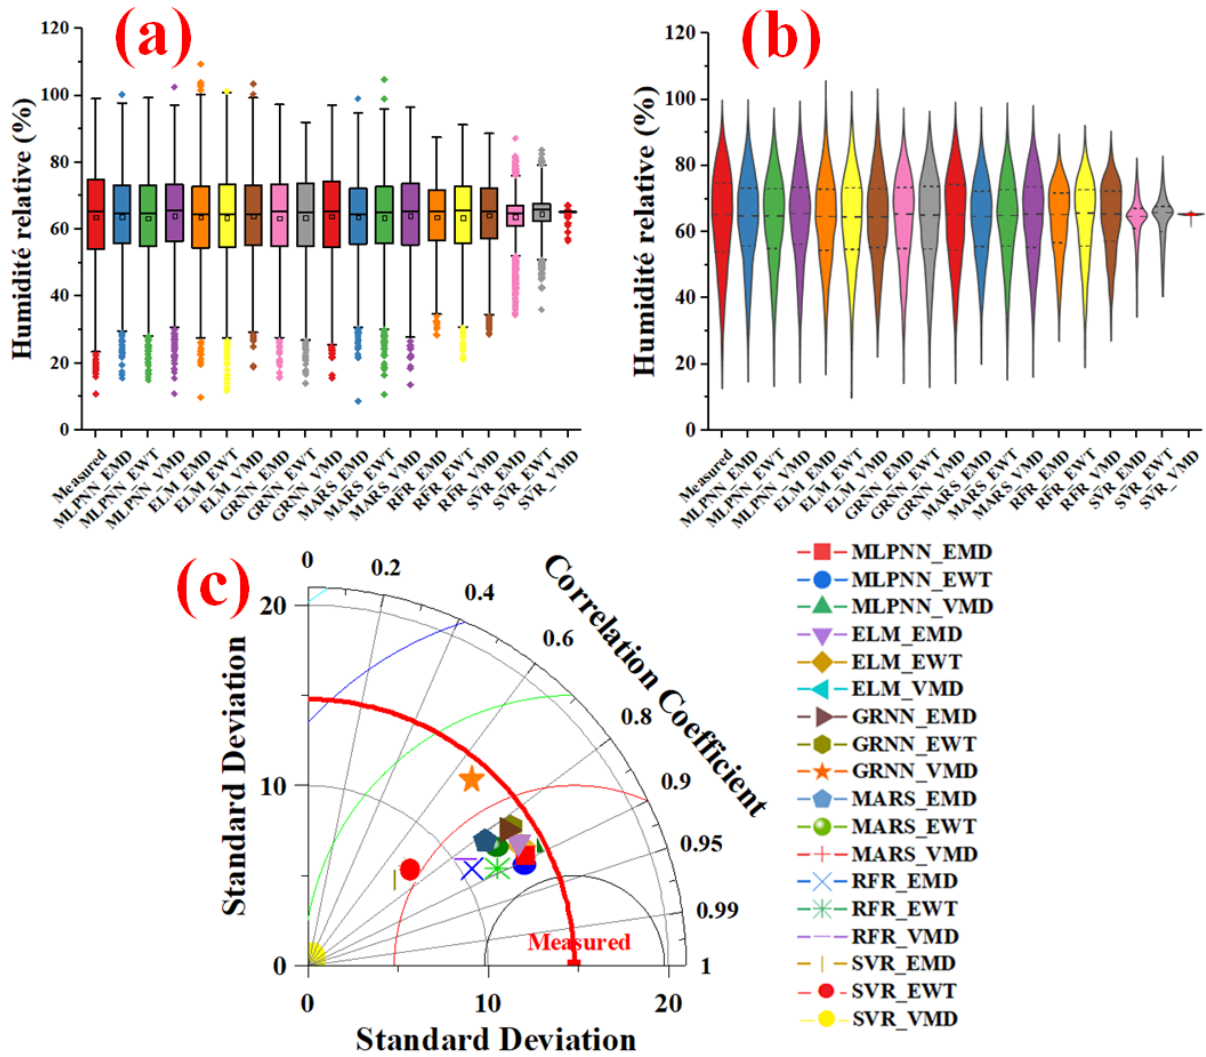


Figure VI.11. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Alger.

Pour la station d'Annaba (Tableau VI.7, Figures VI.12-13), d'une façon générale, les performances de tous les modèles étaient faibles, malgré que la moitié des modèles (neuf) assurent des améliorations de performances par rapport aux modèles simples, les résultats obtenus restent insatisfaisantes. La remarque la plus importante est l'effet prédominant de l'algorithme de décomposition EWT. Les meilleurs résultats pour la station d'Annaba sont obtenus avec les modèles hybrides basés sur cet algorithme. Par contre l'algorithme VMD assure les plus faibles performances au niveau de la station, à l'exception du modèle MARS\_VMD1, qui est meilleure que le modèle MARS\_EMD1.

Comme la station précédente, les modèles MLPNN hybrides assurent des améliorations importantes avec tous les algorithmes de décomposition du signal (MLPNN\_EMD1, MLPNN\_EWT1 et MLPNN\_VMD1). On remarque aussi que ces trois

modèles utilisent la première combinaison d'entrée ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$  et RS) et l'exclusion de chacune des variables, conduit à une réduction des performances. Avec le modèle MLPNN\_EWT1 on obtient les meilleures performances avec des indices de ( $R \approx 0.816$ ,  $NSE \approx 0.665$ ,  $RMSE \approx 4.923$ ,  $MAE \approx 3.90$ ), et des taux d'amélioration de 9.57% et 9.659% en termes de RMSE et MAE, respectivement, par rapport au meilleur modèle simple (MLPNN1) sans décomposition.

Les faibles performances sont obtenues avec les modèles SVR, et le modèle SVR\_VMD6 assure les faibles résultats avec des indices de ( $R \approx 0.212$ ,  $NSE \approx 0.023$ ,  $RMSE \approx 8.401$ ,  $MAE \approx 6.525$ ) par rapport au modèle SVR1 ( $R \approx 0.737$ ,  $NSE \approx 0.544$ ,  $RMSE \approx 5.544$ ,  $MAE \approx 4.382$ ). De plus, les trois meilleurs modèles SVR (SVR\_EMD6, SVR\_EWT6, SVR\_VMD6) utilisent la sixième combinaison avec deux variables d'entrées, et l'inclusion des autres variables résulte des réductions des performances, La représentation graphique (Figure VI.12 et VI.13) montrant les faibles performances pour tous les modèles, et confirmant les résultats numériques trouvés par les indices statistiques.

Tableau VI.7. Résultats obtenus par les meilleures modèles hybrides au niveau de la station d'Annaba

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.878	0.769	4.051	3.197	0.799	0.636	4.951	3.933
MLPNN_EWT1	0.863	0.741	4.229	3.338	0.816	0.665	4.923	3.900
MLPNN_VMD1	0.835	0.688	4.640	3.667	0.784	0.611	5.298	4.209
ELM_EMD1	0.815	0.664	4.884	3.836	0.712	0.495	5.831	4.608
ELM_EWT5	0.798	0.637	5.005	3.975	0.726	0.518	5.904	4.691
ELM_VMD1	0.781	0.610	5.188	4.121	0.706	0.485	6.099	4.864
GRNN_EMD6	0.991	0.981	1.158	0.624	0.681	0.425	6.223	4.784
GRNN_EWT6	0.977	0.953	1.792	1.173	0.724	0.505	5.986	4.589
GRNN_VMD5	1.000	1.000	0.000	0.000	0.464	0.073	8.182	6.411
MARS_EMD1	0.677	0.459	6.202	4.909	0.655	0.429	6.205	4.919
MARS_EWT1	0.742	0.551	5.561	4.406	0.745	0.554	5.678	4.468
MARS_VMD1	0.686	0.470	6.047	4.820	0.681	0.463	6.225	4.979
RFR_EMD1	0.959	0.880	2.915	2.214	0.749	0.542	5.557	4.354
RFR_EWT1	0.960	0.897	2.664	2.026	0.805	0.637	5.129	4.015
RFR_VMD1	0.965	0.872	2.978	2.299	0.726	0.492	6.055	4.770
SVR_EMD6	0.955	0.834	3.434	2.351	0.565	0.270	7.014	5.377
SVR_EWT6	0.949	0.840	3.325	2.348	0.622	0.354	6.836	5.155
SVR_VMD6	0.956	0.793	3.784	2.521	0.212	0.023	8.401	6.525

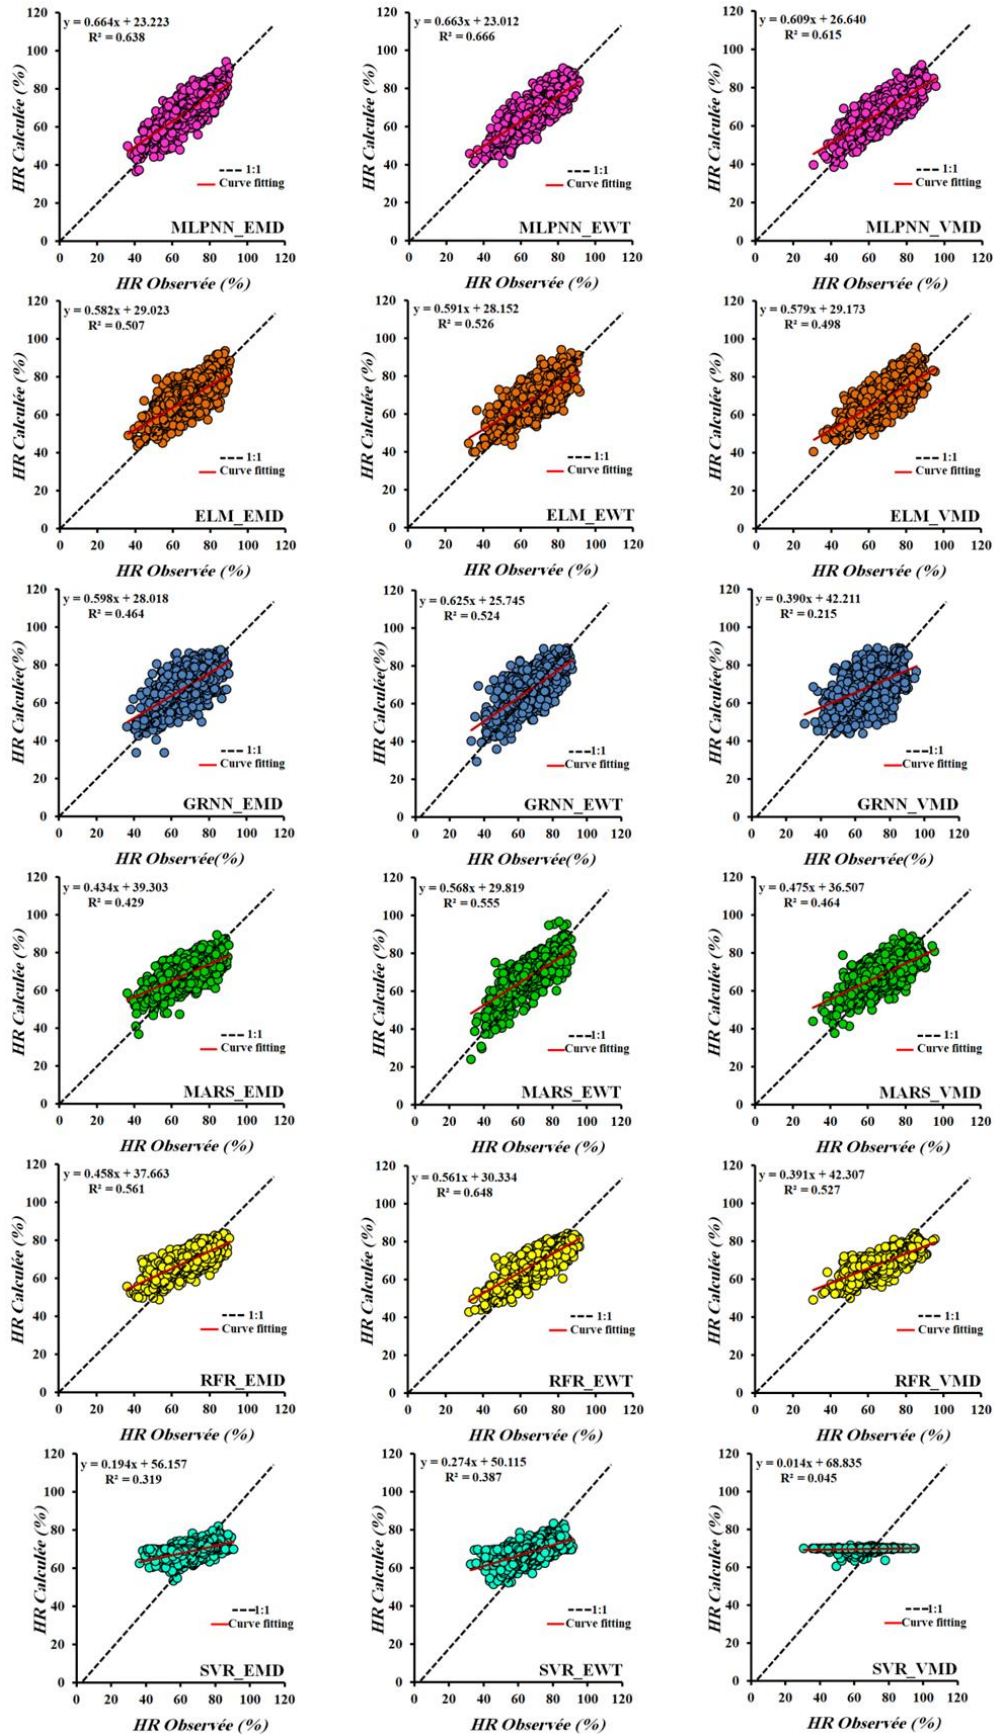


Figure VI.12. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station d'Annaba.

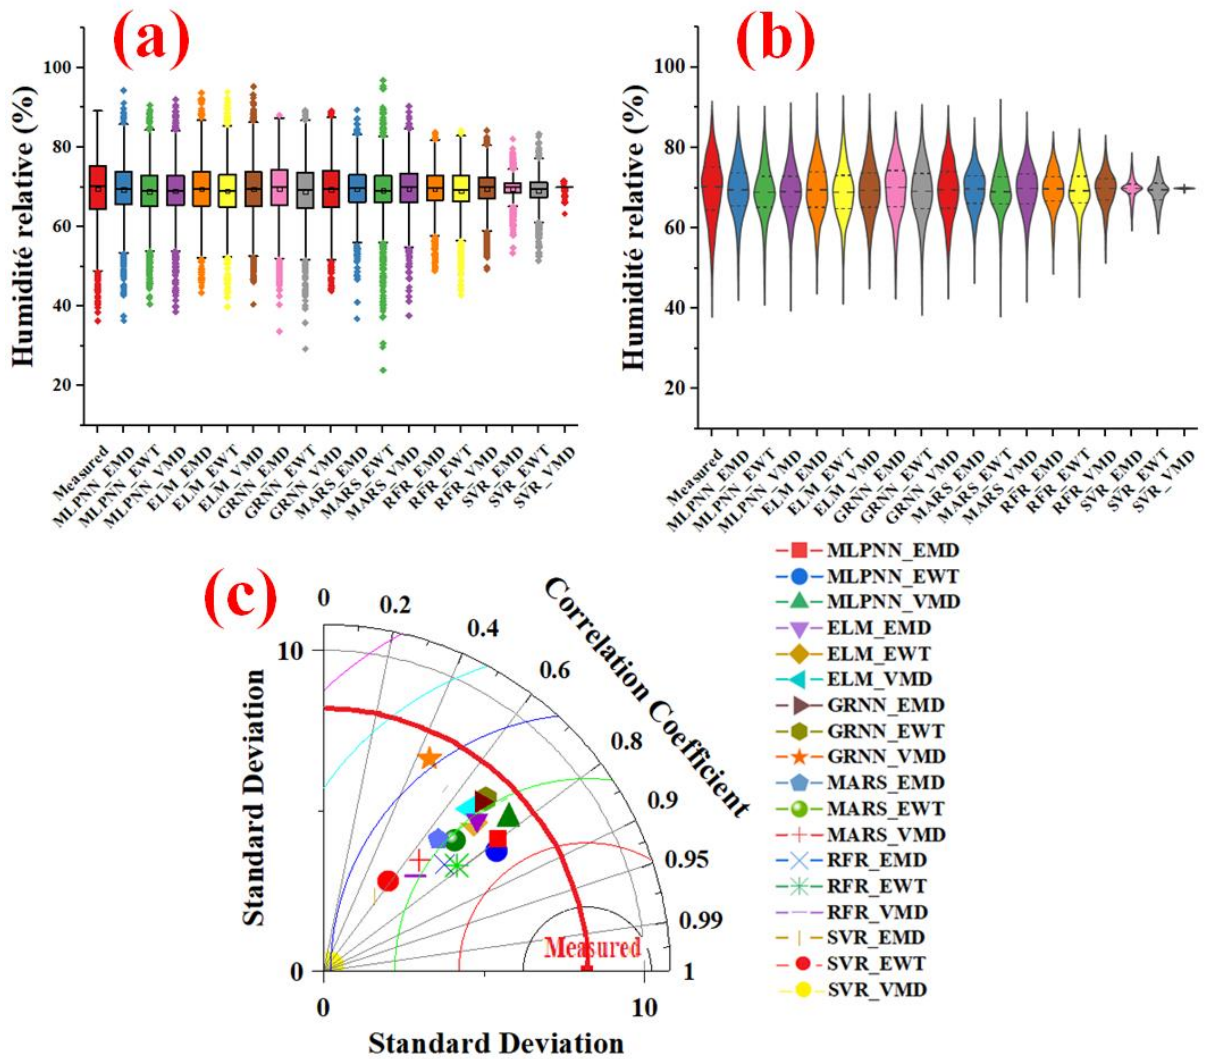


Figure VI.13. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Annaba.

Au niveau de la station de Constantine (Tableau VI.8, Figures VI.14-15), une analyse générale des résultats obtenus à l'aide des algorithmes de décomposition du signal a révélé que sa contribution à l'amélioration des performances des modèles est trop faible, au contraire, les performances numériques se sont légèrement dégradées pour la majorité des cas. La remarque la plus importante est la robustesse et l'efficacité de l'algorithme EWT par rapport aux autres (EMD et VMD). Il est clair que les modèles basés sur l'EWT assurent les meilleurs résultats de prédiction (MLPNN\_EWT2, ELM\_EWT4, GRNN\_EWT6, MARS\_EWT1, RFR\_EWT4 et SVR\_EWT6).

D'autres part, concernant les modèles MLPNN, il est clair que ces derniers sont les seuls modèles assurent des améliorations significatives lors de l'utilisation des algorithmes de décomposition du signal, et l'algorithme EWT à assurer les meilleurs performances au niveau

de la station de Constantine avec le MLPNN\_EWT2 ( $R \approx 0.950$ ,  $NSE \approx 0.902$ ,  $RMSE \approx 6.778$ ,  $MAE \approx 5.203$ ), et l'amélioration par rapport au meilleur modèle MLPNN simple (MLPNN1) atteint les taux de 0.636%, 1.348%, 2.503% et 0.592%, en termes de R, NSE, RMSE et MAE, respectivement. Ce modèle (MLPNN\_EWT2) utilise la deuxième combinaison des variables d'entrées, ce qui explique l'effet mineur des précipitations.

Avec les algorithmes EMD et VMD, le modèle MLPNN\_EMD1 assure les meilleurs résultats de prédiction, avec des indices ( $R \approx 0.949$ ,  $NSE \approx 0.901$ ,  $RMSE \approx 6.615$ ,  $MAE \approx 5.117$ ), suivie par le modèle MLPNN\_VMD1 ( $R \approx 0.947$ ,  $NSE \approx 0.896$ ,  $RMSE \approx 6.882$ ,  $MAE \approx 5.334$ ).

Pour la modélisation avec les ELM, le modèle ELM\_EWT4 assure les meilleurs résultats avec des déférences négligeables par rapport au meilleur modèle ELM simple (ELM1), le modèle ELM\_EWT4 utilise trois variables climatiques d'entrée ( $T_{max}$ , P et  $U_2$ ), ce qui explique l'effet négligeable de la RS.

Pour les algorithmes EMD et VMD, les performances se sont dégradées, avec le modèle ELM\_EMD4 les performances se dégradent par rapport au modèle ELM1 avec des taux de l'ordre de 5.491% et 9.754% en termes des RMSE et MAE, respectivement, et avec le modèle ELM\_VMD1, les performances se dégradent encore, et les R et NSE se dégradent aux valeurs:  $R \approx 0.918$ ,  $NSE \approx 0.843$ .

Pour les modèles GRNN, MARS, RFR et SVR, aucune amélioration n'a été obtenue et les performances de tous les modèles se sont dégradées, ce qui explique la faible contribution des algorithmes de décomposition du signal à l'amélioration de la prédiction de l'HR.

Les modèles SVR étaient les modèles assurent les plus faibles performances. Avec le modèle SVR\_VMD6, on obtient de très faibles résultats au niveau de la station de Constantine avec des indices de l'ordre de ( $R \approx 0.391$ ,  $NSE \approx 0.119$ ,  $RMSE \approx 20.034$ ,  $MAE \approx 16.568$ ).

Les résultats obtenus ont été comparés sur la base des représentations graphiques. Dans la [figure VII.14](#), les Scatterplots nous permettent de conclure que les données étaient moins dispersées en utilisant l'algorithme de décomposition EWT, surtout lorsque en appliquant le modèle MLPNN. Les données les plus dispersées sont obtenues par les modèles SVR hybrides (très faibles corrélation).

Selon le boxplot ([Figure VII.15a](#)) et le violin plot ([Figure VII.15b](#)), les modèles basés sur l'algorithme EWT étaient les plus performants et les modèles MLPNN montrant la similitude des données prédites la plus élevée avec celles mesurées. Cependant, selon le diagramme de Taylor ([Figure VII.15c](#)), les modèles SVR hybrides et le GRNN\_VMD étaient les plus faibles parmi tous les modèles proposés.

Tableau VI.8. Résultats obtenus par les meilleures modèles hybrides au niveau de la station de Constantine

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.969	0.940	5.261	4.046	0.949	0.901	6.615	5.117
MLPNN_EWT2	0.958	0.916	6.121	4.702	0.950	0.902	6.778	5.203
MLPNN_VMD1	0.965	0.931	5.575	4.298	0.947	0.896	6.882	5.334
ELM_EMD4	0.952	0.906	6.552	5.157	0.932	0.868	7.630	6.049
ELM_EWT4	0.954	0.910	6.328	4.972	0.940	0.881	7.441	5.813
ELM_VMD1	0.943	0.888	7.099	5.586	0.918	0.843	8.468	6.643
GRNN_EMD6	0.997	0.994	1.717	0.916	0.888	0.783	9.785	7.395
GRNN_EWT6	0.994	0.987	2.382	1.458	0.907	0.814	9.312	7.011
GRNN_VMD6	1.000	1.000	0.078	0.010	0.780	0.569	14.010	10.751
MARS_EMD2	0.913	0.833	8.739	6.926	0.911	0.829	8.677	6.867
MARS_EWT1	0.925	0.856	8.009	6.277	0.928	0.862	8.039	6.209
MARS_VMD1	0.926	0.857	8.028	6.300	0.924	0.854	8.152	6.402
RFR_EMD1	0.983	0.958	4.406	3.415	0.921	0.834	8.562	6.719
RFR_EWT4	0.983	0.961	4.173	3.225	0.941	0.883	7.397	5.788
RFR_VMD1	0.982	0.954	4.543	3.545	0.903	0.804	9.442	7.623
SVR_EMD6	0.990	0.953	4.617	4.107	0.783	0.527	14.447	11.505
SVR_EWT6	0.988	0.950	4.722	4.096	0.829	0.616	13.393	10.588
SVR_VMD6	0.985	0.915	6.193	5.011	0.391	0.119	20.034	16.568

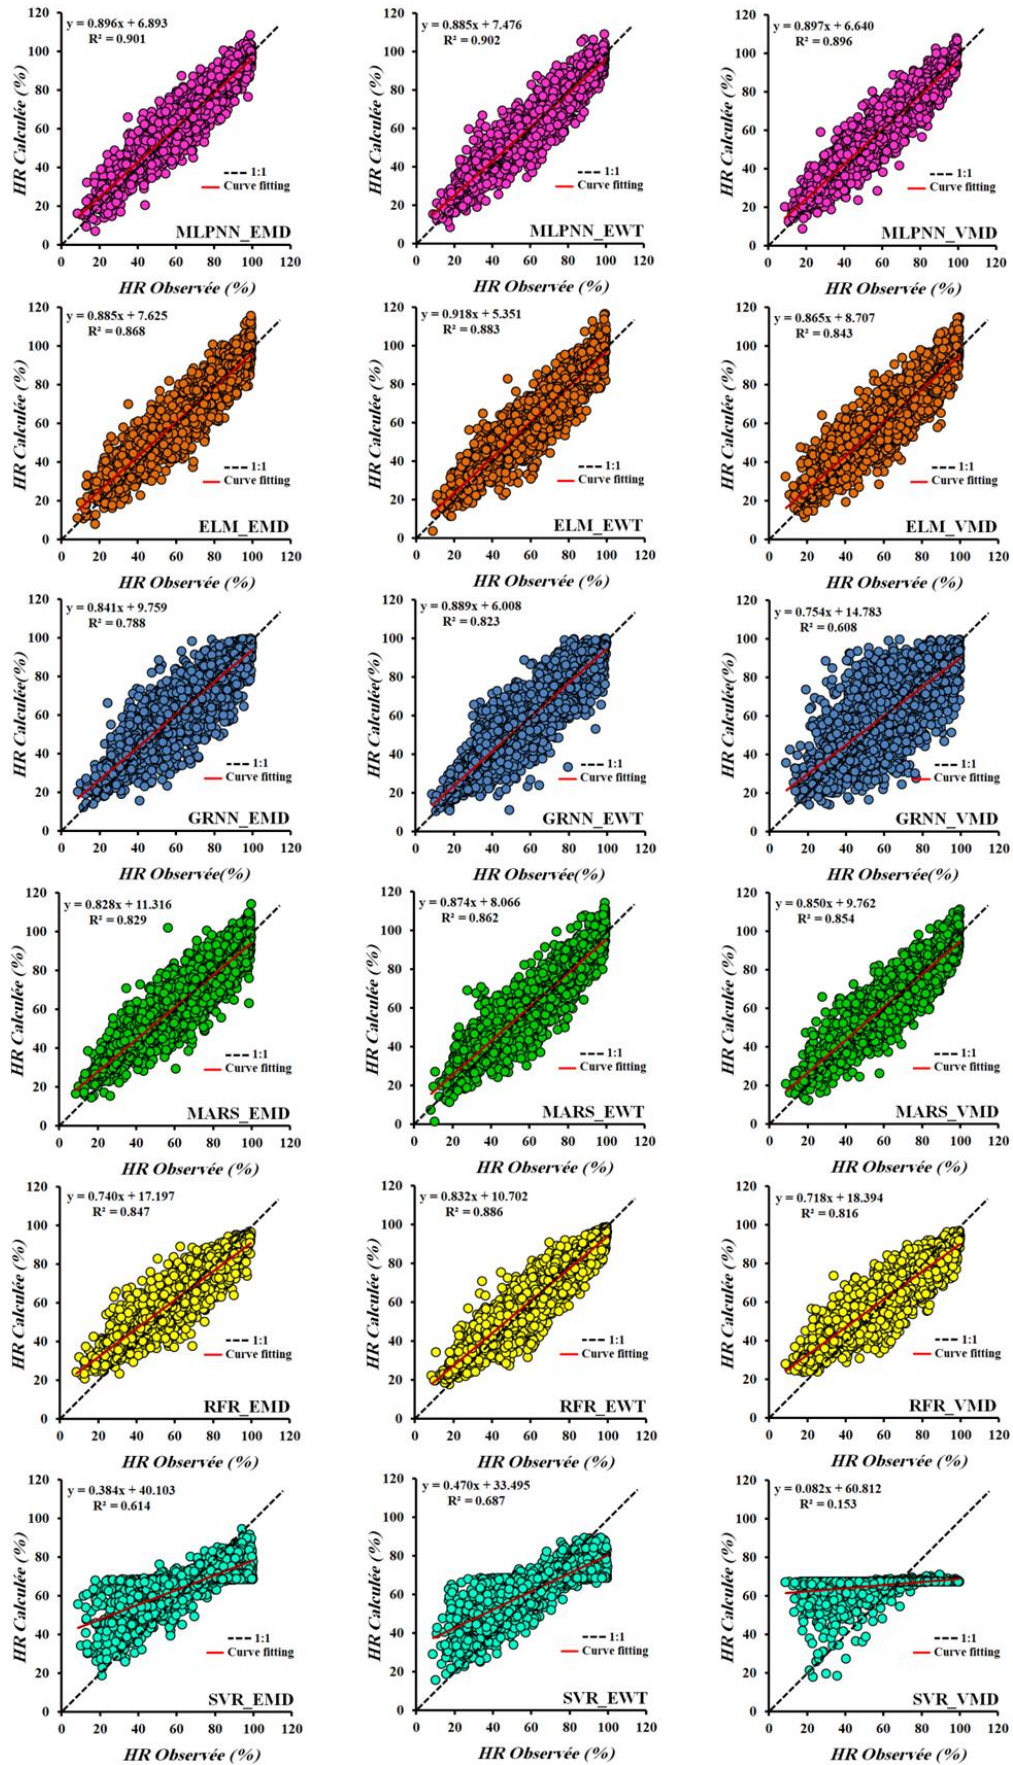


Figure VI.14. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station de Constantine

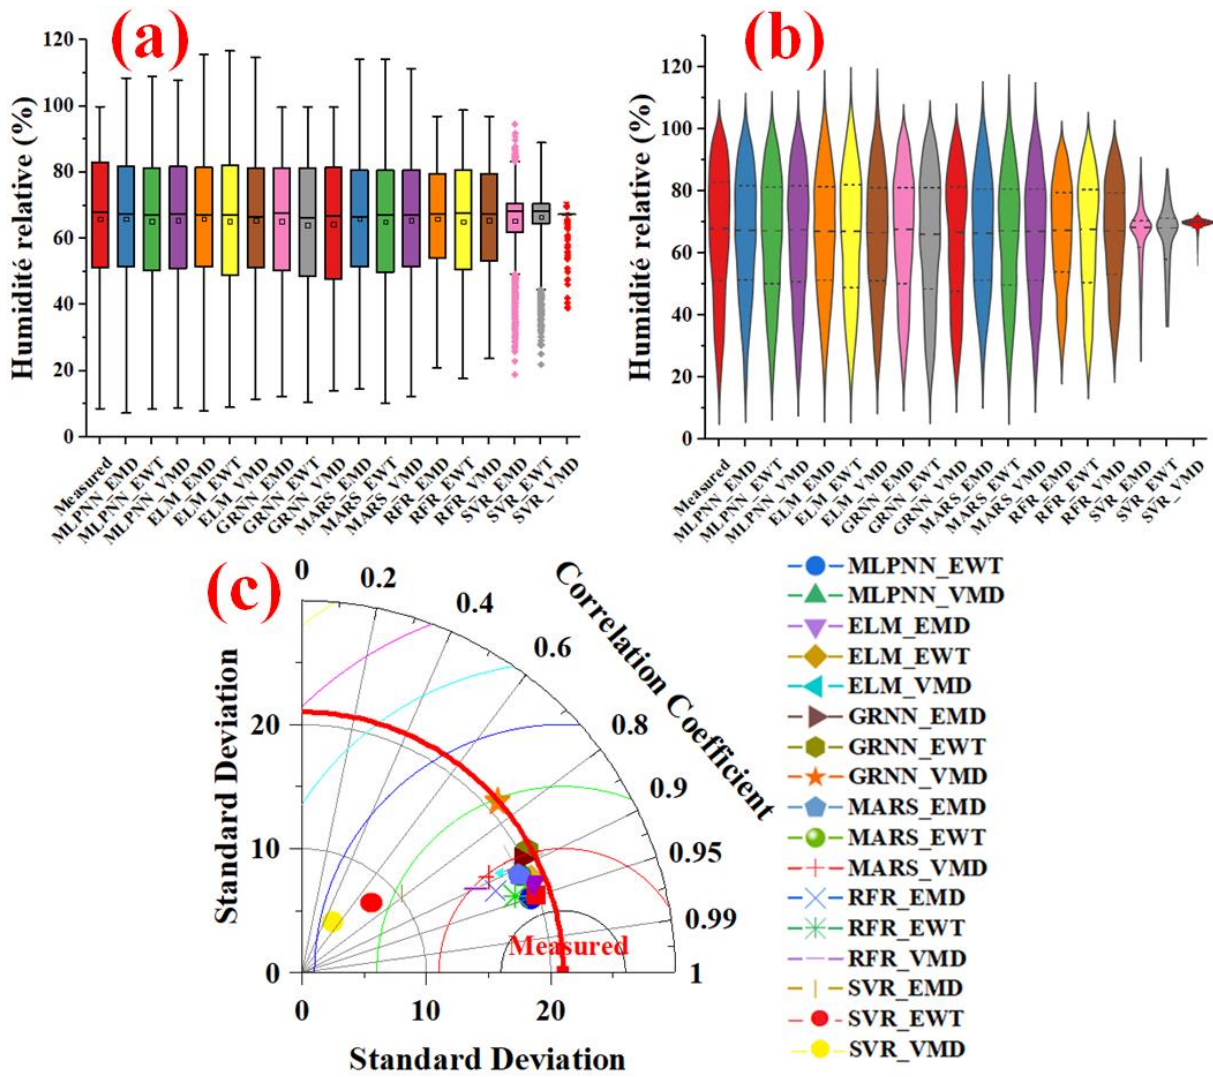


Figure VI.15. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Constantine

Au niveau de la station de Sétif (Tableau VI.9, Figures VI.16-17), d'une façon générale, les performances varient entre bonnes à excellentes avec la plupart des modèles, et le modèle MLPNN donne des meilleures performances pour toutes les algorithmes de décompositions du signal. On remarque que pour les meilleurs modèles MLPNN, que ce soit hybrides ou simples, ils utilisent la première combinaison d'entrées avec l'inclusion de tous les variables climatiques, et l'exclusion d'une variable conduit des réductions de performances.

Pour le modèle MLPNN\_EWT1, qui est le modèle le plus performant au niveau de la station de Sétif, les performances s'améliorent par rapport au meilleur modèle MLPNN simple (MLPNN1) avec des taux de l'ordre de 0.952%, 2.016%, 9.186%, et 7.69% en terme de R, NSE, RMSE et MAE, respectivement.

Comme les stations précédentes, les faibles résultats sont obtenus avec les modèles SVR, et les performances des modèles hybrides se sont dégradés, et le modèle SVR\_VMD6 été le plus faible modèle au niveau de la station de Sétif avec des taux de réductions par rapport au

meilleur modèle de la station (MLPNN\_EWT1) de l'ordre de 68.799% et 71.93%, en termes des valeurs de RMSE et MAE, respectivement.

Lorsqu'on utilise l'algorithme EMD, on obtient des améliorations pour deux modèles hybrides (MLPNN\_EMD1 et ELM\_EMD4) par rapport aux modèles simples, et les valeurs de R et NSE se passent des valeurs (0.945 et 0.893) aux valeurs (0.952 et 0.907) pour le MLPNN\_EMD1, et des valeurs (0.930 et 0.865) aux valeurs (0.934 et 0.872) pour le modèle ELM\_EMD4, par contre, les autres quatre modèles (GRNN\_EMD6, MARS\_EMD1, RFR\_EMD1 et SVR\_EMD6), les performances se dégradent, et le modèle SVR\_EMD6 assure la plus forte dégradation par rapport au modèle MLPNN\_EWT1 avec des taux de l'ordre de 54.663% et 56.94%, en termes de RMSE et MAE, respectivement.

Pour les modèles utilisant l'algorithme de décomposition du signal EWT, trios modèles hybrides (MLPNN\_EWT1, ELM\_EWT4 et RFR\_EWT1) assurent des améliorations des performances, et les autres modèles (GRNN\_EWT6, MARS\_EWT1 et SVR\_EWT6) conduit des faibles résultats par rapport à celle obtenus avec les modèles traditionnels.

Pour les modèles hybrides à base de l'algorithme VMD, seuls les modèles MLPNN ont assuré des améliorations de performances, tandis que les autres modèles (ELM, GRNN, MARS, RFR et SVR), leurs performances se sont significativement dégradées.

La comparaison graphique montre la supériorité des modèles à base de l'algorithme EWT, et les modèles MLPNN ont donné la représentation par nuages de points la moins dispersé (Figures VI.16), par contre la dispersion est très claire lorsqu'en utilisant les modèles SVR hybrides (faible corrélation). La similarité des données prédites par rapport à celles mesurées est plus faible lorsqu'en appliquant le SVR (Figures VI.17a et VI.17b), ces remarques sont confirmées avec le diagramme de Taylor (Figures VI.17c), les trois modèles SVR hybrides et le modèles GRNN\_VMD sont les moins performants au niveau de la station de Sétif.

Tableau VI.9. Résultats obtenus par les meilleures modèles hybrides au niveau de la station de Sétif

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.966	0.934	5.792	4.474	0.952	0.907	6.932	5.357
MLPNN_EWT1	0.965	0.931	5.936	4.520	0.954	0.911	6.742	5.162
MLPNN_VMD1	0.972	0.944	5.302	4.093	0.946	0.894	7.442	5.700
ELM_EMD4	0.953	0.908	6.799	5.374	0.934	0.872	8.127	6.390
ELM_EWT4	0.957	0.916	6.524	5.114	0.941	0.884	7.675	6.056
ELM_VMD1	0.941	0.886	7.554	5.961	0.920	0.845	8.984	7.085
GRNN_EMD6	0.997	0.993	1.832	0.972	0.903	0.812	9.852	7.442
GRNN_EWT6	0.990	0.980	3.223	2.115	0.911	0.827	9.384	6.945
GRNN_VMD6	1.000	1.000	0.039	0.004	0.795	0.592	14.595	11.048
MARS_EMD1	0.918	0.842	8.932	7.069	0.915	0.836	9.188	7.252
MARS_EWT1	0.932	0.868	8.191	6.374	0.929	0.862	8.369	6.518
MARS_VMD1	0.927	0.859	8.408	6.628	0.928	0.860	8.548	6.644
RFR_EMD1	0.984	0.959	4.543	3.514	0.928	0.849	8.822	6.936
RFR_EWT1	0.986	0.968	4.017	3.038	0.942	0.882	7.746	5.999
RFR_VMD4	0.980	0.951	4.960	3.879	0.917	0.830	9.430	7.480
SVR_EMD6	0.991	0.960	4.494	4.156	0.803	0.571	14.871	11.988
SVR_EWT6	0.987	0.957	4.676	4.166	0.861	0.694	12.469	9.840
SVR_VMD6	0.989	0.930	5.943	4.981	0.404	0.106	21.608	18.390

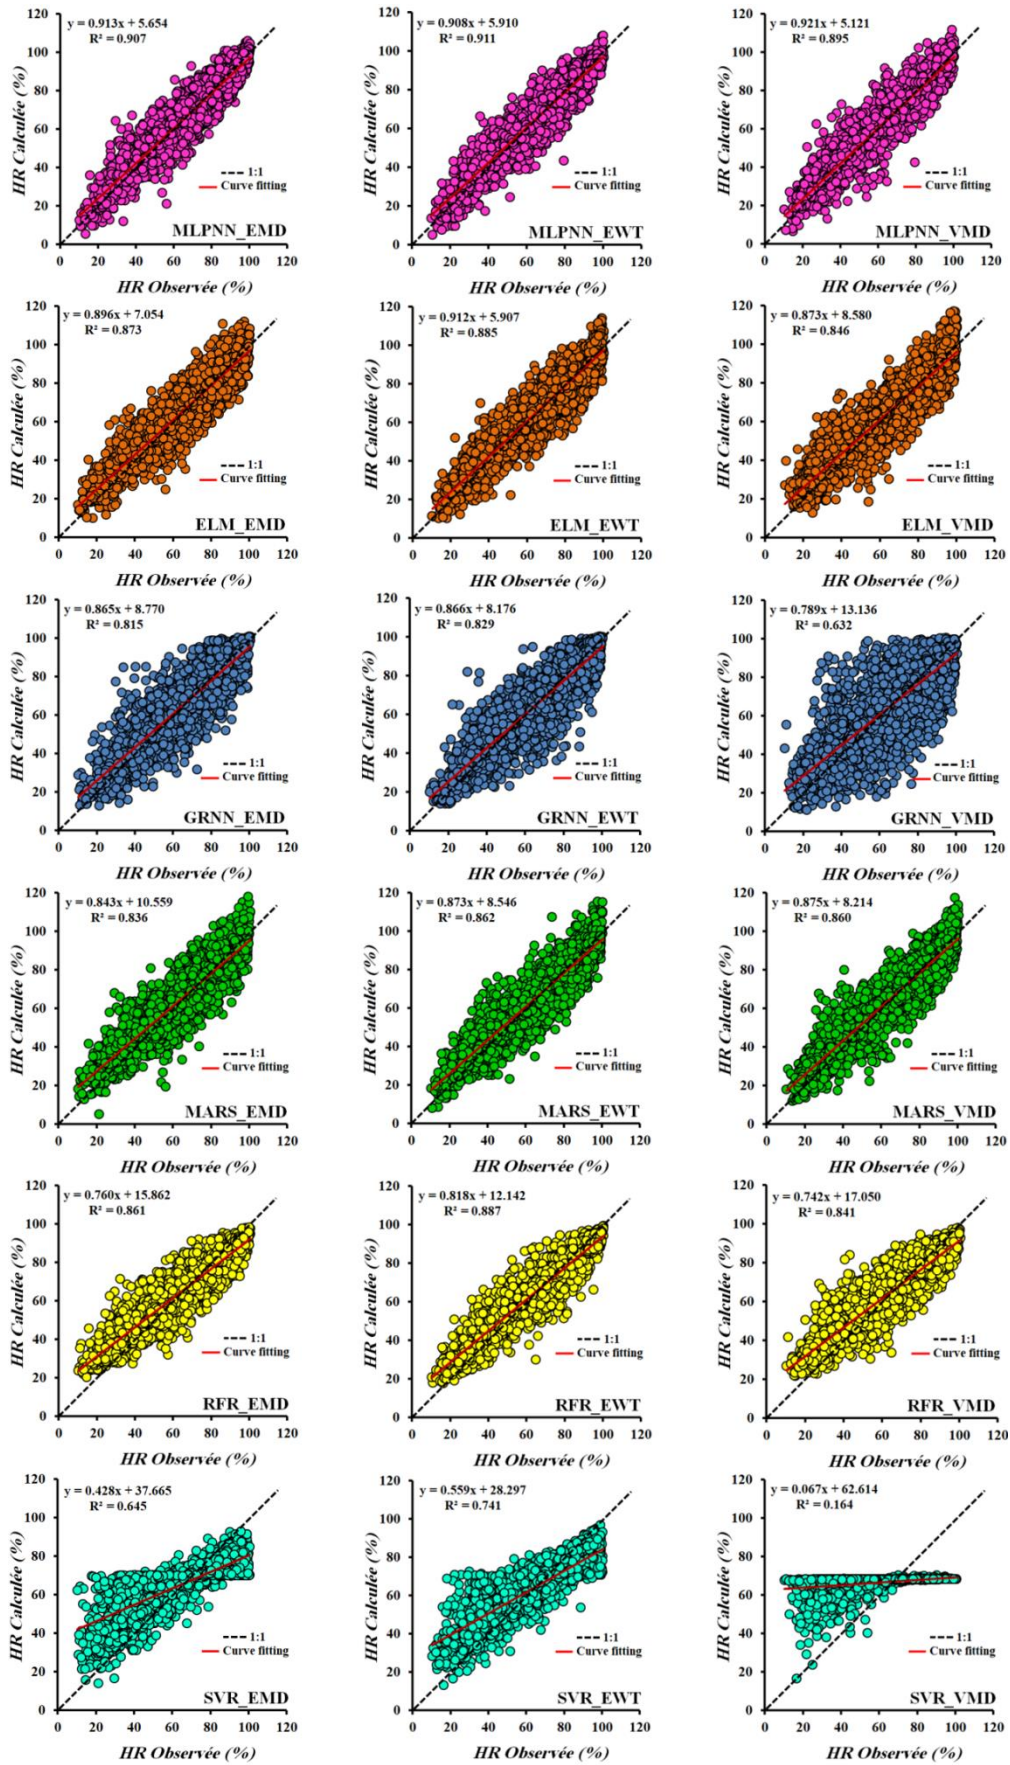


Figure VI.16. Scatterplots des valeurs mesurées et calculées de l'HR durant la phase de validation: modèles hybrides, station de Sétif

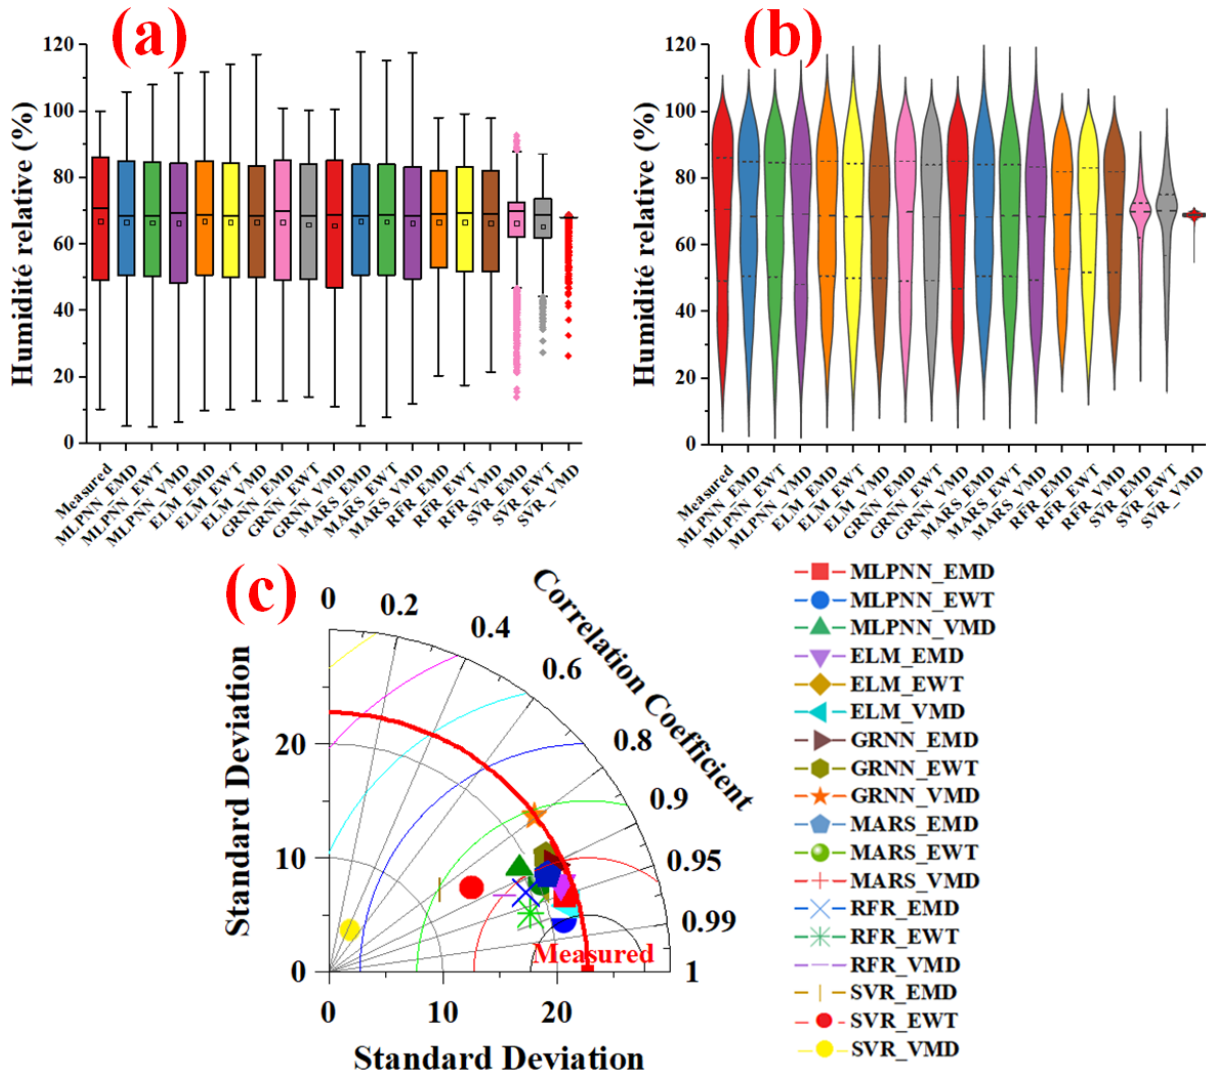


Figure VI.17. Graphiques montrant la comparaison entre l'HR mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Sétif

## VI.4. Conclusion

Dans le présent chapitre, nous avons présenté et discuté les résultats obtenus par six modèles d'intelligences artificielle au niveau de quatre stations situées dans le littorale et la région semi-aride de l'Algérie. Nous avons divisé les résultats et la discussion en deux parties:

- (i) La première, en utilisant les six modèles traditionnels (MLPNN, ELM, GRNN, MARS, RFR et SVR) pour la prédiction de l'HR, et en appliquant ces modèles sur les données climatiques directement, nous avons comparés entre plusieurs combinaisons des variables climatiques et au total six modèles ont été développés, ayant cinq, quatre, trois et deux variables d'entrées, les résultats que nous avons obtenus étaient très

encourageants, surtout au niveau des deux stations situées dans la région semi-aride (Constantine et Sétif), pour les autres stations situées au nord de l'Algérie (Alger et Annaba), nous avons obtenues des performances faibles à moyennes. D'une façon générale, il a été démontré que le MLPNN était plus performant que les autres modèles, par contre, le modèle GRNN assure les faibles résultats pour toutes les stations. On remarque aussi que la majorité des meilleurs modèles utilisent la première combinaison d'entrée avec l'inclusion de tous les variables climatiques.

- (ii) Pour la deuxième partie, nous proposons une nouvelle approche basée sur des algorithmes de décomposition du signal et des modèles hybrides d'apprentissage automatique, nous avons utilisés trois techniques (EMD, EWT et VMD), à fin d'essayer d'améliorer les performances des modèles simples, nous avons démontrés que les algorithmes de décomposition du signal permet une amélioration significative des performances des plusieurs modèles, malgré que les résultats fluctuent d'une station à l'autre, en générale les résultats étaient satisfaisants. A la lumière des résultats obtenus, il a été constaté que l'EWT était l'algorithme qui donne des meilleures performances, suivie par l'EMD, et suivie par le VMD.
- (iii) Il a été démontré que, la RS, les températures minimales et maximales sont les principaux variables climatiques affectant l'HR.

***Chapitre VII: Modélisation de la Radiation Solaire  
(RS) par l'Intelligence Artificielle***

---

## VII.1. Introduction

Dans le chapitre précédent nous avons présenté et discuté les résultats de la modélisation de l'HR. Dans le présent chapitre nous avons gardé les mêmes modèles que ce soit traditionnels ou hybrides pour modéliser la radiation solaire (RS) au niveau de quatre stations situées dans le nord et la région semi-aride de l'Algérie. Pour chaque modèle nous avons testé six combinaisons, ayant chacune différents variables climatique d'entrées (Tableau VII.1), avec cinq, quatre, trois et deux variables climatiques.

Les performances des modèles sont évaluées en utilisant les quatre critères de validation: RMSE, MAE, R, et le critère de NSE. L'organigramme qui synthétise la modélisation proposée est illustré dans la figure VII.1. Nous consacrons la discussion des résultats durant la phase Validation.

Tableau VII.1. Structure des modèles utilisées durant la modélisation de la RS

Modèles						Variables d'entrées (inputs)	Output
MLPNN1	ELM1	GRNN1	MARS1	RFR1	SVR1	$T_{\max}, T_{\min}, P, U_2, HR$	RS
MLPNN2	ELM2	GRNN2	MARS2	RFR2	SVR2	$T_{\max}, T_{\min}, U_2, HR$	RS
MLPNN3	ELM3	GRNN3	MARS3	RFR3	SVR3	$T_{\max}, T_{\min}, P, HR$	RS
MLPNN4	ELM4	GRNN4	MARS4	RFR4	SVR4	$T_{\max}, T_{\min}, U_2$	RS
MLPNN5	ELM5	GRNN5	MARS5	RFR5	SVR5	$T_{\max}, T_{\min}, HR$	RS
MLPNN6	ELM6	GRNN6	MARS6	RFR6	SVR6	$T_{\max}, T_{\min}$	RS

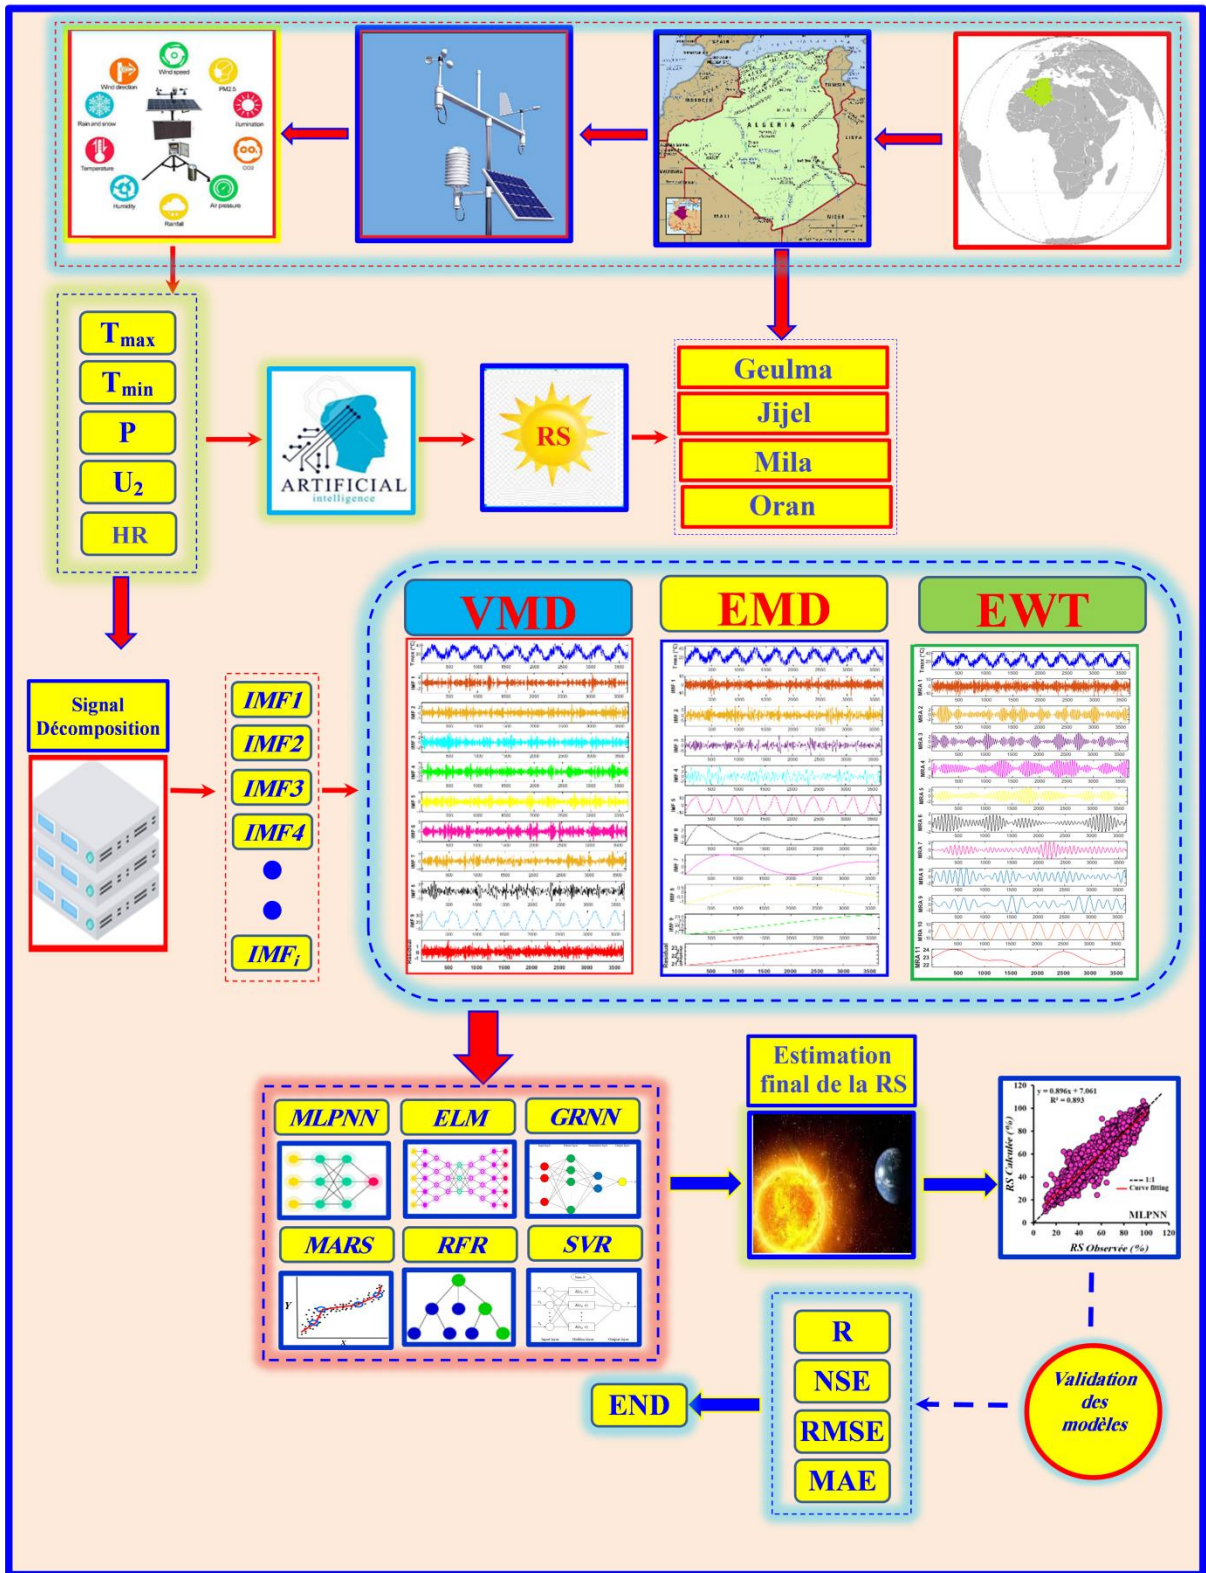


Figure VII.1. L'organigramme de modélisation de la RS

## VII.2. Modélisation de la RS par les modèles traditionnels

Les résultats de modélisation de la RS par les six modèles traditionnels sont présentés séparément pour chaque station dans les tableaux VII.2-5 et les figures VII.2-9. Pour la station de Guelma (Tableau VII.2, Figures VII.2-3), d'une façon générale, les performances étaient faibles à moyenne. La meilleure combinaison des variables d'entrée pour tous les modèles est la première combinaison ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$  et HR) avec l'inclusion de tous les variables climatiques. Par contre, la dernière combinaison ( $T_{\max}$ ,  $T_{\min}$ ) conduit aux plus faibles performances pour cinq modèles (MLPNN6, ELM6, GRNN6, MARS6 et RFR6). Pour les modèles SVR, nous obtenons le meilleur modèle (SVR1) et le faible modèle (SVR5). Avec le SVR1 qui utilise tous les variables climatiques comme entrées, nous obtenons des valeurs de R, NSE, RMSE et MAE de  $\approx 0.882$ ,  $\approx 0.777$ ,  $\approx 4.195$  et  $\approx 3.195$ , respectivement, par contre, le SVR5 qui utilise la cinquième combinaison d'entrée ( $T_{\max}$ ,  $T_{\min}$ , HR) assure des indices de  $R \approx 0.582$ ,  $NSE \approx 0.136$ ,  $RMSE \approx 8.264$  et  $MAE \approx 6.513$ . Par l'exclusion de l'HR (SVR6) ces indices s'améliorent pour atteindre des valeurs de  $R \approx 0.840$ ,  $NSE \approx 0.702$ ,  $RMSE \approx 4.839$  et  $MAE \approx 3.728$ , avec un taux d'amélioration de 44.330%, 41.647%, 41.445% et 42.761% en terme de R, NSE, RMSE et MAE, respectivement. Les moyennes des valeurs de R et NSE pour les six modèles sont rangés entre (0.864, 0.746) du modèles MLPNN et (0.808, 0.642) obtenus par les modèles GRNN.

Par les modèles à quatre et trois entrées (deuxième à cinquième combinaison), les performances obtenues pour chaque modèle d'IA sont proches les uns des autres sauf pour le SVR5. Les modèles proposés ont été comparés sur la base des représentations graphiques, les Scatterplots (Figure VII.2), les boxplot (Figure VII.3a), et les violin plot (Figure VII.3b) ainsi que le diagramme de Taylor (Figure VII.3c). Ces figures montrent que le modèle GRNN est le modèle qui donne les plus faibles performances, les données prédites par ce modèle étaient faibles par rapport aux données mesurées.

Tableau VII.2. Résultats obtenus par les modèles traditionnels au niveau de la station de Guelma

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.888</b>	<b>0.788</b>	<b>4.159</b>	<b>3.249</b>	<b>0.881</b>	<b>0.775</b>	<b>4.217</b>	<b>3.299</b>
MLPNN2	0.884	0.781	4.224	3.297	0.877	0.769	4.272	3.329
MLPNN3	0.875	0.765	4.383	3.418	0.868	0.753	4.421	3.456
MLPNN4	0.862	0.741	4.600	3.552	0.858	0.734	4.585	3.551
MLPNN5	0.868	0.754	4.485	3.472	0.859	0.738	4.552	3.548
MLPNN6	0.848	0.720	4.784	3.770	0.841	0.707	4.810	3.798
<b>ELM1</b>	<b>0.893</b>	<b>0.797</b>	<b>4.068</b>	<b>3.173</b>	<b>0.880</b>	<b>0.774</b>	<b>4.223</b>	<b>3.279</b>
ELM2	0.890	0.793	4.115	3.179	0.873	0.762	4.334	3.308
ELM3	0.879	0.772	4.311	3.334	0.856	0.731	4.611	3.467
ELM4	0.868	0.754	4.485	3.496	0.850	0.722	4.692	3.636
ELM5	0.871	0.759	4.436	3.414	0.855	0.731	4.610	3.565
ELM6	0.850	0.722	4.760	3.737	0.765	0.566	5.858	3.909
<b>GRNN1</b>	<b>0.826</b>	<b>0.675</b>	<b>5.150</b>	<b>4.191</b>	<b>0.815</b>	<b>0.659</b>	<b>5.195</b>	<b>4.284</b>
GRNN2	0.818	0.661	5.264	4.314	0.814	0.655	5.224	4.304
GRNN3	0.810	0.650	5.343	4.393	0.805	0.642	5.318	4.400
GRNN4	0.808	0.636	5.452	4.511	0.810	0.639	5.346	4.458
GRNN5	0.806	0.640	5.421	4.464	0.805	0.639	5.345	4.427
GRNN6	0.797	0.615	5.603	4.648	0.801	0.619	5.488	4.584
<b>MARS1</b>	<b>0.871</b>	<b>0.759</b>	<b>4.436</b>	<b>3.542</b>	<b>0.871</b>	<b>0.758</b>	<b>4.375</b>	<b>3.496</b>
MARS2	0.871	0.758	4.447	3.510	0.867	0.752	4.427	3.495
MARS3	0.864	0.747	4.544	3.594	0.861	0.739	4.539	3.567
MARS4	0.858	0.736	4.647	3.668	0.857	0.734	4.586	3.629
MARS5	0.859	0.738	4.624	3.639	0.855	0.731	4.613	3.627
MARS6	0.846	0.716	4.813	3.814	0.843	0.710	4.789	3.800
<b>RFR1</b>	<b>0.953</b>	<b>0.902</b>	<b>2.823</b>	<b>2.162</b>	<b>0.877</b>	<b>0.768</b>	<b>4.282</b>	<b>3.347</b>
RFR2	0.951	0.899	2.874	2.191	0.869	0.755	4.404	3.434
RFR3	0.946	0.890	2.995	2.282	0.866	0.750	4.442	3.465
RFR4	0.933	0.864	3.333	2.594	0.846	0.715	4.749	3.754
RFR5	0.933	0.865	3.321	2.569	0.851	0.723	4.679	3.683
RFR6	0.920	0.842	3.588	2.775	0.830	0.688	4.964	3.914
<b>SVR1</b>	<b>0.904</b>	<b>0.818</b>	<b>3.855</b>	<b>2.902</b>	<b>0.882</b>	<b>0.777</b>	<b>4.195</b>	<b>3.195</b>
SVR2	0.893	0.797	4.068	3.050	0.877	0.768	4.286	3.249
SVR3	0.879	0.771	4.321	3.256	0.868	0.751	4.433	3.370
SVR4	0.866	0.748	4.540	3.444	0.854	0.728	4.641	3.536
SVR5	0.867	0.750	4.516	3.411	0.582	0.136	8.264	6.513
SVR6	0.846	0.713	4.841	3.732	0.840	0.704	4.839	3.728

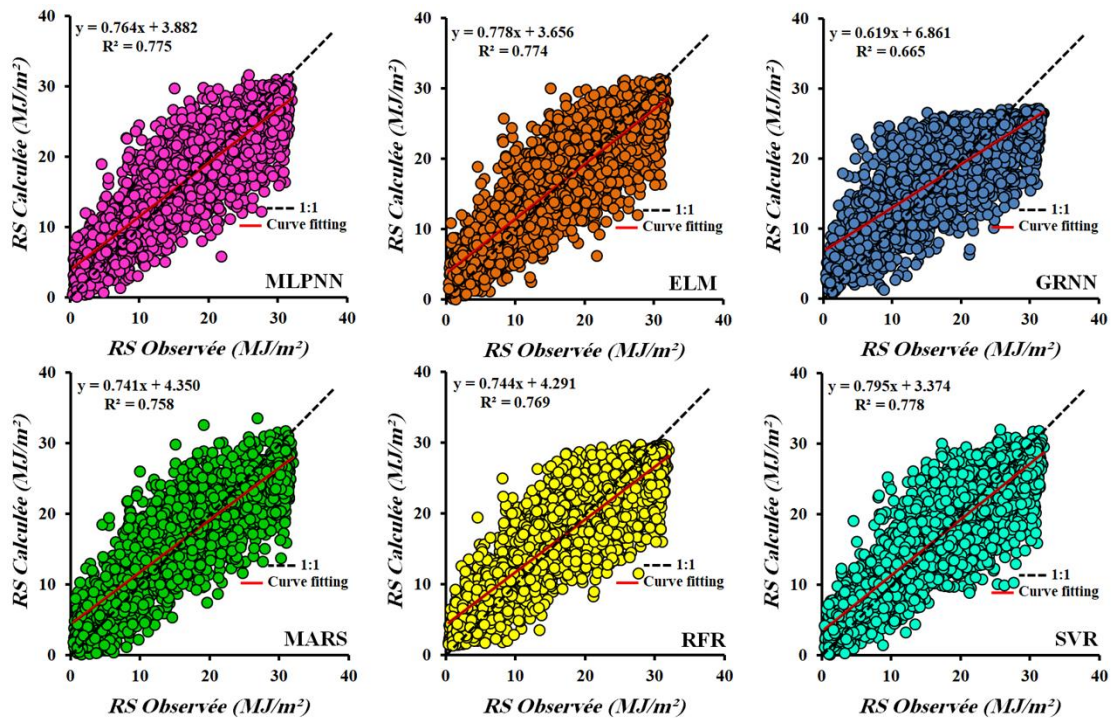


Figure VII.2. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Guelma.

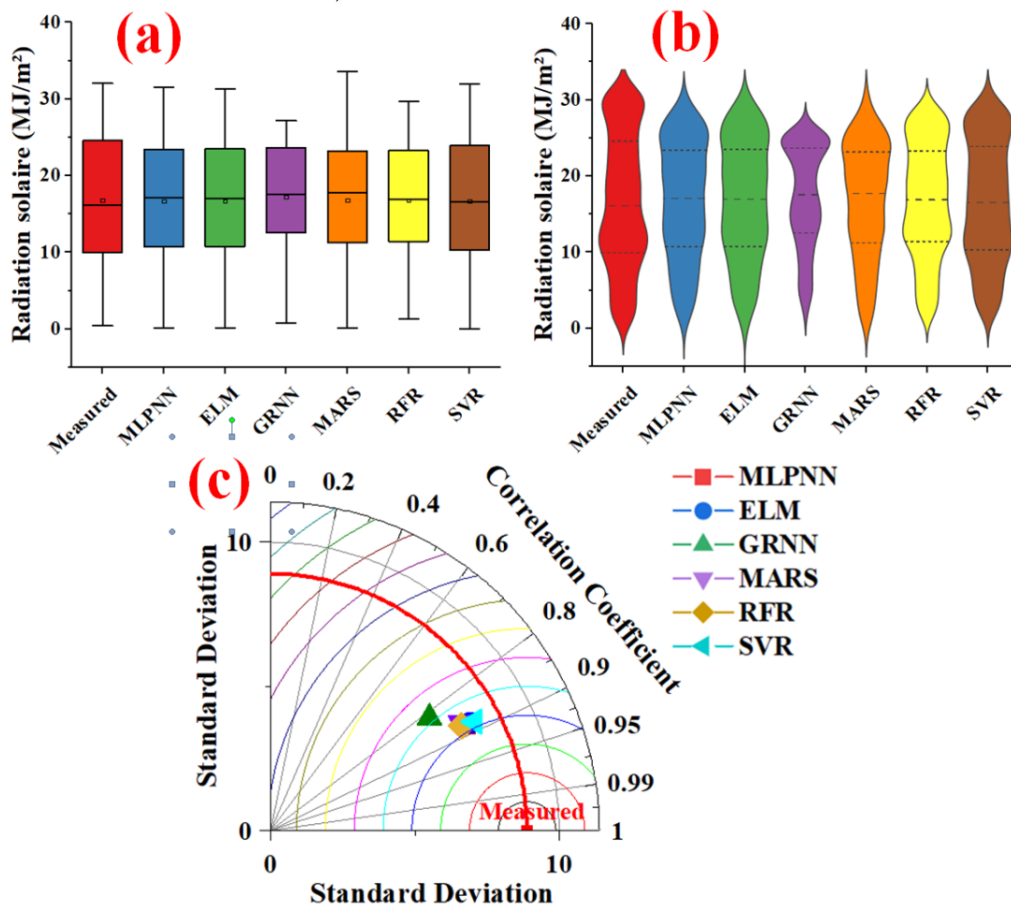


Figure VII.3. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Guelma

Au niveau de la station de Jijel (Tableau VII.3, Figure VII.4-5), les performances des modèles étaient faibles par rapport à celles de la station de Guelma. L'utilisation de la deuxième combinaison avec quatre variables climatiques ( $T_{\max}$ ,  $T_{\min}$ ,  $U_2$ , HR) garantie les meilleures performances pour cinq modèles (MLPNN2, ELM2, GRNN2, MARS2 et SVR2). Avec l'inclusion des précipitations (la première combinaison), les performances se dégradent, et nous obtenons des diminution des performances en terme de R avec des taux de l'ordre de 0.241%, 0.12%, 0.385%, 0.862% et 0.12%, pour les modèles MLPNN2, ELM2, GRNN2, MARS2 et SVR2, respectivement, ce qui nous permet de conclure que l'utilisation de la variable précipitation comme entrée des différents modèles ne permet pas d'améliorer les performances des modèles. Par contre, pour les modèles RFR, le modèle RFR1 qui utilise la première combinaison assure les meilleures performances, et l'exclusion de la précipitation (RFR2) conduit à une dégradation des performances avec des taux de l'ordre de 0.854%, 1.634%, 1.676% et 1.766% en termes de R, NSE, RMSE et MAE, respectivement. Les meilleures performances sont obtenues par les modèles MLPNN, et le MLPNN2 assure les plus grandes valeurs de R et NSE (0.833 et 0.694) et les plus faibles valeurs de RMSE et MAE (4.849 et 3.823), avec des différences négligeables par rapport au modèle ELM2 ( $R \approx 0.833$ ,  $NSE \approx 0.693$ ,  $RMSE \approx 4.855$  et  $MAE \approx 3.825$ ). Les faibles résultats sont obtenus par les modèles GRNN, et le GRNN2 assure les meilleures performances avec des taux de réductions par rapport au meilleur modèle de la station (MLPNN2) de l'ordre de 6.522%, 14.521%, 11.836% et 15.007% en termes de R, NSE, RMSE et MAE, respectivement. La comparaison graphique entre les différents modèles confirme les résultats numériques, les Scatterplots (Figure VII.4) et les figures VII.5a, VII.5b et VII.5c.

Tableau VII.3. Résultats obtenus par les modèles traditionnels au niveau de la station de Jijel

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN1	0.840	0.706	4.733	3.735	0.831	0.690	4.885	3.841
<b>MLPNN2</b>	<b>0.842</b>	<b>0.709</b>	<b>4.705</b>	<b>3.698</b>	<b>0.833</b>	<b>0.694</b>	<b>4.849</b>	<b>3.823</b>
MLPNN3	0.829	0.686	4.885	3.887	0.816	0.665	5.075	4.035
MLPNN4	0.823	0.677	4.959	3.941	0.816	0.667	5.063	4.020
MLPNN5	0.823	0.677	4.960	3.957	0.812	0.659	5.120	4.093
MLPNN6	0.808	0.653	5.139	4.114	0.796	0.633	5.309	4.240
ELM1	0.849	0.721	4.608	3.629	0.832	0.691	4.876	3.809
<b>ELM2</b>	<b>0.846</b>	<b>0.716</b>	<b>4.651</b>	<b>3.640</b>	<b>0.833</b>	<b>0.693</b>	<b>4.855</b>	<b>3.825</b>
ELM3	0.834	0.695	4.817	3.810	0.798	0.633	5.314	4.083
ELM4	0.828	0.686	4.890	3.866	0.812	0.659	5.118	4.041
ELM5	0.828	0.685	4.894	3.869	0.803	0.645	5.225	4.120
ELM6	0.811	0.657	5.108	4.080	0.787	0.619	5.413	4.307
GRNN1	0.802	0.638	5.245	4.273	0.779	0.604	5.518	4.501
<b>GRNN2</b>	<b>0.794</b>	<b>0.623</b>	<b>5.354</b>	<b>4.388</b>	<b>0.782</b>	<b>0.606</b>	<b>5.500</b>	<b>4.498</b>
GRNN3	0.787	0.615	5.416	4.445	0.771	0.592	5.600	4.588
GRNN4	0.776	0.589	5.592	4.625	0.764	0.574	5.723	4.722
GRNN5	0.783	0.605	5.485	4.524	0.775	0.593	5.591	4.595
GRNN6	0.764	0.569	5.727	4.760	0.754	0.556	5.844	4.843
MARS1	0.830	0.689	4.867	3.886	0.812	0.652	5.170	4.101
<b>MARS2</b>	<b>0.828</b>	<b>0.686</b>	<b>4.891</b>	<b>3.868</b>	<b>0.819</b>	<b>0.671</b>	<b>5.029</b>	<b>3.967</b>
MARS3	0.819	0.670	5.009	4.009	0.370	-4.373	20.325	11.726
MARS4	0.814	0.663	5.066	4.055	0.810	0.656	5.143	4.125
MARS5	0.816	0.666	5.045	4.041	0.810	0.657	5.137	4.102
MARS6	0.803	0.645	5.195	4.184	0.797	0.635	5.299	4.257
<b>RFR1</b>	<b>0.936</b>	<b>0.869</b>	<b>3.161</b>	<b>2.460</b>	<b>0.827</b>	<b>0.684</b>	<b>4.928</b>	<b>3.894</b>
RFR2	0.934	0.866	3.199	2.481	0.820	0.673	5.012	3.964
RFR3	0.929	0.856	3.307	2.569	0.808	0.652	5.170	4.064
RFR4	0.915	0.829	3.609	2.852	0.806	0.649	5.192	4.129
RFR5	0.915	0.830	3.600	2.830	0.802	0.642	5.243	4.162
RFR6	0.903	0.809	3.809	2.997	0.780	0.607	5.498	4.347
SVR1	0.863	0.744	4.414	3.322	0.830	0.686	4.912	3.727
<b>SVR2</b>	<b>0.850</b>	<b>0.720</b>	<b>4.613</b>	<b>3.490</b>	<b>0.831</b>	<b>0.686</b>	<b>4.910</b>	<b>3.744</b>
SVR3	0.833	0.692	4.838	3.690	0.812	0.654	5.157	3.950
SVR4	0.825	0.677	4.959	3.804	0.816	0.661	5.104	3.925
SVR5	0.828	0.685	4.894	3.869	0.803	0.645	5.225	4.120
SVR6	0.811	0.657	5.108	4.080	0.787	0.619	5.413	4.307

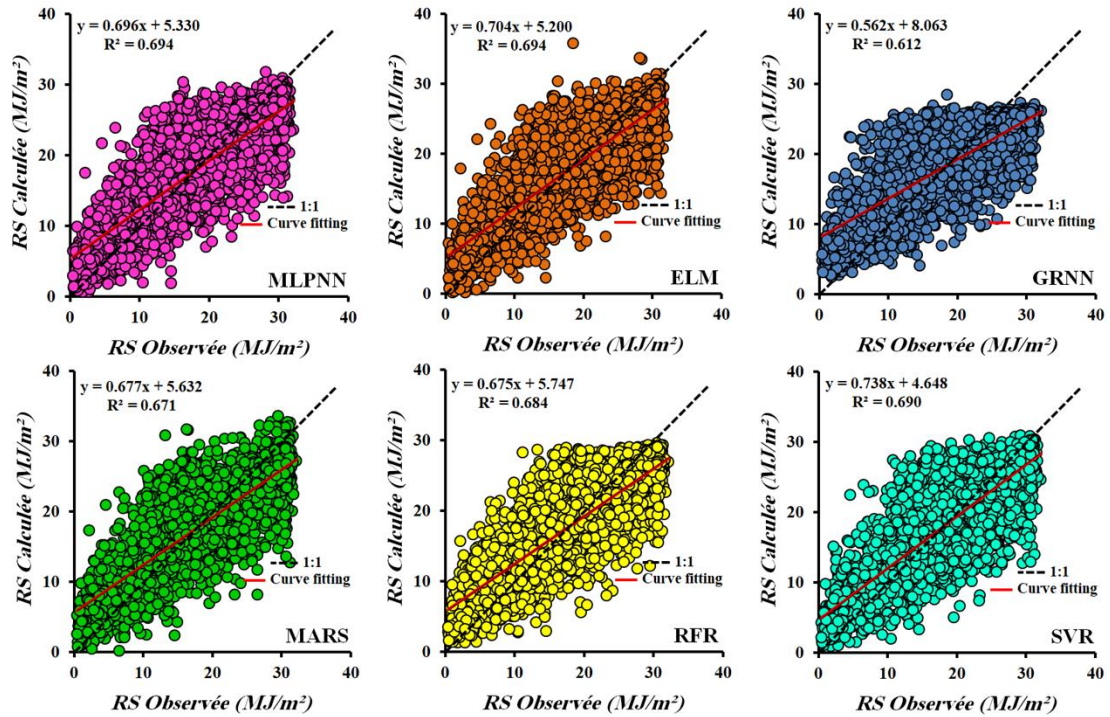


Figure VII.4. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Jijel.

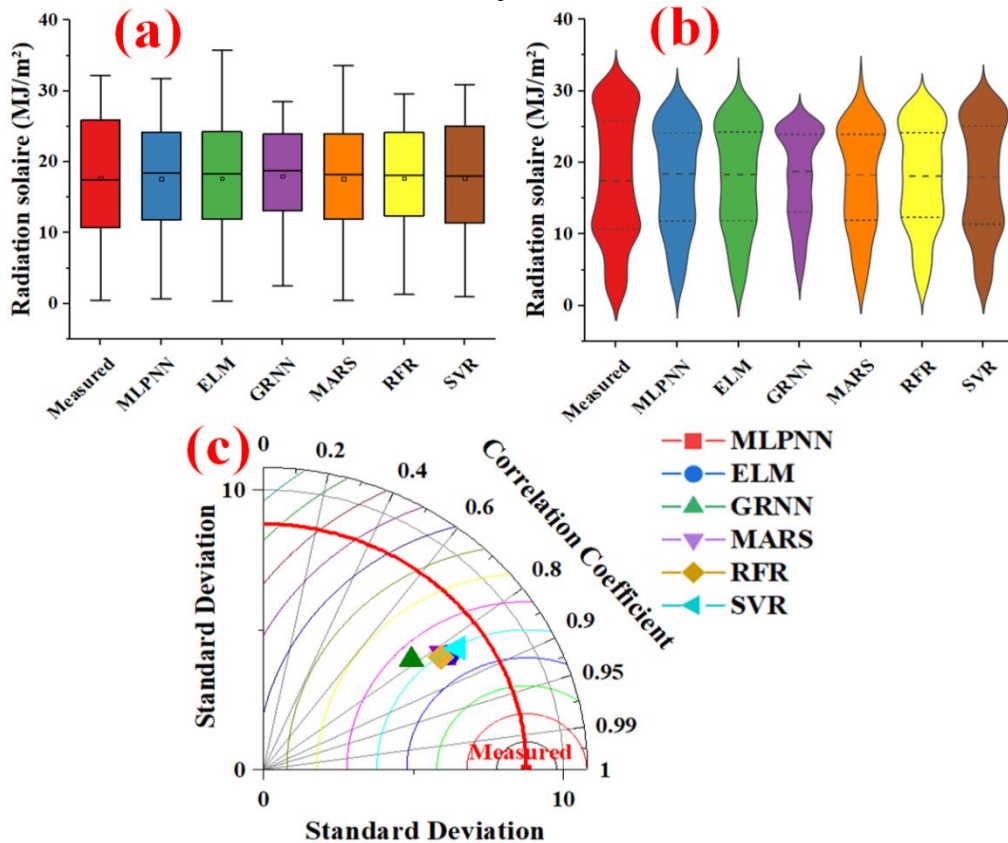


Figure VII.5. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels station de Jijel.

Au niveau de la station de Mila (Tableau VII.4, Figure VII.6-7), les performances obtenues sont plus proche à celle de la station de Guelma, et meilleur par rapport à la station de Jijel. Les résultats varient d'un modèle à l'autre et selon le nombre de variables d'entrée utilisées, et on remarque qu'aucun modèle n'a permis d'obtenir un coefficient de corrélation (R) supérieur à 0.90. Premièrement, en utilisant la première combinaison avec cinq variables d'entrées ( $T_{\max}$ ,  $T_{\min}$ , P,  $U_2$ , HR), les modèles MLPNN1, GRNN1, MARS1 et SVR1 assurent les meilleurs résultats, et le MLPNN1 est le modèle le plus performant au niveau de la station de Mila ( $R \approx 0.886$ ,  $NSE \approx 0.784$ ,  $RMSE \approx 4.07$ ,  $MAE \approx 3.195$ ), par contre, les modèles ELM1 et RFR1 sont moins performants par rapport aux ELM2 et RFR2. Avec quatre variables d'entrée, le ELM2 et RFR2 assurent les meilleures performances pour les modèles ELM et RFR, ce qui explique l'effet négligeable des précipitations. Pour les modèles utilisant la troisième combinaison ( $T_{\max}$ ,  $T_{\min}$ , P, HR), les performances de tous les modèles se sont dégradées, ce qui explique l'effet prédominant de la vitesse du vent ( $U_2$ ) par rapport à la précipitation (P). Avec les modèles utilisant trois variables d'entrée (quatrième et cinquième combinaison), les résultats obtenus sont proche les uns des autres avec des différences négligeables entre les modèles, ce qui nous conduit à conclure que l'effet des deux variables  $U_2$  et HR est similaire. Pour les modèles utilisant la dernière combinaison ( $T_{\max}$ ,  $T_{\min}$ ), nous obtenons des faibles résultats pour tous les modèles d'IA, il est clair que les performances se sont significativement dégradées par rapport aux meilleurs modèles, avec une dégradation des performances en termes de RMSE et MAE de (12.605%,13.203%), (13.609%,14.078%), (7.079%,9.020%), (8.896%,9.088%), (11.818%,12.915%) et (13.859%,15.556%) pour les modèles MLPNN, ELM, GRNN, MARS, RFR et SVR, respectivement, et le modèle GRNN6 garantit les faibles performances au niveau de la station de Mila avec des indices numériques de l'ordre ( $R \approx 0.798$ ,  $NSE \approx 0.619$ ,  $RMSE \approx 5.410$ ,  $MAE \approx 4.468$ ), et des différences en termes de R, NSE, RMSE et MAE par rapport aux meilleurs modèles de l'ordre de (11.028%, 26.656%, 24.769% et 28.491%), (10.526%, 25.525%, 23.494% et 28.424%), (3.133%, 8.401%, 7.079% et 9.02%), (9.774%, 23.748%, 21.627% et 24.552%), (9.524%, 23.263%, 21.109% et 26.052%), (10.526%, 25.687%, 23.715% et 29.655%), par rapport aux modèles MLPNN1, ELM1, GRNN1, MARS1, RFR2 et SVR1, respectivement.

La comparaison graphique entre les modèles est représentés sur les figures VII.6 et VII.7.

Tableau VII.4. Résultats obtenus par les modèles traditionnels au niveau de la station de Mila

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.896</b>	<b>0.803</b>	<b>3.883</b>	<b>3.014</b>	<b>0.886</b>	<b>0.784</b>	<b>4.070</b>	<b>3.195</b>
MLPNN2	0.892	0.796	3.949	3.059	0.883	0.779	4.118	3.209
MLPNN3	0.877	0.769	4.203	3.292	0.866	0.750	4.382	3.447
MLPNN4	0.876	0.767	4.223	3.296	0.868	0.754	4.352	3.420
MLPNN5	0.875	0.765	4.238	3.318	0.865	0.748	4.402	3.457
MLPNN6	0.861	0.741	4.456	3.495	0.847	0.718	4.657	3.681
ELM1	0.900	0.811	3.805	2.935	0.882	0.777	4.138	3.206
<b>ELM2</b>	<b>0.898</b>	<b>0.806</b>	<b>3.853</b>	<b>2.962</b>	<b>0.882</b>	<b>0.777</b>	<b>4.139</b>	<b>3.198</b>
ELM3	0.883	0.779	4.110	3.176	0.854	0.729	4.559	3.482
ELM4	0.881	0.776	4.137	3.210	0.854	0.729	4.561	3.491
ELM5	0.878	0.771	4.186	3.234	0.861	0.741	4.461	3.460
ELM6	0.862	0.743	4.437	3.473	0.838	0.701	4.791	3.722
<b>GRNN1</b>	<b>0.846</b>	<b>0.709</b>	<b>4.721</b>	<b>3.798</b>	<b>0.823</b>	<b>0.671</b>	<b>5.027</b>	<b>4.065</b>
GRNN2	0.839	0.695	4.833	3.923	0.821	0.667	5.058	4.111
GRNN3	0.822	0.670	5.029	4.092	0.809	0.649	5.195	4.272
GRNN4	0.828	0.670	5.023	4.113	0.815	0.649	5.190	4.254
GRNN5	0.818	0.661	5.096	4.173	0.807	0.643	5.241	4.321
GRNN6	0.807	0.634	5.297	4.359	0.798	0.619	5.410	4.468
<b>MARS1</b>	<b>0.880</b>	<b>0.775</b>	<b>4.149</b>	<b>3.256</b>	<b>0.876</b>	<b>0.766</b>	<b>4.240</b>	<b>3.371</b>
MARS2	0.880	0.774	4.156	3.251	0.874	0.764	4.261	3.350
MARS3	0.871	0.759	4.296	3.364	0.861	0.738	4.485	3.607
MARS4	0.870	0.758	4.307	3.389	0.864	0.746	4.420	3.504
MARS5	0.865	0.749	4.384	3.448	0.857	0.735	4.512	3.574
MARS6	0.856	0.733	4.517	3.581	0.847	0.718	4.654	3.708
RFR1	0.956	0.908	2.648	2.025	0.868	0.737	4.494	3.645
<b>RFR2</b>	<b>0.954</b>	<b>0.907</b>	<b>2.673</b>	<b>2.040</b>	<b>0.874</b>	<b>0.763</b>	<b>4.268</b>	<b>3.304</b>
RFR3	0.947	0.894	2.853	2.173	0.850	0.708	4.733	3.838
RFR4	0.939	0.876	3.084	2.395	0.858	0.735	4.512	3.557
RFR5	0.937	0.874	3.109	2.414	0.856	0.732	4.541	3.579
RFR6	0.927	0.857	3.309	2.561	0.834	0.695	4.840	3.794
<b>SVR1</b>	<b>0.911</b>	<b>0.829</b>	<b>3.616</b>	<b>2.708</b>	<b>0.882</b>	<b>0.778</b>	<b>4.127</b>	<b>3.143</b>
SVR2	0.901	0.811	3.801	2.846	0.880	0.773	4.177	3.167
SVR3	0.883	0.779	4.115	3.100	0.869	0.754	4.347	3.334
SVR4	0.880	0.773	4.172	3.157	0.864	0.744	4.432	3.381
SVR5	0.878	0.771	4.186	3.234	0.861	0.741	4.461	3.460
SVR6	0.862	0.743	4.437	3.473	0.838	0.701	4.791	3.722

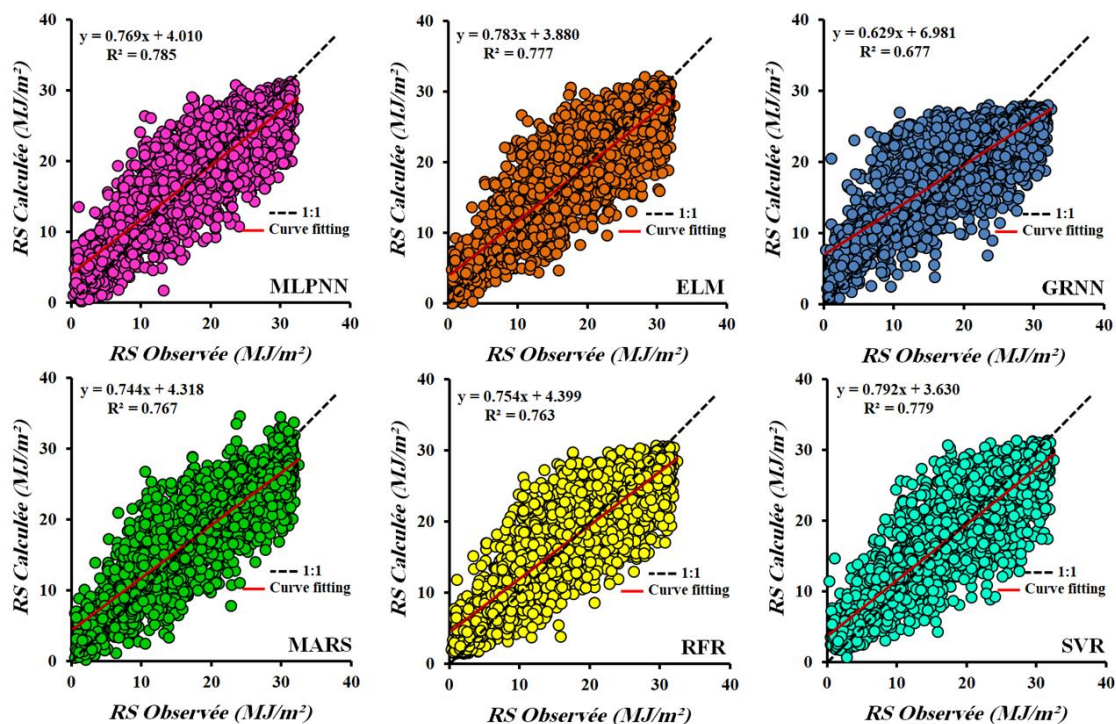


Figure VII.6. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station de Mila.

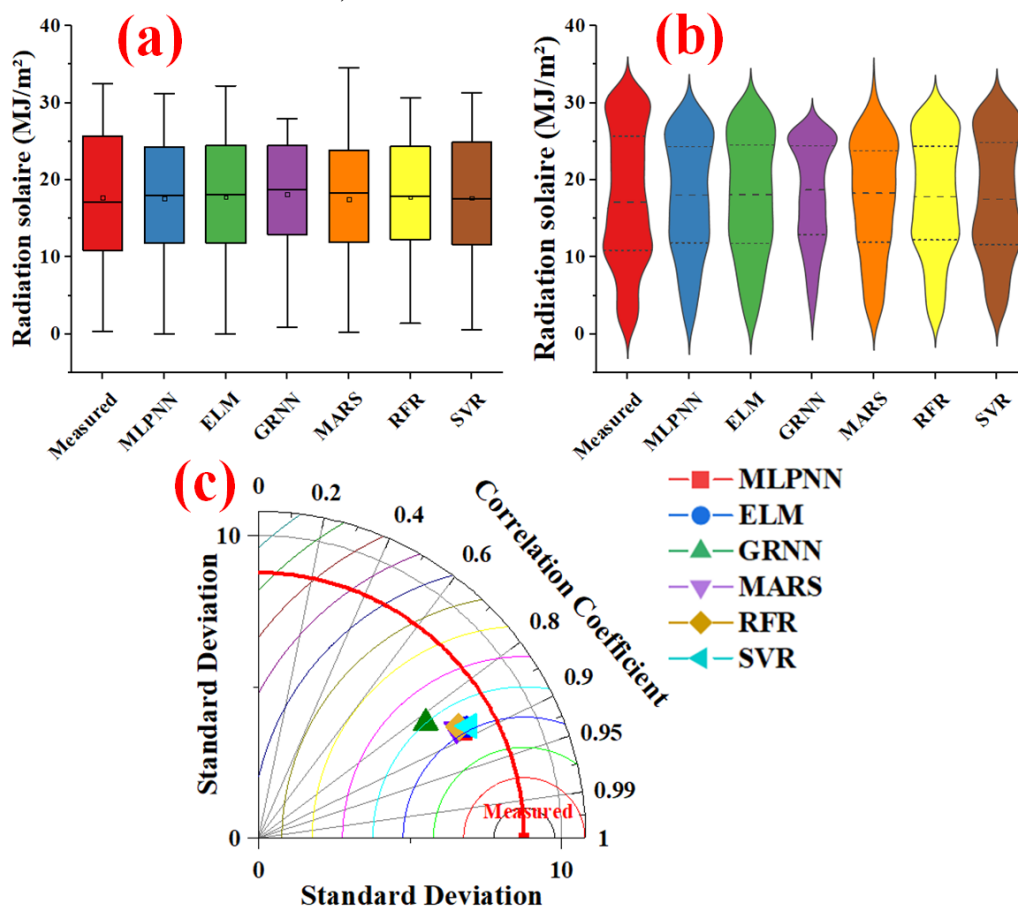


Figure VII.7. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station de Mila.

Pour la station d'Oran (Tableau VII.5, Figure VII.8-9), d'une façon générale, les performances des modèles étaient faibles par rapport aux stations précédentes. Les moyennes des valeurs de R et NSE sont de l'ordre de (0.771 et 0.594), (0.761 et 0.576), (0.725 et 0.523), (0.752 et 0.562), (0.763 et 0.583), (0.770 et 0.590), pour les modèles MLPNN, ELM, GRNN, MARS, RFR et SVR, respectivement. Les différences en termes de ces moyennes sont négligeables pour tous les modèles à l'exception des modèles GRNN, qui ont donnés les plus faibles performances au niveau de la station d'Oran, et le GRNN6 ( $R \approx 0.703$ ,  $NSE \approx 0.490$ ,  $RMSE \approx 5.649$ ,  $MAE \approx 4.560$ ) assure les plus faibles résultats. Le modèle RFR1 est le plus performant au niveau de la station d'Oran avec des indices de l'ordre de ( $R \approx 0.808$ ,  $NSE \approx 0.652$ ,  $RMSE \approx 4.666$ ,  $MAE \approx 3.654$ ), suivie par le modèle MLPNN1 ( $R \approx 0.806$ ,  $NSE \approx 0.650$ ,  $RMSE \approx 4.681$ ,  $MAE \approx 3.676$ ), suivie par le modèle SVR1 ( $R \approx 0.805$ ,  $NSE \approx 0.644$ ,  $RMSE \approx 4.719$ ,  $MAE \approx 3.564$ ), suivie par le modèle ELM1 ( $R \approx 0.790$ ,  $NSE \approx 0.622$ ,  $RMSE \approx 4.859$ ,  $MAE \approx 3.770$ ), suivie par le modèle MARS1 ( $R \approx 0.773$ ,  $NSE \approx 0.592$ ,  $RMSE \approx 5.048$ ,  $MAE \approx 4.095$ ), et en dernier classe le modèle GRNN1 ( $R \approx 0.746$ ,  $NSE \approx 0.555$ ,  $RMSE \approx 5.272$ ,  $MAE \approx 4.242$ ). En ce qui concerne le nombre de variables d'entrées incluses, nous pouvons conclure que l'utilisation de plus d'entrées conduit à une amélioration des performances. Avec l'utilisation de tous les variables climatiques comme entrées (la première combinaison) nous obtenons les meilleurs résultats. En fait, la sixième combinaison d'entrées ( $T_{max}$ ,  $T_{min}$ ) est celle qui assure les plus faibles résultats, et plus précisément, les plus faibles performances pour chaque modèle ont été obtenues avec cette combinaison (MLPNN6, ELM6, GRNN6, MARS6, RFR6 et SVR6). La comparaison graphique (Figures VII.8 et VII.9) a montré que tous les modèles ont donné des faibles performances par rapport aux stations précédentes, les données prédites sont très dispersées, et présentent moins de similarités par rapport aux données mesurées.

Tableau VII.5. Résultats obtenus par les modèles traditionnels au niveau de la station d'Oran

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN1</b>	<b>0.823</b>	<b>0.676</b>	<b>4.542</b>	<b>3.559</b>	<b>0.806</b>	<b>0.650</b>	<b>4.681</b>	<b>3.676</b>
MLPNN2	0.795	0.631	4.845	3.793	0.780	0.608	4.951	3.890
MLPNN3	0.792	0.628	4.869	3.896	0.780	0.608	4.952	3.962
MLPNN4	0.780	0.609	4.990	3.890	0.771	0.594	5.041	3.954
MLPNN5	0.764	0.584	5.149	4.095	0.750	0.562	5.232	4.146
MLPNN6	0.742	0.550	5.352	4.273	0.736	0.542	5.352	4.287
<b>ELM1</b>	<b>0.827</b>	<b>0.685</b>	<b>4.481</b>	<b>3.484</b>	<b>0.790</b>	<b>0.622</b>	<b>4.859</b>	<b>3.770</b>
ELM2	0.809	0.654	4.694	3.605	0.784	0.614	4.914	3.793
ELM3	0.802	0.643	4.766	3.786	0.764	0.574	5.158	3.949
ELM4	0.794	0.630	4.856	3.758	0.743	0.545	5.336	3.975
ELM5	0.781	0.610	4.987	3.925	0.751	0.563	5.226	4.119
ELM6	0.740	0.547	5.371	4.294	0.735	0.540	5.361	4.306
<b>GRNN1</b>	<b>0.789</b>	<b>0.616</b>	<b>4.946</b>	<b>3.998</b>	<b>0.746</b>	<b>0.555</b>	<b>5.272</b>	<b>4.242</b>
GRNN2	0.759	0.570	5.235	4.233	0.731	0.532	5.409	4.321
GRNN3	0.764	0.580	5.172	4.192	0.736	0.541	5.356	4.314
GRNN4	0.728	0.524	5.508	4.466	0.713	0.503	5.571	4.493
GRNN5	0.739	0.542	5.400	4.362	0.722	0.519	5.484	4.379
GRNN6	0.715	0.506	5.609	4.552	0.703	0.490	5.649	4.560
<b>MARS1</b>	<b>0.774</b>	<b>0.598</b>	<b>5.057</b>	<b>4.086</b>	<b>0.773</b>	<b>0.592</b>	<b>5.048</b>	<b>4.095</b>
MARS2	0.766	0.586	5.135	4.032	0.756	0.571	5.178	4.078
MARS3	0.759	0.576	5.197	4.225	0.754	0.557	5.265	4.255
MARS4	0.758	0.575	5.205	4.107	0.754	0.568	5.194	4.108
MARS5	0.752	0.566	5.258	4.189	0.740	0.547	5.320	4.230
MARS6	0.738	0.545	5.386	4.298	0.733	0.538	5.376	4.296
<b>RFR1</b>	<b>0.929</b>	<b>0.852</b>	<b>3.075</b>	<b>2.357</b>	<b>0.808</b>	<b>0.652</b>	<b>4.666</b>	<b>3.645</b>
RFR2	0.922	0.839	3.204	2.424	0.779	0.606	4.960	3.819
RFR3	0.918	0.832	3.267	2.533	0.775	0.601	4.995	3.925
RFR4	0.899	0.795	3.615	2.789	0.761	0.579	5.131	4.011
RFR5	0.895	0.789	3.667	2.854	0.741	0.549	5.307	4.161
RFR6	0.879	0.763	3.884	3.043	0.715	0.509	5.539	4.387
<b>SVR1</b>	<b>0.853</b>	<b>0.728</b>	<b>4.164</b>	<b>3.044</b>	<b>0.805</b>	<b>0.644</b>	<b>4.719</b>	<b>3.564</b>
SVR2	0.821	0.672	4.573	3.346	0.786	0.615	4.906	3.677
SVR3	0.806	0.646	4.750	3.549	0.774	0.587	5.078	3.851
SVR4	0.785	0.614	4.958	3.730	0.769	0.588	5.078	3.872
SVR5	0.781	0.610	4.987	3.925	0.751	0.563	5.226	4.119
SVR6	0.740	0.547	5.371	4.294	0.735	0.540	5.361	4.306

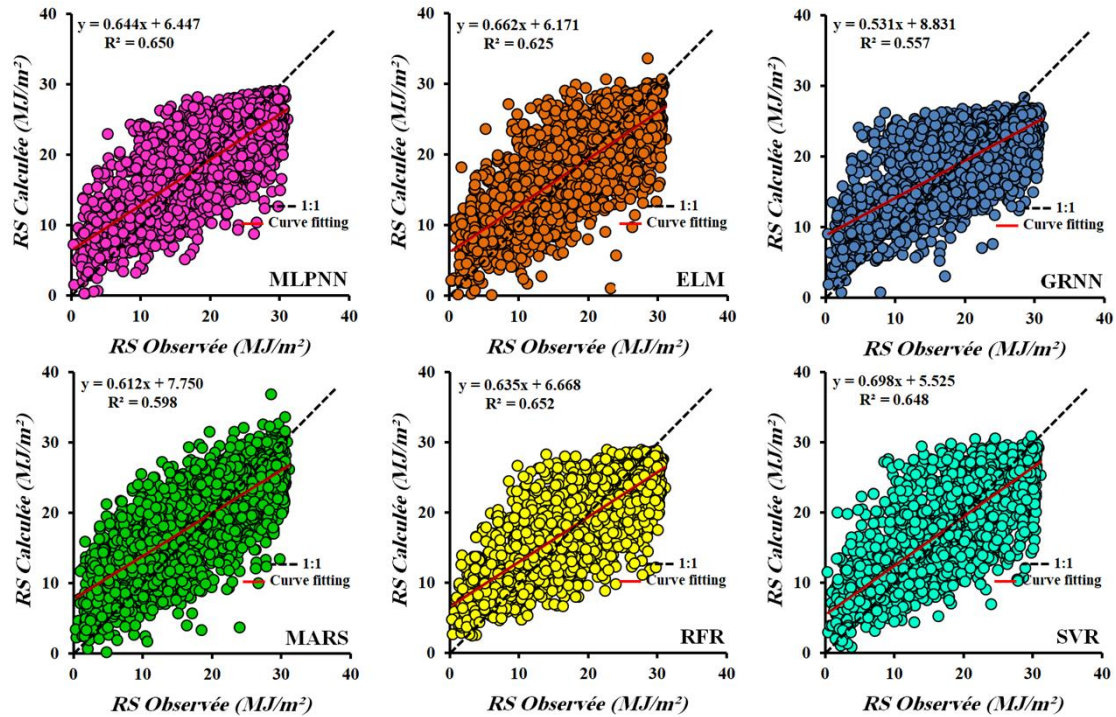


Figure VII.8. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles traditionnels, station d'Oran.

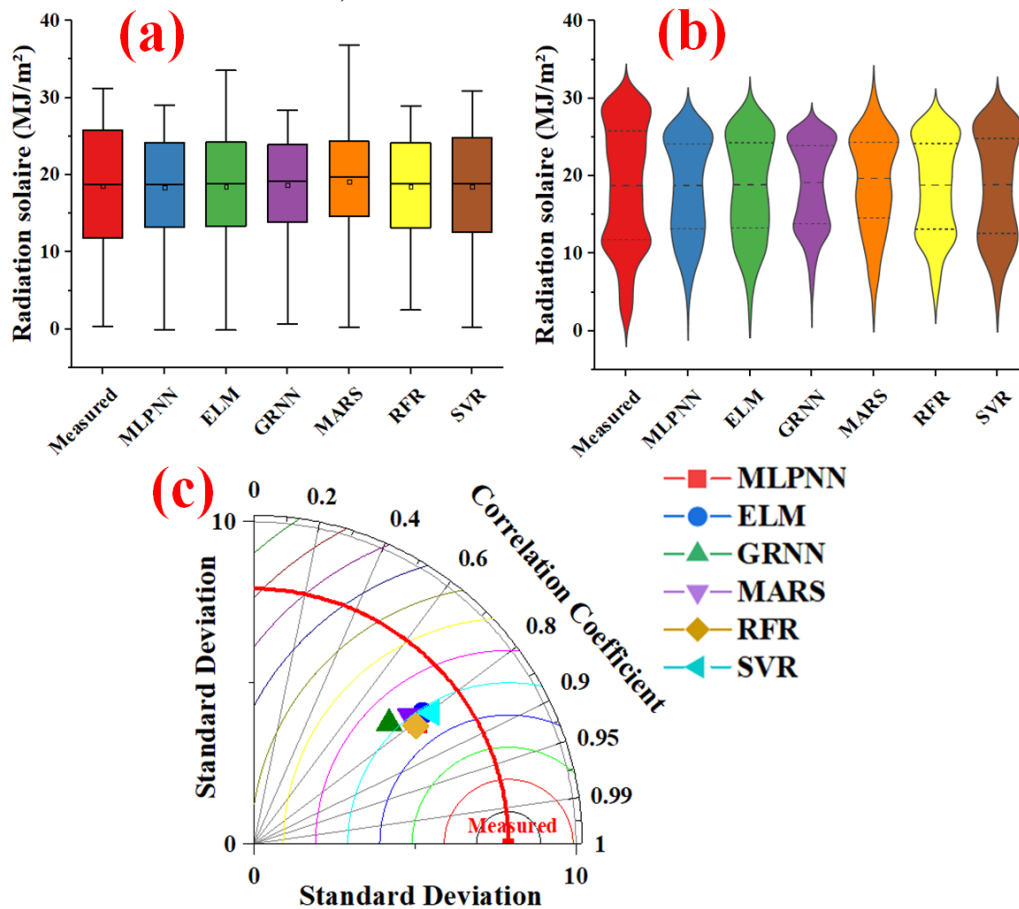


Figure VII.9. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles traditionnels, station d'Oran.

### VII.3. Modélisation de la RS par les algorithmes de décomposition du signal

Dans la deuxième partie, nous avons appliqué les techniques de décomposition du signal (EMD, EWT et VMD) pour essayer d'améliorer les performances. Les résultats obtenus par les modèles hybrides sont présentés dans les tableaux VII.6-9 et les figures VII.10-17. Nous avons discuté les résultats des meilleurs modèles hybrides pour chaque station, les résultats détaillés sont présentés en ANNEX B.

Pour la station de Guelma (Tableau VII.6, Figures VII.10-11), les résultats obtenus sont très encourageantes, et avec les algorithmes de décompositions du signal nous obtenons des améliorations des performances numériques pour la plupart des modèles hybrides par rapport aux modèles traditionnels. Pour les modèles MLPNN hybrides, les techniques de décomposition utilisées assurent des performances significatives par rapport au meilleur modèle traditionnel (MLPNN1), et les valeurs de R et NSE allant de (0.881 et 0.775) à (0.923 et 0.850) pour le MLPNN\_EMD1, et à (0.925 et 0.854) pour le MLPNN\_EWT1, et à (0.912 et 0.832) pour le MLPNN\_VMD1, et les valeurs de RMSE et MAE s'améliorent avec des taux de (18.449% et 19.460%) pour le MLPNN\_EMD1, et de (19.445% et 20.915%) pour le MLPNN\_EWT1, et de (12.948% et 15.277%) pour le MLPNN\_VMD1. Avec les modèles ELM hybrides, l'amélioration des performances des modèles ELM\_EMD6 et ELM\_EWT6 sont faibles par rapport au modèle ELM1, avec des taux d'amélioration en termes de R et NSE de l'ordre de (0.114% et 0.00%) et (1.364% et 2.842%), respectivement. Par contre, les performances du modèle ELM\_VMD5 se dégradent par rapport au modèle ELM1 avec des taux de (10.034% et 11.450%) en termes de valeurs de RMSE et MAE, respectivement. Pour les modèles GRNN et RFR hybrides, les algorithmes de décomposition du signal EMD et EWT (GRNN\_EMD6, GRNN\_EWT6, RFR\_EMD1 et RFR\_EWT1) garantissent des améliorations des performances par rapport aux modèles GRNN1 et RFR1, respectivement, tandis que, par la technique VMD (GRNN\_VMD5 et RFR\_VMD1), les performances se sont dégradées. Avec les modèles MARS hybrides, le modèle MARS\_EWT4 assure une faible amélioration par rapport au modèle MARS1, avec des taux de l'ordre de 0.846% et 3.003% en termes de RMSE et MAE, respectivement. Les autres modèles (MARS\_EMD1 et MARS\_VMD3) n'ont pas permis d'avoir aucune amélioration. Pour les modèles SVR hybrides, aucun modèle n'a permis d'obtenir des améliorations des résultats, au contraire, les techniques de décomposition du signal conduisent à une réduction des performances.

La comparaison graphique entre les modèles en utilisant les Scatterplot nous permet de conclure que les données étaient moins dispersées en utilisant les modèles MLPNN en comparaison avec les modèles SVR (Figure VII.10). Les figures VII.11a et VII.11b ont confirmé celles des Scatterplots. Le diagramme de Taylor (Figure VII.11c) montrant que les trois modèles SVR hybrides (SVR\_EMD, SVR\_EWT et SVR\_VMD) sont les moins performants.

Tableau VII.6. Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Guelma

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.954	0.911	2.701	2.047	0.923	0.850	3.439	2.657
MLPNN_EWT1	0.944	0.890	2.992	2.269	0.925	0.854	3.397	2.609
MLPNN_VMD1	0.945	0.893	2.948	2.274	0.912	0.832	3.671	2.795
ELM_EMD6	0.922	0.850	3.504	2.705	0.881	0.774	4.227	3.229
ELM_EWT6	0.929	0.862	3.353	2.561	0.892	0.796	4.019	3.100
ELM_VMD5	0.896	0.803	3.994	3.170	0.853	0.726	4.694	3.703
GRNN_EMD6	0.999	0.998	0.392	0.156	0.831	0.675	5.067	3.569
GRNN_EWT6	0.993	0.986	1.068	0.604	0.845	0.703	4.843	3.373
GRNN_VMD5	1.000	1.000	0.000	0.000	0.631	0.277	7.625	5.774
MARS_EMD1	0.856	0.733	4.672	3.667	0.853	0.728	4.636	3.674
MARS_EWT4	0.882	0.778	4.255	3.335	0.873	0.762	4.338	3.391
MARS_VMD3	0.844	0.712	4.834	3.814	0.843	0.711	4.819	3.787
RFR_EMD1	0.974	0.936	2.289	1.759	0.883	0.763	4.329	3.449
RFR_EWT1	0.977	0.947	2.078	1.569	0.908	0.814	3.833	3.000
RFR_VMD1	0.971	0.925	2.468	1.932	0.854	0.716	4.781	3.804
SVR_EMD6	0.994	0.960	1.809	1.730	0.711	0.381	6.997	5.826
SVR_EWT6	0.989	0.957	1.882	1.717	0.795	0.575	5.798	4.675
SVR_VMD6	0.995	0.947	2.081	1.938	0.231	0.001	8.961	7.746

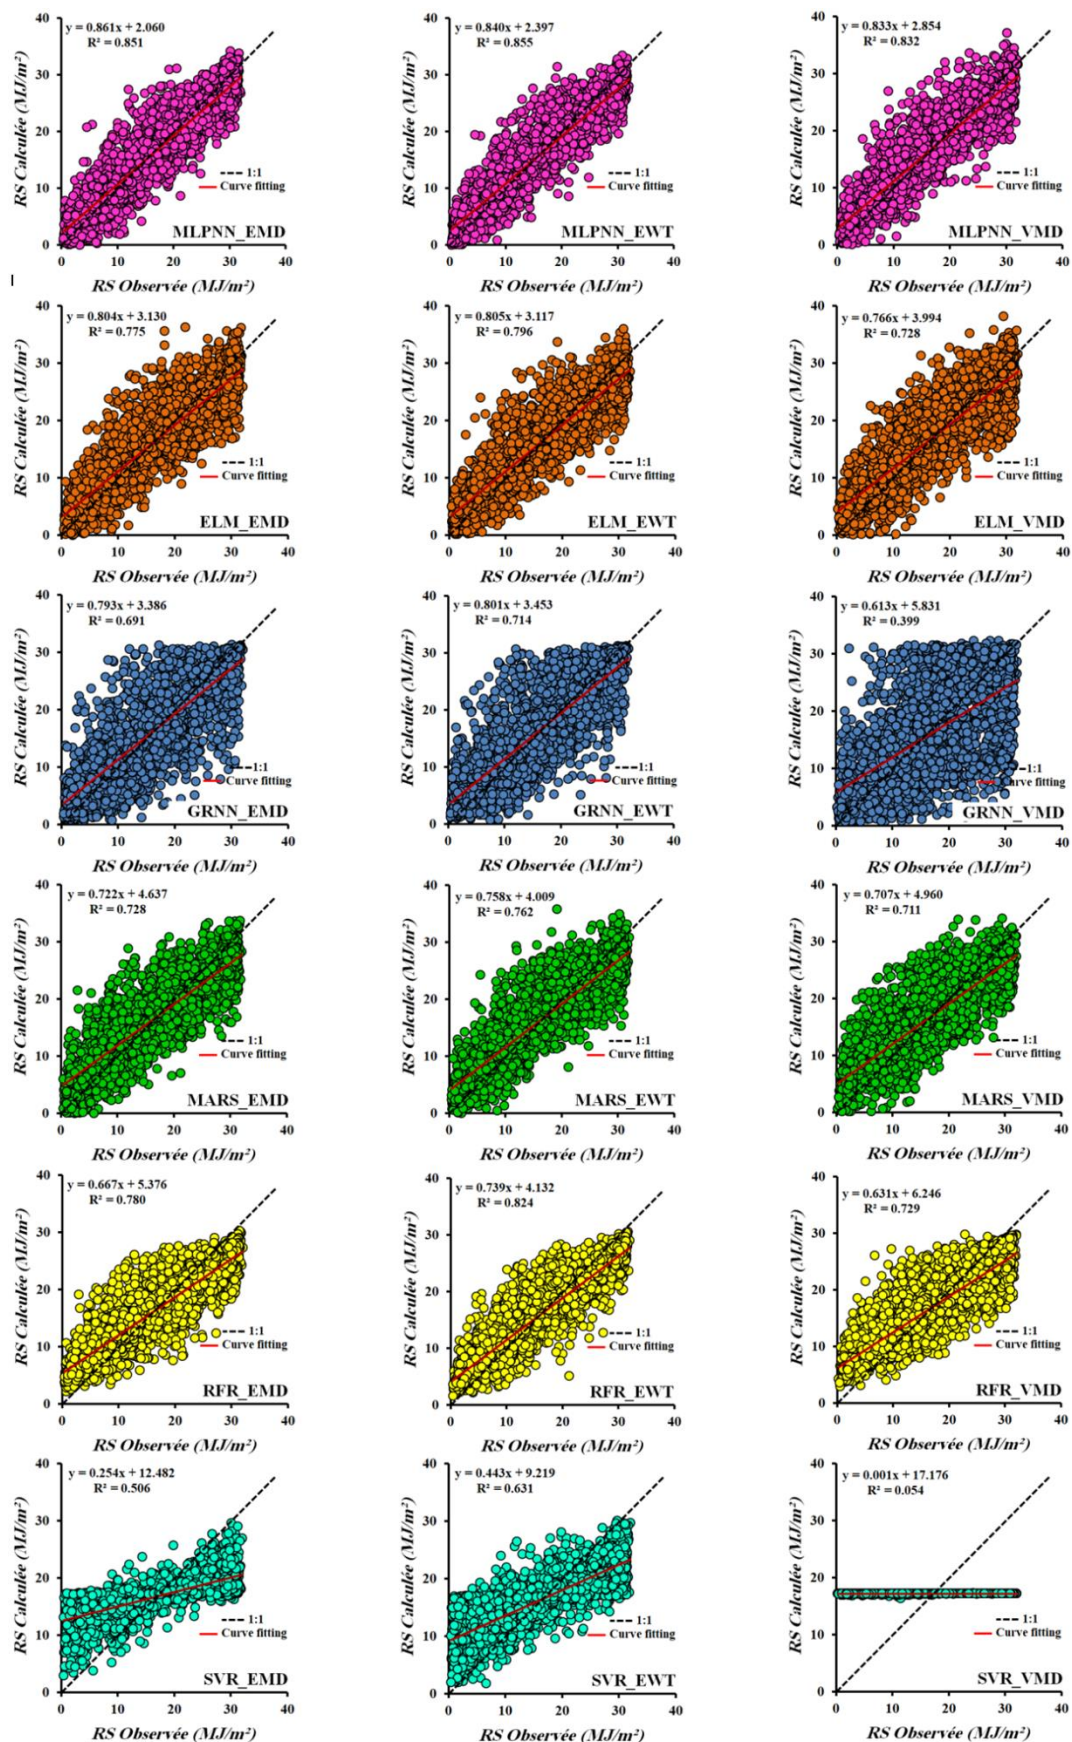


Figure VII.10. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station de Guelma.

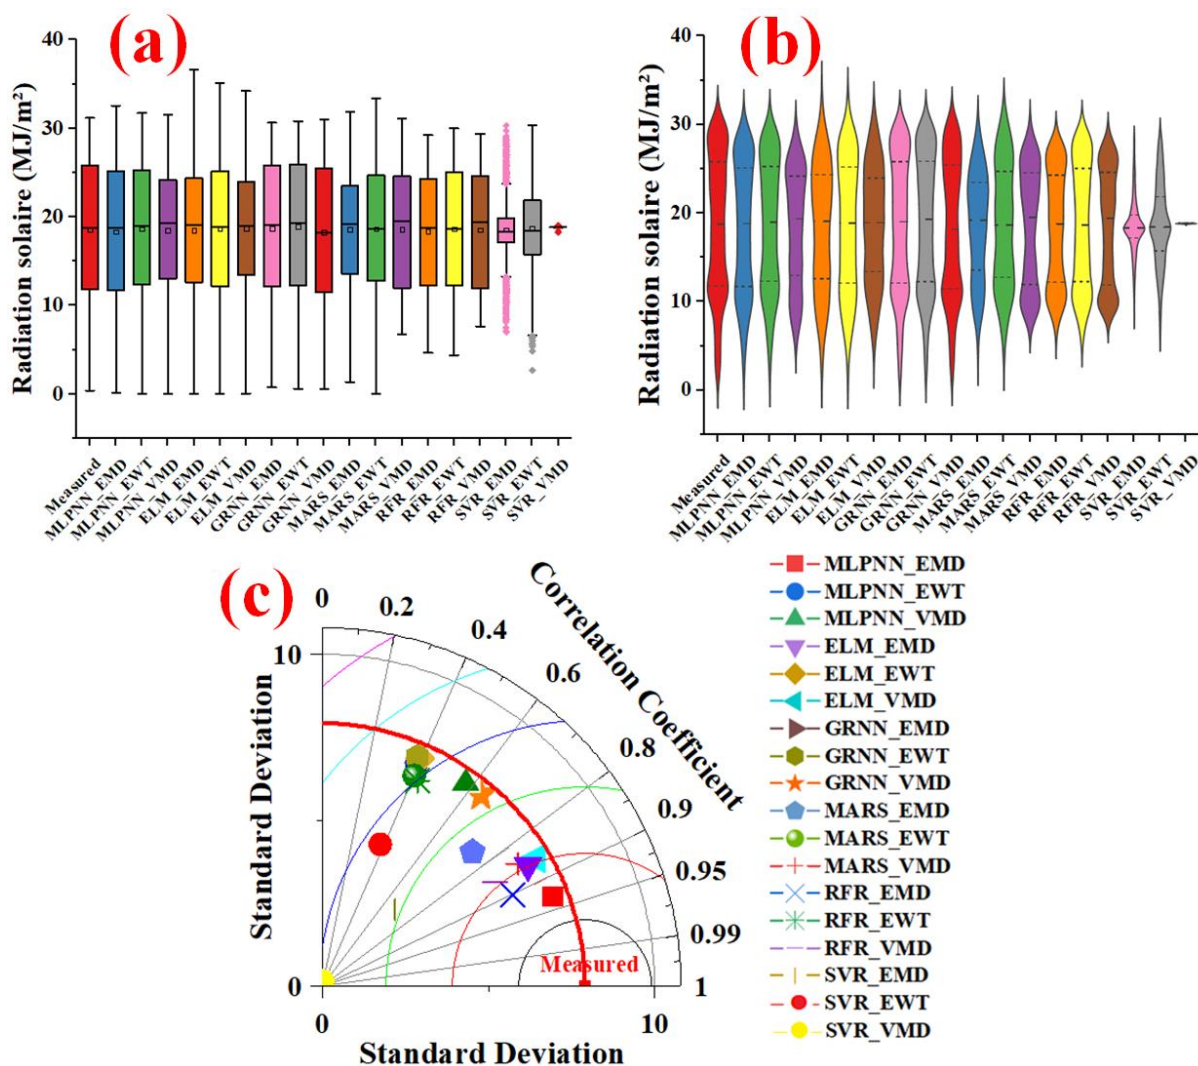


Figure VII.11. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Guelma.

Pour la station de Jijel (Tableau VII.7, Figures VII.12-13), d'une façon générale, les résultats obtenus sont satisfaisants, tous les modèles hybrides ont permis d'obtenir des améliorations des performances à l'exception des trois modèles SVR (SVR\_EMD6, SVR\_EWT6 et SVR\_VMD6), et le modèle GRNN\_VMD1. Ces quatre modèles hybrides assurent les faibles résultats, avec des R et NSE compris entre (0.273, 0.001) et (0.797, 0.592), respectivement. Pour les autres modèles hybrides, les meilleures performances sont obtenues par les modèles MLPNN, et le MLPNN\_EWT3 assure les meilleurs résultats avec des indices numériques de ( $R \approx 0.922$ ,  $NSE \approx 0.849$ ,  $RMSE \approx 3.375$ ,  $MAE \approx 2.487$ ), et avec des taux d'amélioration en termes de R, NSE, RMSE et MAE de 10.684%, 22.334%, 30.398% et 34.946%, respectivement, par rapport au modèle MLPNN2.

Les modèles hybrides ELM, MARS et RFR assurent des améliorations des performances par rapport aux modèles traditionnels, et le modèle MARS\_EWT1 est le plus performant avec des taux d'amélioration des performances en termes de RMSE et MAE de 32.332% et 36.627%, par rapport au modèle MARS2, respectivement, suivie par le modèle RFR\_EWT1 avec des taux d'amélioration en termes de RMSE et MAE de 27.496% et 31.818%, par rapport au modèle RFR1, respectivement, suivie par le modèle ELM\_EWT5 avec des taux d'amélioration en termes de RMSE et MAE de 18.332% et 21.124%, par rapport au modèle ELM2, respectivement. Pour les modèles GRNN hybrides, malgré que les améliorations obtenues pour les deux modèles GRNN\_EMD3 et GRNN\_EWT5, les performances restent faibles. Les valeurs de R et NSE passent aux valeurs (0.782 et 0.606) du modèle GRNN2, à (0.826 et 0.660) pour le modèle GRNN\_EMD3, et aux valeurs (0.845 et 0.699) pour le modèle GRNN\_EWT5.

Tableau VII.7. Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Jijel

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD3	0.945	0.893	2.859	2.118	0.915	0.837	3.540	2.569
MLPNN_EWT3	0.937	0.878	3.067	2.254	0.922	0.849	3.375	2.487
MLPNN_VMD2	0.928	0.857	3.293	2.564	0.907	0.819	3.742	2.918
ELM_EMD3	0.914	0.836	3.535	2.735	0.864	0.742	4.450	3.390
ELM_EWT5	0.923	0.852	3.374	2.581	0.890	0.791	3.965	3.017
ELM_VMD3	0.884	0.781	4.082	3.242	0.839	0.702	4.792	3.781
GRNN_EMD3	1.000	1.000	0.083	0.017	0.826	0.660	5.114	3.366
GRNN_EWT5	0.997	0.993	0.715	0.350	0.845	0.699	4.758	3.114
GRNN_VMD1	1.000	1.000	0.000	0.000	0.649	0.293	7.388	5.542
MARS_EMD1	0.842	0.708	4.713	3.715	0.840	0.705	4.762	3.767
MARS_EWT1	0.939	0.881	3.019	2.238	0.920	0.846	3.403	2.514
MARS_VMD3	0.849	0.721	4.606	3.541	0.850	0.723	4.623	3.569
RFR_EMD1	0.973	0.938	2.172	1.597	0.887	0.776	4.148	3.158
RFR_EWT1	0.975	0.945	2.051	1.481	0.915	0.830	3.573	2.655
RFR_VMD1	0.971	0.928	2.340	1.762	0.865	0.741	4.472	3.442
SVR_EMD6	0.993	0.957	1.819	1.707	0.693	0.361	7.006	5.892
SVR_EWT6	0.985	0.951	1.941	1.711	0.797	0.592	5.542	4.403
SVR_VMD6	0.994	0.947	2.013	1.843	0.273	0.001	8.779	7.637

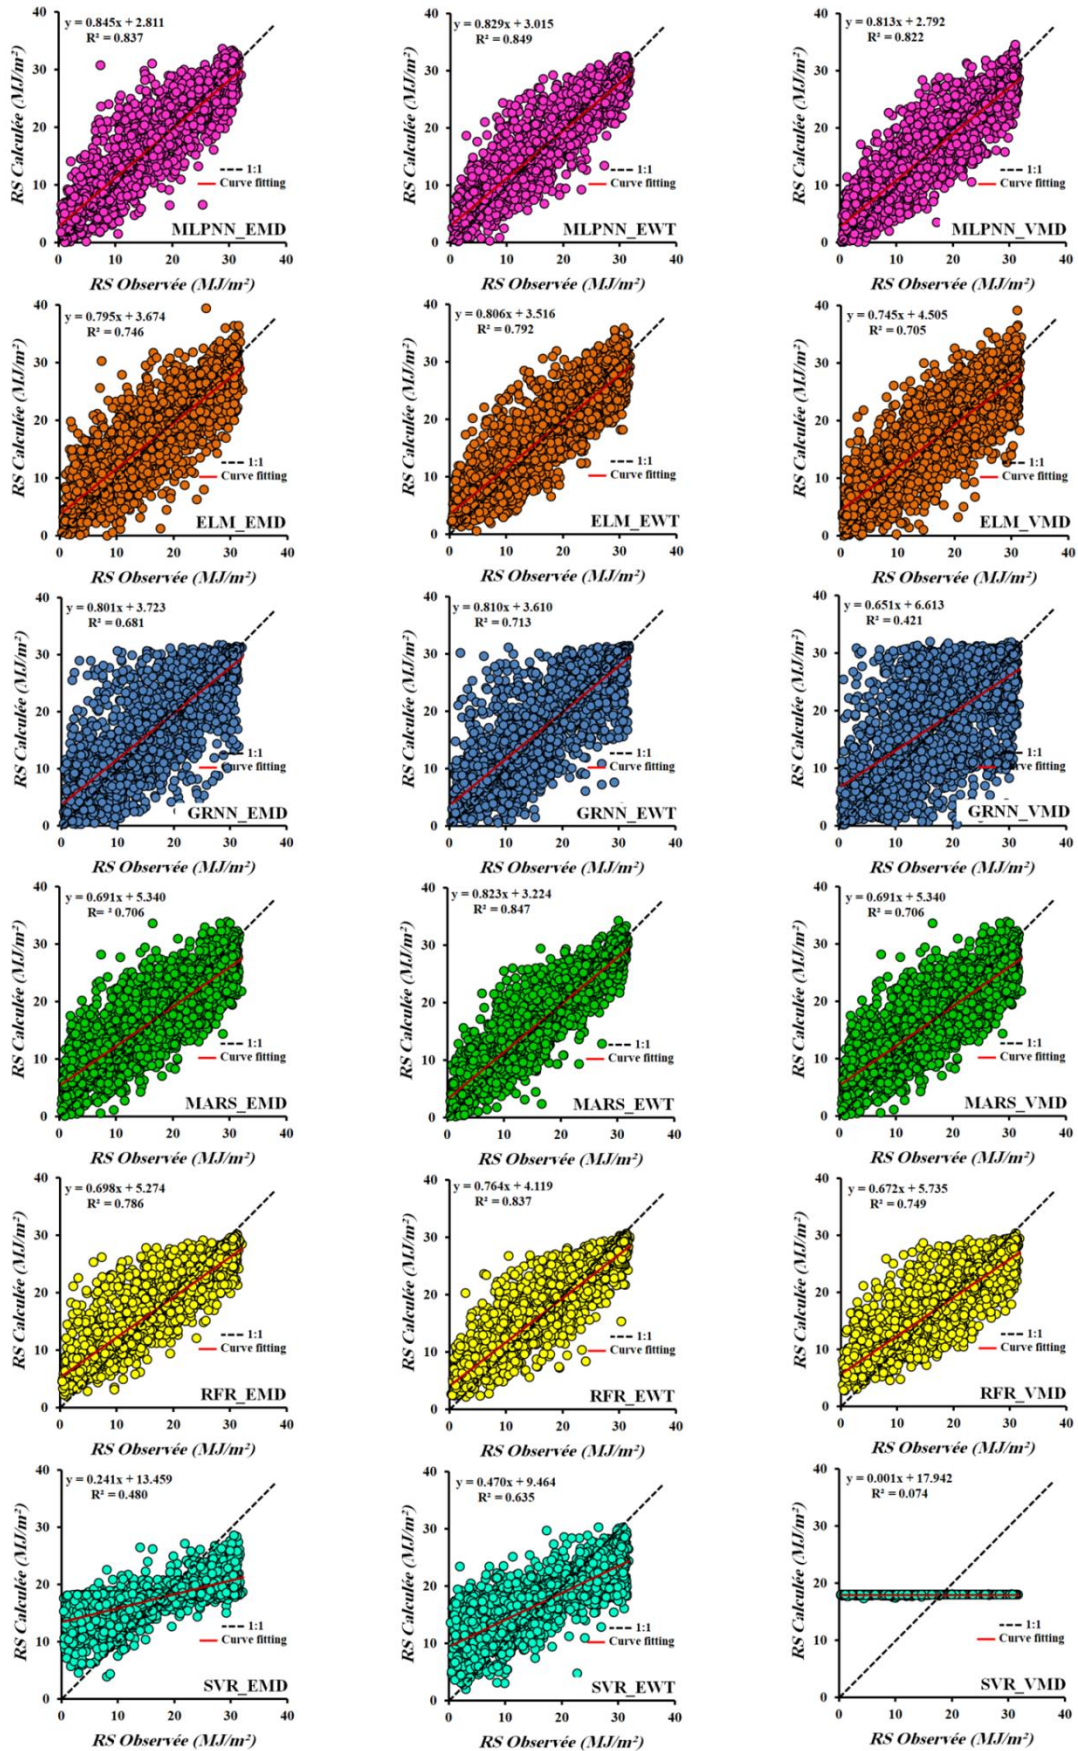


Figure VII.12. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station de Jijel.

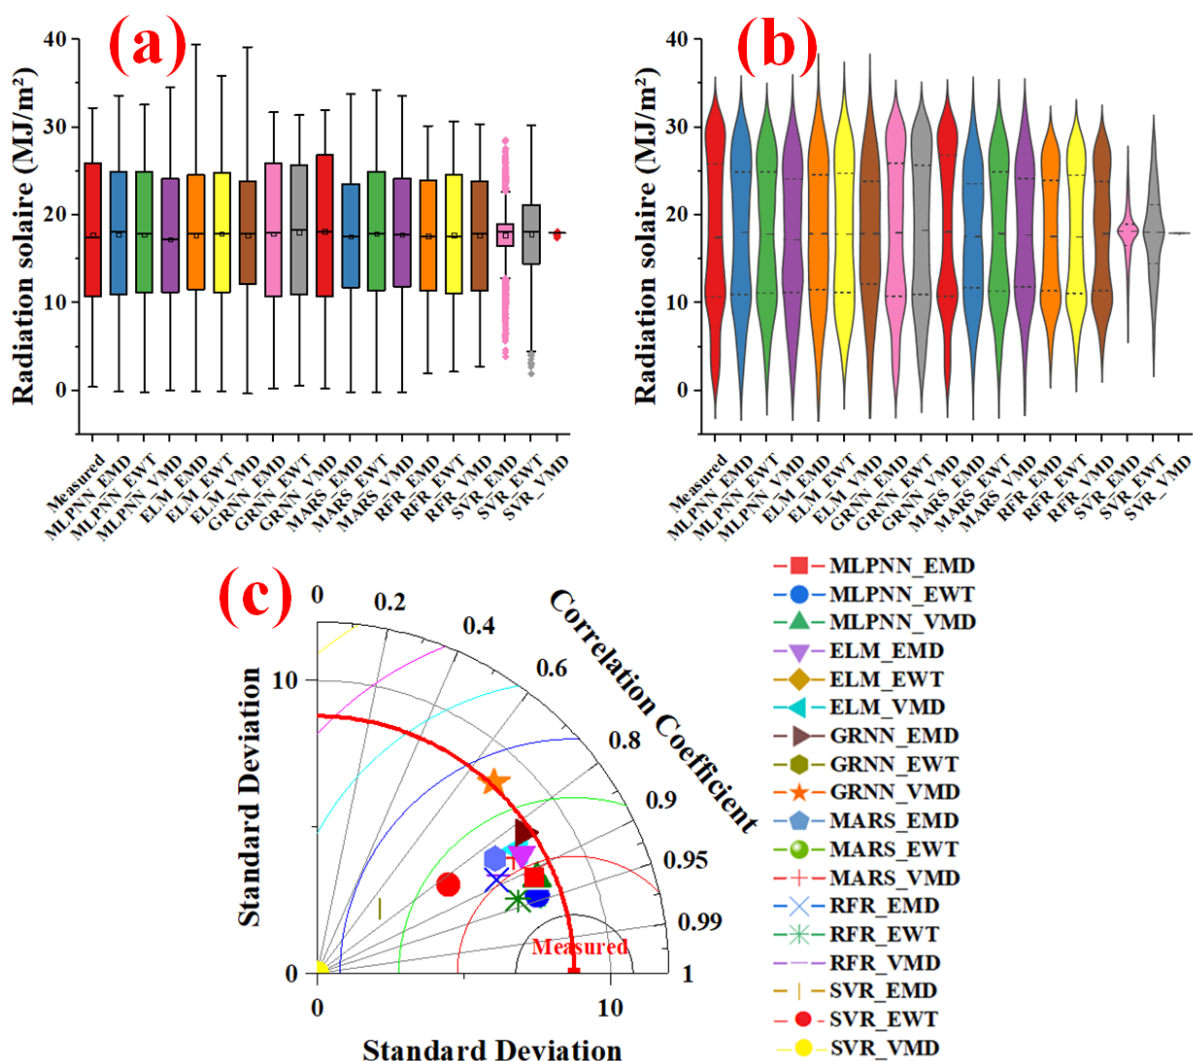


Figure VII.13. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Jijel.

Au niveau de la station de Mila (Tableau VII.8, Figures VII.14-15), les résultats sont similaires à celles obtenus au niveau des deux stations précédentes, la supériorité des modèles MLPNN hybrides avec l'utilisation de la première combinaison d'entrée ( $T_{max}$ ,  $T_{min}$ , P,  $U_2$ , HR) est claire, les meilleures performances sont obtenues avec le modèle MLPNN\_EMD1 ( $R \approx 0.927$ ,  $NSE \approx 0.860$ ,  $RMSE \approx 3.282$ ,  $MAE \approx 2.460$ ), suivie par le modèle MLPNN\_EWT1 ( $R \approx 0.924$ ,  $NSE \approx 0.853$ ,  $RMSE \approx 3.319$ ,  $MAE \approx 2.495$ ), suivie par le modèle MLPNN\_VMD1 ( $R \approx 0.913$ ,  $NSE \approx 0.833$ ,  $RMSE \approx 3.554$ ,  $MAE \approx 2.709$ ), et avec des taux de réductions en termes de RMSE et MAE par rapport au meilleur modèle traditionnel (MLPNN1) de (19.361% et 23.005%), (18.452% et 21.909%) et (12.678% et 15.211%) pour le MLPNN\_EMD1, le MLPNN\_EWT1 et le MLPNN\_VMD1, respectivement.

Pour les modèles hybrides ELM, GRNN et RFR, les performances s'améliorent par l'utilisation des Algorithmes EMD et EWT, par contre, l'algorithme VMD conduit à des dégradations par rapport aux meilleurs modèles simples ELM2, GRNN1 et RFR2. Avec les modèles MARS hybrides, le modèle MARS\_VMD2 assure les meilleures performances par un taux d'amélioration par rapport au modèle MARS1 en termes de R, NSE, RMSE et MAE de l'ordre de 4.110%, 8.486%, 15.495% et 18.333%, respectivement. Pour les modèles SVR hybrides nous avons obtenus les plus faibles performances, et aucun modèle n'a permis d'obtenir des améliorations par rapport au meilleur modèle traditionnel (SVR1), par contre, l'utilisation des techniques de décomposition du signal conduit à des réductions des performances et les R et NSE se dégradent: de (0.882 et 0.778) aux (0.714 et 0.400) pour le SVR\_EMD6, de (0.776 et 0.524) pour le SVR\_EWT6, et de (0.292 et 0.003) pour le SVR\_VMD6.

Tableau VII.8. Résultats obtenus par les meilleurs modèles hybrides au niveau de la station de Mila

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.949	0.899	2.781	2.082	0.927	0.860	3.282	2.460
MLPNN_EWT1	0.948	0.898	2.805	2.101	0.924	0.853	3.319	2.495
MLPNN_VMD1	0.949	0.899	2.787	2.133	0.913	0.833	3.554	2.709
ELM_EMD5	0.921	0.848	3.412	2.643	0.885	0.782	4.094	3.158
ELM_EWT3	0.928	0.861	3.275	2.521	0.891	0.793	3.937	3.055
ELM_VMD6	0.907	0.823	3.691	2.908	0.855	0.729	4.533	3.559
GRNN_EMD3	1.000	1.000	0.102	0.023	0.824	0.657	5.135	3.448
GRNN_EWT6	0.994	0.988	0.944	0.508	0.841	0.696	4.775	3.286
GRNN_VMD2	1.000	1.000	0.000	0.000	0.650	0.309	7.239	5.457
MARS_EMD1	0.870	0.758	4.309	3.380	0.865	0.749	4.393	3.466
MARS_EWT6	0.887	0.787	4.055	3.116	0.880	0.774	4.122	3.175
MARS_VMD2	0.940	0.883	2.997	2.311	0.912	0.831	3.583	2.753
RFR_EMD1	0.974	0.939	2.153	1.635	0.896	0.792	3.997	3.094
RFR_EWT1	0.977	0.949	1.978	1.469	0.909	0.822	3.654	2.834
RFR_VMD1	0.973	0.934	2.260	1.713	0.864	0.739	4.451	3.472
SVR_EMD6	0.993	0.957	1.813	1.699	0.714	0.400	6.792	5.629
SVR_EWT6	0.989	0.955	1.873	1.700	0.776	0.542	5.859	4.704
SVR_VMD6	0.994	0.942	2.107	1.915	0.292	0.003	8.697	7.492

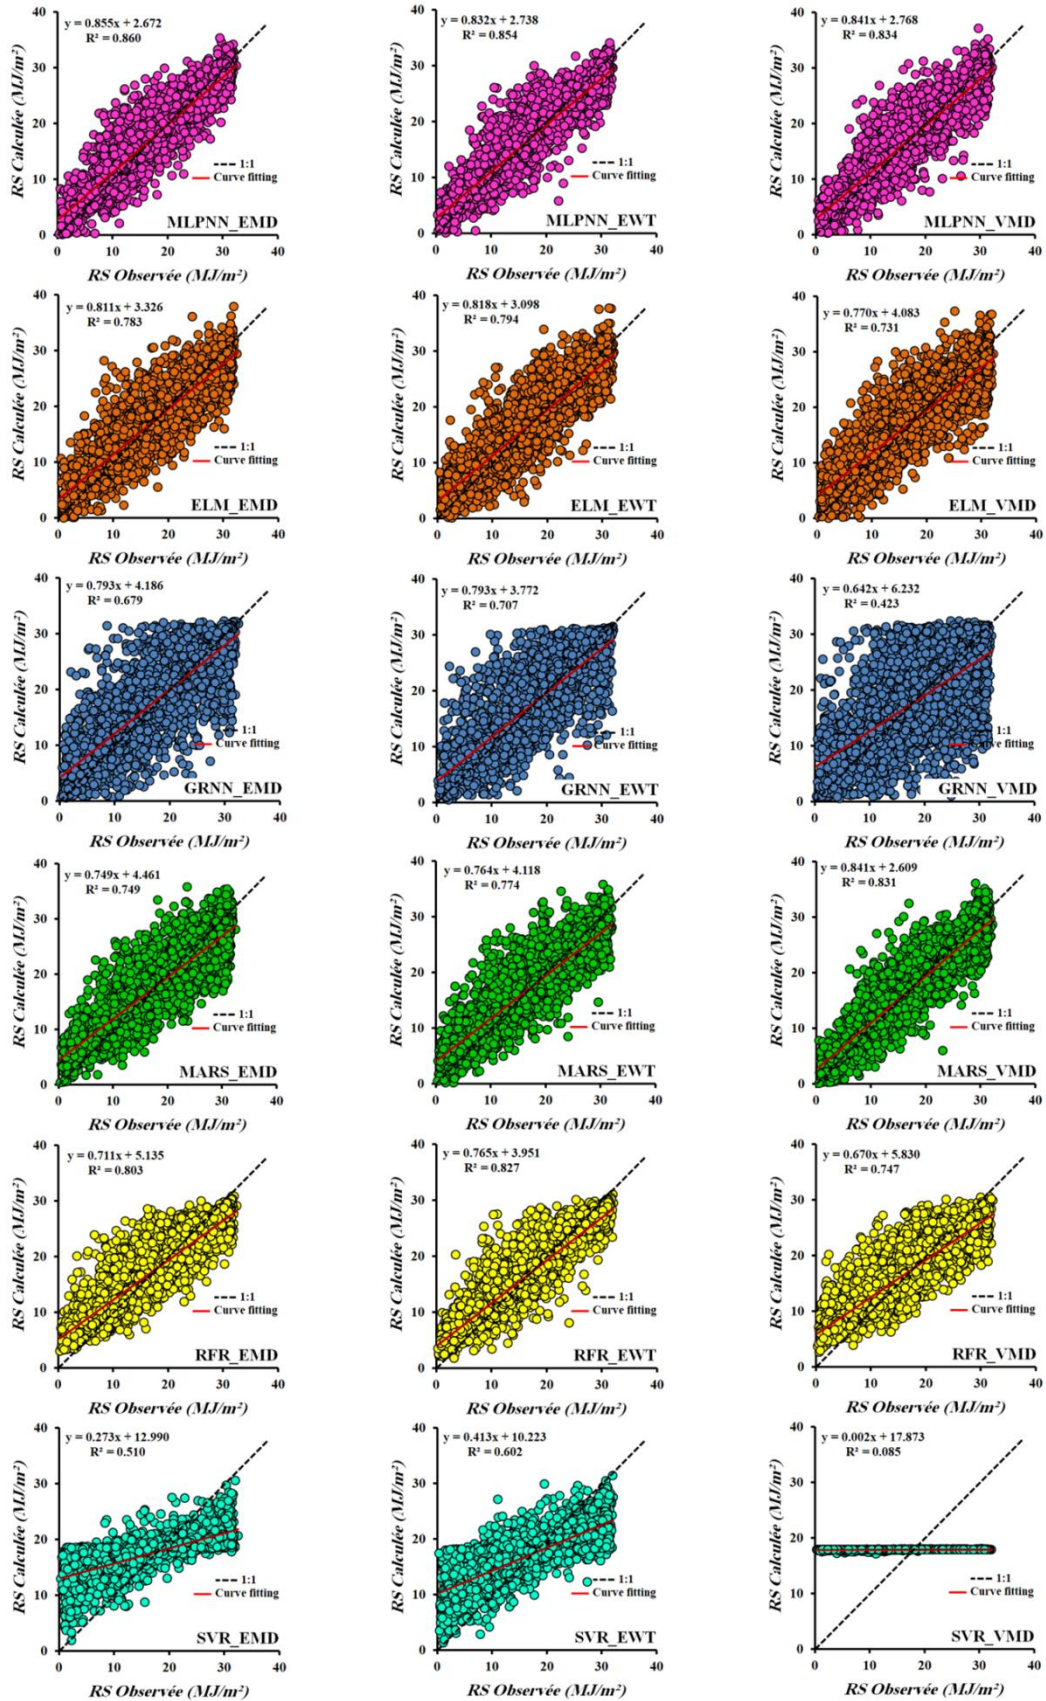


Figure VII.14. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station de Mila

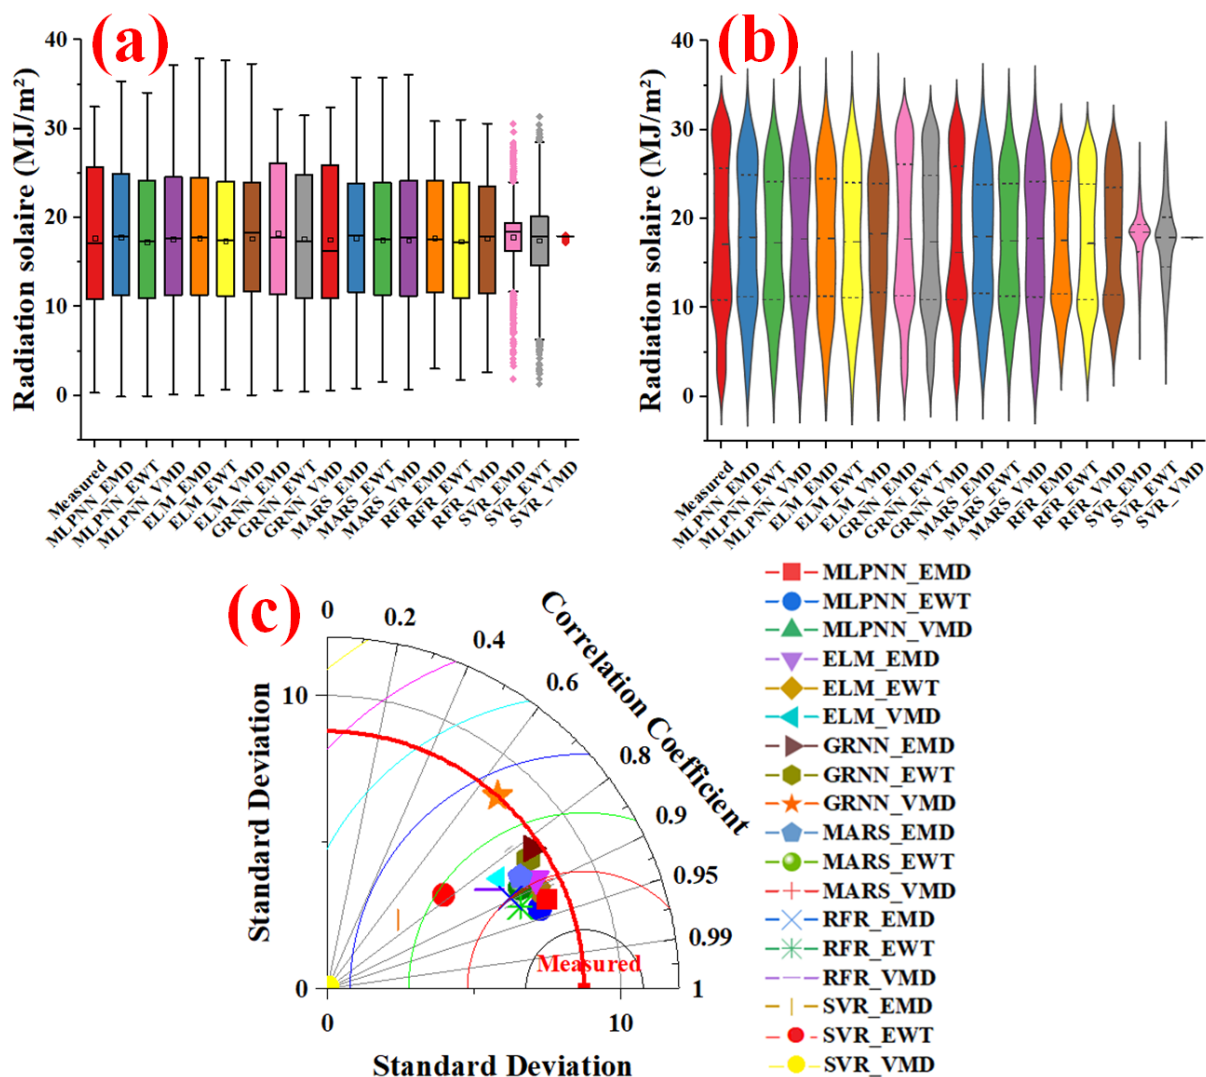


Figure VII.15. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation: (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station de Mila

Au niveau de la station d'Oran (Tableau VII.9, Figures VII.16-17), les meilleurs résultats de tous les modèles hybrides sont obtenus lorsqu'on utilise l'algorithme de décomposition du signal EWT. Le meilleur modèle au niveau de la station est le MLPNN\_EWT3 qui utilise la troisième combinaison d'entrée ( $T_{max}$ ,  $T_{min}$ , P, HR), ce qui explique l'effet mineur de la vitesse du vent ( $U_2$ ). Les taux d'amélioration en termes de R, NSE, RMSE et MAE, par rapport au modèle MLPNN1, sont de l'ordre de 15.881%, 34.308%, 39.821% et 46.736%, respectivement. Lorsqu'en utilisant l'algorithme EMD, les performances s'améliorent pour tous les modèles hybrides à l'exception du modèle SVR\_EMD6, les meilleurs résultat par cette algorithme sont obtenu par le modèle MLPNN\_EMD1 ( $R \approx 0.932$ ,  $NSE \approx 0.868$ ,  $RMSE \approx 2.868$ ,  $MAE \approx 2.049$ ), suivie par le modèle RFR\_EMD1 ( $R \approx 0.902$ ,  $NSE \approx 0.803$ ,  $RMSE \approx 3.514$ ,  $MAE \approx 2.553$ ), suivie par le modèle GRNN\_EMD3 ( $R \approx 0.869$ ,  $NSE \approx 0.747$ ,

RMSE $\approx$ 3.973, MAE $\approx$ 2.443), suivie par le modèle ELM\_EMD4 (R $\approx$ 0.862, NSE $\approx$ 0.741, RMSE $\approx$ 4.022, MAE $\approx$ 3.056), suivie par le modèle MARS\_EMD1 (R $\approx$ 0.779, NSE $\approx$ 0.606, RMSE $\approx$ 4.965, MAE $\approx$ 3.956).

Pour les modèles hybrides basés sur l'algorithme VMD, seuls les modèles MARS et RFR ont assuré des améliorations des performances, tandis que les performances des autres modèles (MLPNN, ELM, GRNN, et SVR) se sont significativement dégradées, et le SVR\_VMD6 assure les plus faibles performances au niveau de la station d'Oran avec des indices numérique de l'ordre de (R $\approx$ 0.321, NSE $\approx$ 0.011, RMSE $\approx$ 8.051, MAE $\approx$ 6.998). Les Scatterplots (Figure VII.16) présentent des grandes dispersions des données pour plusieurs modèles, surtout lorsqu'en utilisant les modèles basés sur l'algorithme VMD. Le boxplot (Figure VII.17a) et le violin plot (Figure VII.17b) présentent une grande dissimilitude des données prédites par les deux modèles SVR hybrides basés sur l'EMD et le VMD et le modèle GRNN\_VMD par rapport aux données mesurées, le diagramme de Taylor (Figure VII.17c) a confirmé cette remarque, montrant que ces trois modèles hybrides ont donné les faibles performances au niveau de la station d'Oran.

Tableau VII.9. Résultats obtenus par les meilleurs modèles hybrides au niveau de la station d'Oran

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.957	0.915	2.325	1.664	0.932	0.868	2.868	2.049
MLPNN_EWT3	0.950	0.902	2.500	1.771	0.934	0.873	2.817	1.958
MLPNN_VMD1	0.838	0.701	4.318	3.238	0.795	0.631	4.917	3.667
ELM_EMD4	0.907	0.822	3.367	2.581	0.862	0.741	4.022	3.056
ELM_EWT5	0.932	0.869	2.887	2.148	0.901	0.810	3.445	2.512
ELM_VMD2	0.818	0.669	4.546	3.488	0.730	0.527	5.567	4.215
GRNN_EMD3	1.000	1.000	0.169	0.028	0.869	0.747	3.973	2.443
GRNN_EWT6	0.989	0.979	1.159	0.562	0.887	0.782	3.687	2.272
GRNN_VMD5	1.000	1.000	0.000	0.000	0.554	0.141	7.503	5.733
MARS_EMD1	0.796	0.634	4.827	3.863	0.779	0.606	4.965	3.956
MARS_EWT1	0.868	0.754	3.962	3.010	0.868	0.753	3.930	2.917
MARS_VMD1	0.820	0.672	4.522	3.311	0.811	0.657	4.740	3.464
RFR_EMD1	0.973	0.942	1.915	1.289	0.902	0.803	3.514	2.553
RFR_EWT1	0.978	0.952	1.752	1.180	0.924	0.849	3.068	2.112
RFR_VMD1	0.960	0.910	2.369	1.646	0.830	0.687	4.532	3.299
SVR_EMD6	0.990	0.950	1.792	1.592	0.687	0.391	6.170	5.044
SVR_EWT6	0.984	0.946	1.861	1.583	0.811	0.606	4.961	3.851
SVR_VMD6	0.993	0.940	1.942	1.710	0.321	0.011	8.051	6.998

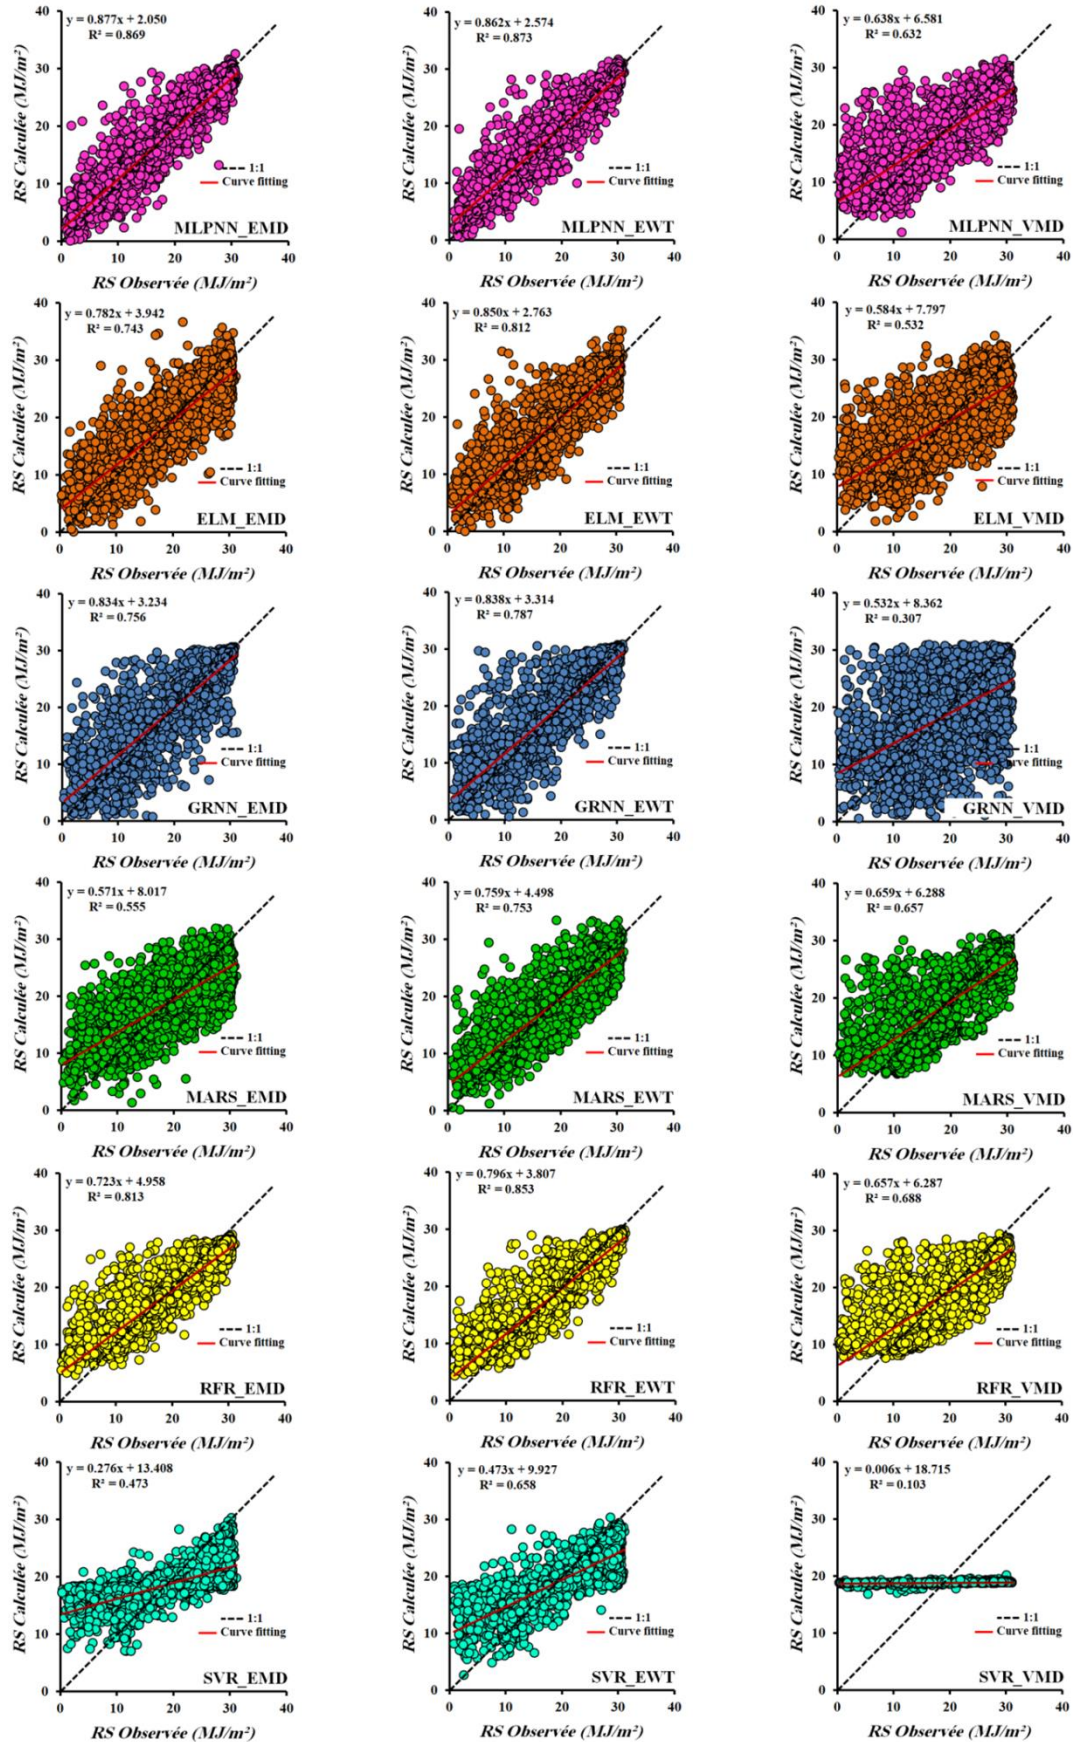


Figure VII.16. Scatterplots des valeurs mesurées et calculées de la RS durant la phase de validation: modèles hybrides, station d'Oran

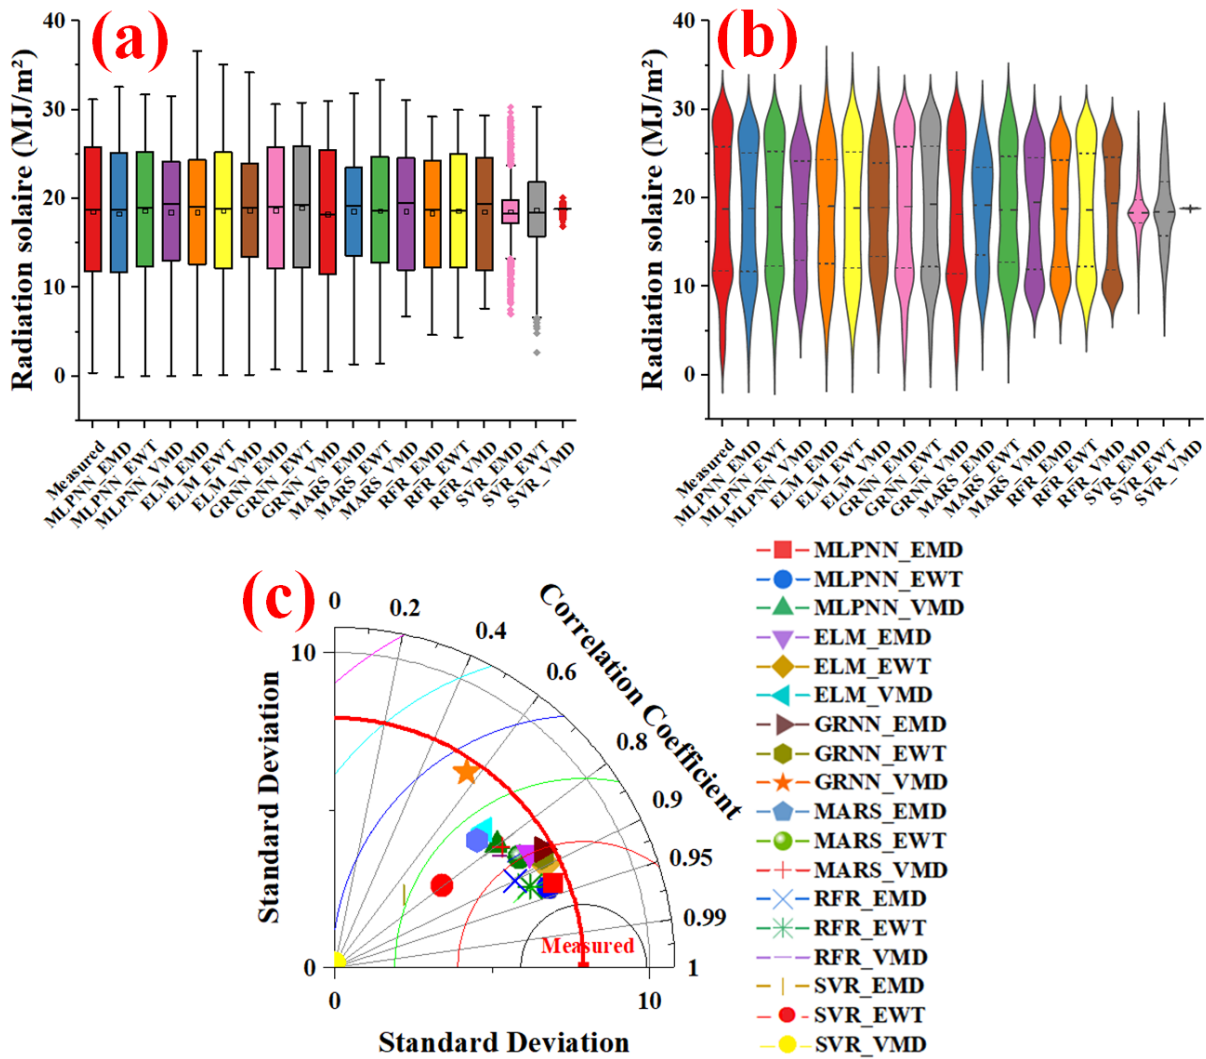


Figure VII.17. Graphiques montrant la comparaison entre la RS mesurée et calculée durant la phase de validation : (a) boxplot, (b) violin plot et (c) diagramme de Taylor: modèles hybrides, station d'Oran

## VII.4. Conclusion

À travers le présent chapitre, nous avons gardé les mêmes approches utilisées dans le chapitre précédent, les résultats de modélisation de la RS par les modèles traditionnels et hybrides sont présentés et discutés. De même, les données de quatre stations situées dans le nord et la région semi-aride de l'Algérie ont été exploitées.

- (i) Premièrement, lorsque l'on modélise la RS par les six modèles traditionnels (MLPNN, ELM, GRNN, MARS, RFR et SVR), les résultats que nous avons obtenus étaient faibles, aucun modèle n'a atteint un coefficient de corrélation de (0.9) durant la phase de validation dans les quatre stations. Comme nous l'avons vu dans le chapitre précédent, les meilleurs résultats ont été obtenus en utilisant la première combinaison d'entrée, par contre, il n'y a pas de modèle prédominant.

- (ii) Deuxièmement, lorsqu'en utilisant des modèles hybrides basés sur les algorithmes de décomposition du signal, tous les stations ont obtenu des résultats meilleurs que ceux des modèles traditionnels avec des coefficients de corrélations supérieurs à (0.9), et la plus grande amélioration des performances est assurée par les modèles MLPNN, surtout lorsqu'ils sont combinés avec l'algorithme EWT.
- (iii) Les facteurs les plus influents des performances de la modélisation de la RS sont principalement la température maximale, suivis par l'HR.

## *Conclusion Générale*

---

## Conclusion Générale

L'humidité relative et la radiation solaire sont parmi les variables climatiques les plus critiques pour les études agronomiques, hydrologiques et climatiques. Ces deux variables affectent d'autres variables climatiques et ont également un impact l'un sur l'autre. Dans la présente thèse, des données climatiques de huit stations, à savoir: Alger, Annaba, Constantine, Sétif, Guelma, Jijel, Mila et Oran, ont été utilisées. Pour chaque branche de modélisation (i.e., RH ou HR) nous utilisons deux stations au nord et deux stations dans la région semi-aride de l'Algérie. Le premier apport de cette thèse est un état de l'art sur les travaux de recherches publiées à l'échelle mondiale sur la modélisation de l'humidité relative (HR) et les recherches publiées au niveau nationale sur la modélisation de la RS par l'outil de l'intelligence artificielle (IA). La deuxième contribution est la comparaison des résultats de modélisation de l'HR et la RS obtenus par les modèles traditionnels simples d'IA qui appliquent la modélisation directement sur les données climatiques, à savoir: MLPNN, ELM, GRNN, MARS, RFR et SVR, par rapport à celles obtenus par les modèles d'IA hybrides basés sur le prétraitement par la décomposition du signal, à savoir: EMD, EWT et VMD.

Pour la modélisation de l'HR, les performances obtenues par les six modèles traditionnels fluctuent d'une station à l'autre. Généralement, ces résultats étaient encourageants, surtout au niveau des stations de Constantine et Sétif, avec un coefficient de corrélation qui atteint ( $R \approx 0.94$ ). De plus, le modèle MLPNN était le plus performant que les autres modèles, par contre, le modèle GRNN garantit les faibles résultats pour toutes les stations. Avec l'utilisation des algorithmes de décompositions du signal, les performances de plusieurs modèles sont améliorées significativement, surtout lorsque on utilise l'algorithme EWT. D'une façon générale, Les résultats obtenus démontrent le potentiel de la méthodologie d'hybridation pour la modélisation de l'HR.

Pour la deuxième branche de modélisation (i.e., RS), les résultats obtenus par les six modèles traditionnels étaient faibles, aucun modèle n'a atteint un coefficient de corrélation de ( $R \approx 0.90$ ) durant la phase de validation dans les quatre stations. Cependant, avec l'utilisation des techniques d'hybridations basées sur les algorithmes de décomposition du signal, tous les stations ont obtenu des résultats meilleurs que les modèles traditionnels avec des coefficients de corrélations supérieurs à ( $R \approx 0.90$ ), et la plus grande amélioration des performances est assurée par les modèles MLPNN, surtout lorsqu'ils sont combinés avec l'algorithme EWT.

## **Perspectives:**

La réalisation de cette thèse a révélé des perspectives d'amélioration auxquelles il semble judicieux de s'intéresser:

- La première perspective qui vient à l'esprit est d'essayer d'adapter les modèles utilisés que ce soit simples ou hybrides, à d'autres sites tout en utilisant les mêmes entrées.
- L'hybridation des modèles simple d'IA avec les trois algorithmes de décomposition du signal donne de bonnes performances. Cependant, la combinaison effectuée doit pouvoir être amélioré notamment par l'utilisation des autres algorithmes de décomposition tels que l'algorithme MODWT (Maximum Overlap Discrete Wavelet Transform), et CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise), etc.
- L'évaluation d'autres techniques d'intelligence artificielle tels que l'apprentissage profond (Deep Learning), les modèles de la logique floue, etc, et d'autre modèles d'hybridation par les algorithmes d'optimisations.
- L'utilisation des techniques de sélection des variables d'entrée, telles que la Gamma test, XGBoost, etc.
- L'étude d'autres facteurs susceptibles de contribuer à améliorer la précision des prévisions, en particulier l'éventuelle inclusion d'autres variables climatiques.

***Références bibliographiques***

---

**Références bibliographiques**

- Abayomi-Alli, A., Odusami, M. O., Abayomi-Alli, O., Misra, S., & Ibeh, G. F. (2019). Long short-term memory model for time series prediction and forecast of solar radiation and other weather parameters. In *2019 19th international conference on computational science and its applications (ICCSA)* (pp. 82-92). IEEE. <https://doi.org/10.1109/ICCSA.2019.00004>
- Abdelhafidi, N., Bachari, N. E. I., & Abdelhafidi, Z. (2021). Estimation of solar radiation using stepwise multiple linear regression with principal component analysis in Algeria. *Meteorology and Atmospheric Physics*, 133, 205-216. <https://doi.org/10.1007/s00703-020-00739-0>
- Abdeljabar, B., Rahmani, L., Mebrouk, B., & Kada, B. (2020). Estimating daily diffuse solar radiation using neuro-fuzzy, fuzzy C-means and subtractive clustering: Case study: Adrar, Algeria. In *Proceedings of the 10th International Conference on Information Systems and Technologies* (pp. 1-6). <https://doi.org/10.1145/3447568.3448516>
- Abdollahpoor, R., & Lotfivand, N. (2020). Fully adaptive denoising of ECG signals using empirical mode decomposition with the modified indirect subtraction and the adaptive window techniques. *Circuits, Systems, and Signal Processing*, 39(8), 4021-4046. <https://doi.org/10.1007/s00034-020-01350-9>
- Abdulhay, E., Alafeef, M., Alzghoul, L., Al Momani, M., Al Abdi, R., Arunkumar, N., ... & de Albuquerque, V. H. C. (2020). Computer-aided autism diagnosis via second-order difference plot area applied to EEG empirical mode decomposition. *Neural Computing and Applications*, 32, 10947-10956. <https://doi.org/10.1007/s00521-018-3738-0>
- Adnan, R. M., Heddami, S., Yaseen, Z. M., Shahid, S., Kisi, O., & Li, B. (2020). Prediction of potential evapotranspiration using temperature-based heuristic approaches. *Sustainability*, 13(1), 297. <https://doi.org/10.3390/su13010297>
- Adnan, M., Adnan, R.M., Liu, S., Saifullah, M., Latif, Y., & Iqbal, M. (2021). Prediction of relative humidity in a high elevated basin of western Karakoram by using different machine learning models. *Weather Forecasting*, 59. <https://doi.org/10.5772/intechopen.98226>

- Adnan, R. M., Mostafa, R. R., Dai, H. L., Heddami, S., Kuriqi, A., & Kisi, O. (2023). Pan evaporation estimation by relevance vector machine tuned with new metaheuristic algorithms using limited climatic data. *Engineering Applications of Computational Fluid Mechanics*, 17(1), 2192258. <https://doi.org/10.1080/19942060.2023.2192258>
- Ağbulut, Ü., Gürel, A. E., & Biçen, Y. (2021). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 135, 110114. <https://doi.org/10.1016/j.rser.2020.110114>
- Aghmadi, A., El Hani, S., Mediouni, H., Naseri, N., & El Issaoui, F. (2021). Hybrid solar forecasting method based on empirical mode decomposition and back propagation neural network. In *E3S web of conferences* (Vol. 231, p. 02001). EDP Sciences. <https://doi.org/10.1051/e3sconf/202123102001>
- Ahmad, A., Anderson, T. N., & Lie, T. T. (2015). Hourly global solar irradiation forecasting for New Zealand. *Solar Energy*, 122, 1398-1408. <https://doi.org/10.1016/j.solener.2015.10.055>
- Ahmadi, F., Nazeri Tahroudi, M., Mirabbasi, R., Khalili, K., & Jhajharia, D. (2018). Spatiotemporal trend and abrupt change analysis of temperature in Iran. *Meteorological Applications*, 25(2), 314-321. <https://doi.org/10.1002/met.1694>
- Aladenola, O. O., & Madramootoo, C. A. (2014). Evaluation of solar radiation estimation methods for reference evapotranspiration estimation in Canada. *Theoretical and Applied Climatology*, 118, 377-385. <https://doi.org/10.1007/s00704-013-1070-2>
- Alaodolehei, B., Jafarian, K., Sheikhan, A., & Beni, H. M. (2020). Performance enhancement of an achalasia automatic detection system using ensemble empirical mode decomposition denoising method. *Journal of Medical and Biological Engineering*, 40, 179-188. <https://doi.org/10.1007/s40846-019-00497-4>
- Ali, M., Prasad, R., Xiang, Y., Khan, M., Farooque, A. A., Zong, T., & Yaseen, Z. M. (2021). Variational mode decomposition based random forest model for solar radiation forecasting: new emerging machine learning technology. *Energy Reports*, 7, 6700-6717. <https://doi.org/10.1016/j.egy.2021.09.113>
- Alizamir, M., Kazemi, Z., Kazemi, Z., Kermani, M., Kim, S., Heddami, S., ... & Chung, I. M. (2023). Investigating Landfill Leachate and Groundwater Quality Prediction Using a

- Robust Integrated Artificial Intelligence Model: Grey Wolf Metaheuristic Optimization Algorithm and Extreme Learning Machine. *Water*, 15(13), 2453. <https://doi.org/10.3390/w15132453>
- Alizamir, M., Shiri, J., Fard, A. F., Kim, S., Gorgij, A. D., Heddami, S., & Singh, V. P. (2023). Improving the accuracy of daily solar radiation prediction by climatic data using an efficient hybrid deep learning model: Long short-term memory (LSTM) network coupled with wavelet transform. *Engineering Applications of Artificial Intelligence*, 123, 106199. <https://doi.org/10.1016/j.engappai.2023.106199>
- Al-Kakey, O., Al-Mukhtar, M., Berhanu, S., & Dunger, V. (2023). Assessing CFSR climate data for rainfall-runoff modeling over an ungauged basin between Iraq and Iran. *Kuwait Journal of Science*. <https://doi.org/10.1016/j.kjs.2022.12.004>
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome, 300(9), D05109.
- Alley, R. B., Emanuel, K. A., & Zhang, F. (2019). Advances in weather prediction. *Science*, 363(6425), 342-344. <https://doi.org/10.1126/science.aav7274>
- Alrashidi, M., Alrashidi, M., & Rahman, S. (2021). Global solar radiation prediction: Application of novel hybrid data-driven model. *Applied Soft Computing*, 112, 107768. <https://doi.org/10.1016/j.asoc.2021.107768>
- Ameen, B., Balzter, H., Jarvis, C., & Wheeler, J. (2019). Modelling hourly global horizontal irradiance from satellite-derived datasets and climate variables as new inputs with artificial neural networks. *Energies*, 12(1), 148. <https://doi.org/10.3390/en12010148>
- Amiri, B., Gómez-Orellana, A. M., Gutiérrez, P. A., Dizène, R., Hervás-Martínez, C., & Kahina, D. (2019). Ten Minutes Solar Irradiation Forecasting on Inclined Plane using Evolutionary Product Unit Neural Networks. In 2019 International Conference of Computer Science and Renewable Energies (ICCSRE) (pp. 1-7). IEEE. <https://doi.org/10.1109/ICCSRE.2019.8807613>
- Amiri, B., Gómez-Orellana, A. M., Gutiérrez, P. A., Dizène, R., Hervás-Martínez, C., & Dahmani, K. (2021). A novel approach for global solar irradiation forecasting on tilted

- plane using Hybrid Evolutionary Neural Networks. *Journal of Cleaner Production*, 287, 125577. <https://doi.org/10.1016/j.jclepro.2020.125577>
- Amjad, M., Asim, M., Azhar, M., Farooq, M., Ali, M. J., Ahmad, S. U., ... & Hussain, A. (2021). Improving the accuracy of solar radiation estimation from reanalysis datasets using surface measurements. *Sustainable Energy Technologies and Assessments*, 47, 101485. <https://doi.org/10.1016/j.seta.2021.101485>
- Andrade, H., Alcoforado, M. J., & Oliveira, S. (2011). Perception of temperature and wind by users of public outdoor spaces: relationships with weather parameters and personal characteristics. *International journal of biometeorology*, 55, 665-680. <https://doi.org/10.1007/s00484-010-0379-0>
- Antonanzas, J., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2015). Solar irradiation mapping with exogenous data from support vector regression machines estimations. *Energy conversion and management*, 100, 380-390. <https://doi.org/10.1016/j.enconman.2015.05.028>
- Arulmozhi, E., Basak, J.K., Sihalath, T., Park, J., Kim, H.T., & Moon, B.E. (2021). Machine learning-based microclimate model for indoor air temperature and relative humidity prediction in a swine building. *Animals*, 11(1), 222. <https://doi.org/10.3390/ani11010222>
- Asl, S. F. Z., Karami, A., Ashari, G., Behrang, A., Assareh, A., & Hedayat, N. (2011). Daily global solar radiation modeling using multi-layer perceptron (MLP) neural networks. *International Journal of Environmental and Ecological Engineering*, 5(7), 403-405.
- Asradj, Z., & Alkama, R. (2014). Prediction of solar radiation in Bejaia city using neural network (MLP). In *2014 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM)* (pp. 1-4). IEEE. <https://doi.org/10.1109/CISTEM.2014.7077057>
- Asradj, Z., & Alkama, R. (2015). MLP/Levenberg-Marquardt for Prediction Solar Radiation: A Case Study Bejaia City. In *2nd International Congress on Energy Efficiency and Energy Related Materials (ENEFM2014) Proceedings*, Oludeniz, Fethiye/Mugla, Turkey, October 16-19, 2014 (pp. 53-60). Springer International Publishing. [https://doi.org/10.1007/978-3-319-16901-9\\_7](https://doi.org/10.1007/978-3-319-16901-9_7)

- Asradj, Z., Alkama, R., & Ouali, K. (2017). Global Solar Radiation Modeling using genetic algorithm optimization for estimation of 8-min time step data in Bejaia city. *International Conference on Green Energy and Environmental Engineering (GEEE)* (PP. 84-89).
- Assas, O., Bouzgou, H., Fetah, S., Salmi, M., & Boursas, A. (2014). Use of the artificial neural network and meteorological data for predicting daily global solar radiation in Djelfa, Algeria. In 2014 International Conference on Composite Materials & Renewable Energy Applications (ICCMREA) (pp. 1-5). IEEE. <https://doi.org/10.1109/ICCMREA.2014.6843807>
- Attar, N. F., Sattari, M. T., Prasad, R., & Apaydin, H. (2022). Comprehensive review of solar radiation modeling based on artificial intelligence and optimization techniques: future concerns and considerations. *Clean Technologies and Environmental Policy*, 1-19. <https://doi.org/10.1007/s10098-022-02434-7>
- Aybar-Ruiz, A., Jiménez-Fernández, S., Cornejo-Bueno, L., Casanova-Mateo, C., Sanz-Justo, J., Salvador-González, P., & Salcedo-Sanz, S. (2016). A novel grouping genetic algorithm–extreme learning machine approach for global solar radiation prediction from numerical weather models inputs. *Solar Energy*, 132, 129-142. <https://doi.org/10.1016/j.solener.2016.03.015>
- Azadeh, A., Maghsoudi, A., & Sohrabkhani, S. (2009). An integrated artificial neural networks approach for predicting global radiation. *Energy conversion and management*, 50(6), 1497-1505. <https://doi.org/10.1016/j.enconman.2009.02.019>
- Babahadj, A., Rahmani, L., Bouchouicha, K., Brahim, B., Necaibia, A., & Mebrouk, B. (2020). ANFIS Technique to Estimate Daily Global Solar Radiation by Day in Southern Algeria. In *Smart Energy Empowerment in Smart and Resilient Cities: Renewable Energy for Smart and Sustainable Cities* (pp. 41-50). Springer International Publishing. [https://doi.org/10.1007/978-3-030-37207-1\\_5](https://doi.org/10.1007/978-3-030-37207-1_5)
- Babatunde, O. M., Munda, J. L., Hamam, Y., & Monyei, C. G. (2023). A critical overview of the (Im) practicability of solar radiation forecasting models. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 100213. <https://doi.org/10.1016/j.prime.2023.100213>

- Babel, M. S., Sirisena, T. A. J. G., & Singhrattna, N. (2017). Incorporating large-scale atmospheric variables in long-term seasonal rainfall forecasting using artificial neural networks: an application to the Ping Basin in Thailand. *Hydrology Research*, 48(3), 867-882. <https://doi.org/10.2166/nh.2016.212>
- Bahaghighat, M., Abedini, F., Xin, Q., Zanjireh, M. M., & Mirjalili, S. (2021). Using machine learning and computer vision to estimate the angular velocity of wind turbines in smart grids remotely. *Energy Reports*, 7, 8561-8576. <https://doi.org/10.1016/j.egy.2021.07.077>
- Bamisile, O., Oluwasanmi, A., Ejayi, C., Yimen, N., Obiora, S., & Huang, Q. (2022). Comparison of machine learning and deep learning algorithms for hourly global/diffuse solar radiation predictions. *International Journal of Energy Research*, 46(8), 10052-10073. <https://doi.org/10.1002/er.6529>
- Barnhart, B. L., & Eichinger, W. E. (2011). Empirical mode decomposition applied to solar irradiance, global temperature, sunspot number, and CO2 concentration data. *Journal of Atmospheric and Solar-Terrestrial Physics*, 73(13), 1771-1779. <https://doi.org/10.1016/j.jastp.2011.04.012>
- Basaran, K., Özçift, A., & Kılınç, D. (2019). A new approach for prediction of solar radiation with using ensemble learning algorithm. *Arabian Journal for Science and Engineering*, 44, 7159-7171. <https://doi.org/10.1007/s13369-019-03841-7>
- Bauer, P., Thorpe, A., & Brunet, G. (2015). The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47-55. <https://doi-org.snd11.arn.dz/10.1038/nature14956>
- Bayatvarkeshi, M., Mohammadi, K., Kisi, O. et al. (2020). A new wavelet conjunction approach for estimation of relative humidity: wavelet principal component analysis combined with ANN. *Neural Comput & Applic* 32, 4989–5000. <https://doi.org/10.1007/s00521-018-3916-0>
- Behera, M. K., Majumder, I., & Nayak, N. (2018). Solar photovoltaic power forecasting using optimized modified extreme learning machine technique. *Engineering Science and Technology, an International Journal*, 21(3), 428-438. <https://doi.org/10.1016/j.jestch.2018.04.013>

- Behrang, M. A., Assareh, E., Ghanbarzadeh, A., & Noghrehabadi, A. R. (2010). The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. *Solar Energy*, 84(8), 1468-1480. <https://doi.org/10.1016/j.solener.2010.05.009>
- Belaid, S., & Mellit, A. (2016). Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. *Energy Conversion and Management*, 118, 105-118. <https://doi.org/10.1016/j.enconman.2016.03.082>
- Belaid, S., Boualit, A., Zaiani, M., & Mellit, A. (2018). New predictive model of hourly global solar component. In *2018 the 5<sup>th</sup> International Seminar on New and Renewable Energies (SIENR)* (pp. 39-46).
- Belaid, S., Mellit, A., Boualit, H., & Zaiani, M. (2022). Hourly global solar forecasting models based on a supervised machine learning algorithm and time series principle. *International Journal of Ambient Energy*, 43(1), 1707-1718. <https://doi.org/10.1080/01430750.2020.1718754>
- Bellaoui, M., Bouchouicha, K., & Oulimar, I. (2021). Estimation of daily global solar radiation based on MODIS satellite measurements: The case study of Adrar region (Algeria). *Measurement*, 183, 109802. <https://doi.org/10.1016/j.measurement.2021.109802>
- Bellido-Jiménez, J. A., Gualda, J. E., & García-Marín, A. P. (2021). Assessing new intra-daily temperature-based machine learning models to outperform solar radiation predictions in different conditions. *Applied Energy*, 298, 117211.
- Bellocchi, G., Rivington, M., Donatelli, M., & Matthews, K. (2011). Validation of biophysical models: issues and methodologies. *Sustainable Agriculture Volume 2*, 577-603. <https://doi.org/10.1051/agro/2009001>
- Benali, L., Notton, G., Fouilloy, A., Voyant, C., & Dizene, R. (2019). Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. *Renewable energy*, 132, 871-884. <https://doi.org/10.1016/j.renene.2018.08.044>

- Benatiallah, D., Benatiallah, A., Bouchouicha, K., & Nasri, B. (2019). Estimation of clear sky global solar radiation in Algeria. *AIMS Energy*, 7(6), 710-727. <https://doi.org/10.3934/energy.2019.6.710>
- Benatiallah, D., Benatiallah, A., Bouchouicha, K., & Nasri, B. (2020). Prediction du rayonnement solaire horaire En utilisant les reseaux de neurone artificiel. *Algerian Journal of Environmental Science and Technology*, 6(1).
- Benatiallah, D., Bouchouicha, K., Benatiallah, A., Harouz, A., & Nasri, B. (2021a). Artificial neural network based solar radiation estimation of Algeria Southwest Cities. In *Artificial Intelligence and Renewables Towards an Energy Transition 4* (pp. 573-583). Springer International Publishing. [https://doi.org/10.1007/978-3-030-63846-7\\_54](https://doi.org/10.1007/978-3-030-63846-7_54)
- Benatiallah, D., Bouchouicha, K., Benatiallah, A., Harouz, A., & Nasri, B. (2021b). Estimation of global solar radiation using adaptive neuro-fuzzy inference system. *Algerian Journal of Environmental Science and Technology*, 7(4).
- Benkaciali, S., Haddadi, M., Khellaf, A., Gairaa, K., & Guermoui, M. (2016). Evaluation of the global solar irradiation from the artificial neural network technique. *Journal of Renewable Energies*, 19(4), 617-631.
- Benkaciali, S., Gairaa, K., Guermoui, M., Haddadi, M., & Khellaf, A. (2017). Assessment of Daily Global Solar Radiation Using Radial Basis Function Techniques. In *2017 International Renewable and Sustainable Energy Conference (IRSEC)* (pp. 1-6). IEEE. <https://doi.org/10.1109/IRSEC.2017.8477297>
- Benmouiza, K., & Cheknane, A. (2013). Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models. *Energy Conversion and Management*, 75, 561-569. <https://doi.org/10.1016/j.enconman.2013.07.003>
- Benmouiza, K., & Cheknane, A. (2016). Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models. *Theoretical and Applied Climatology*, 124, 945-958. <https://doi.org/10.1007/s00704-015-1469-z>
- Benmouiza, K., & Cheknane, A. (2019). Clustered ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting.

- Theoretical and Applied Climatology*, 137, 31-43. <https://doi.org/10.1007/s00704-018-2576-4>
- Benmouiza, K. (2022). Hourly solar irradiation forecast using hybrid local gravitational clustering and group method of data handling methods. *Environmental Science and Pollution Research*, 29(40), 60792-60810. <https://doi.org/10.1007/s11356-022-20114-3>
- Benmouiza, K. (2023). Nonlinear clustered adaptive-network-based fuzzy inference system model for hourly solar irradiation estimation. *Revue roumaine des sciences techniques—serie electrotechnique et energetique*, 68(1), 7-11.
- Bernstein, H. (2022). Temperature Sensors. In: *Measuring Electronics and Sensors*. Springer, Wiesbaden. [https://doi.org/10.1007/978-3-658-35067-3\\_3](https://doi.org/10.1007/978-3-658-35067-3_3)
- Bhawsar, M., Tewari, V., & Khare, P. (2021). A survey of weather forecasting based on machine learning and deep learning techniques. *International Journal of Emerging Trends in Engineering Research*, 9(7). <https://doi.org/10.30534/ijeter/2021/24972021>
- Bhola, P., & Bhardwaj, S. (2019). Estimation of solar radiation using support vector regression. *Journal of Information and Optimization Sciences*, 40(2), 339-350. <https://doi.org/10.1080/02522667.2019.1578093>
- Białobrzewski, I. (2008). Neural modeling of relative air humidity. *Computers and electronics in agriculture*, 60(1), 1-7. <https://doi.org/10.1016/j.compag.2007.02.009>
- Boesgaard, C., Hansen, B. V., Kejser, U. B., Mollerup, S., Ryhl-Svendsen, M., & Torp-Smith, N. (2022). Prediction of the indoor climate in cultural heritage buildings through machine learning: First results from two field tests. *Heritage Science*, 10(1) <https://doi.org/10.1186/s40494-022-00805-3>
- Botero-Valencia, J. S., Mejia-Herrera, M., & Pearce, J. M. (2022). Design of a low-cost mobile multispectral albedometer with geopositioning and absolute orientation. *HardwareX*, 12, e00324. <https://doi.org/10.1016/j.ohx.2022.e00324>
- Boualit, S. B., & Mellit, A. (2016). SARIMA-SVM hybrid model for the prediction of daily global solar radiation time series. In *2016 International Renewable and Sustainable*

- Energy Conference (IRSEC)* (pp. 712-717).  
IEEE. <https://doi.org/10.1109/IRSEC.2016.7983867>
- Bouchouicha, K., Bailek, N., Bellaoui, M., Oulimar, B., & Benatiallah, D. (2021). ANN-based correction model of radiation and temperature for solar energy application in South of Algeria. In *Artificial Intelligence and Renewables Towards an Energy Transition* 4 (pp. 584-591). Springer International Publishing. [https://doi.org/10.1007/978-3-030-63846-7\\_55](https://doi.org/10.1007/978-3-030-63846-7_55)
- 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>
- Bounoua, Z., & Mechaqrane, A. (2023). Hourly and sub-hourly ahead global horizontal solar irradiation forecasting via a novel deep learning approach: A case study. *Sustainable Materials and Technologies*, 36, e00599. <https://doi.org/10.1016/j.susmat.2023.e00599>
- Bourassa, M. A., Meissner, T., Cerovecki, I., Chang, P. S., Dong, X., De Chiara, G., ... & Wentz, F. (2019). Remotely sensed winds and wind stresses for marine forecasting and ocean modeling. *Frontiers in Marine Science*, 6, 443. <https://doi.org/10.3389/fmars.2019.00443>
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Bui, M. T., Lu, J., & Nie, L. (2021). Evaluation of the Climate Forecast System Reanalysis data for hydrological model in the Arctic watershed Målselv. *Journal of Water and Climate Change*, 12(8), 3481-3504. <https://doi.org/10.2166/wcc.2021.346>
- Burianek, T., & Misak, S. (2016). Solar irradiance forecasting model based on extreme learning machine. In *2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC)* (pp. 1-5). IEEE. <https://doi.org/10.1109/EEEIC.2016.7555445>

- Bushara, N. O., & Abraham, A. (2013). Computational intelligence in weather forecasting: A review. *Journal of Network and Innovative Computing*, 1(2013), 320-331.
- Calif, R., Schmitt, F. G., Huang, Y., & Soubdhan, T. (2013). Intermittency study of high frequency global solar radiation sequences under a tropical climate. *Solar Energy*, 98, 349-365. <https://doi.org/10.1016/j.solener.2013.09.018>
- Cao, J. C., & Cao, S. H. (2006). Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis. *Energy*, 31(15), 3435-3445. <https://doi.org/10.1016/j.energy.2006.04.001>
- Cao, W., & Zhang, C. (2021). An effective parallel integrated neural network system for industrial data prediction. *Applied Soft Computing*, 107, 107397. <https://doi.org/10.1016/j.asoc.2021.107397>
- Castelli, M., Stöckli, R., Zardi, D., Tetzlaff, A., Wagner, J. E., Belluardo, G., ... & Petitta, M. (2014). The HeliMont method for assessing solar irradiance over complex terrain: Validation and improvements. *Remote sensing of environment*, 152, 603-613. <https://doi.org/10.1016/j.rse.2014.07.018>
- Cauteruccio, A., Colli, M., Stagnaro, M., Lanza, L.G., Vuerich, E. (2021). In-situ Precipitation Measurements. In: Foken, T. (eds) Springer Handbook of Atmospheric Measurements. Springer Handbooks. Springer, Cham. [https://doi.org/10.1007/978-3-030-52171-4\\_12](https://doi.org/10.1007/978-3-030-52171-4_12)
- Celik, A. N., & Muneer, T. (2013). Neural network based method for conversion of solar radiation data. *Energy conversion and management*, 67, 117-124. <https://doi.org/10.1016/j.enconman.2012.11.010>
- Chaba-Mouna, S., Hanini, S., Laidi, M., & Khaouane, L. (2017). Artificial neural networks based prediction of hourly horizontal solar radiation data: Case study. *International Journal of Applied Decision Sciences*, 10(2), 156-174. <https://doi.org/10.1504/IJADS.2017.084312>
- Chaudhuri, S., Chattopadhyay, S. (2005). Neuro-computing based short range prediction of some meteorological parameters during the pre-monsoon season. *Soft Comput* 9, 349–354. <https://doi.org/10.1007/s00500-004-0414-3>

- Chen, J. L., Liu, H. B., Wu, W., & Xie, D. T. (2011). Estimation of monthly solar radiation from measured temperatures using support vector machines—a case study. *Renewable Energy*, 36(1), 413-420. <https://doi.org/10.1016/j.renene.2010.06.024>
- Chen, J. L., & Li, G. S. (2014). Evaluation of support vector machine for estimation of solar radiation from measured meteorological variables. *Theoretical and applied climatology*, 115, 627-638. <https://doi.org/10.1007/s00704-013-0924-y>
- Chen, H., Birkelund, Y., & Zhang, Q. (2021a). Data-augmented sequential deep learning for wind power forecasting. *Energy Conversion and Management*, 248, 114790. <https://doi.org/10.1016/j.enconman.2021.114790>
- Chen, J., Zhu, W., & Yu, Q. (2021b). Estimating half-hourly solar radiation over the Continental United States using GOES-16 data with iterative random forest. *Renewable Energy*, 178, 916-929. <https://doi.org/10.1016/j.renene.2021.06.129>
- Chen, H. (2022). A comprehensive statistical analysis for residuals of wind speed and direction from numerical weather prediction for wind energy. *Energy Reports*, 8, 618-626. <https://doi.org/10.1016/j.egy.2022.07.080>
- Chen, G., Hua, J., Shi, Y., & Ren, C. (2023). Constructing air temperature and relative humidity-based hourly thermal comfort dataset for a high-density city using machine learning. *Urban Climate*, 47, 101400. <https://doi.org/10.1016/j.uclim.2022.101400>
- Chikh, M., Degla, A., & Mahrane, A. (2021). The Impact of the Solar Radiation Profile on Sizing and Performance of Photovoltaic Systems, Case Study Tamanrasset, Algeria. In *Proceedings of the 4th International Conference on Electrical Engineering and Control Applications: ICEECA 2019, 17–19 December 2019, Constantine, Algeria* (pp. 763-778). Springer Singapore. [https://doi.org/10.1007/978-981-15-6403-1\\_52](https://doi.org/10.1007/978-981-15-6403-1_52)
- Choi, J. H., Chang, K. H., Kim, K. E., & Bang, K. S. (2023). Improvement of Rainfall Measurements by Using a Dual Tipping Bucket Rain Gauge. *Asia-Pacific Journal of Atmospheric Sciences*, 59(2), 271-280. <https://doi.org/10.1007/s13143-022-00295-0>
- Chong, K. L., Lai, S. H., Yao, Y., Ahmed, A. N., Jaafar, W. Z. W., & El-Shafie, A. (2020). Performance enhancement model for rainfall forecasting utilizing integrated wavelet-

- convolutional neural network. *Water Resources Management*, 34, 2371-2387. <https://doi.org/10.1007/s11269-020-02554-z>
- Christiansen, B. (2005). Downward propagation and statistical forecast of the near-surface weather. *Journal of Geophysical Research: Atmospheres*, 110(D14). <https://doi.org/10.1029/2004JD005431>
- Coakley, D., Raftery, P., & Keane, M. (2014). A review of methods to match building energy simulation models to measured data. *Renewable and sustainable energy reviews*, 37, 123-141. <https://doi.org/10.1016/j.rser.2014.05.007>
- Coimbra, W., & Leal-Junior, A. (2022). Sensors for Vital Signs: Humidity Sensors. In *Handbook of Biochips: Integrated Circuits and Systems for Biology and Medicine* (pp. 245-261). New York, NY: Springer New York. [https://doi.org/10.1007/978-1-4614-6623-9\\_4-1](https://doi.org/10.1007/978-1-4614-6623-9_4-1)
- Çolak, A. B., Güzel, T., Shafiq, A., & Nonlaopon, K. (2022). Do Artificial Neural Networks Always Provide High Prediction Performance? An Experimental Study on the Insufficiency of Artificial Neural Networks in Capacitance Prediction of the 6H-SiC/MEH-PPV/Al Diode. *Symmetry*, 14(8), 1511. <https://doi.org/10.3390/sym14081511>
- Cornejo-Bueno, L., Casanova-Mateo, C., Sanz-Justo, J., & Salcedo-Sanz, S. (2019). Machine learning regressors for solar radiation estimation from satellite data. *Solar Energy*, 183, 768-775. <https://doi.org/10.1016/j.solener.2019.03.079>
- Cox, C. B., Moore, P. D., & Ladle, R. J. (2016). *Biogeography: an ecological and evolutionary approach* (Ninth edition). John Wiley & Sons.
- Curceac, S., Ternynck, C., Ouarda, T. B., Chebana, F., & Niang, S. D. (2019). Short-term air temperature forecasting using nonparametric functional data analysis and SARMA models. *Environmental Modelling & Software*, 111, 394-408. <https://doi.org/10.1016/j.envsoft.2018.09.017>
- Czarnecki, W.M., Podolak, I.T. (2013). Machine Learning with Known Input Data Uncertainty Measure. In: Saeed, K., Chaki, R., Cortesi, A., Wierzchoń, S. (eds) Computer Information Systems and Industrial Management. CISIM 2013. Lecture

- Notes in Computer Science, vol 8104. Springer, Berlin, Heidelberg.  
[https://doi.org/10.1007/978-3-642-40925-7\\_35](https://doi.org/10.1007/978-3-642-40925-7_35)
- Dahmani, K., Dizene, R., Notton, G., Paoli, C., Voyant, C., & Nivet, M. L. (2014). Estimation of 5-min time-step data of tilted solar global irradiation using ANN (Artificial Neural Network) model. *Energy*, 70, 374-381. <https://doi.org/10.1016/j.energy.2014.04.011>
- Dahmani, K., Notton, G., Voyant, C., Dizene, R., Nivet, M. L., Paoli, C., & Tamas, W. (2016). Multilayer Perceptron approach for estimating 5-min and hourly horizontal global irradiation from exogenous meteorological data in locations without solar measurements. *Renewable Energy*, 90, 267-282. <https://doi.org/10.1016/j.renene.2016.01.013>
- Dahmani, A., Ammi, Y., Hanini, S., Redha Yaiche, M., & Zentou, H. (2023). Prediction of Hourly Global Solar Radiation: Comparison of Neural Networks/Bootstrap Aggregating. *Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske*, 72(3-4), 201-213. <https://doi.org/10.15255/KUI.2022.065>
- Danandeh Mehr, A., Nourani, V., Karimi Khosrowshahi, V., & Ghorbani, M. A. (2019). A hybrid support vector regression–firefly model for monthly rainfall forecasting. *International Journal of Environmental Science and Technology*, 16, 335-346. <https://doi.org/10.1007/s13762-018-1674-2>
- Dash, P. K., Majumder, I., Nayak, N., & Bisoi, R. (2020). Point and interval solar power forecasting using hybrid empirical wavelet transform and robust wavelet kernel ridge regression. *Natural Resources Research*, 29(5), 2813-2841. <https://doi.org/10.1007/s11053-020-09630-6>
- Dash, D. R., Dash, P. K., & Bisoi, R. (2021). Short term solar power forecasting using hybrid minimum variance expanded RVFLN and Sine-Cosine Levy Flight PSO algorithm. *Renewable Energy*, 174, 513-537. <https://doi.org/10.1016/j.renene.2021.04.088>
- Datta, P., & Das, S. (2019). Analysis of long-term seasonal and annual temperature trends in North Bengal, India. *Spatial Information Research*, 27(4), 475-496. <https://doi.org/10.1007/s41324-019-00250-8>
- Davis, R.A. (1982). Wind . In: Beaches and Coastal Geology. Encyclopedia of Earth Sciences Series. Springer, New York, NY. [https://doi.org/10.1007/0-387-30843-1\\_505](https://doi.org/10.1007/0-387-30843-1_505)

- Demir, V., & Citakoglu, H. (2023). Forecasting of solar radiation using different machine learning approaches. *Neural Computing and Applications*, 35(1), 887-906. <https://doi.org/10.1007/s00521-022-07841-x>
- Deo, R. C., Wen, X., & Qi, F. (2016). A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset. *Applied Energy*, 168, 568-593. <https://doi.org/10.1016/j.apenergy.2016.01.130>
- Deo, R. C., Downs, N., Parisi, A. V., Adamowski, J. F., & Quilty, J. M. (2017). Very short-term reactive forecasting of the solar ultraviolet index using an extreme learning machine integrated with the solar zenith angle. *Environmental research*, 155, 141-166. <https://doi.org/10.1016/j.envres.2017.01.035>
- Diagne, M., David, M., Lauret, P., Boland, J., & Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27, 65-76. <https://doi.org/10.1016/j.rser.2013.06.042>
- Dile, Y. T., & Srinivasan, R. (2014). Evaluation of CFSR climate data for hydrologic prediction in data-scarce watersheds: an application in the Blue Nile River Basin. *JAWRA Journal of the American Water Resources Association*, 50(5), 1226-1241. <https://doi.org/10.1111/jawr.12182>
- Djaafari, A., Ibrahim, A., Bailek, N., Bouchouicha, K., Hassan, M. A., Kuriqi, A., ... & El-Kenawy, E. S. M. (2022). Hourly predictions of direct normal irradiation using an innovative hybrid LSTM model for concentrating solar power projects in hyper-arid regions. *Energy Reports*, 8, 15548-15562. <https://doi.org/10.1016/j.egyr.2022.10.402>
- Djeldjli, H., Benatiallah, D., Bouchouicha, K., & Benatiallah, A. (2023). Solar Radiation Forecasting Based on Artificial Neural Network: A Case Study of Bechar City, Southwest Algeria. In *Advanced Computational Techniques for Renewable Energy Systems* (pp. 3-12). Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-031-21216-1\\_1](https://doi.org/10.1007/978-3-031-21216-1_1)
- Donatelli, M., Acutis, M., Bellocchi, G., & Fila, G. (2004). New indices to quantify patterns of residuals produced by model estimates. *Agronomy Journal*, 96(3), 631-645. <https://doi.org/10.2134/agronj2004.0631>

- Dorvlo, A. S., Jervase, J. A., & Al-Lawati, A. (2002). Solar radiation estimation using artificial neural networks. *Applied Energy*, 71(4), 307-319. [https://doi.org/10.1016/S0306-2619\(02\)00016-8](https://doi.org/10.1016/S0306-2619(02)00016-8)
- Dos Santos, E. P., Dias, R. L. S., Maciel, I. P., Kolling Neto, A., & da Silva, D. D. (2021). Estimation of missing hydrological data in monthly rainfall series using meteorological satellite data. *Environmental Earth Sciences*, 80, 1-9. <https://doi.org/10.1007/s12665-021-09409-9>
- Dotse, S. Q., Larbi, I., Limantol, A. M., & De Silva, L. C. (2023). A review of the application of hybrid machine learning models to improve rainfall prediction. *Modeling Earth Systems and Environment*, 1-26. <https://doi.org/10.1007/s40808-023-01835-x>
- Dragomiretskiy, K., & Zosso, D. (2013). Variational mode decomposition. *IEEE transactions on signal processing*, 62(3), 531-544. <https://doi.org/10.1109/TSP.2013.2288675>
- Drif, M., & Chikh, M. (2000). Estimation de l'irradiation solaire par la logique floue. *Rev. Energ. Ren. Chemss*, 105-110.
- Duong, T. A., Bui, M. D., & Rutschmann, P. (2018). A comparative study of three different models to predict monthly rainfall in Ca Mau, Vietnam. In *Wasserbau-Symposium Graz*.
- El Bouny, L., Khalil, M., & Adib, A. (2019). ECG signal filtering based on CEEMDAN with hybrid interval thresholding and higher order statistics to select relevant modes. *Multimedia Tools and Applications*, 78(10), 13067-13089. <https://doi.org/10.1007/s11042-018-6143-x>
- El-Alaoui, A. M., Mohammed, R., & Allal, S. (2022). The prediction of the inside temperature and relative humidity of a greenhouse using ANN method with limited environmental and meteorological data. *Les Ulis: EDP Sciences*. <https://doi.org/10.1051/e3sconf/202235101004>
- El-Amarty, N., Marzouq, M., El Fadili, H., Bennani, S. D., & Ruano, A. (2023). A comprehensive review of solar irradiation estimation and forecasting using artificial neural networks: data, models and trends. *Environmental Science and Pollution Research*, 30(3), 5407-5439. <https://doi.org/10.1007/s11356-022-24240-w>

- El-Mghouchi, Y., Chham, E., Zemmouri, E. M., & El Bouardi, A. (2019). Assessment of different combinations of meteorological parameters for predicting daily global solar radiation using artificial neural networks. *Building and Environment*, 149, 607-622. <https://doi.org/10.1016/j.buildenv.2018.12.055>
- Elminir, H. K., Azzam, Y. A., & Younes, F. I. (2007). Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy*, 32(8), 1513-1523. <https://doi.org/10.1016/j.energy.2006.10.010>
- Essou, G. R., Brissette, F., & Lucas-Picher, P. (2017). The use of reanalyses and gridded observations as weather input data for a hydrological model: Comparison of performances of simulated river flows based on the density of weather stations. *Journal of Hydrometeorology*, 18(2), 497-513. <https://doi.org/10.1175/JHM-D-16-0088.1>
- Eymen, A., & Köylü, Ü. (2019). Seasonal trend analysis and ARIMA modeling of relative humidity and wind speed time series around Yamula Dam. *Meteorology and Atmospheric Physics*, 131, 601-612. <https://doi.org/10.1007/s00703-018-0591-8>
- Fan, J., Wu, L., Zhang, F., Cai, H., Zeng, W., Wang, X., & Zou, H. (2019). Empirical and machine learning models for predicting daily global solar radiation from sunshine duration: A review and case study in China. *Renewable and Sustainable Energy Reviews*, 100, 186-212. <https://doi.org/10.1016/j.rser.2018.10.018>
- Fan, J., Wang, X., Zhang, F., Ma, X., & Wu, L. (2020). Predicting daily diffuse horizontal solar radiation in various climatic regions of China using support vector machine and tree-based soft computing models with local and extrinsic climatic data. *Journal of Cleaner Production*, 248, 119264. <https://doi.org/10.1016/j.jclepro.2019.119264>
- Farahani, H., Wagiran, R., & Hamidon, M. N. (2014). Humidity sensors principle, mechanism, and fabrication technologies: a comprehensive review. *Sensors*, 14(5), 7881-7939. <https://doi.org/10.3390/s140507881>
- Fathi, M., Haghi Kashani, M., Jameii, S. M., & Mahdipour, E. (2022). Big data analytics in weather forecasting: A systematic review. *Archives of Computational Methods in Engineering*, 29(2), 1247-1275. <https://doi.org/10.1007/s11831-021-09616-4>

- Feng, Y., Cui, N., Zhang, Q., Zhao, L., & Gong, D. (2017). Comparison of artificial intelligence and empirical models for estimation of daily diffuse solar radiation in North China Plain. *International Journal of Hydrogen Energy*, 42(21), 14418-14428. <https://doi.org/10.1016/j.ijhydene.2017.04.084>
- Ferkous, K., Chellali, F., Kouzou, A., Bekkar, B. (2021a). Wavelet-Gaussian process regression model for regression daily solar radiation in Ghardaia, Algeria. *Instrumentation Measure Métrologie*, 20(2), 113-119. <https://doi.org/10.18280/i2m.200208>
- Ferkous, K., Chellali, F., Kouzou, A., & Bekkar, B. (2021b). Wavelet-Gaussian process regression model for forecasting daily solar radiation in the Saharan climate. *Clean Energy*, 5(2), 316-328. <https://doi.org/10.1093/ce/zkab012>
- Ferkous, K., Chellali, F., Kouzou, A., Bekkar, B. & Hacene, N. (2022a). Wavelet packet-Gaussian process regression multivariate and univariate model for forecasting daily solar radiation. *International Journal of Energy for a Clean Environment*, 23(2). <https://doi.org/10.1615/InterJEnerCleanEnv.2021037413>
- Ferkous, K., Boulmaiz, T., Abdelmouiz Ziari, F., & Bekkar, B. (2022b). A hybrid approach based on complete ensemble empirical mode decomposition with adaptive noise for multi-step-ahead solar radiation forecasting. *Clean Energy*, 6(5), 705-715. <https://doi.org/10.1093/ce/zkac045>
- Foken, T., Bange, J. (2021a). Temperature Sensors. In: Foken, T. (eds) *Springer Handbook of Atmospheric Measurements*. Springer Handbooks. Springer, Cham. [https://doi.org/10.1007/978-3-030-52171-4\\_7](https://doi.org/10.1007/978-3-030-52171-4_7)
- Foken, T., Bange, J. (2021b). Wind Sensors. In: Foken, T. (eds) *Springer Handbook of Atmospheric Measurements*. Springer Handbooks. Springer, Cham. [https://doi.org/10.1007/978-3-030-52171-4\\_9](https://doi.org/10.1007/978-3-030-52171-4_9)
- Fouilloy, A., Voyant, C., Notton, G., Motte, F., Paoli, C., Nivet, M. L., ... & Duchaud, J. L. (2018). Solar irradiation prediction with machine learning: Forecasting models selection method depending on weather variability. *Energy*, 165, 620-629. <https://doi.org/10.1016/j.energy.2018.09.116>

- Fraden, J. (2016). Humidity and Moisture Sensors. In: Handbook of Modern Sensors. Springer, Cham. [https://doi.org/10.1007/978-3-319-19303-8\\_14](https://doi.org/10.1007/978-3-319-19303-8_14)
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *The annals of statistics*, 19(1), 1-67. <https://doi.org/10.1214/aos/1176347963>
- Fuka, D. R., Walter, M. T., MacAlister, C., Degaetano, A. T., Steenhuis, T. S., & Easton, Z. M. (2014). Using the Climate Forecast System Reanalysis as weather input data for watershed models. *Hydrological Processes*, 28(22), 5613-5623. <https://doi.org/10.1002/hyp.10073>
- Gairaa, K., Chellali, F., Benkaciali, S., Messlem, Y., & Abdallah, K. (2015). Daily global solar radiation forecasting over a desert area using NAR neural networks comparison with conventional methods. In *2015 international conference on renewable energy research and applications (ICRERA)* (pp. 567-571). IEEE. <https://doi.org/10.1109/ICRERA.2015.7418477>
- Gairaa, K., Khellaf, A., Messlem, Y., & Chellali, F. (2016). Estimation of the daily global solar radiation based on Box–Jenkins and ANN models: A combined approach. *Renewable and Sustainable Energy Reviews*, 57, 238-249. <https://doi.org/10.1016/j.rser.2015.12.111>
- Gairaa, K., Voyant, C., Notton, G., Benkaciali, S., & Guermoui, M. (2022). Contribution of ordinal variables to short-term global solar irradiation forecasting for sites with low variabilities. *Renewable Energy*, 183, 890-902. <https://doi.org/10.1016/j.renene.2021.11.028>
- Gala, Y., Fernández, Á., Díaz, J., & Dorronsoro, J. R. (2016). Hybrid machine learning forecasting of solar radiation values. *Neurocomputing*, 176, 48-59. <https://doi.org/10.1016/j.neucom.2015.02.078>
- Ghadiri M, Marjani A, Mohammadinia S, Shirazian S (2021). An insight into the estimation of relative humidity of air using artificial intelligence schemes. *Environ Dev Sustain* 23(7):10194–10222. <https://doi.org/10.1007/s10668-020-01053-w>

- Ghamariadyan, M., & Imteaz, M. A. (2021). Prediction of seasonal rainfall with one-year lead time using climate indices: a wavelet neural network scheme. *Water Resources Management*, 35, 5347-5365. <https://doi.org/10.1007/s11269-021-03007-x>
- Ghasemzadeh, A., & Ahmed, M. M. (2018). Utilizing naturalistic driving data for in-depth analysis of driver lane-keeping behavior in rain: Non-parametric MARS and parametric logistic regression modeling approaches. *Transportation research part C: emerging technologies*, 90, 379-392. <https://doi.org/10.1016/j.trc.2018.03.018>
- Ghimire, S., Deo, R. C., Downs, N. J., & Raj, N. (2018). Self-adaptive differential evolutionary extreme learning machines for long-term solar radiation prediction with remotely-sensed MODIS satellite and Reanalysis atmospheric products in solar-rich cities. *Remote Sensing of Environment*, 212, 176-198. <https://doi.org/10.1016/j.rse.2018.05.003>
- Ghimire, S., Deo, R. C., Downs, N. J., & Raj, N. (2019a). Global solar radiation prediction by ANN integrated with European Centre for medium range weather forecast fields in solar rich cities of Queensland Australia. *Journal of cleaner production*, 216, 288-310. <https://doi.org/10.1016/j.jclepro.2019.01.158>
- Ghimire, S., Deo, R. C., Raj, N., & Mi, J. (2019b). Wavelet-based 3-phase hybrid SVR model trained with satellite-derived predictors, particle swarm optimization and maximum overlap discrete wavelet transform for solar radiation prediction. *Renewable and Sustainable Energy Reviews*, 113, 109247. <https://doi.org/10.1016/j.rser.2019.109247>
- Ghofrani, M., Ghayekhloo, M., & Azimi, R. (2016). A novel soft computing framework for solar radiation forecasting. *Applied Soft Computing*, 48, 207-216. <https://doi.org/10.1016/j.asoc.2016.07.022>
- Gill, T. E., & Shao, Y. (2004). Introduction: Modelling of wind erosion and aeolian processes. *Environmental Modelling and Software*, 2(19), 91-92. [https://doi.org/10.1016/S1364-8152\(03\)00112-9](https://doi.org/10.1016/S1364-8152(03)00112-9)
- Gilles, J. (2013). Empirical wavelet transform. *IEEE transactions on signal processing*, 61(16), 3999-4010. <https://doi.org/10.1109/TSP.2013.2265222>

- Goliatt, L., & Yaseen, Z. M. (2023). Development of a hybrid computational intelligent model for daily global solar radiation prediction. *Expert Systems with Applications*, 212, 118295. <https://doi.org/10.1016/j.eswa.2022.118295>
- Gorman, M. F. (2016). A “Metasurvey” analysis in Operations Research and Management Science: A survey of literature reviews. *Surveys in Operations Research and Management Science*, 21(1), 18-28. <https://doi.org/10.1016/j.sorms.2016.05.002>
- Gostein, M., Hoffman, A., King, B. H., & Marquis, A. (2022). Measuring Global, Direct, Diffuse, and Ground-Reflected Irradiance Using a Reference Cell Array. In *2022 IEEE 49th Photovoltaics Specialists Conference (PVSC)* (pp. 0285-0290). IEEE. <https://doi.org/10.1109/PVSC48317.2022.9938489>
- Guermoui, M., Rabehi, A., Benkaciali, S., & Djafer, D. (2016). Daily global solar radiation modelling using multi-layer perceptron neural networks in semi-arid region. *Leonardo electronic journal of practices and technologies*, 28, 35-46.
- Guermoui, M., Rabehi, A., Gairaa, K., & Benkaciali, S. (2018a). Support vector regression methodology for estimating global solar radiation in Algeria. *The European Physical Journal Plus*, 133, 1-9. <https://doi.org/10.1140/epjp/i2018-11845-y>
- Guermoui, M., Gairaa, K., Rabehi, A., Djafer, D., & Benkaciali, S. (2018b). Estimation of the daily global solar radiation based on the Gaussian process regression methodology in the Saharan climate. *The European Physical Journal Plus*, 133, 1-17. <https://doi.org/10.1140/epjp/i2018-12029-7>
- Guermoui, M., Melgani, F., & Danilo, C. (2018c). Multi-step ahead forecasting of daily global and direct solar radiation: a review and case study of Ghardaia region. *Journal of Cleaner Production*, 201, 716-734. <https://doi.org/10.1016/j.jclepro.2018.08.006>
- Guermoui, M., & Rabehi, A. (2020). Soft computing for solar radiation potential assessment in Algeria. *International Journal of Ambient Energy*, 41(13), 1524-1533. <https://doi.org/10.1080/01430750.2018.1517686>
- Guermoui, M., Melgani, F., Gairaa, K., & Mekhalfi, M. L. (2020). A comprehensive review of hybrid models for solar radiation forecasting. *Journal of Cleaner Production*, 258, 120357. <https://doi.org/10.1016/j.jclepro.2020.120357>

- Guermoui, M., Gairaa, K., Boland, J., & Arrif, T. (2021). A novel hybrid model for solar radiation forecasting using support vector machine and bee colony optimization algorithm: review and case study. *Journal of Solar Energy Engineering*, 143(2). <https://doi.org/10.1115/1.4047852>
- Guermoui, M., Benkaciali, S., Gairaa, K., Bouchouicha, K., Boulmaiz, T., & Boland, J. W. (2022a). A novel ensemble learning approach for hourly global solar radiation forecasting. *Neural Computing and Applications*, 1-23. <https://doi.org/10.1007/s00521-021-06421-9>
- Guermoui, M., Abdelaziz, R., Gairaa, K., Djemoui, L., & Benkaciali, S. (2022b). New temperature-based predicting model for global solar radiation using support vector regression. *International Journal of Ambient Energy*, 43(1), 1397-1407. <https://doi.org/10.1080/01430750.2019.1708792>
- Guermoui, M., Bouchouicha, K., Benkaciali, S., Gairaa, K., & Bailek, N. (2022c). New soft computing model for multi-hours forecasting of global solar radiation. *The European Physical Journal Plus*, 137(1), 162. <https://doi.org/10.1140/epjp/s13360-021-02263-5>
- Guermoui, M., Gairaa, K., Ferkous, K., Santos Jr, D. S. D. O., Arrif, T., & Belaid, A. (2023). Potential assessment of the TVF-EMD algorithm in forecasting hourly global solar radiation: Review and case studies. *Journal of Cleaner Production*, 385, 135680. <https://doi.org/10.1016/j.jclepro.2022.135680>
- Gunawardhana, L. N., Al-Rawas, G. A., & Kazama, S. (2017). An alternative method for predicting relative humidity for climate change studies. *Meteorological Applications*, 24(4), 551-559. <https://doi.org/10.1002/met.1641>
- Guo, J., Zhang, L., & Guo, R. (2023a). Relative humidity prediction with covariates and error correction based on SARIMA-EG-ECM model. *Modeling Earth Systems and Environment*, 1-13. <https://doi.org/10.1007/s40808-023-01738-x>
- Guo, J., Zan, X., Wang, L., Lei, L., Ou, C., & Bai, S. (2023b). A random forest regression with Bayesian optimization-based method for fatigue strength prediction of ferrous alloys. *Engineering Fracture Mechanics*, 109714. <https://doi.org/10.1016/j.engfracmech.2023.109714>

- Gürel, A. E., Ağbulut, Ü., Bakır, H., Ergün, A., & Yıldız, G. (2023). A state of art review on estimation of solar radiation with various models. *Heliyon*, e13167. <https://doi.org/10.1016/j.heliyon.2023.e13167>
- Halabi, L. M., Mekhilef, S., & Hossain, M. (2018). Performance evaluation of hybrid adaptive neuro-fuzzy inference system models for predicting monthly global solar radiation. *Applied energy*, 213, 247-261. <https://doi.org/10.1016/j.apenergy.2018.01.035>
- Hamidane, H., Faiz, S. E., Rkik, I., Khayat, M. E., Guerbaoui, M., Abdelali Ed-Dhhak, & Lachhab, A. (2021). Application analysis of ANFIS strategy for greenhouse climate parameters prediction: *Internal temperature and internal relative humidity case of study*. Les Ulis: EDP Sciences. <https://doi.org/10.1051/e3sconf/202129701041>
- Hammad, M., Shoaib, M., Salahudin, H., Baig, M. A. I., Khan, M. M., & Ullah, M. K. (2021). Rainfall forecasting in upper Indus basin using various artificial intelligence techniques. *Stochastic Environmental Research and Risk Assessment*, 35, 2213-2235. <https://doi.org/10.1007/s00477-021-02013-0>
- Hanoon, M. S., Ahmed, A. N., Zaini, N. A., Razzaq, A., Kumar, P., Sherif, M., ... & El-Shafie, A. (2021). Developing machine learning algorithms for meteorological temperature and humidity forecasting at Terengganu state in Malaysia. *Scientific Reports*, 11(1), 18935. <https://doi.org/10.1038/s41598-021-96872-w>
- Hasni, A., Sehli, A., Draoui, B., Bassou, A., & Amieur, B. (2012). Estimating global solar radiation using artificial neural network and climate data in the south-western region of Algeria. *Energy Procedia*, 18, 531-537. <https://doi.org/10.1016/j.egypro.2012.05.064>
- Hassan, M. A., Khalil, A., Kaseb, S., & Kassem, M. A. (2017). Potential of four different machine-learning algorithms in modeling daily global solar radiation. *Renewable energy*, 111, 52-62. <https://doi.org/10.1016/j.renene.2017.03.083>
- Hassan, M. A., Khalil, A., Kaseb, S., & Kassem, M. A. (2018). Independent models for estimation of daily global solar radiation: A review and a case study. *Renewable and Sustainable Energy Reviews*, 82, 1565-1575. <https://doi.org/10.1016/j.rser.2017.07.002>

- Haykin, S. (1999). *Neural networks a comprehensive foundation*. Prentice Hall, Upper Saddle River
- He, F., & Ma, C. (2010). Modeling greenhouse air humidity by means of artificial neural network and principal component analysis. *Computers and Electronics in Agriculture*, 71, S19-S23. <https://doi.org/10.1016/j.compag.2009.07.011>
- Heddam, S. (2016). Multilayer perceptron neural network-based approach for modeling phycoyanin pigment concentrations: case study from lower Charles River buoy, USA. *Environmental Science and Pollution Research*, 23(17), 17210-17225. <https://doi.org/10.1007/s11356-016-6905-9>
- Heddam, S. (2017). Generalized regression neural network based approach as a new tool for predicting Total Dissolved Gas (TDG) downstream of spillways of dams: a case study of Columbia river basin dams, USA. *Environmental Processes*, 4(1), 235-253. <https://doi.org/10.1007/s40710-016-0196-5>
- Heddam, S., Ptak, M., & Zhu, S. (2020). Modelling of daily lake surface water temperature from air temperature: Extremely randomized trees (ERT) versus Air2Water, MARS, M5Tree, RF and MLPNN. *Journal of Hydrology*, 588, 125130. <https://doi.org/10.1016/j.jhydrol.2020.125130>
- Heddam, S. (2023). Hybrid Kernel Extreme Learning Machine-Based Empirical Wavelet Transform for Water Quality Prediction Using Only River Flow as Predictor. In *Climate Change Impacts on Natural Resources, Ecosystems and Agricultural Systems* (pp. 413-429). Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-031-19059-9\\_16](https://doi.org/10.1007/978-3-031-19059-9_16)
- Heddam, S., Merabet, K., Difi, S., Kim, S., Ptak, M., Sojka, M., ... & Kisi, O. (2023). River water temperature prediction using hybrid machine learning coupled signal decomposition: EWT versus MODWT. *Ecological Informatics*, 102376. <https://doi.org/10.1016/j.ecoinf.2023.102376>
- Heng, J., Wang, J., Xiao, L., & Lu, H. (2017). Research and application of a combined model based on frequent pattern growth algorithm and multi-objective optimization for solar radiation forecasting. *Applied Energy*, 208, 845-866. <https://doi.org/10.1016/j.apenergy.2017.09.063>

- Ho, Z. Y., Jain, M., & Dev, S. (2021). Multivariate convolutional LSTMs for relative humidity forecasting. In *2021 Photonics & Electromagnetics Research Symposium (PIERS)* (pp. 2317-2323). IEEE. <https://doi.org/10.1109/PIERS53385.2021.9695076>
- Hontoria, L., Aguilera, J., & Zufiria, P. (2005). An application of the multilayer perceptron: solar radiation maps in Spain. *Solar energy*, 79(5), 523-530. <https://doi.org/10.1016/j.solener.2004.11.013>
- Hornik, K., Stinchcombe, M., White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Netw* 2:359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Netw* 4(2):251–257. [https://doi.org/10.1016/0893-6080\(91\)90009-T](https://doi.org/10.1016/0893-6080(91)90009-T)
- Hu, J., Wang, J., & Ma, K. (2015). A hybrid technique for short-term wind speed prediction. *Energy*, 81, 563-574. <https://doi.org/10.1016/j.energy.2014.12.074>
- Hu, S., Qiu, H., Yang, D., Cao, M., Song, J., Wu, J., ... & Gao, Y. (2017). Evaluation of the applicability of climate forecast system reanalysis weather data for hydrologic simulation: a case study in the Bahe River Basin of the Qinling Mountains, China. *Journal of Geographical Sciences*, 27, 546-564. <https://doi.org/10.1007/s11442-017-1392-6>
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995. <https://doi.org/10.1098/rspa.1998.0193>
- Huang GB, Chen L, Siew CK. (2006a). Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Trans Neural Netw* 17(4):879–892. <https://doi.org/10.1109/TNN.2006.875977>
- Huang GB, Zhu QY, Siew CK. (2006b). Extreme learning machine: theory and applications. *Neurocomputing* 70:489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>

- Huang, G. B., & Chen, L. (2008). Enhanced random search based incremental extreme learning machine. *neurocomputing*, 71(16-18), 3460-3468. <https://doi.org/10.1016/j.neucom.2007.10.008>
- Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513-529. <https://doi.org/10.1109/TSMCB.2011.2168604>
- Huang, J., Troccoli, A., & Coppin, P. (2014). An analytical comparison of four approaches to modelling the daily variability of solar irradiance using meteorological records. *Renewable energy*, 72, 195-202. <https://doi.org/10.1016/j.renene.2014.07.015>
- Huang, G. B. (2015). What are extreme learning machines? Filling the gap between Frank Rosenblatt's dream and John von Neumann's puzzle. *Cognitive Computation*, 7, 263-278. <https://doi.org/10.1007/s12559-015-9333-0>
- Huang, G., Huang, G. B., Song, S., & You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61, 32-48. <https://doi.org/10.1016/j.neunet.2014.10.001>
- Huang, X., Shi, J., Gao, B., Tai, Y., Chen, Z., & Zhang, J. (2019). Forecasting hourly solar irradiance using hybrid wavelet transformation and Elman model in smart grid. *IEEE Access*, 7, 139909-139923. <https://doi.org/10.1109/ACCESS.2019.2943886>
- 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>
- Hutapea, M. I., Pratiwi, Y. Y., Sarkis, I. M., Jaya, I. K., & Sinambela, M. (2020). Prediction of relative humidity based on long short-term memory network. In *AIP Conference Proceedings* (Vol. 2221, No. 1, p. 060003). AIP Publishing LLC. <https://doi.org/10.1063/5.0003171>
- Huynh, A. N. L., Deo, R. C., Ali, M., Abdulla, S., & Raj, N. (2021). Novel short-term solar radiation hybrid model: Long short-term memory network integrated with robust local mean decomposition. *Applied Energy*, 298, 117193. <https://doi.org/10.1016/j.apenergy.2021.117193>

- Ibrahim, I. A., & Khatib, T. (2017). A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm. *Energy Conversion and Management*, 138, 413-425. <https://doi.org/10.1016/j.enconman.2017.02.006>
- Ihya, B., Mechaqrane, A., Tadili, R., & Bargach, M. N. (2015). Prediction of hourly and daily diffuse solar fraction in the city of Fez (Morocco). *Theoretical and applied climatology*, 120(3-4), 737-749. <https://doi.org/10.1007/s00704-014-1207-y>
- Izady, A., Davary, K., Alizadeh, A., Ziaei, A. N., Akhavan, S., Alipoor, A., ... & Brusseau, M. L. (2015). Groundwater conceptualization and modeling using distributed SWAT-based recharge for the semi-arid agricultural Neishaboor plain, Iran. *Hydrogeology Journal*, 1(23), 47-68. <https://doi.org/10.1007/s10040-014-1219-9>
- Jadidi, A., Menezes, R., De Souza, N., & de Castro Lima, A. C. (2018). A hybrid GA–MLPNN Model for one-hour-ahead forecasting of the global horizontal irradiance in Elizabeth City, North Carolina. *Energies*, 11(10), 2641. <https://doi.org/10.3390/en11102641>
- Jahani, B., Dinpashoh, Y., & Nafchi, A. R. (2017). Evaluation and development of empirical models for estimating daily solar radiation. *Renewable and Sustainable Energy Reviews*, 73, 878-891. <https://doi.org/10.1016/j.rser.2017.01.124>
- Jain, S. K., & Kumar, V. (2012). Trend analysis of rainfall and temperature data for India. *Current Science*, 102(1), 37–49. <http://www.jstor.org/stable/24080385>
- Jamei, M., Karbasi, M., Ali, M., Malik, A., Chu, X., & Yaseen, Z. M. (2023). A novel global solar exposure forecasting model based on air temperature: Designing a new multi-processing ensemble deep learning paradigm. *Expert Systems with Applications*, 222, 119811. <https://doi.org/10.1016/j.eswa.2023.119811>
- Janjai, S. (2010). A method for estimating direct normal solar irradiation from satellite data for a tropical environment. *Solar energy*, 84(9), 1685-1695. <https://doi.org/10.1016/j.solener.2010.05.017>
- Jian, Q. F., Ma, G. Q., & Qiu, X. L. (2014). Influences of gas relative humidity on the temperature of membrane in PEMFC with interdigitated flow field. *Renewable Energy*, 62, 129-136. <https://doi.org/10.1016/j.renene.2013.06.046>

- Jin, X., Du, J., Liu, H., Wang, Z., Song, K. (2016). Remote estimation of soil organic matter content in the Sanjiang Plain, Northeast China: the optimal band algorithm versus the GRA-ANN model. *Agric For Meteorol* 218–219:250–260. <https://doi.org/10.1016/j.agrformet.2015.12.062>
- Jing, W., Yaseen, Z. M., Shahid, S., Saggi, M. K., Tao, H., Kisi, O., ... & Chau, K. W. (2019). Implementation of evolutionary computing models for reference evapotranspiration modeling: short review, assessment and possible future research directions. *Engineering applications of computational fluid mechanics*, 13(1), 811-823. <https://doi.org/10.1080/19942060.2019.1645045>
- Joseph, R., Mujumdar, P. P., & Das Bhowmik, R. (2022). Reconstruction of Urban Rainfall Measurements to Estimate the Spatiotemporal Variability of Extreme Rainfall. *Water*, 14(23), 3900. <https://doi.org/10.3390/w14233900>
- Kaligambe, A., Fujita, G., & Keisuke, T. (2022). Estimation of Unmeasured Room Temperature, Relative Humidity, and CO<sub>2</sub> Concentrations for a Smart Building Using Machine Learning and Exploratory Data Analysis. *Energies*, 15(12), 4213. <https://doi.org/10.3390/en15124213>
- Karaman, Ö. A., Ađır, T. T., & Arsel, İ. (2021). Estimation of solar radiation using modern methods. *Alexandria Engineering Journal*, 60(2), 2447-2455. <https://doi.org/10.1016/j.aej.2020.12.048>
- Karasu, S., & Altan, A. (2019). Recognition model for solar radiation time series based on random forest with feature selection approach. In *2019 11th international conference on electrical and electronics engineering (ELECO)* (pp. 8-11). IEEE. <https://doi.org/10.23919/ELECO47770.2019.8990664>
- Kaur, A., Sharma, J. K., & Agrawal, S. (2011). Artificial neural networks in forecasting maximum and minimum relative humidity. *International Journal of Computer Science and Network Security*, 11(5), 197-199.
- Kaushika, N. D., Tomar, R. K., & Kaushik, S. C. (2014). Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations. *Solar Energy*, 103, 327-342. <https://doi.org/10.1016/j.solener.2014.02.015>

- Keshtegar, B., Heddami, S., Sebbar, A., Zhu, S. P., & Trung, N. T. (2019). SVR-RSM: a hybrid heuristic method for modeling monthly pan evaporation. *Environmental Science and Pollution Research*, 26, 35807-35826. <https://doi.org/10.1007/s11356-019-06596-8>
- Keshtegar, B., Mert, C., & Kisi, O. (2018). Comparison of four heuristic regression techniques in solar radiation modeling: Kriging method vs RSM, MARS and M5 model tree. *Renewable and sustainable energy reviews*, 81, 330-341. <https://doi.org/10.1016/j.rser.2017.07.054>
- Khatib, T., Mohamed, A., & Sopian, K. (2011). Modeling of wind speed and relative humidity for Malaysia using ANNs: approach to estimate dust deposition on PV Systems. In *2011 5th International Power Engineering and Optimization Conference* (pp. 42-47). IEEE. <https://doi.org/10.1109/PEOCO.2011.5970383>
- Khatibi, R., Naghipour, L., Ghorbani, M. A., & Aalami, M. T. (2013). Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. *Neural Computing and Applications*, 23, 2241-2252. <https://doi.org/10.1007/s00521-012-1175-z>
- Khelifi, R., Guermoui, M., Rabehi, A., & Lalmi, D. (2020). Multi-step-ahead forecasting of daily solar radiation components in the Saharan climate. *International Journal of Ambient Energy*, 41(6), 707-715. <https://doi.org/10.1080/01430750.2018.1490349>
- Khosravi, A., Koury, R. N. N., Machado, L., & Pabon, J. J. G. (2018). Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms. *Journal of Cleaner Production*, 176, 63-75. <https://doi.org/10.1016/j.jclepro.2017.12.065>
- Kim, S., Seo, Y., Malik, A., Kim, S., Heddami, S., Yaseen, Z. M., ... & Singh, V. P. (2023). Quantification of river total phosphorus using integrative artificial intelligence models. *Ecological Indicators*, 153, 110437. <https://doi.org/10.1016/j.ecolind.2023.110437>
- Kisi, O., & Heddami, S. (2019). Evaporation modelling by heuristic regression approaches using only temperature data. *Hydrological Sciences Journal*, 64(6), 653-672. <https://doi.org/10.1080/02626667.2019.1599487>
- Kisi, O., Heddami, 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>
- Ko, H. J., Kwon, D. S., Pyo, S., & Kim, J. (2022). Curved flap array-based triboelectric self-powered sensor for omnidirectional monitoring of wind speed and direction. *Nano Energy*, 102, 107717. <https://doi.org/10.1016/j.nanoen.2022.107717>
- Kraus, S., Breier, M., & Dasí-Rodríguez, S. (2020). The art of crafting a systematic literature review in entrepreneurship research. *International Entrepreneurship and Management Journal*, 16, 1023-1042. <https://doi.org/10.1007/s11365-020-00635-4>
- Kraus, S., Mahto, R. V., & Walsh, S. T. (2021). The importance of literature reviews in small business and entrepreneurship research. *Journal of small business management*, 1-12. <https://doi.org/10.1080/00472778.2021.1955128>
- Kraus, S., Breier, M., Lim, W. M., Dabić, M., Kumar, S., Kanbach, D., ... & Ferreira, J. J. (2022). Literature reviews as independent studies: guidelines for academic practice. *Review of Managerial Science*, 16(8), 2577-2595. <https://doi.org/10.1007/s11846-022-00588-8>
- Krebs, F. C., Gevorgyan, S. A., & Alstrup, J. (2009). A roll-to-roll process to flexible polymer solar cells: model studies, manufacture and operational stability studies. *Journal of Materials Chemistry*, 19(30), 5442-5451. <https://doi.org/10.1039/b823001c>
- Krömer, P., & Platoš, J. (2017). Simultaneous prediction of wind speed and direction by evolutionary fuzzy rule forest. *Procedia Computer Science*, 108, 295-304. <https://doi.org/10.1016/j.procs.2017.05.195>
- Krupar III, R.J. (2020). Wind. In: Manzello, S.L. (eds) *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires*. Springer, Cham. [https://doi.org/10.1007/978-3-319-52090-2\\_133](https://doi.org/10.1007/978-3-319-52090-2_133)
- Kuang, W. (2020). Seasonal variation in air temperature and relative humidity on building areas and in green spaces in Beijing, China. *Chinese Geographical Science*, 30, 75-88. <https://doi.org/10.1007/s11769-020-1097-0>

- Kumar, S., & Kaur, T. (2016). Development of ANN based model for solar potential assessment using various meteorological parameters. *Energy Procedia*, 90, 587-592. <https://doi.org/10.1016/j.egypro.2016.11.227>
- Kuter, S., Akyurek, Z., & Weber, G. W. (2018). Retrieval of fractional snow covered area from MODIS data by multivariate adaptive regression splines. *Remote Sensing of Environment*, 205, 236-252. <https://doi.org/10.1016/j.rse.2017.11.021>
- Kuzugudenli, E. (2018). Relative humidity modeling with artificial neural networks. *Applied Ecology and Environmental Research*, 16(4), 5227-5235. [https://doi.org/10.15666/aeer/1604\\_52275235](https://doi.org/10.15666/aeer/1604_52275235)
- Laidi, M., Hanini, S., Cheggaga, N., Nadjemi, O., Razrazi, A., & el Hadj Abdallah, A. (2013). Artificial neural network estimation of 5-min solar global radiation values using air temperature, relative humidity and wind speed in the region of Blida (Algeria). *first Int. Conf. Nanoelectron. Commun. Renew. Energy*, p. 449–55.
- Laidi, M., el hadj Abdallah, A., Hanini, S., & Rezrazi, A. (2014a). Prediction and extrapolation of global solar irradiation on tilted surfaces from horizontal ones using an artificial neural network. In *3rd International Symposium on Environmental Friendly Energies and Applications (EFEA)* (pp. 1-6). IEEE. <https://Doi.org/10.1109/EFEA.2014.7059998>
- Laidi, M., Hanini, S., Cheggaga, N., Nadjemi, O. (2014b). Predicting global solar radiation for North Algeria. *Int. Conf. Renew. Energies Power Qual. ICREPQ'14*. <https://Doi.org/10.24084/repqj12.230>
- Laidi, M., Hanini, S., Rezrazi, A., Yaiche, M. R., El Hadj, A. A., & Chellali, F. (2017). Supervised artificial neural network-based method for conversion of solar radiation data (case study: Algeria). *Theoretical and applied climatology*, 128, 439-451. <https://doi.org/10.1007/s00704-015-1720-7>
- LeCun, Y. (1985). Une procédure d'apprentissage pour réseau à seuil asymétrique Cognitiva, Vol. 85, pp 599-604.
- Li, L., & Zha, Y. (2018). Mapping relative humidity, average and extreme temperature in hot summer over China. *Science of the Total Environment*, 615, 875-881. <https://doi.org/10.1016/j.scitotenv.2017.10.022>

- Li, F. F., Wang, S. Y., & Wei, J. H. (2018). Long term rolling prediction model for solar radiation combining empirical mode decomposition (EMD) and artificial neural network (ANN) techniques. *Journal of Renewable and Sustainable Energy*, 10(1), 013704. <https://doi.org/10.1063/1.4999240>
- Li, Z., Zou, H., & Qi, B. (2019a). Application of ARIMA and LSTM in relative humidity prediction. In 2019 IEEE 19th International Conference on Communication Technology (ICCT) (pp. 1544-1549). IEEE. <https://doi.org/10.1109/ICCT46805.2019.8947142>
- Li, D. H., Chen, W., Li, S., & Lou, S. (2019b). Estimation of hourly global solar radiation using Multivariate Adaptive Regression Spline (MARS)—A case study of Hong Kong. *Energy*, 186, 115857. <https://doi.org/10.1016/j.energy.2019.115857>
- Li, H., Yang, Y., Cheng, Y., Jin, Y., Luo, H., & Zhang, L. (2020). Application of time series model in relative humidity prediction. *Journal of Physics: Conference Series*, 1584(1) <https://doi.org/10.1088/1742-6596/1584/1/012017>
- Li, G., Chen, K., & Yang, H. (2022). A new hybrid prediction model of cumulative COVID-19 confirmed data. *Process Safety and Environmental Protection*, 157, 1-19. <https://doi.org/10.1016/j.psep.2021.10.047>
- Lin, S., Moore, N. J., Messina, J. P., DeVisser, M. H., & Wu, J. (2012). Evaluation of estimating daily maximum and minimum air temperature with MODIS data in east Africa. *International Journal of Applied Earth Observation and Geoinformation*, 18, 128-140. <https://doi.org/10.1016/j.jag.2012.01.004>
- Linares-Rodriguez, A., Ruiz-Arias, J. A., Pozo-Vazquez, D., & Tovar-Pescador, J. (2013). An artificial neural network ensemble model for estimating global solar radiation from Meteosat satellite images. *Energy*, 61, 636-645. <https://doi.org/10.1016/j.energy.2013.09.008>
- Liu, S., Wang, X., Liu, M., & Zhu, J. (2017). Towards better analysis of machine learning models: A visual analytics perspective. *Visual Informatics*, 1(1), 48-56. <https://doi.org/10.1016/j.visinf.2017.01.006>

- Liu, H., Yu, C., Wu, H., Duan, Z., & Yan, G. (2020). A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting. *Energy*, 202, 117794. <https://doi.org/10.1016/j.energy.2020.117794>
- Liu, Y., Feng, G., Tsui, K. L., & Sun, S. (2021). Forecasting influenza epidemics in Hong Kong using Google search queries data: A new integrated approach. *Expert Systems with Applications*, 185, 115604. <https://doi.org/10.1016/j.eswa.2021.115604>
- Liu, F., Wang, X., Sun, F., & Wang, H. (2022a). Correct and remap solar radiation and photovoltaic power in China based on machine learning models. *Applied Energy*, 312, 118775. <https://doi.org/10.1016/j.apenergy.2022.118775>
- Liu, J., Zhang, Y., Yang, L., & Li, Y. (2022b). Hydrological Modeling in the Chaohu Lake Basin of China—Driven by Open-Access Gridded Meteorological and Remote Sensing Precipitation Products. *Water*, 14(9), 1406. <https://doi.org/10.3390/w14091406>
- Lofgren, B. M., Hunter, T. S., & Wilbarger, J. (2011). Effects of using air temperature as a proxy for potential evapotranspiration in climate change scenarios of Great Lakes basin hydrology. *Journal of Great Lakes Research*, 37(4), 744-752. <https://doi.org/10.1016/j.jglr.2011.09.006>
- Lokuge, W., Wilson, A., Gunasekara, C., Law, D. W., & Setunge, S. (2018). Design of fly ash geopolymer concrete mix proportions using Multivariate Adaptive Regression Spline model. *Construction and Building Materials*, 166, 472-481. <https://doi.org/10.1016/j.conbuildmat.2018.01.175>
- Lotfinejad, M. M., Hafezi, R., Khanali, M., Hosseini, S. S., Mehrpooya, M., & Shamshirband, S. (2018). A comparative assessment of predicting daily solar radiation using bat neural network (BNN), generalized regression neural network (GRNN), and neuro-fuzzy (NF) system: A case study. *Energies*, 11(5), 1188. <https://doi.org/10.3390/en11051188>
- Lu, T., & Viljanen, M. (2009). Prediction of indoor temperature and relative humidity using neural network models: model comparison. *Neural Computing and Applications*, 18(4), 345-357. <https://doi.org/10.1007/s00521-008-0185-3>

- Ma, X., Fang, C., & Ji, J. (2020). Prediction of outdoor air temperature and humidity using Xgboost. In *IOP Conference Series: Earth and Environmental Science* (Vol. 427, No. 1, p. 012013). IOP Publishing. <https://doi.org/10.1088/1755-1315/427/1/012013>
- Majumder, I., Dash, P. K., & Bisoi, R. (2018). Variational mode decomposition based low rank robust kernel extreme learning machine for solar irradiation forecasting. *Energy conversion and management*, 171, 787-806. <https://doi.org/10.1016/j.enconman.2018.06.021>
- Malik, A., Kumar, A., Salih, S. Q., Kim, S., Kim, N. W., Yaseen, Z. M., & Singh, V. P. (2020). Drought index prediction using advanced fuzzy logic model: Regional case study over Kumaon in India. *Plos one*, 15(5), e0233280. <https://doi.org/10.1371/journal.pone.0233280>
- Mantri, R., Raghavendra, K. R., Puri, H., Chaudhary, J., & Bingi, K. (2021). Weather prediction and classification using neural networks and k-nearest neighbors. In *2021 8th International Conference on Smart Computing and Communications (ICSCC)* (pp. 263-268). IEEE. <https://doi.org/10.1109/ICSCC51209.2021.9528115>
- Maqsood, I., Khan, M. R., & Abraham, A. (2004). An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 13, 112-122. <https://doi.org/10.1007/s00521-004-0413-4>
- Martins, F. R., Pereira, E. B., & Abreu, S. L. (2007). Satellite-derived solar resource maps for Brazil under SWERA project. *Solar Energy*, 81(4), 517-528. <https://doi.org/10.1016/j.solener.2006.07.009>
- Marzo, A., Trigo-Gonzalez, M., Alonso-Montesinos, J., Martínez-Durbán, M., López, G., Ferrada, P., ... & Batlles, F. J. (2017). Daily global solar radiation estimation in desert areas using daily extreme temperatures and extraterrestrial radiation. *Renewable Energy*, 113, 303-311. <https://doi.org/10.1016/j.renene.2017.01.061>
- Mba L, Meukam P, Kemajou A. (2016). Application of artificial neural network for predicting hourly indoor air temperature and relative humidity in modern building in humid region. *Energy Build* 121:32–42. <https://doi.org/10.1016/j.enbuild.2016.03.046>

- McRoberts, M. (2013). Temperature Sensors. In: Beginning Arduino. Apress, Berkeley, CA. [https://doi.org/10.1007/978-1-4302-5017-3\\_13](https://doi.org/10.1007/978-1-4302-5017-3_13)
- Mebrouk, B., Kada, B., Nouar, A., Brahim, O., & Abdeljabar, B. (2020). Auto regression Integrated moving average (ARIMA) to estimate temporal series of global solar radiation from measured data: Adrar region study. In Proceedings of the 10th International Conference on Information Systems and Technologies (pp. 1-4). <https://doi.org/10.1145/3447568.3448517>
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S., & Elmahdi, A. (2013). Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11-21. <https://doi.org/10.1016/j.jhydrol.2013.08.035>
- Mellit, A., Benghanem, M., Arab, A. H., & Guessoum, A. (2005a). A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach. *Solar energy*, 79(5), 469-482. <https://doi.org/10.1016/j.solener.2004.12.006>
- Mellit, A., Benghanem, M., & Bendekhis, M. (2005b). Artificial neural network model for prediction solar radiation data: application for sizing stand-alone photovoltaic power system. In IEEE Power Engineering Society General Meeting, 2005 (pp. 40-44). IEEE. <https://doi.org/10.1109/PES.2005.1489526>
- Mellit, A., Benghanem, M., & Kalogirou, S. A. (2006). An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*, 83(7), 705-722. <https://doi.org/10.1016/j.apenergy.2005.06.003>
- Mellit, A., Arab, A. H., Khorissi, N., & Salhi, H. (2007a). An ANFIS-based forecasting for solar radiation data from sunshine duration and ambient temperature. In 2007 IEEE Power Engineering Society General Meeting (pp. 1-6). IEEE. <https://doi.org/10.1109/PES.2007.386131>
- Mellit, A., Arab, A. H., & Shaari, S. (2007b). An ANFIS-based prediction for monthly clearness index and daily solar radiation: application for sizing of a stand-alone Photovoltaic system. *Journal of Physical Science*, 18(2), 15-35.

- Mellit, A., Kalogirou, S. A., Shaari, S., Salhi, H., & Arab, A. H. (2008). Methodology for predicting sequences of mean monthly clearness index and daily solar radiation data in remote areas: Application for sizing a stand-alone PV system. *Renewable Energy*, 33(7), 1570-1590. <https://doi.org/10.1016/j.renene.2007.08.006>
- Mellit, A., Drif, M., & Malek, A. (2010a). EPNN-based prediction of meteorological data for renewable energy systems. *Journal of Renewable Energies*, 13(1), 25-47.
- Mellit, A., & Pavan, A. M. (2010b). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar energy*, 84(5), 807-821. <https://doi.org/10.1016/j.solener.2010.02.006>
- Mellit, A., Pavan, A. M., & Benghanem, M. (2013). Least squares support vector machine for short-term prediction of meteorological time series. *Theoretical and applied climatology*, 111, 297-307. <https://doi.org/10.1007/s00704-012-0661-7>
- Merabet, K., & Heddami, S. (2023). Improving the accuracy of air relative humidity prediction using hybrid machine learning based on empirical mode decomposition: a comparative study. *Environmental Science and Pollution Research*, 1-22. <https://doi.org/10.1007/s11356-023-26779-8>
- Miloudi, L., & Acheli, D. (2015). Prediction global solar radiation and modeling photovoltaic module based on artificial neural networks. In *2015 3rd International Conference on Control, Engineering & Information Technology (CEIT)* (pp. 1-6). IEEE. <https://doi.org/10.1109/CEIT.2015.7233111>
- Miloudi, L., Acheli, D., & Kesraoui, M. (2017). Application of artificial neural networks for forecasting photovoltaic system parameters. *Applied Solar Energy*, 53(2), 85-91. <https://doi.org/10.3103/S0003701X17020104>
- Mirbolouki, A., Heddami, S., Singh Parmar, K., Trajkovic, S., Mehraein, M., & Kisi, O. (2022). Comparison of the advanced machine learning methods for better prediction accuracy of solar radiation using only temperature data: A case study. *International Journal of Energy Research*, 46(3), 2709-2736. <https://doi.org/10.1002/er.7341>
- Mishra, A. K. (2013). Effect of rain gauge density over the accuracy of rainfall: a case study over Bangalore, India. *SpringerPlus*, 2, 1-7. <https://doi.org/10.1186/2193-1801-2-311>

- Mishra, D. P., Jena, S., Senapati, R., Panigrahi, A., & Salkuti, S. R. (2023). Global solar radiation forecast using an ensemble learning approach. *International Journal of Power Electronics and Drive Systems*, 14(1), 496. <http://doi.org/10.11591/ijpeds.v14.i1.pp496-505>
- Mohammadi, K., Shamsirband, S., Anisi, M. H., Alam, K. A., & Petković, D. (2015). Support vector regression based prediction of global solar radiation on a horizontal surface. *Energy Conversion and Management*, 91, 433-441. <https://doi.org/10.1016/j.enconman.2014.12.015>
- Mohammadi, B., & Aghashariatmadari, Z. (2020). Estimation of solar radiation using neighboring stations through hybrid support vector regression boosted by Krill Herd algorithm. *Arabian Journal of Geosciences*, 13, 1-16. <https://doi.org/10.1007/s12517-020-05355-1>
- Mohanty, S., Patra, P. K., & Sahoo, S. S. (2016). Prediction and application of solar radiation with soft computing over traditional and conventional approach—A comprehensive review. *Renewable and Sustainable Energy Reviews*, 56, 778-796. <https://doi.org/10.1016/j.rser.2015.11.078>
- Mohd-Safar, N. Z., Ndzi, D., Kagalidis, I., Yang, Y., & Zakaria, A. (2018). Short-term localized weather forecasting by using different artificial neural network algorithm in tropical climate. In *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016: Volume 2* (pp. 463-476). Springer International Publishing. [https://doi.org/10.1007/978-3-319-56991-8\\_35](https://doi.org/10.1007/978-3-319-56991-8_35)
- Molano-Jimenez, A., Orjuela-Cañón, A. D., & Acosta-Burbano, W. (2018). Temperature and relative humidity prediction in swine livestock buildings. In *2018 IEEE Latin American Conference on Computational Intelligence (LA-CCI)* (pp. 1-4). IEEE. <https://doi.org/10.1109/LA-CCI.2018.8625245>
- Monjoly, S., André, M., Calif, R., & Soubdhan, T. (2017). Hourly forecasting of global solar radiation based on multiscale decomposition methods: A hybrid approach. *Energy*, 119, 288-298. <https://doi.org/10.1016/j.energy.2016.11.061>
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in

- watershed simulations. *Transactions of the ASABE*, 50(3), 885-900. <https://doi.org/10.13031/2013.23153>
- Mousavi Maleki, S. A., Hizam, H., & Gomes, C. (2017). Estimation of hourly, daily and monthly global solar radiation on inclined surfaces: Models re-visited. *Energies*, 10(1), 134. <https://doi.org/10.3390/en10010134>
- Nazeri Tahroudi, M., Khalili, K., Ahmadi, F., Mirabbasi, R., & Jhajharia, D. (2019). Development and application of a new index for analyzing temperature concentration for Iran's climate. *International Journal of Environmental Science and Technology*, 16, 2693-2706. <https://doi.org/10.1007/s13762-018-1739-2>
- Nazhad, S. H., Lotfinejad, M. M., Danesh, M., Amin, R. U., & Shamshirband, S. (2017). A comparison of the performance of some extreme learning machine empirical models for predicting daily horizontal diffuse solar radiation in a region of southern Iran. *Int. J. Remote Sens*, 38(23), 6894-6909. <https://doi.org/10.1080/01431161.2017.1368098>
- Nilsson, L. O., Hansen, K. K., & Azenha, M. (2018). Hygrometry. *Methods of Measuring Moisture in Building Materials and Structures: State-of-the-Art Report of the RILEM Technical Committee 248-MMB*, 73-86. [https://doi.org/10.1007/978-3-319-74231-1\\_10](https://doi.org/10.1007/978-3-319-74231-1_10)
- Obiora, C. N., Hasan, A. N., Ali, A., & Alajarmeh, N. (2021). Forecasting hourly solar radiation using artificial intelligence techniques. *IEEE Canadian Journal of Electrical and Computer Engineering*, 44(4), 497-508. <https://doi.org/10.1109/ICJECE.2021.3093369>
- Ouali, K., & Alkama, R. (2014). A new model of global solar radiation based on meteorological data in Bejaia City (Algeria). *Energy Procedia*, 50, 670-676. <https://doi.org/10.1016/j.egypro.2014.06.082>
- Outanoute, M., Lachhab, A., Ed-Dahhak, A., Selmani, A., Guerbaoui, M., & Bouchikhi, B. (2015). A neural network dynamic model for temperature and relative humidity control under greenhouse. In *2015 Third International Workshop on RFID And Adaptive Wireless Sensor Networks (RAWSN)* (pp. 6-11). IEEE. <https://doi.org/10.1109/RAWSN.2015.7173270>.

- Özbalta, T. G., Sezer, A., & Yıldız, Y. (2012). Models for prediction of daily mean indoor temperature and relative humidity: Education building in Izmir, Turkey. *Indoor and Built Environment*, 21(6), 772-781. <https://doi.org/10.1177/1420326X11422163>
- Ozbek, A., Ünal, Ş., & Bilgili, M. (2022). Daily average relative humidity forecasting with LSTM neural network and ANFIS approaches. *Theoretical and Applied Climatology*, 150(1-2), 697-714. <https://doi.org/10.1007/s00704-022-04181-7>
- Palmatier, R. W., Houston, M. B., & Hulland, J. (2018). Review articles: Purpose, process, and structure. *Journal of the Academy of Marketing Science*, 46, 1-5. <https://doi.org/10.1007/s11747-017-0563-4>
- Pang, Z., Niu, F., & O'Neill, Z. (2020). Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons. *Renewable Energy*, 156, 279-289. <https://doi.org/10.1016/j.renene.2020.04.042>
- Paoli, C., Voyant, C., Muselli, M., & Nivet, M. L. (2010). Forecasting of preprocessed daily solar radiation time series using neural networks. *Solar energy*, 84(12), 2146-2160. <https://doi.org/10.1016/j.solener.2010.08.011>
- Paras, S. M., Kumar, A., & Chandra, M. (2009). A feature based neural network model for weather forecasting. *International Journal of Computational Intelligence*, 4(3), 209-216.
- Park, J., & Kim, K. Y. (2017). Meta-modeling using generalized regression neural network and particle swarm optimization. *Applied Soft Computing*, 51, 354-369. <https://doi.org/10.1016/j.asoc.2016.11.029>
- Park, H., Lee, J., Yoo, C., Sim, S., & Im, J. (2021). Estimation of spatially continuous near-surface relative humidity over Japan and South Korea. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 8614-8626. <https://doi.org/10.1109/JSTARS.2021.3103754>
- Pazikadin, A. R., Rifai, D., Ali, K., Malik, M. Z., Abdalla, A. N., & Faraj, M. A. (2020). Solar irradiance measurement instrumentation and power solar generation forecasting based on Artificial Neural Networks (ANN): A review of five years research trend. *Science*

- of *The Total Environment*, 715, 136848.  
<https://doi.org/10.1016/j.scitotenv.2020.136848>
- Peng, T., Zhang, C., Zhou, J., & Nazir, M. S. (2020). Negative correlation learning-based RELM ensemble model integrated with OVMD for multi-step ahead wind speed forecasting. *Renewable Energy*, 156, 804-819.  
<https://doi.org/10.1016/j.renene.2020.03.168>
- Peng, F. L., Qiao, Y. K., & Yang, C. (2023). A LSTM-RNN based intelligent control approach for temperature and humidity environment of urban utility tunnels. *Heliyon*, 9(2). <https://doi.org/10.1016/j.heliyon.2023.e13182>
- Petrakis, T., Kavga, A., Thomopoulos, V., & Argiriou, A. A. (2022). Neural network model for greenhouse microclimate predictions. *Agriculture*, 12(6), 780.  
<https://doi.org/10.3390/agriculture12060780>
- Pfenninger, S., & Staffell, I. (2016). Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. *Energy*, 114, 1251-1265.  
<https://doi.org/10.1016/j.energy.2016.08.060>
- Pham, Q. B., Abba, S. I., Usman, A. G., Linh, N. T. T., Gupta, V., Malik, A., ... & Tri, D. Q. (2019). Potential of hybrid data-intelligence algorithms for multi-station modelling of rainfall. *Water Resources Management*, 33, 5067-5087.  
<https://doi.org/10.1007/s11269-019-02408-3>
- Poornima, S., & Pushpalatha, M. (2019). Prediction of rainfall using intensified LSTM based recurrent neural network with weighted linear units. *Atmosphere*, 10(11), 668.  
<https://doi.org/10.3390/atmos10110668>
- Pour, S. H., Abd Wahab, A. K., & Shahid, S. (2020). Physical-empirical models for prediction of seasonal rainfall extremes of Peninsular Malaysia. *Atmospheric Research*, 233, 104720. <https://doi.org/10.1016/j.atmosres.2019.104720>
- Prasad, R., Ali, M., Xiang, Y., & Khan, H. (2020). A double decomposition-based modelling approach to forecast weekly solar radiation. *Renewable Energy*, 152, 9-22.  
<https://doi.org/10.1016/j.renene.2020.01.005>

- Prihatno, A. T., Nurcahyanto, H., & Jang, Y. M. (2021). Predictive maintenance of relative humidity using random forest method. In *2021 international conference on artificial intelligence in information and communication (ICAIIIC)* (pp. 497-499). IEEE. <https://doi.org/10.1109/ICAIIIC51459.2021.9415213>
- Qadeer, K., Ahmad, A., Qyyum, M.A., Nizami, A.S., & Lee, M. (2021). Developing machine learning models for relative humidity prediction in air-based energy systems and environmental management applications. *Journal of Environmental Management*, 292, 112736. <https://doi.org/10.1016/j.jenvman.2021.112736>
- Rabehi, A., Guermoui, M., Djafer, D., & Zaiani, M. (2015). Radial basis function neural networks model to estimate global solar radiation in semi-arid area. *Leonardo Electronic Journal of Practices and Technologies*, 27, 177-184.
- Rabehi, A., Guermoui, M., & Mihoub, R. (2017). Direct and diffuse solar radiation components estimation based on RBF model: Case study. *Leonardo Electronic Journal of Practices and Technologies*, 31, 93-110.
- Rabehi, A., Guermoui, M., & Lalmi, D. (2020a). Hybrid models for global solar radiation prediction: a case study. *International Journal of Ambient Energy*, 41(1), 31-40. <https://doi.org/10.1080/01430750.2018.1443498>
- Rabehi, A., Guermoui, M., Khelifi, R., & Mekhalfi, M. L. (2020b). Decomposing global solar radiation into its diffuse and direct normal radiation. *International Journal of Ambient Energy*, 41(7), 738-743. <https://doi.org/10.1080/01430750.2018.1492445>
- Rabehi, A., Rabehi, A., & Guermoui, M. (2021). Evaluation of Different Models for Global Solar Radiation Components Assessment. *Applied Solar Energy*, 57, 81-92. <https://doi.org/10.3103/S0003701X21010060>
- Rajendra, P., Murthy, K. V. N., Subbarao, A., & Boadh, R. (2019). Use of ANN models in the prediction of meteorological data. *Modeling Earth Systems and Environment*, 5, 1051-1058. <https://doi.org/10.1007/s40808-019-00590-2>
- Ramedani, Z., Omid, M., Keyhani, A., Shamshirband, S., & Khoshnevisan, B. (2014). Potential of radial basis function based support vector regression for global solar radiation prediction. *Renewable and Sustainable Energy Reviews*, 39, 1005-1011. <https://doi.org/10.1016/j.rser.2014.07.108>

- Ramesh, K., & Anitha, R. (2014). MARSpline model for lead seven-day maximum and minimum air temperature prediction in Chennai, India. *Journal of Earth System Science*, 123, 665-672. <https://doi.org/10.1007/s12040-014-0434-z>
- Rasel, R. I., Sultana, N., & Meesad, P. (2018). An application of data mining and machine learning for weather forecasting. In *Recent Advances in Information and Communication Technology 2017: Proceedings of the 13th International Conference on Computing and Information Technology (IC2IT)* (pp. 169-178). Springer International Publishing. [https://doi.org/10.1007/978-3-319-60663-7\\_16](https://doi.org/10.1007/978-3-319-60663-7_16)
- Rezaie-Balf, M., Kim, S., Ghaemi, A., & Deo, R. (2021). Design and performance of two decomposition paradigms in forecasting daily solar radiation with evolutionary polynomial regression: wavelet transform versus ensemble empirical mode decomposition. In *Predictive Modelling for Energy Management and Power Systems Engineering* (pp. 115-142). Elsevier. <https://doi.org/10.1016/B978-0-12-817772-3.00005-7>
- Rezrazi, A., Hanini, S., & Laidi, M. (2016). An optimisation methodology of artificial neural network models for predicting solar radiation: a case study. *Theoretical and applied climatology*, 123, 769-783. <https://doi.org/10.1007/s00704-015-1398-x>
- Rigollier, C., Lefèvre, M., & Wald, L. (2004). The method Heliosat-2 for deriving shortwave solar radiation from satellite images. *Solar energy*, 77(2), 159-169. <https://doi.org/10.1016/j.solener.2004.04.017>
- Roy, D. S. (2020). Forecasting the air temperature at a weather station using deep neural networks. *Procedia Computer Science*, 178, 38-46. <https://doi.org/10.1016/j.procs.2020.11.005>
- Ruiz-Arias, J. A., Quesada-Ruiz, S., Fernández, E. F., & Gueymard, C. A. (2015). Optimal combination of gridded and ground-observed solar radiation data for regional solar resource assessment. *Solar Energy*, 112, 411-424. <https://doi.org/10.1016/j.solener.2014.12.011>
- Rumelhart, D.E., Hinton, G.E., Williams, R.J. (1986a). Learning internal representations by error propagation. In: Rumelhart DE, McClelland PDP, Research Group (eds) *Parallel*

- distributed processing: explorations in the microstructure of cognition. Foundations, vol I. Cambridge, MA, MIT Press, p 318–62
- Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986b). Learning internal representations by back-propagating errors. *Nature*, 323:533-536.
- Rusen, S. E., & Konuralp, A. (2020). Quality control of diffuse solar radiation component with satellite-based estimation methods. *Renewable Energy*, 145, 1772-1779. <https://doi.org/10.1016/j.renene.2019.07.085>
- Şahin, M., Kaya, Y., Uyar, M., & Yıldırım, S. (2014). Application of extreme learning machine for estimating solar radiation from satellite data. *International Journal of Energy Research*, 38(2), 205-212. <https://doi.org/10.1002/er.3030>
- Salaeh, N., Ditthakit, P., Pinthong, S., Hasan, M. A., Islam, S., Mohammadi, B., & Linh, N. T. T. (2022). Long-Short Term Memory Technique for Monthly Rainfall Prediction in Thale Sap Songkhla River Basin, Thailand. *Symmetry*, 14(8), 1599. <https://doi.org/10.3390/sym14081599>
- Salcedo-Sanz, S., Casanova-Mateo, C., Pastor-Sánchez, A., Gallo-Marazuela, D., Labajo-Salazar, A., & Portilla-Figueras, A. (2013). Direct solar radiation prediction based on soft-computing algorithms including novel predictive atmospheric variables. In *Intelligent Data Engineering and Automated Learning–IDEAL 2013: 14th International Conference, IDEAL 2013, Hefei, China, October 20-23, 2013. Proceedings 14* (pp. 318-325). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-41278-3\\_39](https://doi.org/10.1007/978-3-642-41278-3_39)
- Salcedo-Sanz, S., Casanova-Mateo, C., Pastor-Sánchez, A., & Sánchez-Girón, M. (2014). Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization–Extreme Learning Machine approach. *Solar Energy*, 105, 91-98. <https://doi.org/10.1016/j.solener.2014.04.009>
- Salcedo-Sanz, S., Deo, R. C., Carro-Calvo, L., & Saavedra-Moreno, B. (2016). Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theoretical and applied climatology*, 125, 13-25. <https://doi.org/10.1007/s00704-015-1480-4>

- Salcedo-Sanz, S., Jiménez-Fernández, S., Aybar-Ruíz, A., Casanova-Mateo, C., Sanz-Justo, J., & García-Herrera, R. (2017). A CRO-species optimization scheme for robust global solar radiation statistical downscaling. *Renewable Energy*, *111*, 63-76. <https://doi.org/10.1016/j.renene.2017.03.079>
- Salcedo-Sanz, S., Deo, R. C., Cornejo-Bueno, L., Camacho-Gómez, C., & Ghimire, S. (2018). An efficient neuro-evolutionary hybrid modelling mechanism for the estimation of daily global solar radiation in the Sunshine State of Australia. *Applied Energy*, *209*, 79-94. <https://doi.org/10.1016/j.apenergy.2017.10.076>
- Sanikhani, H., Deo, R. C., Samui, P., Kisi, O., Mert, C., Mirabbasi, R., ... & Yaseen, Z. M. (2018). Survey of different data-intelligent modeling strategies for forecasting air temperature using geographic information as model predictors. *Computers and Electronics in Agriculture*, *152*, 242-260. <https://doi.org/10.1016/j.compag.2018.07.008>
- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2013). Complex-valued forecasting of the global solar irradiation. *Journal of Renewable and Sustainable Energy*, *5*(4), 043124. <https://doi.org/10.1063/1.4818618>
- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2014). Prediction of the daily global solar Irradiation of the great Maghreb region using the complex-valued neural networks. *Journal of Renewable Energies*, *17*(1), 173-185.
- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2015a). Complex-valued wavelet neural network prediction of the daily global solar irradiation of the Great Maghreb Region. *Progress in Clean Energy*, Volume 1: Analysis and Modeling, 321-339. [https://doi.org/10.1007/978-3-319-16709-1\\_23](https://doi.org/10.1007/978-3-319-16709-1_23)
- Saoud, L. S., Rahmoune, F., Tourtchine, V., Baddari, K. (2015b). Quaternion neural network to forecast the daily solar irradiation. 3rd InternatioanalSymp.Innov. Technol. Eng. Sci. ISITES2015, p. 229–338.
- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2015c). Short-Term Forecasting of the Global Solar Irradiation Using the Fuzzy Modeling Technique: Case Study of Tamanrasset City, Algeria. *Progress in Clean Energy*, Volume 1: Analysis and Modeling, 281-289. [https://doi.org/10.1007/978-3-319-16709-1\\_19](https://doi.org/10.1007/978-3-319-16709-1_19)

- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2017). Fully complex valued wavelet network for forecasting the global solar irradiation. *Neural Processing Letters*, 45, 475-505. <https://doi.org/10.1007/s11063-016-9537-7>
- Saoud, L. S., Rahmoune, F., Tourtchine, V., & Baddari, K. (2018). A novel method to forecast 24 h of global solar irradiation. *Energy Systems*, 9(1), 171-193. <https://doi.org/10.1007/s12667-016-0218-4>
- Saoud, L. S., & AlMarzouqi, H. (2022). Forecasting Solar Irradiance using Hybrid Stationary Wavelet Transform-Quaternion Valued Neural Network with a Softplus AMSGrad Learning Algorithm. In 2022 IEEE International Conference on Power Systems Technology (POWERCON) (pp. 1-6). IEEE. <https://doi.org/10.1109/POWERCON53406.2022.9929612>
- Schmidt, J., Marques, M. R., Botti, S., & Marques, M. A. (2019). Recent advances and applications of machine learning in solid-state materials science. *npj Computational Materials*, 5(1), 83. <https://doi.org/10.1038/s41524-019-0221-0>
- Schryen, G., & Sperling, M. (2023). Literature reviews in operations research: A new taxonomy and a meta review. *Computers & Operations Research*, 106269. <https://doi.org/10.1016/j.cor.2023.106269>
- Sein, Z. M. M., Ullah, I., Iyakaremye, V., Azam, K., Ma, X., Syed, S., & Zhi, X. (2022). Observed spatiotemporal changes in air temperature, dew point temperature and relative humidity over Myanmar during 2001–2019. *Meteorology and Atmospheric Physics*, 134, 1-17. <https://doi.org/10.1007/s00703-021-00837-7>
- Sekertekin, A., Bilgili, M., Arslan, N., Yildirim, A., Celebi, K., & Ozbek, A. (2021). Short-term air temperature prediction by adaptive neuro-fuzzy inference system (ANFIS) and long short-term memory (LSTM) network. *Meteorology and Atmospheric Physics*, 133, 943-959. <https://doi.org/10.1007/s00703-021-00791-4>
- Şenkal, O. (2010). Modeling of solar radiation using remote sensing and artificial neural network in Turkey. *Energy*, 35(12), 4795-4801. <https://doi.org/10.1016/j.energy.2010.09.009>
- Şenkal, O. Z. A. N., Şahin, M. E. H. M. E. T., & Peştimalci, V. (2010). The estimation of solar radiation for different time periods. *Energy Sources, Part A: Recovery*,

- Utilization, and Environmental Effects*, 32(13), 1176-1184.  
<https://doi.org/10.1080/15567030902967850>
- Shaari, S., Mekki, H., & Khorissi, N. (2008). FPGA-based artificial neural network for prediction of solar radiation data from sunshine duration and air temperature. In *2008 IEEE Region 8 International Conference on Computational Technologies in Electrical and Electronics Engineering* (pp. 118-123). IEEE.  
<https://doi.org/10.1109/SIBIRCON.2008.4602597>
- Shad, M., Sharma, Y. D., & Singh, A. (2022). Forecasting of monthly relative humidity in Delhi, India, using SARIMA and ANN models. *Modeling earth systems and environment*, 8(4), 4843–4851. <https://doi.org/10.1007/s40808-022-01385-8>
- Shamshirband, S., Mohammadi, K., Yee, L., Petković, D., & Mostafaeipour, A. (2015). A comparative evaluation for identifying the suitability of extreme learning machine to predict horizontal global solar radiation. *Renewable and sustainable energy reviews*, 52, 1031-1042. <https://doi.org/10.1016/j.rser.2015.07.173>
- Shamshirband, S., Mohammadi, K., Khorasanizadeh, H., Yee, L., Lee, M., Petković, D., & Zalnezhad, E. (2016). Estimating the diffuse solar radiation using a coupled support vector machine–wavelet transform model. *Renewable and Sustainable Energy Reviews*, 56, 428-435. <https://doi.org/10.1016/j.rser.2015.11.055>
- Sharma, A., & Goyal, M. K. (2015). Bayesian network model for monthly rainfall forecast. In *2015 IEEE international conference on research in computational intelligence and communication networks (ICRCICN)* (pp. 241-246). IEEE.  
<https://doi.org/10.1109/ICRCICN.2015.7434243>
- Sharma, V., Yang, D., Walsh, W., & Reindl, T. (2016). Short term solar irradiance forecasting using a mixed wavelet neural network. *Renewable Energy*, 90, 481-492.  
<https://doi.org/10.1016/j.renene.2016.01.020>
- Shelia, V., Hansen, J., Sharda, V., Porter, C., Aggarwal, P., Wilkerson, C. J., & Hoogenboom, G. (2019). A multi-scale and multi-model gridded framework for forecasting crop production, risk analysis, and climate change impact studies. *Environmental Modelling & Software*, 115, 144-154. <https://doi.org/10.1016/j.envsoft.2019.02.006>

- Shi, X., Lu, W., Zhao, Y., & Qin, P. (2018). Prediction of indoor temperature and relative humidity based on cloud database by using an improved BP neural network in Chongqing. *IEEE Access*, 6, 30559-30566. <https://doi.org/10.1109/ACCESS.2018.2844299>
- Shrestha, A. K., Thapa, A., & Gautam, H. (2019). Solar radiation, air temperature, relative humidity, and dew point study: Damak, Jhapa, Nepal. *International Journal of Photoenergy*, 2019, 1-7. <https://doi.org/10.1155/2019/8369231>
- Si, Y., Zhang, Z., Kong, L., Li, S., Wang, Q., Kong, C., & Li, Y. (2019). Aging condition identification of viscoelastic sandwich structure based on empirical wavelet transform and Hilbert envelope demodulation. *Composite Structures*, 215, 13-22. <https://doi.org/10.1016/j.compstruct.2019.02.039>
- Sibtain, M., Li, X., Saleem, S., Asad, M. S., Tahir, T., & Apaydin, H. (2021). A multistage hybrid model ICEEMDAN-SE-VMD-RDPG for a multivariate solar irradiance forecasting. *IEEE Access*, 9, 37334-37363. [10.1109/ACCESS.2021.3062764](https://doi.org/10.1109/ACCESS.2021.3062764)
- Singla, P., Duhan, M., & Saroha, S. (2021). A comprehensive review and analysis of solar forecasting techniques. *Frontiers in Energy*, 1-37. <https://doi.org/10.1007/s11708-021-0722-7>
- Smola, A. (1996). Regression estimation with support vector learning machines. Tech. report, Physik Department, Technische Universität München.
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of business research*, 104, 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Sonntag, D., Foken, T., Vömel, H., Hellmuth, O. (2021). Humidity Sensors. In: Foken, T. (eds) Springer Handbook of Atmospheric Measurements. Springer Handbooks. Springer, Cham. [https://doi.org/10.1007/978-3-030-52171-4\\_8](https://doi.org/10.1007/978-3-030-52171-4_8)
- Specht, D. F. (1991). A general regression neural network. *IEEE transactions on neural networks*, 2(6), 568-576. <https://doi.org/10.1109/72.97934>

- Srivastava, R., Tiwari, A. N., & Giri, V. K. (2019). Solar radiation forecasting using MARS, CART, M5, and random forest model: A case study for India. *Heliyon*, 5(10), e02692. <https://doi.org/10.1016/j.heliyon.2019.e02692>
- Stahl, K., Moore, R. D., Floyer, J. A., Asplin, M. G., & McKendry, I. G. (2006). Comparison of approaches for spatial interpolation of daily air temperature in a large region with complex topography and highly variable station density. *Agricultural and forest meteorology*, 139(3-4), 224-236. <https://doi.org/10.1016/j.agrformet.2006.07.004>
- Stöckle, C. O., Donatelli, M., & Nelson, R. (2003). CropSyst, a cropping systems simulation model. *European journal of agronomy*, 18(3-4), 289-307. [https://doi.org/10.1016/S1161-0301\(02\)00109-0](https://doi.org/10.1016/S1161-0301(02)00109-0)
- Suradhaniwar, S., Kar, S., Durbha, S.S., & Jagarlapudi, A. (2021). Time series forecasting of univariate agrometeorological data: A comparative performance evaluation via one-step and multi-step ahead forecasting strategies. *Sensors*, 21(7), 2430. <https://doi.org/10.3390/s21072430>.
- Tai, Q., You, P., Sang, H., Liu, Z., Hu, C., Chan, H. L., & Yan, F. (2016). Efficient and stable perovskite solar cells prepared in ambient air irrespective of the humidity. *Nature communications*, 7(1), 11105. <https://doi.org/10.1038/ncomms11105>
- Taki, M., Rohani, A., & Yildizhan, H. (2021). Application of machine learning for solar radiation modeling. *Theoretical and Applied Climatology*, 143(3-4), 1599-1613. <https://doi.org/10.1007/s00704-020-03484-x>
- Takilalte, A., Harrouni, S., & Mora, J. (2022). Forecasting global solar irradiance for various resolutions using time series models-case study: Algeria. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 44(1), 1-20. <https://doi.org/10.1080/15567036.2019.1649756>
- Tao, H., Awadh, S. M., Salih, S. Q., Shafik, S. S., & Yaseen, Z. M. (2022). Integration of extreme gradient boosting feature selection approach with machine learning models: application of weather relative humidity prediction. *Neural Computing and Applications*, 34(1), 515-533. <https://doi.org/10.1007/s00521-021-06362-3>
- Tekleyohannes, M., Grum, B., Abebe, N., & Abebe, B. A. (2021). Optimization of rain gauge network using multi-criteria decision analysis and entropy approaches: case of Tekeze

- River basin, northwestern Ethiopia. *Theoretical and Applied Climatology*, 145(1-2), 159-174. <https://doi.org/10.1007/s00704-021-03604-1>
- Thapliyal, P.K., Shukla, M.V., Bisht, J.H., Pal, P.K., & Navalgund, R.R. (2014). Improvement in the retrieval of humidity profiles using hybrid regression technique from infrared sounder data: A simulation study. *Meteorological Applications*, 21(2), 301-308. <https://doi.org/10.1002/met.1330>
- Tikhamarine, Y., Malik, A., Pandey, K., Sammen, S. S., Souag-Gamane, D., Heddam, S., & Kisi, O. (2020). Monthly evapotranspiration estimation using optimal climatic parameters: efficacy of hybrid support vector regression integrated with whale optimization algorithm. *Environmental Monitoring and Assessment*, 192, 1-19. <https://doi.org/10.1007/s10661-020-08659-7>
- Tolabi, H. B., Moradi, M. H., & Ayob, S. B. M. (2014). A review on classification and comparison of different models in solar radiation estimation. *International journal of energy research*, 38(6), 689-701. <https://doi.org/10.1002/er.3161>
- Tolera, M. B., Chung, I. M., & Chang, S. W. (2018). Evaluation of the climate forecast system reanalysis weather data for watershed modeling in Upper Awash basin, Ethiopia. *Water*, 10(6), 725. <https://doi.org/10.3390/w10060725>
- Torres-Barrán, A., Alonso, Á., & Dorronsoro, J. R. (2019). Regression tree ensembles for wind energy and solar radiation prediction. *Neurocomputing*, 326, 151-160. <https://doi.org/10.1016/j.neucom.2017.05.104>
- Urraca, R., Antonanzas, J., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2015). Estimation of solar global irradiation in remote areas. *Journal of Renewable and Sustainable Energy*, 7(2), 023136. <https://doi.org/10.1063/1.4919084>
- Valík, A., Brázdil, R., Zahradníček, P., Tolasz, R., & Fiala, R. (2021). Precipitation measurements by manual and automatic rain gauges and their influence on homogeneity of long-term precipitation series. *International Journal of Climatology*, 41, E2537-E2552. <https://doi.org/10.1002/joc.6862>
- Vapnik, V. N. (1995). The nature of statistical learning theory (p. 314). New York: Springer. <https://doi.org/10.1007/978-1-4757-2440-0>

- Vasu, N. N., & Lee, S. R. (2016). A hybrid feature selection algorithm integrating an extreme learning machine for landslide susceptibility modeling of Mt. Woomyeon, South Korea. *Geomorphology*, 263, 50-70. <https://doi.org/10.1016/j.geomorph.2016.03.023>
- Vivas, E., de Guenni, L. B., Allende-Cid, H., & Salas, R. (2023). Deep Lagged-Wavelet for monthly rainfall forecasting in a tropical region. *Stochastic Environmental Research and Risk Assessment*, 37(3), 831-848. <https://doi.org/10.1007/s00477-022-02323-x>
- Voyant, C., Muselli, M., Paoli, C., & Nivet, M. L. (2012). Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. *Energy*, 39(1), 341-355. <https://doi.org/10.1016/j.energy.2012.01.006>
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable energy*, 105, 569-582. <https://doi.org/10.1016/j.renene.2016.12.095>
- Wang, J., & Hu, J. (2015). A robust combination approach for short-term wind speed forecasting and analysis—Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy*, 93, 41-56. <https://doi.org/10.1016/j.energy.2015.08.045>
- Wang, Y., & Wu, L. (2016). On practical challenges of decomposition-based hybrid forecasting algorithms for wind speed and solar irradiation. *Energy*, 112, 208-220. <https://doi.org/10.1016/j.energy.2016.06.075>
- Wang, L., Kisi, O., Zounemat-Kermani, M., Salazar, G. A., Zhu, Z., & Gong, W. (2016). Solar radiation prediction using different techniques: model evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 61, 384-397. <https://doi.org/10.1016/j.rser.2016.04.024>
- Wang, Y., & Peng, H. (2018). Underwater acoustic source localization using generalized regression neural network. *The Journal of the Acoustical Society of America*, 143(4), 2321-2331. <https://doi.org/10.1121/1.5032311>

- Wang, S. Y., Qiu, J., & Li, F. F. (2018a). Hybrid decomposition-reconfiguration models for long-term solar radiation prediction only using historical radiation records. *Energies*, *11*(6), 1376. <https://doi.org/10.3390/en11061376>
- Wang, Z., Tian, C., Zhu, Q., & Huang, M. (2018b). Hourly solar radiation forecasting using a voltterra-least squares support vector machine model combined with signal decomposition. *Energies*, *11*(1), 68. <https://doi.org/10.3390/en11010068>
- Wang, X., Wang, X., Wang, L., Jiang, L., & Zhan, Y. (2021). A Distributed Fusion LSTM Model to Forecast Temperature and Relative Humidity in Smart Buildings. In *2021 IEEE 16th Conference on Industrial Electronics and Applications (ICIEA)* (pp. 1-6). IEEE. <https://doi.org/10.1109/ICIEA51954.2021.9516165>.
- Wang, Y., Lu, Z., Ma, Y., Li, X., Ren, W., & Zou, X. (2022). Analysis on the characteristics of wind speed and wind energy resources from 1961 to 2020 and the impact of urban underlying surface change on them in Shenyang. *Energy Reports*, *8*, 335-342. <https://doi.org/10.1016/j.egy.2022.03.06>
- Webber, H., Ewert, F., Kimball, B. A., Siebert, S., White, J. W., Wall, G. W., ... & Gaiser, T. (2016). Simulating canopy temperature for modelling heat stress in cereals. *Environmental Modelling & Software*, *77*, 143-155. <https://doi.org/10.1016/j.envsoft.2015.12.003>
- WMO. (2018). Guide to Instruments and Methods of Observation: Volume I—Measurement of Meteorological Variables; WMO: Geneva, Switzerland; pp. 221–224
- Wu, X., Hou, J., Hui, J., Tang, Z., & Wang, W. (2022). Revealing microclimate around buildings with long-term monitoring through the neural network algorithms. *Buildings*, *12*(4), 395. <https://doi.org/10.3390/buildings12040395>
- Xu, X., Du, H., Zhou, G., Mao, F., Li, P., Fan, W., & Zhu, D. (2016). A method for daily global solar radiation estimation from two instantaneous values using MODIS atmospheric products. *Energy*, *111*, 117-125. <https://doi.org/10.1016/j.energy.2016.05.095>
- Yacef, R., Mellit, A., Belaid, S., & Şen, Z. (2014). New combined models for estimating daily global solar radiation from measured air temperature in semi-arid climates: application

- in Ghardaïa, Algeria. *Energy conversion and management*, 79, 606-615. <https://doi.org/10.1016/j.enconman.2013.12.057>
- Yadav, A. K., & Chandel, S. S. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and sustainable energy reviews*, 33, 772-781. <https://doi.org/10.1016/j.rser.2013.08.055>
- Yadav, A. P., & Behera, L. (2014). Solar Radiation forecasting using neural networks and Wavelet Transform. *IFAC Proceedings Volumes*, 47(1), 890-896. <https://doi.org/10.3182/20140313-3-IN-3024.00218>
- Yang, K., Koike, T., & Ye, B. (2006). Improving estimation of hourly, daily, and monthly solar radiation by importing global data sets. *Agricultural and Forest Meteorology*, 137(1-2), 43-55. <https://doi.org/10.1016/j.agrformet.2006.02.001>
- Yasar, A., Simsek, E., Bilgili, M., Yucel, A., & Ilhan, I. (2012). Estimation of relative humidity based on artificial neural network approach in the Aegean Region of Turkey. *Meteorology and Atmospheric Physics*, 115, 81-87. <https://doi.org/10.1007/s00703-011-0168-2>
- Yaseen, Z. M., Ghareb, M. I., Ebtehaj, I., Bonakdari, H., Siddique, R., Heddami, S., ... & Deo, R. (2018). Rainfall pattern forecasting using novel hybrid intelligent model based ANFIS-FFA. *Water resources management*, 32, 105-122. <https://doi.org/10.1007/s11269-017-1797-0>
- Yaseen, Z. M., Sulaiman, S. O., Deo, R. C., & Chau, K. W. (2019). An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology*, 569, 387-408. <https://doi.org/10.1016/j.jhydrol.2018.11.069>
- Yilmaz, B., Aras, E., Nacar, S., & Kankal, M. (2018). Estimating suspended sediment load with multivariate adaptive regression spline, teaching-learning based optimization, and artificial bee colony models. *Science of the Total Environment*, 639, 826-840. <https://doi.org/10.1016/j.scitotenv.2018.05.153>
- Zambrano, F., Vrieling, A., Nelson, A., Meroni, M., & Tadesse, T. (2018). Prediction of drought-induced reduction of agricultural productivity in Chile from MODIS, rainfall

- estimates, and climate oscillation indices. *Remote sensing of environment*, 219, 15-30. <https://doi.org/10.1016/j.rse.2018.10.006>
- Zemouri, N., & Bouzgou, H. (2018). Ensemble of support vector methods to estimate global solar radiation in Algeria. In *Artificial Intelligence in Renewable Energetic Systems: Smart Sustainable Energy Systems* (pp. 155-163). Springer International Publishing. [https://doi.org/10.1007/978-3-319-73192-6\\_16](https://doi.org/10.1007/978-3-319-73192-6_16)
- Zerouali, B., Santos, C. A. G., de Farias, C. A. S., Muniz, R. S., Difi, S., Abda, Z., Chettih, M., Heddami, S., Anwar, S. A., & Elbeltagi, A. (2023). Artificial intelligent systems optimized by metaheuristic algorithms and teleconnection indices for rainfall modeling: The case of a humid region in the mediterranean basin. *Heliyon*, 9(4). <https://doi.org/10.1016/j.heliyon.2023.e15355>
- Zhang, J., Zhao, L., Deng, S., Xu, W., & Zhang, Y. (2017). A critical review of the models used to estimate solar radiation. *Renewable and Sustainable Energy Reviews*, 70, 314-329. <https://doi.org/10.1016/j.rser.2016.11.124>
- Zhang, W., & Wu, C. (2020). Machine learning predictive models for pile drivability: an evaluation of random forest regression and multivariate adaptive regression splines. In *Information Technology in Geo-Engineering: Proceedings of the 3rd International Conference (ICITG), Guimarães, Portugal 3* (pp. 243-255). Springer International Publishing. [https://doi.org/10.1007/978-3-030-32029-4\\_21](https://doi.org/10.1007/978-3-030-32029-4_21)
- Zhang, Y., Pan, G., Chen, B., Han, J., Zhao, Y., & Zhang, C. (2020). Short-term wind speed prediction model based on GA-ANN improved by VMD. *Renewable Energy*, 156, 1373-1388. <https://doi.org/10.1016/j.renene.2019.12.047>
- Zhang, S., Li, K., Wang, S., Li, J., Pang, Y., & Song, X. (2023). Recursive surrogate model based on generalized regression neural network. *Applied Soft Computing*, 145, 110576. <https://doi.org/10.1016/j.asoc.2023.110576>
- Zhao, C., Wu, Y., Dai, X., Han, J., Dong, B., & Huang, L. B. (2022). Calliopsis structure-based triboelectric nanogenerator for harvesting wind energy and self-powered wind speed/direction sensor. *Materials & Design*, 221, 111005. <https://doi.org/10.1016/j.matdes.2022.111005>

- Zhou, Y., Liu, Y., Wang, D., Liu, X., & Wang, Y. (2021). A review on global solar radiation prediction with machine learning models in a comprehensive perspective. *Energy Conversion and Management*, 235, 113960. <https://doi.org/10.1016/j.enconman.2021.113960>
- Zhou, Z., Lin, A., He, L., & Wang, L. (2022). Evaluation of Various Tree-Based Ensemble Models for Estimating Solar Energy Resource Potential in Different Climatic Zones of China. *Energies*, 15(9), 3463. <https://doi.org/10.3390/en15093463>
- Zhu, S., Heddam, S., Wu, S., Dai, J., & Jia, B. (2019). Extreme learning machine-based prediction of daily water temperature for rivers. *Environmental Earth Sciences*, 78, 1-17. <https://doi.org/10.1007/s12665-019-8202-7>
- Zjavka, L. (2015). Wind speed forecast correction models using polynomial neural networks. *Renewable Energy*, 83, 998-1006. <https://doi.org/10.1016/j.renene.2015.04.054>

Annexe A. Résultats détaillées obtenus par les modèles hybrides durant la modélisation de l'HR

Tableau A.1. Résultats obtenus par les modèles hybrides au niveau de la station d'Alger

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.925	0.854	5.689	4.504	0.891	0.793	6.731	5.316
MLPNN_EMD2	0.926	0.855	5.661	4.474	0.885	0.784	6.878	5.440
<b>MLPNN_EMD3</b>	<b>0.927</b>	<b>0.858</b>	<b>5.602</b>	<b>4.417</b>	<b>0.892</b>	<b>0.794</b>	<b>6.704</b>	<b>5.328</b>
MLPNN_EMD4	0.915	0.836	6.034	4.761	0.882	0.777	6.977	5.548
MLPNN_EMD5	0.895	0.798	6.684	5.346	0.863	0.743	7.497	6.025
MLPNN_EMD6	0.886	0.785	6.906	5.496	0.859	0.738	7.565	6.078
<b>MLPNN_EWT1</b>	<b>0.927</b>	<b>0.857</b>	<b>5.583</b>	<b>4.411</b>	<b>0.905</b>	<b>0.818</b>	<b>6.408</b>	<b>5.067</b>
MLPNN_EWT2	0.919	0.843	5.853	4.649	0.900	0.809	6.568	5.184
MLPNN_EWT3	0.919	0.843	5.859	4.614	0.898	0.807	6.608	5.258
MLPNN_EWT4	0.909	0.826	6.171	4.875	0.895	0.800	6.717	5.340
MLPNN_EWT5	0.894	0.794	6.702	5.360	0.884	0.780	7.056	5.679
MLPNN_EWT6	0.879	0.770	7.085	5.628	0.867	0.750	7.507	6.006
<b>MLPNN_VMD1</b>	<b>0.931</b>	<b>0.865</b>	<b>5.440</b>	<b>4.308</b>	<b>0.894</b>	<b>0.800</b>	<b>6.706</b>	<b>5.257</b>
MLPNN_VMD2	0.923	0.849	5.745	4.516	0.885	0.783	6.985	5.498
MLPNN_VMD3	0.917	0.839	5.946	4.718	0.882	0.777	7.072	5.536
MLPNN_VMD4	0.909	0.825	6.199	4.910	0.870	0.756	7.398	5.812
MLPNN_VMD5	0.887	0.785	6.864	5.479	0.855	0.730	7.779	6.250
MLPNN_VMD6	0.870	0.756	7.319	5.839	0.843	0.711	8.058	6.485
ELM_EMD1	0.905	0.820	6.321	5.040	0.862	0.740	7.543	5.977
ELM_EMD2	0.900	0.810	6.486	5.143	0.854	0.727	7.731	6.139
ELM_EMD3	0.903	0.815	6.396	5.092	0.855	0.728	7.708	6.163
<b>ELM_EMD4</b>	<b>0.905</b>	<b>0.819</b>	<b>6.334</b>	<b>5.032</b>	<b>0.863</b>	<b>0.741</b>	<b>7.523</b>	<b>5.988</b>
ELM_EMD5	0.887	0.788	6.862	5.492	0.836	0.696	8.151	6.474
ELM_EMD6	0.893	0.798	6.698	5.346	0.844	0.710	7.964	6.395
ELM_EWT1	0.905	0.819	6.292	4.982	0.867	0.750	7.508	6.009
<b>ELM_EWT2</b>	<b>0.904</b>	<b>0.817</b>	<b>6.328</b>	<b>4.991</b>	<b>0.869</b>	<b>0.753</b>	<b>7.466</b>	<b>5.932</b>
ELM_EWT3	0.905	0.819	6.283	4.987	0.868	0.752	7.490	5.945
ELM_EWT4	0.907	0.823	6.211	4.948	0.867	0.748	7.537	5.971
ELM_EWT5	0.890	0.791	6.752	5.368	0.850	0.718	7.982	6.342
ELM_EWT6	0.895	0.801	6.603	5.296	0.850	0.719	7.963	6.292
<b>ELM_VMD1</b>	<b>0.891</b>	<b>0.793</b>	<b>6.732</b>	<b>5.375</b>	<b>0.844</b>	<b>0.709</b>	<b>8.081</b>	<b>6.497</b>
ELM_VMD2	0.884	0.781	6.926	5.511	0.835	0.696	8.264	6.582
ELM_VMD3	0.891	0.793	6.730	5.388	0.838	0.700	8.208	6.559
ELM_VMD4	0.889	0.790	6.787	5.395	0.837	0.697	8.241	6.573
ELM_VMD5	0.865	0.749	7.420	5.931	0.791	0.617	9.268	7.432
ELM_VMD6	0.868	0.754	7.344	5.877	0.793	0.623	9.201	7.422

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.150	0.028	0.787	0.595	9.405	7.348
GRNN_EMD2	1.000	1.000	0.193	0.037	0.788	0.592	9.441	7.378
GRNN_EMD3	1.000	0.999	0.416	0.120	0.799	0.616	9.166	7.121
GRNN_EMD4	0.999	0.998	0.704	0.263	0.811	0.641	8.858	6.920
GRNN_EMD5	0.998	0.996	0.910	0.365	0.805	0.631	8.981	6.917
<b>GRNN_EMD6</b>	<b>0.993</b>	<b>0.985</b>	<b>1.797</b>	<b>1.009</b>	<b>0.826</b>	<b>0.676</b>	<b>8.413</b>	<b>6.538</b>
GRNN_EWT1	0.999	0.999	0.538	0.188	0.806	0.630	9.141	7.019
GRNN_EWT2	0.999	0.997	0.748	0.310	0.810	0.638	9.046	6.985
GRNN_EWT3	0.998	0.996	0.959	0.445	0.817	0.654	8.845	6.830
GRNN_EWT4	0.996	0.991	1.374	0.725	0.840	0.697	8.274	6.453
GRNN_EWT5	0.994	0.989	1.569	0.854	0.822	0.663	8.723	6.703
<b>GRNN_EWT6</b>	<b>0.988</b>	<b>0.976</b>	<b>2.299</b>	<b>1.437</b>	<b>0.850</b>	<b>0.717</b>	<b>7.991</b>	<b>6.217</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.622	0.256	12.922	10.159
GRNN_VMD2	1.000	1.000	0.000	0.000	0.621	0.275	12.753	10.034
GRNN_VMD3	1.000	1.000	0.000	0.000	0.639	0.274	12.766	9.902
GRNN_VMD4	1.000	1.000	0.000	0.000	0.663	0.341	12.156	9.590
GRNN_VMD5	1.000	1.000	0.000	0.000	0.664	0.354	12.036	9.403
<b>GRNN_VMD6</b>	<b>1.000</b>	<b>1.000</b>	<b>0.067</b>	<b>0.008</b>	<b>0.694</b>	<b>0.427</b>	<b>11.340</b>	<b>8.935</b>
<b>MARS_EMD1</b>	<b>0.820</b>	<b>0.673</b>	<b>8.517</b>	<b>6.831</b>	<b>0.817</b>	<b>0.668</b>	<b>8.520</b>	<b>6.881</b>
<b>MARS_EMD2</b>	<b>0.820</b>	<b>0.673</b>	<b>8.517</b>	<b>6.831</b>	<b>0.817</b>	<b>0.668</b>	<b>8.520</b>	<b>6.881</b>
MARS_EMD3	0.819	0.671	8.536	6.854	0.814	0.662	8.591	6.948
MARS_EMD4	0.819	0.671	8.536	6.854	0.814	0.662	8.591	6.948
MARS_EMD5	0.819	0.671	8.536	6.854	0.814	0.662	8.591	6.948
MARS_EMD6	0.819	0.671	8.536	6.854	0.814	0.662	8.591	6.948
<b>MARS_EWT1</b>	<b>0.857</b>	<b>0.735</b>	<b>7.607</b>	<b>6.041</b>	<b>0.862</b>	<b>0.743</b>	<b>7.623</b>	<b>6.062</b>
MARS_EWT2	0.839	0.704	8.048	6.411	0.848	0.719	7.971	6.381
MARS_EWT3	0.841	0.707	8.000	6.388	0.849	0.721	7.944	6.331
MARS_EWT4	0.829	0.688	8.257	6.582	0.837	0.701	8.215	6.588
MARS_EWT5	0.821	0.674	8.441	6.758	0.831	0.691	8.351	6.716
MARS_EWT6	0.821	0.674	8.441	6.758	0.831	0.691	8.351	6.716
<b>MARS_VMD1</b>	<b>0.854</b>	<b>0.729</b>	<b>7.704</b>	<b>6.141</b>	<b>0.847</b>	<b>0.718</b>	<b>7.956</b>	<b>6.373</b>
MARS_VMD2	0.825	0.681	8.365	6.684	0.823	0.677	8.510	6.867
MARS_VMD3	0.804	0.646	8.803	7.062	0.799	0.639	9.005	7.277
MARS_VMD4	0.804	0.646	8.803	7.062	0.799	0.639	9.005	7.277
MARS_VMD5	0.804	0.646	8.803	7.062	0.799	0.639	9.005	7.277
MARS_VMD6	0.804	0.646	8.803	7.062	0.799	0.639	9.005	7.277

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.973</b>	<b>0.927</b>	<b>4.009</b>	<b>3.136</b>	<b>0.861</b>	<b>0.720</b>	<b>7.818</b>	<b>6.300</b>
RFR_EMD2	0.971	0.922	4.150	3.244	0.856	0.714	7.909	6.371
RFR_EMD3	0.972	0.924	4.117	3.218	0.858	0.715	7.899	6.340
RFR_EMD4	0.969	0.919	4.236	3.321	0.858	0.713	7.922	6.388
RFR_EMD5	0.968	0.917	4.286	3.366	0.853	0.709	7.978	6.418
RFR_EMD6	0.965	0.912	4.420	3.481	0.851	0.707	8.007	6.469
<b>RFR_EWT1</b>	<b>0.974</b>	<b>0.939</b>	<b>3.659</b>	<b>2.848</b>	<b>0.895</b>	<b>0.795</b>	<b>6.809</b>	<b>5.438</b>
RFR_EWT2	0.971	0.933	3.823	2.973	0.891	0.788	6.923	5.527
RFR_EWT3	0.973	0.936	3.734	2.910	0.895	0.794	6.816	5.439
RFR_EWT4	0.971	0.932	3.867	3.021	0.891	0.788	6.912	5.503
RFR_EWT5	0.969	0.928	3.966	3.109	0.888	0.783	6.999	5.615
RFR_EWT6	0.965	0.922	4.139	3.250	0.883	0.775	7.122	5.687
<b>RFR_VMD1</b>	<b>0.972</b>	<b>0.923</b>	<b>4.109</b>	<b>3.197</b>	<b>0.839</b>	<b>0.687</b>	<b>8.384</b>	<b>6.733</b>
RFR_VMD2	0.970	0.919	4.216	3.283	0.836	0.682	8.451	6.806
RFR_VMD3	0.971	0.920	4.192	3.261	0.839	0.686	8.389	6.747
RFR_VMD4	0.969	0.915	4.318	3.367	0.838	0.685	8.401	6.765
RFR_VMD5	0.967	0.912	4.391	3.435	0.829	0.673	8.561	6.910
RFR_VMD6	0.963	0.906	4.544	3.563	0.827	0.674	8.556	6.932
SVR_EMD1	0.970	0.841	5.937	4.188	0.345	0.050	14.409	11.531
SVR_EMD2	0.970	0.843	5.903	4.165	0.364	0.060	14.334	11.465
SVR_EMD3	0.971	0.857	5.623	3.994	0.463	0.126	13.820	10.965
SVR_EMD4	0.973	0.878	5.209	3.764	0.581	0.235	12.930	10.170
SVR_EMD5	0.972	0.874	5.293	3.812	0.569	0.237	12.912	10.084
<b>SVR_EMD6</b>	<b>0.974</b>	<b>0.903</b>	<b>4.647</b>	<b>3.490</b>	<b>0.709</b>	<b>0.440</b>	<b>11.067</b>	<b>8.448</b>
SVR_EWT1	0.972	0.863	5.480	3.908	0.532	0.170	13.691	10.886
SVR_EWT2	0.972	0.870	5.324	3.803	0.587	0.231	13.176	10.383
SVR_EWT3	0.973	0.882	5.072	3.670	0.621	0.292	12.642	9.897
SVR_EWT4	0.974	0.895	4.792	3.525	0.699	0.398	11.657	9.068
SVR_EWT5	0.973	0.891	4.881	3.588	0.666	0.371	11.917	9.195
<b>SVR_EWT6</b>	<b>0.971</b>	<b>0.903</b>	<b>4.616</b>	<b>3.472</b>	<b>0.753</b>	<b>0.507</b>	<b>10.548</b>	<b>8.071</b>
SVR_VMD1	0.969	0.829	6.119	4.285	0.027	-0.003	14.999	12.120
SVR_VMD2	0.969	0.829	6.119	4.285	0.020	-0.003	14.999	12.120
SVR_VMD3	0.969	0.829	6.119	4.285	0.102	-0.003	14.999	12.120
SVR_VMD4	0.969	0.830	6.106	4.278	0.204	-0.001	14.983	12.107
SVR_VMD5	0.969	0.830	6.106	4.278	0.136	-0.001	14.983	12.104
<b>SVR_VMD6</b>	<b>0.970</b>	<b>0.848</b>	<b>5.776</b>	<b>4.079</b>	<b>0.334</b>	<b>0.065</b>	<b>14.483</b>	<b>11.658</b>

Tableau A.2. Résultats obtenus par les modèles hybrides au niveau de la station d'Annaba

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.878</b>	<b>0.769</b>	<b>4.051</b>	<b>3.197</b>	<b>0.799</b>	<b>0.636</b>	<b>4.951</b>	<b>3.933</b>
MLPNN_EMD2	0.860	0.739	4.311	3.395	0.773	0.596	5.220	4.157
MLPNN_EMD3	0.860	0.738	4.317	3.407	0.770	0.592	5.247	4.170
MLPNN_EMD4	0.817	0.667	4.866	3.844	0.746	0.556	5.472	4.338
MLPNN_EMD5	0.838	0.700	4.621	3.632	0.769	0.590	5.255	4.188
MLPNN_EMD6	0.795	0.631	5.120	4.046	0.735	0.539	5.572	4.417
<b>MLPNN_EWT1</b>	<b>0.863</b>	<b>0.741</b>	<b>4.229</b>	<b>3.338</b>	<b>0.816</b>	<b>0.665</b>	<b>4.923</b>	<b>3.900</b>
MLPNN_EWT2	0.829	0.679	4.701	3.740	0.785	0.612	5.296	4.210
MLPNN_EWT3	0.840	0.699	4.554	3.607	0.797	0.635	5.141	4.102
MLPNN_EWT4	0.810	0.652	4.896	3.874	0.767	0.588	5.462	4.361
MLPNN_EWT5	0.822	0.667	4.790	3.821	0.786	0.614	5.284	4.231
MLPNN_EWT6	0.788	0.616	5.142	4.080	0.756	0.569	5.582	4.440
<b>MLPNN_VMD1</b>	<b>0.835</b>	<b>0.688</b>	<b>4.640</b>	<b>3.667</b>	<b>0.784</b>	<b>0.611</b>	<b>5.298</b>	<b>4.209</b>
MLPNN_VMD2	0.838	0.696	4.582	3.631	0.750	0.554	5.672	4.496
MLPNN_VMD3	0.842	0.703	4.528	3.578	0.757	0.570	5.573	4.395
MLPNN_VMD4	0.802	0.638	4.997	3.949	0.723	0.522	5.874	4.629
MLPNN_VMD5	0.815	0.659	4.853	3.844	0.749	0.560	5.634	4.466
MLPNN_VMD6	0.761	0.575	5.418	4.293	0.706	0.497	6.027	4.716
<b>ELM_EMD1</b>	<b>0.815</b>	<b>0.664</b>	<b>4.884</b>	<b>3.836</b>	<b>0.712</b>	<b>0.495</b>	<b>5.831</b>	<b>4.608</b>
ELM_EMD2	0.801	0.641	5.050	4.005	0.689	0.461	6.027	4.769
ELM_EMD3	0.801	0.642	5.047	3.973	0.690	0.459	6.037	4.791
ELM_EMD4	0.793	0.629	5.138	4.076	0.674	0.435	6.169	4.883
ELM_EMD5	0.801	0.642	5.046	4.001	0.696	0.470	5.975	4.747
ELM_EMD6	0.795	0.632	5.112	4.056	0.686	0.457	6.050	4.821
ELM_EWT1	0.812	0.660	4.844	3.825	0.721	0.509	5.960	4.687
ELM_EWT2	0.797	0.635	5.018	3.970	0.713	0.500	6.015	4.775
ELM_EWT3	0.801	0.641	4.973	3.951	0.719	0.508	5.967	4.721
ELM_EWT4	0.791	0.625	5.081	4.049	0.702	0.481	6.128	4.855
<b>ELM_EWT5</b>	<b>0.798</b>	<b>0.637</b>	<b>5.005</b>	<b>3.975</b>	<b>0.726</b>	<b>0.518</b>	<b>5.904</b>	<b>4.691</b>
ELM_EWT6	0.796	0.633	5.026	3.986	0.712	0.492	6.064	4.737
<b>ELM_VMD1</b>	<b>0.781</b>	<b>0.610</b>	<b>5.188</b>	<b>4.121</b>	<b>0.706</b>	<b>0.485</b>	<b>6.099</b>	<b>4.864</b>
ELM_VMD2	0.761	0.579	5.391	4.270	0.662	0.425	6.443	5.110
ELM_VMD3	0.757	0.572	5.433	4.299	0.658	0.417	6.487	5.145
ELM_VMD4	0.753	0.567	5.465	4.354	0.651	0.409	6.533	5.167
ELM_VMD5	0.743	0.552	5.561	4.418	0.636	0.386	6.657	5.243
ELM_VMD6	0.749	0.560	5.509	4.391	0.628	0.375	6.715	5.308

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.124	0.022	0.647	0.332	6.710	5.140
GRNN_EMD2	1.000	1.000	0.136	0.026	0.644	0.324	6.749	5.208
GRNN_EMD3	0.999	0.999	0.275	0.076	0.668	0.371	6.510	4.990
GRNN_EMD4	0.998	0.996	0.523	0.193	0.666	0.383	6.451	5.002
GRNN_EMD5	0.998	0.996	0.521	0.200	0.674	0.391	6.407	4.908
<b>GRNN_EMD6</b>	<b>0.991</b>	<b>0.981</b>	<b>1.158</b>	<b>0.624</b>	<b>0.681</b>	<b>0.425</b>	<b>6.223</b>	<b>4.784</b>
GRNN_EWT1	0.999	0.998	0.382	0.142	0.677	0.404	6.568	5.025
GRNN_EWT2	0.998	0.997	0.476	0.192	0.669	0.389	6.647	5.076
GRNN_EWT3	0.998	0.995	0.583	0.252	0.682	0.410	6.534	5.007
GRNN_EWT4	0.995	0.989	0.862	0.436	0.688	0.426	6.443	4.959
GRNN_EWT5	0.991	0.982	1.121	0.625	0.703	0.458	6.265	4.795
<b>GRNN_EWT6</b>	<b>0.977</b>	<b>0.953</b>	<b>1.792</b>	<b>1.173</b>	<b>0.724</b>	<b>0.505</b>	<b>5.986</b>	<b>4.589</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.425	-0.002	8.503	6.606
GRNN_VMD2	1.000	1.000	0.000	0.000	0.422	-0.018	8.574	6.741
GRNN_VMD3	1.000	1.000	0.000	0.000	0.436	0.014	8.436	6.571
GRNN_VMD4	1.000	1.000	0.000	0.000	0.436	0.009	8.457	6.611
<b>GRNN_VMD5</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.464</b>	<b>0.073</b>	<b>8.182</b>	<b>6.411</b>
GRNN_VMD6	1.000	1.000	0.039	0.005	0.457	0.052	8.273	6.451
<b>MARS_EMD1</b>	<b>0.677</b>	<b>0.459</b>	<b>6.202</b>	<b>4.909</b>	<b>0.655</b>	<b>0.429</b>	<b>6.205</b>	<b>4.919</b>
MARS_EMD2	0.677	0.458	6.208	4.910	0.649	0.421	6.249	4.953
MARS_EMD3	0.655	0.429	6.368	5.027	0.636	0.404	6.336	5.033
MARS_EMD4	0.645	0.415	6.446	5.110	0.626	0.392	6.403	5.063
MARS_EMD5	0.655	0.429	6.368	5.027	0.636	0.404	6.336	5.033
MARS_EMD6	0.645	0.415	6.446	5.110	0.626	0.392	6.403	5.063
<b>MARS_EWT1</b>	<b>0.742</b>	<b>0.551</b>	<b>5.561</b>	<b>4.406</b>	<b>0.745</b>	<b>0.554</b>	<b>5.678</b>	<b>4.468</b>
MARS_EWT2	0.715	0.511	5.803	4.601	0.725	0.526	5.856	4.592
MARS_EWT3	0.709	0.503	5.855	4.655	0.711	0.506	5.979	4.753
MARS_EWT4	0.684	0.468	6.055	4.781	0.691	0.478	6.148	4.880
MARS_EWT5	0.701	0.491	5.921	4.701	0.703	0.494	6.051	4.815
MARS_EWT6	0.680	0.462	6.089	4.806	0.688	0.473	6.177	4.898
<b>MARS_VMD1</b>	<b>0.686</b>	<b>0.470</b>	<b>6.047</b>	<b>4.820</b>	<b>0.681</b>	<b>0.463</b>	<b>6.225</b>	<b>4.979</b>
MARS_VMD2	0.638	0.407	6.396	5.098	0.635	0.403	6.567	5.222
MARS_VMD3	0.612	0.375	6.568	5.215	0.611	0.373	6.726	5.346
MARS_VMD4	0.601	0.361	6.641	5.278	0.605	0.366	6.766	5.355
MARS_VMD5	0.612	0.375	6.568	5.215	0.611	0.373	6.726	5.346
MARS_VMD6	0.601	0.361	6.641	5.278	0.605	0.366	6.766	5.355

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.959</b>	<b>0.880</b>	<b>2.915</b>	<b>2.214</b>	<b>0.749</b>	<b>0.542</b>	<b>5.557</b>	<b>4.354</b>
RFR_EMD2	0.954	0.869	3.051	2.330	0.736	0.524	5.666	4.466
RFR_EMD3	0.955	0.873	3.008	2.291	0.741	0.532	5.615	4.422
RFR_EMD4	0.950	0.860	3.155	2.410	0.730	0.515	5.716	4.474
RFR_EMD5	0.951	0.864	3.108	2.373	0.737	0.528	5.640	4.448
RFR_EMD6	0.943	0.849	3.276	2.512	0.722	0.510	5.748	4.512
<b>RFR_EWT1</b>	<b>0.960</b>	<b>0.897</b>	<b>2.664</b>	<b>2.026</b>	<b>0.805</b>	<b>0.637</b>	<b>5.129</b>	<b>4.015</b>
RFR_EWT2	0.955	0.885	2.811	2.147	0.785	0.606	5.340	4.188
RFR_EWT3	0.956	0.889	2.770	2.119	0.795	0.621	5.238	4.142
RFR_EWT4	0.950	0.875	2.935	2.244	0.785	0.605	5.346	4.185
RFR_EWT5	0.952	0.880	2.880	2.206	0.791	0.615	5.276	4.173
RFR_EWT6	0.943	0.863	3.068	2.355	0.780	0.600	5.379	4.231
<b>RFR_VMD1</b>	<b>0.965</b>	<b>0.872</b>	<b>2.978</b>	<b>2.299</b>	<b>0.726</b>	<b>0.492</b>	<b>6.055</b>	<b>4.770</b>
RFR_VMD2	0.961	0.862	3.083	2.383	0.706	0.470	6.185	4.910
RFR_VMD3	0.962	0.864	3.061	2.369	0.722	0.488	6.078	4.780
RFR_VMD4	0.956	0.847	3.245	2.507	0.692	0.453	6.283	4.919
RFR_VMD5	0.957	0.856	3.152	2.444	0.719	0.489	6.075	4.787
RFR_VMD6	0.947	0.834	3.381	2.616	0.682	0.449	6.306	4.937
SVR_EMD1	0.956	0.790	3.860	2.560	0.306	0.038	8.052	6.295
SVR_EMD2	0.957	0.792	3.845	2.550	0.335	0.047	8.016	6.259
SVR_EMD3	0.958	0.803	3.739	2.492	0.387	0.085	7.855	6.119
SVR_EMD4	0.958	0.819	3.590	2.409	0.478	0.154	7.552	5.853
SVR_EMD5	0.958	0.814	3.635	2.437	0.470	0.149	7.572	5.850
<b>SVR_EMD6</b>	<b>0.955</b>	<b>0.834</b>	<b>3.434</b>	<b>2.351</b>	<b>0.565</b>	<b>0.270</b>	<b>7.014</b>	<b>5.377</b>
SVR_EWT1	0.961	0.819	3.528	2.380	0.429	0.116	7.996	6.145
SVR_EWT2	0.961	0.825	3.473	2.350	0.460	0.143	7.873	6.030
SVR_EWT3	0.963	0.833	3.389	2.316	0.492	0.171	7.747	5.944
SVR_EWT4	0.963	0.845	3.266	2.261	0.555	0.240	7.417	5.648
SVR_EWT5	0.959	0.840	3.320	2.296	0.555	0.258	7.330	5.565
<b>SVR_EWT6</b>	<b>0.949</b>	<b>0.840</b>	<b>3.325</b>	<b>2.348</b>	<b>0.622</b>	<b>0.354</b>	<b>6.836</b>	<b>5.155</b>
SVR_VMD1	0.957	0.788	3.829	2.556	0.016	-0.002	8.504	6.624
SVR_VMD2	0.957	0.788	3.829	2.556	0.015	-0.002	8.504	6.624
SVR_VMD3	0.957	0.788	3.829	2.556	0.040	-0.002	8.503	6.624
SVR_VMD4	0.957	0.788	3.826	2.553	0.132	0.001	8.493	6.615
SVR_VMD5	0.957	0.788	3.827	2.554	0.078	0.000	8.498	6.620
<b>SVR_VMD6</b>	<b>0.956</b>	<b>0.793</b>	<b>3.784</b>	<b>2.521</b>	<b>0.212</b>	<b>0.023</b>	<b>8.401</b>	<b>6.525</b>

Tableau A.3. Résultats obtenus par les modèles hybrides au niveau de la station de Constantine

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.969</b>	<b>0.940</b>	<b>5.261</b>	<b>4.046</b>	<b>0.949</b>	<b>0.901</b>	<b>6.615</b>	<b>5.117</b>
MLPNN_EMD2	0.966	0.933	5.551	4.278	0.930	0.864	7.757	6.101
MLPNN_EMD3	0.962	0.925	5.844	4.492	0.949	0.901	6.610	5.137
MLPNN_EMD4	0.953	0.904	6.643	5.297	0.939	0.878	7.324	5.753
MLPNN_EMD5	0.953	0.909	6.467	4.975	0.934	0.872	7.512	5.770
MLPNN_EMD6	0.944	0.890	7.087	5.524	0.931	0.866	7.677	5.991
MLPNN_EWT1	0.961	0.914	6.204	4.913	0.947	0.882	7.414	5.801
<b>MLPNN_EWT2</b>	<b>0.958</b>	<b>0.916</b>	<b>6.121</b>	<b>4.702</b>	<b>0.950</b>	<b>0.902</b>	<b>6.778</b>	<b>5.203</b>
MLPNN_EWT3	0.946	0.894	6.897	5.464	0.940	0.883	7.397	5.811
MLPNN_EWT4	0.939	0.877	7.427	5.918	0.934	0.867	7.893	6.195
MLPNN_EWT5	0.952	0.907	6.459	4.974	0.943	0.888	7.216	5.532
MLPNN_EWT6	0.938	0.880	7.329	5.726	0.934	0.873	7.709	5.946
<b>MLPNN_VMD1</b>	<b>0.965</b>	<b>0.931</b>	<b>5.575</b>	<b>4.298</b>	<b>0.947</b>	<b>0.896</b>	<b>6.882</b>	<b>5.334</b>
MLPNN_VMD2	0.958	0.917	6.112	4.716	0.943	0.889	7.127	5.504
MLPNN_VMD3	0.959	0.918	6.073	4.655	0.945	0.892	7.010	5.396
MLPNN_VMD4	0.942	0.881	7.329	5.833	0.924	0.850	8.276	6.562
MLPNN_VMD5	0.948	0.898	6.794	5.184	0.927	0.859	8.024	6.122
MLPNN_VMD6	0.934	0.871	7.623	5.911	0.925	0.855	8.115	6.248
ELM_EMD1	0.950	0.903	6.678	5.231	0.930	0.864	7.738	6.063
ELM_EMD2	0.947	0.896	6.902	5.425	0.924	0.854	8.029	6.301
ELM_EMD3	0.951	0.904	6.635	5.226	0.930	0.864	7.736	6.012
<b>ELM_EMD4</b>	<b>0.952</b>	<b>0.906</b>	<b>6.552</b>	<b>5.157</b>	<b>0.932</b>	<b>0.868</b>	<b>7.630</b>	<b>6.049</b>
ELM_EMD5	0.943	0.889	7.118	5.617	0.916	0.838	8.457	6.699
ELM_EMD6	0.945	0.893	6.995	5.503	0.919	0.844	8.291	6.565
ELM_EWT1	0.953	0.909	6.376	5.013	0.936	0.874	7.671	6.006
ELM_EWT2	0.950	0.902	6.622	5.197	0.934	0.871	7.768	6.059
ELM_EWT3	0.952	0.906	6.474	5.090	0.937	0.876	7.599	5.899
<b>ELM_EWT4</b>	<b>0.954</b>	<b>0.910</b>	<b>6.328</b>	<b>4.972</b>	<b>0.940</b>	<b>0.881</b>	<b>7.441</b>	<b>5.813</b>
ELM_EWT5	0.942	0.887	7.096	5.587	0.926	0.857	8.160	6.403
ELM_EWT6	0.944	0.892	6.944	5.431	0.929	0.862	8.018	6.183
<b>ELM_VMD1</b>	<b>0.943</b>	<b>0.888</b>	<b>7.099</b>	<b>5.586</b>	<b>0.918</b>	<b>0.843</b>	<b>8.468</b>	<b>6.643</b>
ELM_VMD2	0.937	0.879	7.400	5.837	0.913	0.833	8.724	6.867
ELM_VMD3	0.945	0.893	6.950	5.494	0.918	0.843	8.461	6.689
ELM_VMD4	0.944	0.891	7.016	5.511	0.918	0.842	8.477	6.672
ELM_VMD5	0.930	0.865	7.807	6.130	0.897	0.804	9.439	7.406
ELM_VMD6	0.934	0.873	7.587	5.967	0.904	0.816	9.164	7.050

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.119	0.020	0.864	0.737	10.774	8.062
GRNN_EMD2	1.000	1.000	0.133	0.026	0.870	0.749	10.520	7.881
GRNN_EMD3	1.000	1.000	0.320	0.076	0.862	0.733	10.844	8.116
GRNN_EMD4	1.000	0.999	0.627	0.220	0.874	0.755	10.388	7.836
GRNN_EMD5	0.999	0.999	0.789	0.286	0.868	0.745	10.597	7.951
<b>GRNN_EMD6</b>	<b>0.997</b>	<b>0.994</b>	<b>1.717</b>	<b>0.916</b>	<b>0.888</b>	<b>0.783</b>	<b>9.785</b>	<b>7.395</b>
GRNN_EWT1	1.000	1.000	0.353	0.108	0.882	0.766	10.452	7.916
GRNN_EWT2	1.000	0.999	0.499	0.182	0.885	0.772	10.323	7.842
GRNN_EWT3	0.999	0.999	0.682	0.266	0.885	0.772	10.320	7.781
GRNN_EWT4	0.998	0.996	1.363	0.708	0.897	0.795	9.777	7.390
GRNN_EWT5	0.998	0.997	1.174	0.546	0.886	0.771	10.342	7.794
<b>GRNN_EWT6</b>	<b>0.994</b>	<b>0.987</b>	<b>2.382</b>	<b>1.458</b>	<b>0.907</b>	<b>0.814</b>	<b>9.312</b>	<b>7.011</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.748	0.472	15.512	11.887
GRNN_VMD2	1.000	1.000	0.000	0.000	0.750	0.475	15.462	11.866
GRNN_VMD3	1.000	1.000	0.000	0.000	0.730	0.438	16.005	12.152
GRNN_VMD4	1.000	1.000	0.000	0.000	0.745	0.471	15.530	12.006
GRNN_VMD5	1.000	1.000	0.000	0.000	0.748	0.498	15.119	11.541
<b>GRNN_VMD6</b>	<b>1.000</b>	<b>1.000</b>	<b>0.078</b>	<b>0.010</b>	<b>0.780</b>	<b>0.569</b>	<b>14.010</b>	<b>10.751</b>
MARS_EMD1	0.913	0.833	8.740	6.928	0.911	0.829	8.680	6.869
<b>MARS_EMD2</b>	<b>0.913</b>	<b>0.833</b>	<b>8.739</b>	<b>6.926</b>	<b>0.911</b>	<b>0.829</b>	<b>8.677</b>	<b>6.867</b>
MARS_EMD3	0.905	0.819	9.093	7.220	0.904	0.816	8.996	7.099
MARS_EMD4	0.905	0.819	9.093	7.220	0.904	0.816	8.996	7.099
MARS_EMD5	0.905	0.820	9.082	7.220	0.904	0.818	8.957	7.104
MARS_EMD6	0.905	0.820	9.082	7.220	0.904	0.818	8.957	7.104
<b>MARS_EWT1</b>	<b>0.925</b>	<b>0.856</b>	<b>8.009</b>	<b>6.277</b>	<b>0.928</b>	<b>0.862</b>	<b>8.039</b>	<b>6.209</b>
MARS_EWT2	0.911	0.830	8.704	6.891	0.915	0.838	8.702	6.789
MARS_EWT3	0.909	0.827	8.799	6.952	0.916	0.838	8.686	6.795
MARS_EWT4	0.899	0.808	9.254	7.306	0.905	0.820	9.177	7.186
MARS_EWT5	0.896	0.803	9.372	7.428	0.903	0.815	9.296	7.316
MARS_EWT6	0.896	0.802	9.406	7.465	0.901	0.812	9.370	7.357
<b>MARS_VMD1</b>	<b>0.926</b>	<b>0.857</b>	<b>8.028</b>	<b>6.300</b>	<b>0.924</b>	<b>0.854</b>	<b>8.152</b>	<b>6.402</b>
MARS_VMD2	0.909	0.826	8.873	7.007	0.907	0.823	8.977	7.129
MARS_VMD3	0.896	0.802	9.445	7.467	0.894	0.798	9.585	7.581
MARS_VMD4	0.896	0.802	9.445	7.467	0.894	0.798	9.585	7.581
MARS_VMD5	0.896	0.802	9.445	7.467	0.894	0.798	9.585	7.581
MARS_VMD6	0.896	0.802	9.445	7.467	0.894	0.798	9.585	7.581

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.983</b>	<b>0.958</b>	<b>4.406</b>	<b>3.415</b>	<b>0.921</b>	<b>0.834</b>	<b>8.562</b>	<b>6.719</b>
RFR_EMD2	0.982	0.955	4.544	3.512	0.919	0.832	8.613	6.745
RFR_EMD3	0.982	0.955	4.546	3.538	0.917	0.827	8.725	6.839
RFR_EMD4	0.981	0.953	4.657	3.654	0.917	0.827	8.731	6.909
RFR_EMD5	0.980	0.952	4.707	3.662	0.914	0.824	8.817	6.911
RFR_EMD6	0.978	0.949	4.853	3.797	0.913	0.822	8.857	6.974
RFR_EWT1	0.985	0.966	3.926	3.006	0.941	0.882	7.410	5.774
RFR_EWT2	0.983	0.962	4.114	3.152	0.937	0.875	7.636	5.935
RFR_EWT3	0.984	0.963	4.043	3.089	0.941	0.882	7.409	5.786
<b>RFR_EWT4</b>	<b>0.983</b>	<b>0.961</b>	<b>4.173</b>	<b>3.225</b>	<b>0.941</b>	<b>0.883</b>	<b>7.397</b>	<b>5.788</b>
RFR_EWT5	0.981	0.958	4.311	3.307	0.936	0.873	7.708	6.035
RFR_EWT6	0.980	0.955	4.466	3.458	0.936	0.873	7.687	6.029
<b>RFR_VMD1</b>	<b>0.982</b>	<b>0.954</b>	<b>4.543</b>	<b>3.545</b>	<b>0.903</b>	<b>0.804</b>	<b>9.442</b>	<b>7.623</b>
RFR_VMD2	0.980	0.951	4.722	3.678	0.901	0.801	9.513	7.634
RFR_VMD3	0.981	0.952	4.662	3.646	0.903	0.802	9.494	7.658
RFR_VMD4	0.980	0.950	4.775	3.754	0.903	0.801	9.524	7.713
RFR_VMD5	0.978	0.947	4.907	3.829	0.897	0.794	9.680	7.767
RFR_VMD6	0.977	0.944	5.039	3.935	0.898	0.796	9.641	7.748
SVR_EMD1	0.987	0.912	6.353	5.163	0.400	0.063	20.323	16.881
SVR_EMD2	0.987	0.913	6.297	5.122	0.443	0.080	20.148	16.715
SVR_EMD3	0.988	0.922	5.990	4.944	0.495	0.139	19.487	16.088
SVR_EMD4	0.989	0.934	5.491	4.620	0.618	0.266	17.994	14.663
SVR_EMD5	0.989	0.936	5.417	4.614	0.634	0.276	17.863	14.582
<b>SVR_EMD6</b>	<b>0.990</b>	<b>0.953</b>	<b>4.617</b>	<b>4.107</b>	<b>0.783</b>	<b>0.527</b>	<b>14.447</b>	<b>11.505</b>
SVR_EWT1	0.987	0.914	6.184	4.995	0.530	0.153	19.883	16.513
SVR_EWT2	0.987	0.920	5.978	4.861	0.592	0.217	19.124	15.774
SVR_EWT3	0.987	0.926	5.750	4.734	0.614	0.254	18.669	15.358
SVR_EWT4	0.988	0.941	5.132	4.338	0.744	0.449	16.045	12.864
SVR_EWT5	0.988	0.936	5.345	4.517	0.694	0.364	17.234	14.054
<b>SVR_EWT6</b>	<b>0.988</b>	<b>0.950</b>	<b>4.722</b>	<b>4.096</b>	<b>0.829</b>	<b>0.616</b>	<b>13.393</b>	<b>10.588</b>
SVR_VMD1	0.985	0.898	6.785	5.383	0.051	-0.001	21.362	17.772
SVR_VMD2	0.985	0.898	6.785	5.383	0.064	-0.001	21.362	17.772
SVR_VMD3	0.985	0.898	6.785	5.383	0.098	-0.001	21.362	17.772
SVR_VMD4	0.986	0.899	6.746	5.361	0.199	0.005	21.294	17.721
SVR_VMD5	0.985	0.898	6.775	5.377	0.172	0.000	21.345	17.759
<b>SVR_VMD6</b>	<b>0.985</b>	<b>0.915</b>	<b>6.193</b>	<b>5.011</b>	<b>0.391</b>	<b>0.119</b>	<b>20.034</b>	<b>16.568</b>

Tableau A.4. Résultats obtenus par les modèles hybrides au niveau de la station de Sétif

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.966</b>	<b>0.934</b>	<b>5.792</b>	<b>4.474</b>	<b>0.952</b>	<b>0.907</b>	<b>6.932</b>	<b>5.357</b>
MLPNN_EMD2	0.961	0.922	6.257	4.763	0.948	0.898	7.265	5.497
MLPNN_EMD3	0.963	0.927	6.052	4.628	0.951	0.903	7.059	5.373
MLPNN_EMD4	0.948	0.892	7.373	5.849	0.933	0.865	8.347	6.604
MLPNN_EMD5	0.942	0.877	7.873	6.263	0.931	0.859	8.529	6.794
MLPNN_EMD6	0.944	0.891	7.415	5.703	0.937	0.877	7.953	6.164
<b>MLPNN_EWT1</b>	<b>0.965</b>	<b>0.931</b>	<b>5.936</b>	<b>4.520</b>	<b>0.954</b>	<b>0.911</b>	<b>6.742</b>	<b>5.162</b>
MLPNN_EWT2	0.959	0.919	6.406	4.860	0.950	0.901	7.076	5.397
MLPNN_EWT3	0.952	0.904	6.972	5.505	0.942	0.886	7.622	6.016
MLPNN_EWT4	0.956	0.913	6.657	5.125	0.948	0.899	7.168	5.515
MLPNN_EWT5	0.933	0.863	8.347	6.634	0.923	0.846	8.851	7.063
MLPNN_EWT6	0.932	0.867	8.229	6.485	0.926	0.855	8.585	6.829
<b>MLPNN_VMD1</b>	<b>0.972</b>	<b>0.944</b>	<b>5.302</b>	<b>4.093</b>	<b>0.946</b>	<b>0.894</b>	<b>7.442</b>	<b>5.700</b>
MLPNN_VMD2	0.961	0.923	6.202	4.759	0.944	0.890	7.565	5.701
MLPNN_VMD3	0.953	0.901	7.043	5.521	0.932	0.865	8.391	6.435
MLPNN_VMD4	0.931	0.862	8.327	6.655	0.914	0.834	9.304	7.304
MLPNN_VMD5	0.951	0.903	6.985	5.383	0.918	0.839	9.181	7.060
MLPNN_VMD6	0.937	0.877	7.843	6.014	0.930	0.865	8.411	6.399
ELM_EMD1	0.952	0.906	6.887	5.440	0.928	0.861	8.477	6.743
ELM_EMD2	0.948	0.898	7.174	5.644	0.929	0.862	8.433	6.579
ELM_EMD3	0.953	0.908	6.817	5.355	0.930	0.863	8.398	6.517
<b>ELM_EMD4</b>	<b>0.953</b>	<b>0.908</b>	<b>6.799</b>	<b>5.374</b>	<b>0.934</b>	<b>0.872</b>	<b>8.127</b>	<b>6.390</b>
ELM_EMD5	0.946	0.895	7.274	5.716	0.924	0.853	8.715	6.859
ELM_EMD6	0.950	0.902	7.043	5.471	0.928	0.861	8.471	6.656
ELM_EWT1	0.956	0.915	6.586	5.193	0.937	0.878	7.861	6.183
ELM_EWT2	0.953	0.909	6.799	5.314	0.935	0.873	8.020	6.279
ELM_EWT3	0.956	0.915	6.579	5.167	0.939	0.880	7.800	6.090
<b>ELM_EWT4</b>	<b>0.957</b>	<b>0.916</b>	<b>6.524</b>	<b>5.114</b>	<b>0.941</b>	<b>0.884</b>	<b>7.675</b>	<b>6.056</b>
ELM_EWT5	0.948	0.900	7.145	5.616	0.927	0.859	8.476	6.654
ELM_EWT6	0.952	0.907	6.866	5.347	0.934	0.873	8.049	6.327
<b>ELM_VMD1</b>	<b>0.941</b>	<b>0.886</b>	<b>7.554</b>	<b>5.961</b>	<b>0.920</b>	<b>0.845</b>	<b>8.984</b>	<b>7.085</b>
ELM_VMD2	0.936	0.876	7.880	6.246	0.913	0.833	9.338	7.344
ELM_VMD3	0.944	0.891	7.380	5.840	0.918	0.842	9.097	7.107
ELM_VMD4	0.942	0.888	7.502	5.933	0.918	0.841	9.116	7.110
ELM_VMD5	0.934	0.872	8.021	6.299	0.905	0.817	9.763	7.704
ELM_VMD6	0.937	0.879	7.797	6.099	0.910	0.828	9.488	7.411

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.105	0.017	0.877	0.760	11.136	8.317
GRNN_EMD2	1.000	1.000	0.124	0.024	0.880	0.765	11.005	8.190
GRNN_EMD3	1.000	1.000	0.344	0.076	0.884	0.775	10.777	7.996
GRNN_EMD4	1.000	0.999	0.679	0.228	0.891	0.789	10.432	7.803
GRNN_EMD5	0.999	0.999	0.822	0.292	0.891	0.786	10.498	7.808
<b>GRNN_EMD6</b>	<b>0.997</b>	<b>0.993</b>	<b>1.832</b>	<b>0.972</b>	<b>0.903</b>	<b>0.812</b>	<b>9.852</b>	<b>7.442</b>
GRNN_EWT1	1.000	0.999	0.663	0.241	0.887	0.780	10.580	7.837
GRNN_EWT2	0.999	0.999	0.849	0.355	0.890	0.786	10.438	7.747
GRNN_EWT3	0.999	0.998	1.091	0.497	0.893	0.791	10.309	7.661
GRNN_EWT4	0.997	0.994	1.757	0.980	0.908	0.821	9.529	7.114
GRNN_EWT5	0.996	0.992	1.982	1.091	0.889	0.783	10.506	7.731
<b>GRNN_EWT6</b>	<b>0.990</b>	<b>0.980</b>	<b>3.223</b>	<b>2.115</b>	<b>0.911</b>	<b>0.827</b>	<b>9.384</b>	<b>6.945</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.761	0.498	16.182	12.179
GRNN_VMD2	1.000	1.000	0.000	0.000	0.749	0.483	16.425	12.426
GRNN_VMD3	1.000	1.000	0.000	0.000	0.758	0.486	16.380	12.305
GRNN_VMD4	1.000	1.000	0.000	0.000	0.769	0.503	16.113	12.326
GRNN_VMD5	1.000	1.000	0.000	0.000	0.762	0.519	15.841	11.881
<b>GRNN_VMD6</b>	<b>1.000</b>	<b>1.000</b>	<b>0.039</b>	<b>0.004</b>	<b>0.795</b>	<b>0.592</b>	<b>14.595</b>	<b>11.048</b>
<b>MARS_EMD1</b>	<b>0.918</b>	<b>0.842</b>	<b>8.932</b>	<b>7.069</b>	<b>0.915</b>	<b>0.836</b>	<b>9.188</b>	<b>7.252</b>
MARS_EMD2	0.917	0.841	8.949	7.065	0.914	0.835	9.222	7.281
MARS_EMD3	0.910	0.829	9.298	7.321	0.907	0.822	9.576	7.581
MARS_EMD4	0.910	0.829	9.297	7.321	0.907	0.822	9.576	7.581
MARS_EMD5	0.910	0.829	9.298	7.321	0.907	0.822	9.576	7.581
MARS_EMD6	0.910	0.829	9.297	7.321	0.907	0.822	9.576	7.581
<b>MARS_EWT1</b>	<b>0.932</b>	<b>0.868</b>	<b>8.191</b>	<b>6.374</b>	<b>0.929</b>	<b>0.862</b>	<b>8.369</b>	<b>6.518</b>
MARS_EWT2	0.918	0.842	8.954	7.013	0.911	0.830	9.304	7.271
MARS_EWT3	0.918	0.842	8.954	7.014	0.911	0.830	9.304	7.272
MARS_EWT4	0.908	0.825	9.436	7.460	0.900	0.810	9.822	7.726
MARS_EWT5	0.905	0.820	9.570	7.583	0.898	0.807	9.916	7.854
MARS_EWT6	0.905	0.820	9.570	7.583	0.898	0.807	9.916	7.854
<b>MARS_VMD1</b>	<b>0.927</b>	<b>0.859</b>	<b>8.408</b>	<b>6.628</b>	<b>0.928</b>	<b>0.860</b>	<b>8.548</b>	<b>6.644</b>
MARS_VMD2	0.908	0.824	9.408	7.409	0.912	0.831	9.394	7.359
MARS_VMD3	0.897	0.805	9.886	7.803	0.902	0.813	9.871	7.694
MARS_VMD4	0.897	0.805	9.886	7.803	0.902	0.813	9.871	7.694
MARS_VMD5	0.897	0.805	9.886	7.803	0.902	0.813	9.871	7.694
MARS_VMD6	0.897	0.805	9.886	7.803	0.902	0.813	9.871	7.694

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.984</b>	<b>0.959</b>	<b>4.543</b>	<b>3.514</b>	<b>0.928</b>	<b>0.849</b>	<b>8.822</b>	<b>6.936</b>
RFR_EMD2	0.983	0.957	4.655	3.571	0.924	0.843	8.987	7.015
RFR_EMD3	0.983	0.957	4.651	3.589	0.926	0.847	8.892	6.992
RFR_EMD4	0.982	0.955	4.776	3.718	0.927	0.846	8.902	7.066
RFR_EMD5	0.981	0.954	4.843	3.738	0.924	0.845	8.951	7.045
RFR_EMD6	0.979	0.950	5.047	3.933	0.924	0.843	9.004	7.152
<b>RFR_EWT1</b>	<b>0.986</b>	<b>0.968</b>	<b>4.017</b>	<b>3.038</b>	<b>0.942</b>	<b>0.882</b>	<b>7.746</b>	<b>5.999</b>
RFR_EWT2	0.984	0.965	4.197	3.164	0.938	0.875	7.958	6.144
RFR_EWT3	0.985	0.967	4.117	3.120	0.942	0.882	7.756	5.987
RFR_EWT4	0.984	0.964	4.260	3.271	0.941	0.880	7.811	6.035
RFR_EWT5	0.982	0.961	4.430	3.352	0.937	0.873	8.032	6.235
RFR_EWT6	0.981	0.959	4.565	3.486	0.937	0.873	8.035	6.246
RFR_VMD1	0.982	0.955	4.729	3.672	0.915	0.828	9.484	7.487
RFR_VMD2	0.981	0.952	4.911	3.804	0.912	0.822	9.629	7.576
RFR_VMD3	0.982	0.954	4.812	3.741	0.916	0.828	9.487	7.534
<b>RFR_VMD4</b>	<b>0.980</b>	<b>0.951</b>	<b>4.960</b>	<b>3.879</b>	<b>0.917</b>	<b>0.830</b>	<b>9.430</b>	<b>7.480</b>
RFR_VMD5	0.979	0.949	5.038	3.911	0.910	0.820	9.697	7.659
RFR_VMD6	0.978	0.946	5.194	4.040	0.913	0.825	9.563	7.533
SVR_EMD1	0.990	0.928	6.045	5.071	0.399	0.054	22.089	18.680
SVR_EMD2	0.990	0.931	5.881	4.987	0.480	0.089	21.677	18.306
SVR_EMD3	0.990	0.935	5.720	4.892	0.512	0.128	21.212	17.891
SVR_EMD4	0.991	0.942	5.391	4.701	0.573	0.211	20.173	16.893
SVR_EMD5	0.992	0.948	5.122	4.559	0.647	0.293	19.093	15.859
<b>SVR_EMD6</b>	<b>0.991</b>	<b>0.960</b>	<b>4.494</b>	<b>4.156</b>	<b>0.803</b>	<b>0.571</b>	<b>14.871</b>	<b>11.988</b>
SVR_EWT1	0.990	0.940	5.502	4.724	0.608	0.237	19.688	16.412
SVR_EWT2	0.991	0.944	5.329	4.621	0.670	0.310	18.724	15.476
SVR_EWT3	0.991	0.948	5.158	4.507	0.691	0.364	17.985	14.793
SVR_EWT4	0.990	0.954	4.820	4.273	0.788	0.535	15.366	12.318
SVR_EWT5	0.991	0.955	4.806	4.319	0.768	0.504	15.871	12.800
<b>SVR_EWT6</b>	<b>0.987</b>	<b>0.957</b>	<b>4.676</b>	<b>4.166</b>	<b>0.861</b>	<b>0.694</b>	<b>12.469</b>	<b>9.840</b>
SVR_VMD1	0.988	0.916	6.501	5.287	0.032	-0.001	22.865	19.479
SVR_VMD2	0.988	0.916	6.502	5.288	0.039	-0.001	22.865	19.479
SVR_VMD3	0.988	0.916	6.501	5.288	0.112	-0.001	22.865	19.478
SVR_VMD4	0.988	0.916	6.473	5.273	0.243	0.003	22.819	19.444
SVR_VMD5	0.988	0.916	6.497	5.286	0.160	-0.001	22.859	19.474
<b>SVR_VMD6</b>	<b>0.989</b>	<b>0.930</b>	<b>5.943</b>	<b>4.981</b>	<b>0.404</b>	<b>0.106</b>	<b>21.608</b>	<b>18.390</b>

Annexe B. Résultats détaillées obtenus par les modèles hybrides durant la modélisation de la RS

Tableau B.1. Résultats obtenus par les modèles hybrides au niveau de la station de Guelma

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.954</b>	<b>0.911</b>	<b>2.701</b>	<b>2.047</b>	<b>0.923</b>	<b>0.850</b>	<b>3.439</b>	<b>2.657</b>
MLPNN_EMD2	0.940	0.884	3.079	2.348	0.919	0.844	3.515	2.698
MLPNN_EMD3	0.941	0.886	3.056	2.315	0.913	0.832	3.639	2.765
MLPNN_EMD4	0.935	0.875	3.200	2.450	0.917	0.840	3.553	2.720
MLPNN_EMD5	0.931	0.867	3.299	2.530	0.910	0.827	3.696	2.825
MLPNN_EMD6	0.921	0.847	3.531	2.724	0.902	0.813	3.846	2.945
<b>MLPNN_EWT1</b>	<b>0.944</b>	<b>0.890</b>	<b>2.992</b>	<b>2.269</b>	<b>0.925</b>	<b>0.854</b>	<b>3.397</b>	<b>2.609</b>
MLPNN_EWT2	0.910	0.810	3.941	3.163	0.890	0.772	4.249	3.392
MLPNN_EWT3	0.938	0.879	3.145	2.354	0.921	0.848	3.470	2.647
MLPNN_EWT4	0.931	0.866	3.308	2.526	0.917	0.840	3.551	2.725
MLPNN_EWT5	0.932	0.868	3.286	2.472	0.917	0.840	3.559	2.710
MLPNN_EWT6	0.900	0.809	3.951	3.091	0.887	0.784	4.132	3.240
<b>MLPNN_VMD1</b>	<b>0.945</b>	<b>0.893</b>	<b>2.948</b>	<b>2.274</b>	<b>0.912</b>	<b>0.832</b>	<b>3.671</b>	<b>2.795</b>
MLPNN_VMD2	0.937	0.877	3.161	2.440	0.911	0.830	3.697	2.841
MLPNN_VMD3	0.935	0.873	3.212	2.480	0.906	0.821	3.792	2.887
MLPNN_VMD4	0.919	0.844	3.558	2.786	0.891	0.795	4.063	3.156
MLPNN_VMD5	0.925	0.855	3.428	2.639	0.906	0.820	3.807	2.913
MLPNN_VMD6	0.903	0.814	3.878	3.025	0.885	0.783	4.178	3.234
ELM_EMD1	0.909	0.826	3.770	2.949	0.868	0.751	4.436	3.445
ELM_EMD2	0.914	0.835	3.670	2.888	0.866	0.748	4.468	3.506
ELM_EMD3	0.914	0.836	3.656	2.861	0.871	0.757	4.383	3.409
ELM_EMD4	0.918	0.842	3.588	2.799	0.876	0.765	4.310	3.322
ELM_EMD5	0.918	0.842	3.589	2.801	0.873	0.759	4.364	3.383
<b>ELM_EMD6</b>	<b>0.922</b>	<b>0.850</b>	<b>3.504</b>	<b>2.705</b>	<b>0.881</b>	<b>0.774</b>	<b>4.227</b>	<b>3.229</b>
ELM_EWT1	0.914	0.835	3.667	2.871	0.878	0.771	4.255	3.317
ELM_EWT2	0.919	0.845	3.561	2.768	0.884	0.782	4.156	3.220
ELM_EWT3	0.919	0.845	3.555	2.754	0.877	0.768	4.284	3.271
ELM_EWT4	0.922	0.851	3.488	2.711	0.883	0.777	4.199	3.250
ELM_EWT5	0.927	0.859	3.396	2.612	0.888	0.787	4.102	3.174
<b>ELM_EWT6</b>	<b>0.929</b>	<b>0.862</b>	<b>3.353</b>	<b>2.561</b>	<b>0.892</b>	<b>0.796</b>	<b>4.019</b>	<b>3.100</b>
ELM_VMD1	0.884	0.782	4.203	3.338	0.834	0.693	4.967	3.941
ELM_VMD2	0.882	0.779	4.237	3.365	0.841	0.706	4.861	3.837
ELM_VMD3	0.894	0.799	4.033	3.212	0.847	0.715	4.787	3.770
ELM_VMD4	0.885	0.783	4.195	3.309	0.839	0.701	4.905	3.843
<b>ELM_VMD5</b>	<b>0.896</b>	<b>0.803</b>	<b>3.994</b>	<b>3.170</b>	<b>0.853</b>	<b>0.726</b>	<b>4.694</b>	<b>3.703</b>
ELM_VMD6	0.898	0.807	3.958	3.133	0.851	0.721	4.734	3.723

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.037	0.006	0.809	0.625	5.446	3.766
GRNN_EMD2	1.000	1.000	0.054	0.010	0.817	0.641	5.325	3.707
GRNN_EMD3	1.000	1.000	0.097	0.020	0.816	0.639	5.345	3.663
GRNN_EMD4	1.000	1.000	0.125	0.032	0.819	0.648	5.274	3.685
GRNN_EMD5	1.000	1.000	0.166	0.045	0.824	0.656	5.215	3.661
<b>GRNN_EMD6</b>	<b>0.999</b>	<b>0.998</b>	<b>0.392</b>	<b>0.156</b>	<b>0.831</b>	<b>0.675</b>	<b>5.067</b>	<b>3.569</b>
GRNN_EWT1	1.000	1.000	0.169	0.045	0.816	0.639	5.339	3.666
GRNN_EWT2	0.999	0.999	0.320	0.115	0.825	0.661	5.179	3.559
GRNN_EWT3	0.999	0.999	0.303	0.098	0.818	0.643	5.311	3.633
GRNN_EWT4	0.998	0.997	0.518	0.225	0.826	0.664	5.152	3.539
GRNN_EWT5	0.998	0.995	0.633	0.300	0.842	0.693	4.927	3.402
<b>GRNN_EWT6</b>	<b>0.993</b>	<b>0.986</b>	<b>1.068</b>	<b>0.604</b>	<b>0.845</b>	<b>0.703</b>	<b>4.843</b>	<b>3.373</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.616	0.233	7.852	5.986
GRNN_VMD2	1.000	1.000	0.000	0.000	0.609	0.230	7.867	6.011
GRNN_VMD3	1.000	1.000	0.000	0.000	0.624	0.267	7.680	5.829
GRNN_VMD4	1.000	1.000	0.000	0.000	0.603	0.220	7.919	6.005
<b>GRNN_VMD5</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.631</b>	<b>0.277</b>	<b>7.625</b>	<b>5.774</b>
GRNN_VMD6	1.000	1.000	0.000	0.000	0.607	0.258	7.722	5.806
<b>MARS_EMD1</b>	<b>0.856</b>	<b>0.733</b>	<b>4.672</b>	<b>3.667</b>	<b>0.853</b>	<b>0.728</b>	<b>4.636</b>	<b>3.674</b>
MARS_EMD2	0.818	0.670	5.194	4.093	0.814	0.662	5.170	4.117
MARS_EMD3	0.814	0.662	5.252	4.172	0.805	0.648	5.276	4.227
MARS_EMD4	0.818	0.670	5.194	4.093	0.814	0.662	5.170	4.117
MARS_EMD5	0.818	0.670	5.194	4.093	0.814	0.662	5.170	4.117
MARS_EMD6	0.818	0.670	5.194	4.093	0.814	0.662	5.170	4.117
MARS_EWT1	0.884	0.782	4.222	3.277	0.872	0.761	4.350	3.386
MARS_EWT2	0.882	0.779	4.252	3.312	0.873	0.762	4.342	3.379
MARS_EWT3	0.884	0.782	4.223	3.277	0.872	0.761	4.351	3.386
<b>MARS_EWT4</b>	<b>0.882</b>	<b>0.778</b>	<b>4.255</b>	<b>3.335</b>	<b>0.873</b>	<b>0.762</b>	<b>4.338</b>	<b>3.391</b>
MARS_EWT5	0.882	0.779	4.251	3.311	0.873	0.762	4.341	3.378
MARS_EWT6	0.882	0.778	4.257	3.321	0.871	0.759	4.368	3.395
MARS_VMD1	0.844	0.712	4.834	3.815	0.843	0.711	4.820	3.787
MARS_VMD2	0.842	0.710	4.853	3.833	0.841	0.707	4.853	3.828
<b>MARS_VMD3</b>	<b>0.844</b>	<b>0.712</b>	<b>4.834</b>	<b>3.814</b>	<b>0.843</b>	<b>0.711</b>	<b>4.819</b>	<b>3.787</b>
MARS_VMD4	0.820	0.672	5.160	4.086	0.813	0.661	5.222	4.100
MARS_VMD5	0.829	0.687	5.038	3.986	0.828	0.685	5.035	3.978
MARS_VMD6	0.820	0.672	5.160	4.086	0.813	0.661	5.222	4.100

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.974</b>	<b>0.936</b>	<b>2.289</b>	<b>1.759</b>	<b>0.883</b>	<b>0.763</b>	<b>4.329</b>	<b>3.449</b>
RFR_EMD2	0.971	0.930	2.397	1.847	0.876	0.750	4.450	3.543
RFR_EMD3	0.972	0.933	2.335	1.795	0.879	0.755	4.404	3.501
RFR_EMD4	0.968	0.923	2.508	1.929	0.869	0.737	4.558	3.628
RFR_EMD5	0.970	0.926	2.463	1.903	0.870	0.738	4.554	3.629
RFR_EMD6	0.966	0.918	2.587	1.992	0.862	0.725	4.664	3.710
<b>RFR_EWT1</b>	<b>0.977</b>	<b>0.947</b>	<b>2.078</b>	<b>1.569</b>	<b>0.908</b>	<b>0.814</b>	<b>3.833</b>	<b>3.000</b>
RFR_EWT2	0.976	0.944	2.133	1.607	0.905	0.810	3.875	3.019
RFR_EWT3	0.976	0.945	2.124	1.602	0.904	0.808	3.895	3.038
RFR_EWT4	0.972	0.936	2.292	1.737	0.902	0.801	3.963	3.096
RFR_EWT5	0.974	0.940	2.207	1.663	0.901	0.803	3.945	3.070
RFR_EWT6	0.970	0.931	2.370	1.791	0.896	0.793	4.041	3.142
<b>RFR_VMD1</b>	<b>0.971</b>	<b>0.925</b>	<b>2.468</b>	<b>1.932</b>	<b>0.854</b>	<b>0.716</b>	<b>4.781</b>	<b>3.804</b>
RFR_VMD2	0.970	0.921	2.531	1.989	0.851	0.711	4.822	3.847
RFR_VMD3	0.970	0.922	2.517	1.972	0.852	0.713	4.805	3.821
RFR_VMD4	0.966	0.913	2.658	2.088	0.843	0.696	4.942	3.950
RFR_VMD5	0.968	0.917	2.589	2.039	0.851	0.710	4.826	3.845
RFR_VMD6	0.965	0.911	2.687	2.118	0.847	0.704	4.880	3.914
SVR_EMD1	0.995	0.949	2.031	1.902	0.407	0.065	8.600	7.395
SVR_EMD2	0.995	0.951	2.006	1.886	0.453	0.088	8.493	7.292
SVR_EMD3	0.995	0.951	1.991	1.874	0.498	0.117	8.355	7.149
SVR_EMD4	0.995	0.953	1.959	1.852	0.540	0.160	8.151	6.950
SVR_EMD5	0.995	0.956	1.890	1.806	0.597	0.204	7.932	6.759
<b>SVR_EMD6</b>	<b>0.994</b>	<b>0.960</b>	<b>1.809</b>	<b>1.730</b>	<b>0.711</b>	<b>0.381</b>	<b>6.997</b>	<b>5.826</b>
SVR_EWT1	0.995	0.953	1.951	1.845	0.567	0.187	8.018	6.824
SVR_EWT2	0.994	0.957	1.875	1.785	0.658	0.296	7.462	6.285
SVR_EWT3	0.994	0.955	1.917	1.815	0.618	0.259	7.654	6.448
SVR_EWT4	0.993	0.958	1.846	1.750	0.703	0.383	6.983	5.791
SVR_EWT5	0.993	0.960	1.815	1.724	0.748	0.461	6.528	5.391
<b>SVR_EWT6</b>	<b>0.989</b>	<b>0.957</b>	<b>1.882</b>	<b>1.717</b>	<b>0.795</b>	<b>0.575</b>	<b>5.798</b>	<b>4.675</b>
SVR_VMD1	0.995	0.946	2.084	1.940	0.067	-0.001	8.970	7.755
SVR_VMD2	0.995	0.946	2.084	1.942	0.073	-0.001	8.970	7.755
SVR_VMD3	0.995	0.946	2.082	1.944	0.041	-0.001	8.970	7.755
SVR_VMD4	0.995	0.946	2.081	1.942	0.139	0.000	8.970	7.755
SVR_VMD5	0.995	0.946	2.084	1.939	0.098	0.000	8.970	7.755
<b>SVR_VMD6</b>	<b>0.995</b>	<b>0.947</b>	<b>2.081</b>	<b>1.938</b>	<b>0.231</b>	<b>0.001</b>	<b>8.961</b>	<b>7.746</b>

Tableau B.2. Résultats obtenus par les modèles hybrides au niveau de la station de Jijel

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN_EMD1	0.948	0.899	2.774	2.074	0.914	0.835	3.558	2.633
MLPNN_EMD2	0.940	0.884	2.976	2.248	0.912	0.831	3.605	2.711
<b>MLPNN_EMD3</b>	<b>0.945</b>	<b>0.893</b>	<b>2.859</b>	<b>2.118</b>	<b>0.915</b>	<b>0.837</b>	<b>3.540</b>	<b>2.569</b>
MLPNN_EMD4	0.926	0.857	3.300	2.505	0.903	0.816	3.766	2.852
MLPNN_EMD5	0.932	0.869	3.158	2.385	0.910	0.828	3.641	2.729
MLPNN_EMD6	0.914	0.835	3.545	2.675	0.893	0.797	3.946	2.974
MLPNN_EWT1	0.939	0.881	3.019	2.238	0.920	0.846	3.403	2.514
MLPNN_EWT2	0.936	0.875	3.100	2.331	0.918	0.841	3.458	2.583
<b>MLPNN_EWT3</b>	<b>0.937</b>	<b>0.878</b>	<b>3.067</b>	<b>2.254</b>	<b>0.922</b>	<b>0.849</b>	<b>3.375</b>	<b>2.487</b>
MLPNN_EWT4	0.926	0.858	3.306	2.462	0.913	0.834	3.540	2.631
MLPNN_EWT5	0.887	0.769	4.210	3.359	0.876	0.751	4.329	3.402
MLPNN_EWT6	0.894	0.792	3.995	3.165	0.879	0.767	4.188	3.295
MLPNN_VMD1	0.935	0.873	3.109	2.391	0.902	0.813	3.799	2.922
<b>MLPNN_VMD2</b>	<b>0.928</b>	<b>0.857</b>	<b>3.293</b>	<b>2.564</b>	<b>0.907</b>	<b>0.819</b>	<b>3.742</b>	<b>2.918</b>
MLPNN_VMD3	0.928	0.860	3.265	2.550	0.896	0.802	3.908	3.036
MLPNN_VMD4	0.914	0.833	3.559	2.774	0.888	0.788	4.047	3.164
MLPNN_VMD5	0.915	0.836	3.527	2.719	0.895	0.801	3.918	3.037
MLPNN_VMD6	0.879	0.772	4.164	3.289	0.859	0.738	4.495	3.525
ELM_EMD1	0.909	0.826	3.636	2.819	0.861	0.737	4.493	3.453
ELM_EMD2	0.907	0.822	3.680	2.876	0.855	0.728	4.570	3.550
<b>ELM_EMD3</b>	<b>0.914</b>	<b>0.836</b>	<b>3.535</b>	<b>2.735</b>	<b>0.864</b>	<b>0.742</b>	<b>4.450</b>	<b>3.390</b>
ELM_EMD4	0.904	0.817	3.727	2.912	0.855	0.729	4.567	3.551
ELM_EMD5	0.912	0.832	3.581	2.806	0.863	0.744	4.437	3.448
ELM_EMD6	0.909	0.826	3.641	2.829	0.858	0.735	4.512	3.440
ELM_EWT1	0.925	0.855	3.335	2.553	0.885	0.782	4.047	3.085
ELM_EWT2	0.916	0.840	3.506	2.696	0.883	0.779	4.077	3.134
ELM_EWT3	0.924	0.853	3.355	2.546	0.884	0.780	4.071	3.073
ELM_EWT4	0.913	0.833	3.576	2.754	0.876	0.767	4.187	3.155
<b>ELM_EWT5</b>	<b>0.923</b>	<b>0.852</b>	<b>3.374</b>	<b>2.581</b>	<b>0.890</b>	<b>0.791</b>	<b>3.965</b>	<b>3.017</b>
ELM_EWT6	0.922	0.850	3.392	2.550	0.887	0.786	4.015	3.008
ELM_VMD1	0.875	0.765	4.228	3.339	0.828	0.683	4.943	3.907
ELM_VMD2	0.878	0.770	4.179	3.322	0.824	0.675	5.008	3.969
<b>ELM_VMD3</b>	<b>0.884</b>	<b>0.781</b>	<b>4.082</b>	<b>3.242</b>	<b>0.839</b>	<b>0.702</b>	<b>4.792</b>	<b>3.781</b>
ELM_VMD4	0.882	0.777	4.116	3.246	0.835	0.696	4.846	3.812
ELM_VMD5	0.886	0.785	4.046	3.218	0.836	0.696	4.846	3.830
ELM_VMD6	0.888	0.789	4.007	3.183	0.834	0.692	4.876	3.844

Modelés	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.034	0.005	0.818	0.643	5.237	3.413
GRNN_EMD2	1.000	1.000	0.051	0.010	0.810	0.627	5.354	3.501
<b>GRNN_EMD3</b>	<b>1.000</b>	<b>1.000</b>	<b>0.083</b>	<b>0.017</b>	<b>0.826</b>	<b>0.660</b>	<b>5.114</b>	<b>3.366</b>
GRNN_EMD4	1.000	1.000	0.140	0.034	0.793	0.597	5.563	3.650
GRNN_EMD5	1.000	1.000	0.177	0.044	0.825	0.660	5.111	3.388
GRNN_EMD6	0.999	0.998	0.432	0.159	0.807	0.631	5.327	3.553
GRNN_EWT1	1.000	0.999	0.248	0.077	0.837	0.685	4.874	3.169
GRNN_EWT2	0.999	0.998	0.357	0.133	0.833	0.677	4.934	3.240
GRNN_EWT3	0.999	0.997	0.451	0.174	0.842	0.694	4.802	3.126
GRNN_EWT4	0.998	0.995	0.594	0.263	0.824	0.662	5.048	3.332
<b>GRNN_EWT5</b>	<b>0.997</b>	<b>0.993</b>	<b>0.715</b>	<b>0.350</b>	<b>0.845</b>	<b>0.699</b>	<b>4.758</b>	<b>3.114</b>
GRNN_EWT6	0.990	0.980	1.244	0.712	0.841	0.697	4.780	3.185
<b>GRNN_VMD1</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.649</b>	<b>0.293</b>	<b>7.388</b>	<b>5.542</b>
GRNN_VMD2	1.000	1.000	0.000	0.000	0.645	0.305	7.322	5.553
GRNN_VMD3	1.000	1.000	0.000	0.000	0.632	0.257	7.574	5.688
GRNN_VMD4	1.000	1.000	0.000	0.000	0.613	0.251	7.602	5.797
GRNN_VMD5	1.000	1.000	0.000	0.000	0.635	0.258	7.566	5.715
GRNN_VMD6	1.000	1.000	0.000	0.000	0.610	0.232	7.701	5.803
<b>MARS_EMD1</b>	<b>0.842</b>	<b>0.708</b>	<b>4.713</b>	<b>3.715</b>	<b>0.840</b>	<b>0.705</b>	<b>4.762</b>	<b>3.767</b>
MARS_EMD2	0.795	0.631	5.296	4.211	0.785	0.616	5.430	4.326
MARS_EMD3	0.794	0.631	5.298	4.233	0.792	0.627	5.352	4.284
MARS_EMD4	0.792	0.627	5.325	4.196	0.781	0.609	5.480	4.348
MARS_EMD5	0.794	0.630	5.307	4.183	0.783	0.613	5.458	4.324
MARS_EMD6	0.795	0.633	5.289	4.137	0.782	0.611	5.469	4.294
<b>MARS_EWT1</b>	<b>0.939</b>	<b>0.881</b>	<b>3.019</b>	<b>2.238</b>	<b>0.920</b>	<b>0.846</b>	<b>3.403</b>	<b>2.514</b>
MARS_EWT2	0.876	0.768	4.223	3.264	0.878	0.770	4.160	3.192
MARS_EWT3	0.878	0.771	4.191	3.237	0.877	0.768	4.176	3.216
MARS_EWT4	0.878	0.771	4.191	3.189	0.879	0.772	4.142	3.180
MARS_EWT5	0.870	0.757	4.323	3.328	0.869	0.755	4.297	3.280
MARS_EWT6	0.878	0.771	4.190	3.177	0.878	0.770	4.161	3.196
MARS_VMD1	0.849	0.721	4.606	3.540	0.850	0.723	4.623	3.570
MARS_VMD2	0.837	0.701	4.769	3.715	0.835	0.697	4.837	3.782
<b>MARS_VMD3</b>	<b>0.849</b>	<b>0.721</b>	<b>4.606</b>	<b>3.541</b>	<b>0.850</b>	<b>0.723</b>	<b>4.623</b>	<b>3.569</b>
MARS_VMD4	0.838	0.703	4.754	3.674	0.834	0.696	4.842	3.785
MARS_VMD5	0.829	0.688	4.872	3.767	0.827	0.683	4.943	3.855
MARS_VMD6	0.828	0.685	4.892	3.770	0.823	0.678	4.986	3.895

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.973</b>	<b>0.938</b>	<b>2.172</b>	<b>1.597</b>	<b>0.887</b>	<b>0.776</b>	<b>4.148</b>	<b>3.158</b>
RFR_EMD2	0.970	0.931	2.296	1.698	0.875	0.753	4.359	3.333
RFR_EMD3	0.972	0.936	2.208	1.627	0.886	0.775	4.159	3.174
RFR_EMD4	0.965	0.920	2.463	1.815	0.859	0.726	4.587	3.498
RFR_EMD5	0.968	0.927	2.361	1.754	0.870	0.744	4.439	3.410
RFR_EMD6	0.963	0.915	2.538	1.881	0.853	0.712	4.706	3.616
<b>RFR_EWT1</b>	<b>0.975</b>	<b>0.945</b>	<b>2.051</b>	<b>1.481</b>	<b>0.915</b>	<b>0.830</b>	<b>3.573</b>	<b>2.655</b>
RFR_EWT2	0.973	0.941	2.124	1.546	0.913	0.825	3.626	2.716
RFR_EWT3	0.974	0.943	2.092	1.504	0.914	0.828	3.594	2.680
RFR_EWT4	0.969	0.930	2.327	1.702	0.897	0.796	3.920	2.931
RFR_EWT5	0.972	0.937	2.193	1.597	0.911	0.823	3.652	2.751
RFR_EWT6	0.966	0.925	2.398	1.748	0.894	0.790	3.975	2.978
<b>RFR_VMD1</b>	<b>0.971</b>	<b>0.928</b>	<b>2.340</b>	<b>1.762</b>	<b>0.865</b>	<b>0.741</b>	<b>4.472</b>	<b>3.442</b>
RFR_VMD2	0.969	0.922	2.429	1.831	0.858	0.727	4.586	3.579
RFR_VMD3	0.969	0.925	2.394	1.810	0.864	0.738	4.493	3.473
RFR_VMD4	0.965	0.914	2.550	1.913	0.853	0.718	4.665	3.602
RFR_VMD5	0.967	0.919	2.485	1.883	0.859	0.727	4.594	3.607
RFR_VMD6	0.964	0.912	2.584	1.948	0.857	0.724	4.619	3.599
SVR_EMD1	0.994	0.948	1.999	1.836	0.388	0.059	8.507	7.379
SVR_EMD2	0.994	0.949	1.977	1.824	0.438	0.078	8.421	7.294
SVR_EMD3	0.994	0.949	1.967	1.816	0.474	0.107	8.286	7.139
SVR_EMD4	0.994	0.951	1.930	1.796	0.531	0.154	8.064	6.926
SVR_EMD5	0.994	0.953	1.892	1.770	0.578	0.194	7.870	6.763
<b>SVR_EMD6</b>	<b>0.993</b>	<b>0.957</b>	<b>1.819</b>	<b>1.707</b>	<b>0.693</b>	<b>0.361</b>	<b>7.006</b>	<b>5.892</b>
SVR_EWT1	0.994	0.953	1.908	1.781	0.627	0.255	7.488	6.356
SVR_EWT2	0.994	0.956	1.846	1.737	0.679	0.331	7.096	5.972
SVR_EWT3	0.993	0.954	1.878	1.750	0.695	0.353	6.981	5.836
SVR_EWT4	0.993	0.957	1.815	1.706	0.721	0.422	6.599	5.446
SVR_EWT5	0.992	0.958	1.793	1.676	0.768	0.500	6.135	5.044
<b>SVR_EWT6</b>	<b>0.985</b>	<b>0.951</b>	<b>1.941</b>	<b>1.711</b>	<b>0.797</b>	<b>0.592</b>	<b>5.542</b>	<b>4.403</b>
SVR_VMD1	0.994	0.947	2.015	1.845	0.069	-0.001	8.788	7.645
SVR_VMD2	0.994	0.947	2.015	1.845	0.087	-0.001	8.788	7.645
SVR_VMD3	0.994	0.947	2.015	1.845	0.023	-0.001	8.788	7.645
SVR_VMD4	0.994	0.947	2.015	1.845	0.080	-0.001	8.788	7.645
SVR_VMD5	0.994	0.947	2.015	1.845	0.169	-0.001	8.788	7.645
<b>SVR_VMD6</b>	<b>0.994</b>	<b>0.947</b>	<b>2.013</b>	<b>1.843</b>	<b>0.273</b>	<b>0.001</b>	<b>8.779</b>	<b>7.637</b>

Tableau B.3. Résultats obtenus par les modèles hybrides au niveau de la station de Mila

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.949</b>	<b>0.899</b>	<b>2.781</b>	<b>2.082</b>	<b>0.927</b>	<b>0.860</b>	<b>3.282</b>	<b>2.460</b>
MLPNN_EMD2	0.950	0.902	2.744	2.059	0.924	0.853	3.359	2.504
MLPNN_EMD3	0.940	0.884	2.983	2.242	0.918	0.843	3.474	2.595
MLPNN_EMD4	0.934	0.873	3.122	2.364	0.917	0.841	3.500	2.645
MLPNN_EMD5	0.933	0.870	3.150	2.370	0.912	0.831	3.599	2.697
MLPNN_EMD6	0.921	0.848	3.415	2.590	0.906	0.821	3.706	2.795
<b>MLPNN_EWT1</b>	<b>0.948</b>	<b>0.898</b>	<b>2.805</b>	<b>2.101</b>	<b>0.924</b>	<b>0.853</b>	<b>3.319</b>	<b>2.495</b>
MLPNN_EWT2	0.912	0.831	3.614	2.808	0.890	0.790	3.972	3.077
MLPNN_EWT3	0.941	0.886	2.968	2.197	0.920	0.846	3.403	2.539
MLPNN_EWT4	0.911	0.829	3.640	2.806	0.892	0.795	3.923	3.039
MLPNN_EWT5	0.913	0.820	3.731	2.929	0.890	0.779	4.071	3.163
MLPNN_EWT6	0.928	0.861	3.281	2.452	0.905	0.820	3.678	2.744
<b>MLPNN_VMD1</b>	<b>0.949</b>	<b>0.899</b>	<b>2.787</b>	<b>2.133</b>	<b>0.913</b>	<b>0.833</b>	<b>3.554</b>	<b>2.709</b>
MLPNN_VMD2	0.940	0.883	2.997	2.311	0.912	0.831	3.583	2.753
MLPNN_VMD3	0.935	0.875	3.108	2.390	0.900	0.809	3.804	2.923
MLPNN_VMD4	0.930	0.864	3.238	2.510	0.900	0.810	3.795	2.946
MLPNN_VMD5	0.901	0.800	3.922	3.132	0.874	0.754	4.320	3.448
MLPNN_VMD6	0.917	0.840	3.507	2.714	0.892	0.796	3.933	3.032
ELM_EMD1	0.917	0.841	3.484	2.731	0.879	0.771	4.197	3.262
ELM_EMD2	0.919	0.844	3.455	2.695	0.879	0.771	4.194	3.259
ELM_EMD3	0.920	0.846	3.433	2.670	0.884	0.780	4.114	3.227
ELM_EMD4	0.920	0.847	3.423	2.650	0.885	0.782	4.092	3.176
<b>ELM_EMD5</b>	<b>0.921</b>	<b>0.848</b>	<b>3.412</b>	<b>2.643</b>	<b>0.885</b>	<b>0.782</b>	<b>4.094</b>	<b>3.158</b>
ELM_EMD6	0.923	0.851	3.374	2.610	0.881	0.775	4.156	3.193
ELM_EWT1	0.926	0.857	3.325	2.558	0.886	0.784	4.023	3.073
ELM_EWT2	0.925	0.855	3.351	2.597	0.887	0.787	4.001	3.091
<b>ELM_EWT3</b>	<b>0.928</b>	<b>0.861</b>	<b>3.275</b>	<b>2.521</b>	<b>0.891</b>	<b>0.793</b>	<b>3.937</b>	<b>3.055</b>
ELM_EWT4	0.927	0.859	3.303	2.551	0.889	0.790	3.972	3.060
ELM_EWT5	0.930	0.864	3.241	2.478	0.889	0.790	3.965	3.036
ELM_EWT6	0.928	0.862	3.265	2.481	0.889	0.789	3.975	3.021
ELM_VMD1	0.899	0.808	3.843	3.030	0.846	0.713	4.666	3.692
ELM_VMD2	0.901	0.811	3.812	2.999	0.849	0.717	4.637	3.690
ELM_VMD3	0.904	0.817	3.753	2.956	0.848	0.716	4.642	3.679
ELM_VMD4	0.903	0.815	3.770	2.978	0.855	0.729	4.538	3.612
ELM_VMD5	0.905	0.819	3.732	2.963	0.850	0.720	4.609	3.618
<b>ELM_VMD6</b>	<b>0.907</b>	<b>0.823</b>	<b>3.691</b>	<b>2.908</b>	<b>0.855</b>	<b>0.729</b>	<b>4.533</b>	<b>3.559</b>

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.038	0.006	0.810	0.627	5.355	3.613
GRNN_EMD2	1.000	1.000	0.055	0.010	0.805	0.615	5.438	3.668
<b>GRNN_EMD3</b>	<b>1.000</b>	<b>1.000</b>	<b>0.102</b>	<b>0.023</b>	<b>0.824</b>	<b>0.657</b>	<b>5.135</b>	<b>3.448</b>
GRNN_EMD4	1.000	1.000	0.135	0.030	0.802	0.609	5.481	3.688
GRNN_EMD5	1.000	1.000	0.158	0.048	0.817	0.643	5.234	3.522
GRNN_EMD6	0.999	0.998	0.414	0.168	0.822	0.658	5.129	3.493
GRNN_EWT1	1.000	1.000	0.182	0.054	0.821	0.654	5.092	3.488
GRNN_EWT2	0.999	0.999	0.298	0.111	0.830	0.671	4.968	3.423
GRNN_EWT3	0.999	0.998	0.372	0.133	0.828	0.668	4.994	3.415
GRNN_EWT4	0.999	0.997	0.452	0.193	0.825	0.663	5.026	3.492
GRNN_EWT5	0.998	0.995	0.613	0.288	0.841	0.694	4.788	3.283
<b>GRNN_EWT6</b>	<b>0.994</b>	<b>0.988</b>	<b>0.944</b>	<b>0.508</b>	<b>0.841</b>	<b>0.696</b>	<b>4.775</b>	<b>3.286</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.642	0.284	7.369	5.557
<b>GRNN_VMD2</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.650</b>	<b>0.309</b>	<b>7.239</b>	<b>5.457</b>
GRNN_VMD3	1.000	1.000	0.000	0.000	0.647	0.289	7.346	5.494
GRNN_VMD4	1.000	1.000	0.000	0.000	0.641	0.310	7.235	5.430
GRNN_VMD5	1.000	1.000	0.000	0.000	0.646	0.291	7.331	5.550
GRNN_VMD6	1.000	1.000	0.000	0.000	0.638	0.292	7.327	5.522
<b>MARS_EMD1</b>	<b>0.870</b>	<b>0.758</b>	<b>4.309</b>	<b>3.380</b>	<b>0.865</b>	<b>0.749</b>	<b>4.393</b>	<b>3.466</b>
MARS_EMD2	0.830	0.689	4.881	3.858	0.827	0.683	4.934	3.924
MARS_EMD3	0.821	0.674	4.995	3.890	0.814	0.663	5.087	3.975
MARS_EMD4	0.830	0.689	4.881	3.858	0.827	0.683	4.934	3.924
MARS_EMD5	0.832	0.693	4.851	3.787	0.821	0.674	5.003	3.911
MARS_EMD6	0.832	0.693	4.851	3.787	0.821	0.674	5.003	3.911
MARS_EWT1	0.872	0.760	4.304	3.412	0.858	0.735	4.455	3.501
MARS_EWT2	0.874	0.763	4.280	3.406	0.862	0.743	4.393	3.459
MARS_EWT3	0.872	0.760	4.304	3.412	0.858	0.735	4.455	3.501
MARS_EWT4	0.881	0.775	4.167	3.238	0.871	0.758	4.260	3.300
MARS_EWT5	0.872	0.760	4.304	3.398	0.861	0.741	4.406	3.448
<b>MARS_EWT6</b>	<b>0.887</b>	<b>0.787</b>	<b>4.055</b>	<b>3.116</b>	<b>0.880</b>	<b>0.774</b>	<b>4.122</b>	<b>3.175</b>
MARS_VMD1	0.849	0.721	4.635	3.565	0.840	0.705	4.728	3.677
<b>MARS_VMD2</b>	<b>0.940</b>	<b>0.883</b>	<b>2.997</b>	<b>2.311</b>	<b>0.912</b>	<b>0.831</b>	<b>3.583</b>	<b>2.753</b>
MARS_VMD3	0.858	0.736	4.507	3.469	0.850	0.722	4.589	3.560
MARS_VMD4	0.850	0.722	4.628	3.596	0.843	0.711	4.684	3.655
MARS_VMD5	0.840	0.705	4.766	3.720	0.833	0.694	4.821	3.776
MARS_VMD6	0.835	0.697	4.826	3.749	0.826	0.682	4.914	3.837

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.974</b>	<b>0.939</b>	<b>2.153</b>	<b>1.635</b>	<b>0.896</b>	<b>0.792</b>	<b>3.997</b>	<b>3.094</b>
RFR_EMD2	0.972	0.933	2.257	1.708	0.887	0.775	4.156	3.222
RFR_EMD3	0.972	0.934	2.242	1.700	0.890	0.780	4.114	3.206
RFR_EMD4	0.968	0.926	2.375	1.797	0.880	0.763	4.268	3.296
RFR_EMD5	0.970	0.927	2.356	1.792	0.879	0.760	4.296	3.365
RFR_EMD6	0.965	0.918	2.511	1.912	0.869	0.742	4.456	3.488
<b>RFR_EWT1</b>	<b>0.977</b>	<b>0.949</b>	<b>1.978</b>	<b>1.469</b>	<b>0.909</b>	<b>0.822</b>	<b>3.654</b>	<b>2.834</b>
RFR_EWT2	0.976	0.946	2.044	1.526	0.906	0.814	3.731	2.917
RFR_EWT3	0.976	0.946	2.051	1.522	0.906	0.814	3.732	2.894
RFR_EWT4	0.973	0.938	2.181	1.639	0.897	0.797	3.901	3.057
RFR_EWT5	0.973	0.940	2.146	1.602	0.900	0.804	3.838	2.993
RFR_EWT6	0.970	0.932	2.298	1.725	0.890	0.786	4.005	3.115
<b>RFR_VMD1</b>	<b>0.973</b>	<b>0.934</b>	<b>2.260</b>	<b>1.713</b>	<b>0.864</b>	<b>0.739</b>	<b>4.451</b>	<b>3.472</b>
RFR_VMD2	0.971	0.928	2.352	1.790	0.857	0.727	4.554	3.570
RFR_VMD3	0.972	0.931	2.310	1.758	0.861	0.733	4.496	3.529
RFR_VMD4	0.968	0.922	2.452	1.865	0.853	0.720	4.609	3.599
RFR_VMD5	0.970	0.926	2.392	1.834	0.855	0.723	4.580	3.604
RFR_VMD6	0.967	0.920	2.488	1.905	0.853	0.720	4.605	3.597
SVR_EMD1	0.994	0.942	2.112	1.909	0.392	0.062	8.490	7.302
SVR_EMD2	0.994	0.944	2.077	1.888	0.446	0.084	8.388	7.209
SVR_EMD3	0.994	0.945	2.056	1.873	0.509	0.124	8.204	7.013
SVR_EMD4	0.994	0.946	2.027	1.857	0.525	0.151	8.078	6.887
SVR_EMD5	0.994	0.952	1.910	1.781	0.611	0.226	7.711	6.578
<b>SVR_EMD6</b>	<b>0.993</b>	<b>0.957</b>	<b>1.813</b>	<b>1.699</b>	<b>0.714</b>	<b>0.400</b>	<b>6.792</b>	<b>5.629</b>
SVR_EWT1	0.994	0.949	1.983	1.829	0.587	0.204	7.728	6.511
SVR_EWT2	0.994	0.953	1.902	1.773	0.652	0.296	7.269	6.067
SVR_EWT3	0.994	0.951	1.939	1.792	0.648	0.292	7.288	6.060
SVR_EWT4	0.993	0.955	1.872	1.743	0.688	0.364	6.905	5.687
SVR_EWT5	0.992	0.956	1.834	1.711	0.742	0.459	6.370	5.215
<b>SVR_EWT6</b>	<b>0.989</b>	<b>0.955</b>	<b>1.873</b>	<b>1.700</b>	<b>0.776</b>	<b>0.542</b>	<b>5.859</b>	<b>4.704</b>
SVR_VMD1	0.994	0.942	2.115	1.919	0.094	-0.001	8.713	7.507
SVR_VMD2	0.994	0.942	2.115	1.919	0.082	-0.001	8.713	7.507
SVR_VMD3	0.994	0.942	2.114	1.919	0.077	-0.001	8.713	7.507
SVR_VMD4	0.994	0.942	2.114	1.919	0.115	-0.001	8.713	7.507
SVR_VMD5	0.994	0.942	2.114	1.919	0.189	-0.001	8.712	7.506
<b>SVR_VMD6</b>	<b>0.994</b>	<b>0.942</b>	<b>2.107</b>	<b>1.915</b>	<b>0.292</b>	<b>0.003</b>	<b>8.697</b>	<b>7.492</b>

Tableau B.4. Résultats obtenus par les modèles hybrides au niveau de la station d'Oran

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>MLPNN_EMD1</b>	<b>0.957</b>	<b>0.915</b>	<b>2.325</b>	<b>1.664</b>	<b>0.932</b>	<b>0.868</b>	<b>2.868</b>	<b>2.049</b>
MLPNN_EMD2	0.948	0.898	2.555	1.852	0.926	0.858	2.981	2.161
MLPNN_EMD3	0.948	0.898	2.546	1.852	0.923	0.851	3.055	2.208
MLPNN_EMD4	0.934	0.870	2.873	2.144	0.915	0.837	3.195	2.373
MLPNN_EMD5	0.935	0.874	2.831	2.082	0.914	0.835	3.208	2.379
MLPNN_EMD6	0.908	0.823	3.360	2.530	0.892	0.793	3.593	2.696
MLPNN_EWT1	0.952	0.905	2.463	1.780	0.933	0.871	2.844	1.998
MLPNN_EWT2	0.945	0.891	2.634	1.844	0.928	0.860	2.956	2.013
<b>MLPNN_EWT3</b>	<b>0.950</b>	<b>0.902</b>	<b>2.500</b>	<b>1.771</b>	<b>0.934</b>	<b>0.873</b>	<b>2.817</b>	<b>1.958</b>
MLPNN_EWT4	0.939	0.880	2.765	1.948	0.924	0.853	3.031	2.073
MLPNN_EWT5	0.941	0.885	2.703	1.897	0.930	0.865	2.901	2.001
MLPNN_EWT6	0.831	0.685	4.480	3.299	0.819	0.662	4.593	3.332
<b>MLPNN_VMD1</b>	<b>0.838</b>	<b>0.701</b>	<b>4.318</b>	<b>3.238</b>	<b>0.795</b>	<b>0.631</b>	<b>4.917</b>	<b>3.667</b>
MLPNN_VMD2	0.846	0.712	4.237	3.181	0.783	0.614	5.034	3.761
MLPNN_VMD3	0.830	0.686	4.430	3.399	0.759	0.573	5.291	4.018
MLPNN_VMD4	0.835	0.697	4.351	3.253	0.791	0.625	4.960	3.668
MLPNN_VMD5	0.821	0.673	4.520	3.419	0.766	0.585	5.217	3.906
MLPNN_VMD6	0.804	0.644	4.713	3.572	0.766	0.587	5.206	3.910
ELM_EMD1	0.901	0.812	3.458	2.678	0.851	0.721	4.179	3.176
ELM_EMD2	0.900	0.810	3.483	2.694	0.853	0.723	4.158	3.177
ELM_EMD3	0.904	0.817	3.410	2.619	0.856	0.728	4.123	3.159
<b>ELM_EMD4</b>	<b>0.907</b>	<b>0.822</b>	<b>3.367</b>	<b>2.581</b>	<b>0.862</b>	<b>0.741</b>	<b>4.022</b>	<b>3.056</b>
ELM_EMD5	0.906	0.821	3.373	2.596	0.858	0.733	4.084	3.141
ELM_EMD6	0.910	0.829	3.303	2.521	0.852	0.723	4.162	3.144
ELM_EWT1	0.913	0.833	3.261	2.495	0.871	0.757	3.900	2.944
ELM_EWT2	0.920	0.846	3.129	2.369	0.878	0.768	3.803	2.838
ELM_EWT3	0.920	0.847	3.123	2.381	0.871	0.756	3.903	2.904
ELM_EWT4	0.920	0.846	3.131	2.353	0.879	0.770	3.793	2.800
<b>ELM_EWT5</b>	<b>0.932</b>	<b>0.869</b>	<b>2.887</b>	<b>2.148</b>	<b>0.901</b>	<b>0.810</b>	<b>3.445</b>	<b>2.512</b>
ELM_EWT6	0.931	0.866	2.921	2.142	0.898	0.804	3.499	2.559
ELM_VMD1	0.811	0.658	4.618	3.541	0.711	0.495	5.751	4.402
<b>ELM_VMD2</b>	<b>0.818</b>	<b>0.669</b>	<b>4.546</b>	<b>3.488</b>	<b>0.730</b>	<b>0.527</b>	<b>5.567</b>	<b>4.215</b>
ELM_VMD3	0.804	0.647	4.695	3.634	0.705	0.491	5.776	4.491
ELM_VMD4	0.825	0.680	4.469	3.415	0.726	0.518	5.623	4.265
ELM_VMD5	0.806	0.650	4.675	3.617	0.711	0.496	5.750	4.375
ELM_VMD6	0.811	0.658	4.617	3.555	0.723	0.515	5.638	4.324

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
GRNN_EMD1	1.000	1.000	0.057	0.006	0.861	0.730	4.110	2.482
GRNN_EMD2	1.000	1.000	0.096	0.010	0.859	0.725	4.150	2.540
<b>GRNN_EMD3</b>	<b>1.000</b>	<b>1.000</b>	<b>0.169</b>	<b>0.028</b>	<b>0.869</b>	<b>0.747</b>	<b>3.973</b>	<b>2.443</b>
GRNN_EMD4	1.000	0.999	0.216	0.037	0.844	0.699	4.337	2.658
GRNN_EMD5	0.999	0.999	0.289	0.058	0.856	0.722	4.172	2.612
GRNN_EMD6	0.996	0.992	0.705	0.215	0.829	0.678	4.490	2.941
GRNN_EWT1	1.000	1.000	0.122	0.027	0.864	0.735	4.068	2.401
GRNN_EWT2	0.999	0.999	0.259	0.075	0.873	0.752	3.934	2.333
GRNN_EWT3	1.000	0.999	0.230	0.064	0.875	0.757	3.897	2.308
GRNN_EWT4	0.998	0.996	0.481	0.170	0.870	0.748	3.970	2.360
GRNN_EWT5	0.997	0.993	0.650	0.251	0.886	0.779	3.713	2.237
<b>GRNN_EWT6</b>	<b>0.989</b>	<b>0.979</b>	<b>1.159</b>	<b>0.562</b>	<b>0.887</b>	<b>0.782</b>	<b>3.687</b>	<b>2.272</b>
GRNN_VMD1	1.000	1.000	0.000	0.000	0.541	0.084	7.748	5.822
GRNN_VMD2	1.000	1.000	0.000	0.000	0.523	0.065	7.830	5.894
GRNN_VMD3	1.000	1.000	0.000	0.000	0.546	0.118	7.603	5.744
GRNN_VMD4	1.000	1.000	0.000	0.000	0.552	0.123	7.583	5.735
<b>GRNN_VMD5</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>0.000</b>	<b>0.554</b>	<b>0.141</b>	<b>7.503</b>	<b>5.733</b>
GRNN_VMD6	1.000	1.000	0.000	0.000	0.545	0.130	7.550	5.776
<b>MARS_EMD1</b>	<b>0.796</b>	<b>0.634</b>	<b>4.827</b>	<b>3.863</b>	<b>0.779</b>	<b>0.606</b>	<b>4.965</b>	<b>3.956</b>
MARS_EMD2	0.763	0.582	5.158	4.119	0.745	0.555	5.276	4.203
MARS_EMD3	0.760	0.578	5.187	4.197	0.743	0.552	5.291	4.251
MARS_EMD4	0.763	0.582	5.158	4.119	0.745	0.555	5.276	4.203
MARS_EMD5	0.763	0.582	5.158	4.119	0.745	0.555	5.276	4.203
MARS_EMD6	0.763	0.583	5.156	4.118	0.745	0.554	5.278	4.202
<b>MARS_EWT1</b>	<b>0.868</b>	<b>0.754</b>	<b>3.962</b>	<b>3.010</b>	<b>0.868</b>	<b>0.753</b>	<b>3.930</b>	<b>2.917</b>
MARS_EWT2	0.870	0.756	3.942	2.989	0.866	0.751	3.947	2.964
MARS_EWT3	0.867	0.751	3.982	3.020	0.864	0.746	3.985	2.984
MARS_EWT4	0.870	0.757	3.931	2.956	0.867	0.751	3.946	2.925
MARS_EWT5	0.870	0.756	3.942	2.989	0.866	0.751	3.947	2.964
MARS_EWT6	0.870	0.757	3.931	2.956	0.867	0.751	3.946	2.925
<b>MARS_VMD1</b>	<b>0.820</b>	<b>0.672</b>	<b>4.522</b>	<b>3.311</b>	<b>0.811</b>	<b>0.657</b>	<b>4.740</b>	<b>3.464</b>
MARS_VMD2	0.818	0.670	4.539	3.319	0.809	0.655	4.757	3.464
MARS_VMD3	0.795	0.633	4.787	3.586	0.788	0.621	4.986	3.691
MARS_VMD4	0.814	0.662	4.591	3.362	0.804	0.646	4.816	3.488
MARS_VMD5	0.790	0.625	4.839	3.620	0.784	0.614	5.030	3.722
MARS_VMD6	0.790	0.624	4.843	3.617	0.782	0.611	5.049	3.715

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
<b>RFR_EMD1</b>	<b>0.973</b>	<b>0.942</b>	<b>1.915</b>	<b>1.289</b>	<b>0.902</b>	<b>0.803</b>	<b>3.514</b>	<b>2.553</b>
RFR_EMD2	0.972	0.939	1.965	1.330	0.899	0.798	3.554	2.582
RFR_EMD3	0.973	0.942	1.927	1.306	0.900	0.799	3.546	2.603
RFR_EMD4	0.969	0.932	2.081	1.412	0.888	0.779	3.716	2.693
RFR_EMD5	0.971	0.938	1.988	1.356	0.896	0.792	3.605	2.653
RFR_EMD6	0.967	0.929	2.129	1.468	0.881	0.765	3.830	2.828
<b>RFR_EWT1</b>	<b>0.978</b>	<b>0.952</b>	<b>1.752</b>	<b>1.180</b>	<b>0.924</b>	<b>0.849</b>	<b>3.068</b>	<b>2.112</b>
RFR_EWT2	0.976	0.948	1.822	1.218	0.921	0.845	3.109	2.145
RFR_EWT3	0.977	0.951	1.768	1.193	0.924	0.849	3.072	2.116
RFR_EWT4	0.972	0.939	1.976	1.334	0.910	0.824	3.316	2.300
RFR_EWT5	0.975	0.946	1.859	1.245	0.921	0.845	3.112	2.157
RFR_EWT6	0.970	0.935	2.027	1.366	0.910	0.824	3.318	2.296
<b>RFR_VMD1</b>	<b>0.960</b>	<b>0.910</b>	<b>2.369</b>	<b>1.646</b>	<b>0.830</b>	<b>0.687</b>	<b>4.532</b>	<b>3.299</b>
RFR_VMD2	0.958	0.906	2.419	1.688	0.827	0.682	4.567	3.326
RFR_VMD3	0.955	0.899	2.514	1.793	0.808	0.652	4.774	3.539
RFR_VMD4	0.956	0.901	2.489	1.744	0.827	0.682	4.563	3.328
RFR_VMD5	0.952	0.892	2.592	1.868	0.802	0.643	4.840	3.596
RFR_VMD6	0.946	0.881	2.728	1.982	0.797	0.634	4.901	3.656
SVR_EMD1	0.993	0.941	1.938	1.714	0.416	0.061	7.663	6.642
SVR_EMD2	0.993	0.941	1.932	1.710	0.444	0.074	7.608	6.587
SVR_EMD3	0.993	0.943	1.900	1.695	0.479	0.134	7.358	6.313
SVR_EMD4	0.993	0.945	1.874	1.679	0.560	0.175	7.183	6.147
SVR_EMD5	0.993	0.945	1.875	1.676	0.525	0.180	7.161	6.097
<b>SVR_EMD6</b>	<b>0.990</b>	<b>0.950</b>	<b>1.792</b>	<b>1.592</b>	<b>0.687</b>	<b>0.391</b>	<b>6.170</b>	<b>5.044</b>
SVR_EWT1	0.993	0.945	1.879	1.689	0.561	0.180	7.155	6.111
SVR_EWT2	0.993	0.948	1.823	1.655	0.650	0.279	6.710	5.648
SVR_EWT3	0.993	0.948	1.825	1.657	0.626	0.272	6.741	5.671
SVR_EWT4	0.993	0.950	1.786	1.624	0.709	0.390	6.171	5.065
SVR_EWT5	0.991	0.951	1.767	1.597	0.744	0.456	5.829	4.736
<b>SVR_EWT6</b>	<b>0.984</b>	<b>0.946</b>	<b>1.861</b>	<b>1.583</b>	<b>0.811</b>	<b>0.606</b>	<b>4.961</b>	<b>3.851</b>
SVR_VMD1	0.992	0.939	1.955	1.715	0.074	-0.001	8.099	7.045
SVR_VMD2	0.992	0.939	1.955	1.715	0.068	-0.001	8.099	7.045
SVR_VMD3	0.992	0.939	1.955	1.715	0.079	-0.001	8.099	7.045
SVR_VMD4	0.992	0.939	1.955	1.715	0.199	0.000	8.098	7.043
SVR_VMD5	0.992	0.939	1.955	1.715	0.124	-0.001	8.099	7.044
<b>SVR_VMD6</b>	<b>0.993</b>	<b>0.940</b>	<b>1.942</b>	<b>1.710</b>	<b>0.321</b>	<b>0.011</b>	<b>8.051</b>	<b>6.998</b>