

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



Université 20 Août 1955 Skikda

Faculté des Sciences

Département des Sciences Agronomiques



**Filière :** Sciences Agronomiques

**Option :** Aménagement Hydro-Agricole

**Mémoire de fin d'études :**

En vue de l'obtention du diplôme de Master II en Sciences Agronomiques

**Thème**

*Modélisation de l'évaporation à partir des plans d'eau (EP) par les  
Algorithms du Machine Learning: Développement Sur les plates  
Forme Anaconda & Spyder et R-Studio.*

**Présenté par :**

• Chaib Ghouzlane
• Bouzental Ilhem
• Louzat Abir
• Boughagha Inès

**Membres de Jury:**

Dr : KHALFAOUI Hakim	(MCA) <b>Président</b>	Université du 20 Août 1955- Skikda
Mr : SADOUNE Abdelaziz	(MAA) <b>Examineur</b>	Université du 20 Août 1955 - Skikda
Pr : HEDDAM Salim	(Pr.) <b>Promoteur</b>	Université du 20 Août 1955 - Skikda

**Année universitaire : 2023-2024**

## *Dédicaces*

بسم الله الرحمن الرحيم: "وأخر دعواتهم أن الحمد لله رب العالمين"

الحمد لله الذي ما تم جهد ولا ختم سعى الا بفضلله وما تخطى العبد من عقبات وصعوبات الا بتوفيقه ومعونته

Aux plus nobles gestes de générosité humaine... À mes chers parents ... Je vous dédie cette humble recherche... Puisse-t-elle être une aumône perpétuelle pour moi et pour vous...

À mes sœurs.. Nawal, Maroua, Hayet, Karima avec qui je partage mes moments...

À ceux qui se réjouissent de mes réussites comme si c'étaient les leurs...

À mes frères.. Issa, Akram, Ilyass que Dieu les guides et les protèges de sa bienveillance...

À ceux qui ont été un soutien inébranlable...

Aux petits de la maison et à leur bonheur...

À l'envie de mon cœur... ALI : À celui qui est plus proche de moi que ma propre âme...

À mes grand-mères et à mon grand-père, le destin a voulu que je ne puisse pas vous voir, que Dieu vous ait en sa miséricorde..... Et à mon grand-père, que Dieu prolonge sa vie et le protège.

À mes collègues... À celles qui ont partagé ce travail avec moi, qu'Allah vous protège : Ilhem, Inès, Abir.

CHAIB Ghouzlane



# Dédicaces

بِسْمِ: {وَمَا تَوْفِيقِي إِلَّا بِاللَّهِ عَلَيْهِ تَوَكَّلْتُ وَإِلَيْهِ أُنِيبُ}

je dédie ce modeste travail ,la récolte de mes efforts

A mon Chèr père :

le maître des hommes, la prunelle de mes yeux et la lumière de mon chemin ,la main qui a récolté les épines pour m'ouvrir la voie de mon succès

A ma Chère mère :

mon adorable mère, à celle qui est toujours présente et continue de l'être pour faire mon bonheur.

A mes Chères frères Mohcen, Zaki, Wail :

mes veines reliées au cœur, les plus grandes bénédictions de Dieu sur moi ,que Dieu les protège

A la joie de ma vie Aymen :

Le plus proche de mon cœur, avec lui j'ai appris le sens de la vie  
et a leur famille qui est ma deuxième famille

A mes Chères amies : Asmaa, Nawel ,Ilhem, Mina, Bouchra ,Maya, Sara,Amel, Marwa,chaima.

A ma cousine Sirine : a la place de ma sœur que je n'ai pas.

A mes collègues :Ghouzlane, Inès, Abir que Dieu les bénisse

A toute ma famille, mon oncle abderrezzak et mes grands-parents  
surtout ma défunte grand- mère

A mes Chères cousines Chaima ,Bouchra,Nessrine

et mes petites princesses Sidra et Hiba

بِسْمِ : {وَأَخِرُ دَعْوَاهُمْ أَنْ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ}



## *Dédicaces*

J'ai dit à elle et je l'ai atteinte

Et même si elle refuse, je l'apporte malgré tout

Aujourd'hui, une grande gloire, je l'ai faite malgré toutes les difficultés

Ce n'était pas impossible, c'est le fruit de mes efforts

Je remercie Dieu pour tout

C'est pourquoi je dédie le fruit de mes efforts à :

Mon père qui veille sur moi et ma mère qui prie pour moi dans ses prières

Pour mes sœurs Safa et Ghada et mon frère Badr Eddine

Pour celui qui a conquis mon cœur

Pour mes amies Achouak, Dounia, Chaima et Djihane

Pour ceux que j'ai élevés depuis leur enfance, je les appelle ma moitié de mon âme Alva et Bicho.

Pour mes collègues et compagnes dans cet effort Ilhem, Ghouzlane et Inès.

À toute ma famille

Et enfin, je n'aurais jamais pu faire cela sans la guidance d'Allah. C'est le jour que j'ai tant attendu, loué soit Allah qui, chaque fois que j'ai eu foi en Lui, m'a comblé de bonheur et de joie.

ABIR LOUZAT



## *Dédicaces*

À mes chers parents

Du fond du cœur, je te remercie pour ta présence et tout ce que tu as fait pour moi, je te présente mes excuses pour toutes les fois où j'ai oublié de te dire à quel point je suis heureuse de t'avoir dans ma vie. mon père.

À celui qui a été le premier à me soutenir dans la réalisation de mes ambitions, à celui qui a été mon refuge mon bras droit à ce stade, à celui qui m'a montré le chemin de ma vie et de mon estime de soi, au cœur compatissant, à celle dont les prières m'entouraient, à toi, ma mère bien-aimée.

À mes sœurs, et mon frère

Pour leur encouragement et leur bonté a qu'ils m'ont accorde j'exprime ma profonde reconnaissance et mon grand respect.

À toutes ma familles, mes amis et tous ceux que j'aime

Je dédie ce travaille expression de mon grand amour avec tous mes vœux de bonheur et prospérité.

Un merci dévoué et spécial à mes collègues : Bouzental Ilhem, Chaib Ghouzlane Louzat Abir.

Boughagha Inès





## Remerciements

Tout d'abord, nous remercions ALLAH le tout puissant et miséricordieux, qui nous a donné la force et la patience d'accomplir ce modeste travail.

Nous exprimons nos profonds remerciements, notre vive reconnaissance et notre sincère gratitude à :

Mr .HEDDAM Salim pour sa disponibilité, son écoute active, sa qualité humaine et tous ses précieux conseils.

Nous remercions vivement l'ensemble des membres du jury :

Mr.SAADOUNE Abdelaziz et Mr.KHALFAOUI Hakim qui nous ont fait l'honneur d'examiner ce travail.

Nous tenons à exprimer notre gratitude à l'ensemble des Enseignants de l'université de 20 Aout 1955 Skikda plus particulièrement à les Enseignants de département des Sciences Agronomiques qui ont enrichi notre richesse scientifique.

Ainsi qu'à tout le personnel CP2K de l'entreprise Sonatrach qui nous a fait part de son expérience.

Enfin, nous remercions tous ceux qui ont participé de près ou de loin à la réalisation de ce mémoire.

## ملخص

خلال السنوات الأخيرة زاد بشكل كبير الاهتمام باستعمال نماذج الذكاء الاصطناعي وتوسعت استعمالاتها لتشمل كلما يرتبط بالحياة اليومية للإنسان، ففي مجال الري والعلوم الزراعية أصبحت الحاجة المتزايدة لإدخال واقتراح هذه النماذج حتمية لا مفر منها. تدخل هذه الدراسة في اطار تحضير مذكرة نهاية التخرج تخصص ماستر تهيئة مائية-فلاحية و التي تهدف الى اعداد نماذج رياضية و تطويرها لحساب التبخر من المساحات المائية الذي يعتبر مكونا أساسيا في الدورة الهيدرولوجية . من اجل ذلك قمنا باستعمال نموذجان من الشبكات العصبية الاصطناعية وهما:(i) الشبكة العصبية متعددة الطبقات (ANN)، (ii) شبكة الانحدار العصبي المعمم (GRNN) مع مقارنة النتائج ب (iii) نموذج الانحدار الخطي (MLR). من اجل تطوير هذه النماذج الرياضية استعملنا معطيات مناخية تخص اربع محطات وهي قسنطينة ، سطيف ، قالمة ،ميلة على مستوى كل محطة قمنا بجمع قاعدة بيانات تحتوي على قياسات يومية و التي توافق الفترة الممتدة من(2004- 2013) و تتمثل في المتغيرات التالية:(i) درجة الحرارة القصوى ( $T_{max}$ )، (ii) درجة الحرارة الدنيا ( $T_{min}$ )، (iii) سرعة الرياح ( $U_2$ )، (iv) الرطوبة النسبية ( $H\%$ )، (v) الاشعاع الشمسي (SR) و التي استعملت كنماذج لنمذجة التبخر (EP). قسمت قاعدة البيانات الى قسمين % 70 من اجل تدريب و تطوير النموذج (Apprentissage) و% 30 من اجل تقييم قدرة النموذج على التنبؤ الصحيح بالتبخر اليومي (Validation). قمنا باستعمال مجموعة من معايير التحقق الاحصائي و التي تمثل في:(i) معامل الارتباط (R)، (ii) معامل الكفاءة (NSE)، (iii) متوسط الخطأ المطلق (MAE)، (iv) الجذر التربيعي لمربع الخطأ (RMSE). من اجل التعرف على تأثير مختلف المتغيرات على استجابة النموذج الرياضي قارنا ما بين 12 نموذج بتشكيلات مختلفة من المتغيرات المناخية . اثبتت النتائج المتحصل عليها قدرة الشبكات الاصطناعية على حساب التبخر (EP) بدقة ممتازة وتجاوزت نموذج المنحدر الخطي وكانت الحسابات ذات دقة تنبؤية عالية حيث وصل معامل الارتباط (R) ومعامل الكفاءة (NSE) ما بين (0.99, 0.97) ) تعتبر النتائج المتحصل عليها جد مشجعة و تفتح آفاق مستقبلية واعدة

**الكلمات المفتاحية :** التبخر من المساحات المائية ، نماذج الذكاء الاصطناعي ، محطات مناخية متغيرات مناخية، تدريب النموذج ، تقييم النموذج .

## Résumé

Au cours des dernières années, l'intérêt pour l'utilisation de modèles d'intelligence artificielle a considérablement augmenté et leurs applications se sont étendues pour inclure tout ce qui est lié à la vie quotidienne de l'homme. Dans le domaine de l'irrigation et des sciences agricoles, le besoin croissant d'introduire et de proposer ces modèles est devenu inévitable. Cette étude s'inscrit dans le cadre de la préparation d'un mémoire de fin d'études (Master II) en Aménagement Hydro-Agricole. Elle vise à développer des modèles mathématiques et à les améliorer pour calculer l'évaporation à partir des plans d'eau, qui est un élément essentiel du cycle hydrologique. Pour cela nous avons utilisé deux modèles de réseaux de neurones artificiels: (i) le Multilayer Perceptron Neural Network (MLPNN), (ii) Generalized Regression Neural Network (GRNN), et en comparant les résultats avec (iii) le modèle de régression linéaire multiple (MLR). Pour développer ces modèles, nous avons utilisé des données climatiques provenant de quatre stations : Constantine, Sétif, Guelma et Mila. Au niveau de chaque station, nous avons collecté une base de données contenant des mesures quotidiennes enregistrées durant la période allant de 2004 à 2013, comprenant les variables suivantes: (i) température maximale ( $T_{max}$ ), (ii) température minimale ( $T_{min}$ ), (iii) vitesse du vent ( $U_2$ ), (iv) humidité relative (H%), (v) rayonnement solaire (SR). Ces variables ont été utilisées comme entrées pour modéliser l'évaporation (EP). La base de données a été divisée en deux parties: 70% pour l'apprentissage et 30% pour évaluer la capacité des modèles à prédire correctement l'évaporation quotidienne (validation). Nous avons utilisé un ensemble de critères de performances numériques pour la validation et l'évaluation des modèles: (i) Coefficient de corrélation (R), (ii) Coefficient de Nash-Sutcliffe efficiency (NSE), (iii) erreur absolue moyenne (MAE), (iv) racine carrée de l'erreur quadratique moyenne (RMSE). Afin d'étudier l'impact des différentes variables sur la réponse des modèles, nous avons comparé 12 modèles avec différentes combinaisons de variables climatiques. Les résultats ont démontré la capacité des réseaux de neurones artificiels à calculer l'évaporation (EP) avec une excellente précision, surpassant le modèle de régression linéaire. Les calculs étaient hautement prédictifs, avec des R et des NSE compris entre 0.97 et 0.99. Ces résultats sont très encourageants et ouvrent des perspectives futures prometteuses.

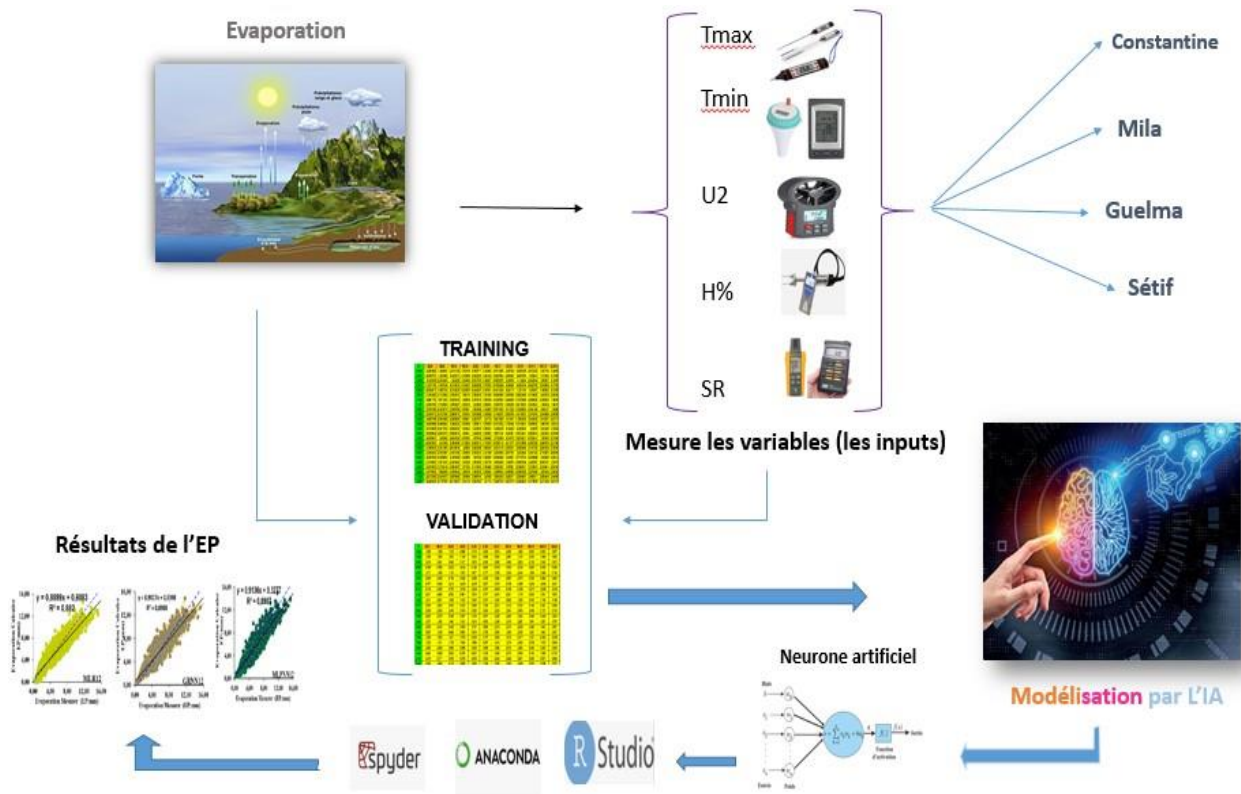
**Mots-Clés :** l'évaporation à partir des plans d'eau, modèles d'intelligence artificielle, MLPNN, GRNN, stations météorologiques, variables climatiques, apprentissage, validation.

## Abstract

In recent years, there has been a significant increase in the use of artificial intelligence (AI) models in various engineering areas. In the field of irrigation and agricultural sciences, the growing interest in introducing these models has become of great importance. The present Master's degree thesis in water and agricultural development, aims to apply some AI models for modelling pan evaporation. For this purpose, we used two artificial neural network models namely: (i) the multilayer perceptron neural network (MLPNN), (ii) the generalized regression neural network (GRNN), and one regression model, *i.e.*, the multiple linear regression (MLR) for modelling daily pan evaporation (EP). For developing the models we use various climatic variables namely, (i) the maximum temperature ( $T_{\max}$ ), (ii) the minimum temperature ( $T_{\min}$ ), (iii) wind speed ( $U_2$ ), (iv) relative humidity (H%), and (v) solar radiation (SR). these variables were collected from four climatic stations namely, Constantine, Guelma, Mila et Setif. For each station, we divide the data into two parts: 70% for training and calibrating the model (training) and 30% for evaluating the model's (validation). Models evaluation and comparison was done using various statistical indices namely: the correlation coefficient (R), The Nash-Sutcliffe efficiency (NSE), mean absolute error (MAE), and root mean square error (RMSE). In order to understand the impact of different variables on the response of the models, we compared 12 models with different combinations of climatic variables. The results demonstrated the excellent accuracy of artificial neural networks in calculating evaporation (EP), surpassing the linear regression model. The calculations showed high predictive accuracy, with R and NSE ranging between 0.97 and 0.99.

**Keywords:** Pan Evaporation, artificial intelligence models, MLPNN, GRNN, climatic stations, climatic variables, training ,validation.

# Graphical Abstract & Résumé Graphique



## *Liste des Figures*

<b><i>ChapitreI:</i></b>	
<b>FigureI.1.</b> L'atmomètre de Bellani	06
<b>FigureI.2.</b> Le bac de classe A	07
<b>FigureI.3.</b> Le bac Colorado	07
<b>FigureI.4.</b> Le bac flottant	08
<b><i>ChapitreII:</i></b>	
<b>FigureII.1.</b> Situation géographique de la zone d'étude	11
<b>FigureII.2.</b> Matrice de corrélation des différentes variables pour les quatre stations climatiques	13
<b>FigureII.3.</b> Installation de la fonction HydroGOF	14
<b>FigureII.4.</b> Présentation de la plateforme RStudio	14
<b>FigureII.5.</b> Les étapes de calcul sous RStudio	15
<b><i>ChapitreIII :</i></b>	
<b>FigureIII.1.</b> Schéma d'un Neurone biologique	20
<b>FigureIII.2.</b> Schéma d'un Neurone formel	21
<b>FigureIII.3.</b> Schéma d'un Neurone artificiel	21
<b>FigureIII.4.</b> Le perceptron multicouche (MLPNN)	23
<b>FigureIII.5.</b> Le réseau de neurones de type (GRNN)	23
<b>FigureIII.6.</b> Apprentissage supervisé	24
<b>FigureIII.7.</b> Apprentissage non supervisé	24
<b>FigureIII.8.</b> Présentation de la plateforme Anaconda	25
<b>FigureIII.9.</b> Présentation de l'environnement de développement Spyder	26
<b>FigureIII.10.</b> Développement des modèles MLR sous Excel	27
<b>FigureIII.11.</b> Organigramme général des différentes étapes de modélisation de l'évaporation.	27
<b><i>ChapitreIV:</i></b>	
<b>FigureIV.1.</b> Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles MLR	33
<b>FigureIV.2.</b> Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles MLPNN	34
<b>FigureIV.3.</b> Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles GRNN	35
<b>FigureIV.4.</b> Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Mila & modèles MLR	38
<b>FigureIV.5.</b> Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Mila & modèles MLPNN	39

<b>FigureIV.6.</b> Scatterplots des valeurs mesurées et calculéesde l'EPen phase de validation: Station de Mila& modèles GRNN	40
<b>FigureIV.7</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Guelma& modèles MLR	43
<b>FigureIV.8.</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Guelma& modèles MLPNN	44
<b>FigureIV.9.</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Guelma& modèles GRNN	45
<b>FigureIV.10.</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Sétif& modèles GRNN	48
<b>FigureIV.11.</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Sétif & modèles GRNN	49
<b>FigureIV.12.</b> Scatterplots des valeurs mesurées et calculéesde l'EP en phase de validation: Station de Sétif & modèles GRNN	50

## ***Liste des Tableaux***

<b><i>Chapitre II :</i></b>	
Tableau II.1. Présentation des sites utilisés durant la modélisation de l'EP	11
Tableau II.2. Paramètres statistiques de la base de données utilisée: modélisation de l'EP	12
Tableau II.3. Structure des modèles utilisés	15
<b><i>Chapitre IV :</i></b>	
Tableau IV.1. Performances des différents modèles: Station de Constantine	31
Tableau IV.2. Performances des différents modèles: Station de Mila	37
Tableau IV.3. Performances des différents modèles: Station de Guelma	42
Tableau IV.4. Performances des différents modèles: Station de Sétif	47

## *Table des Matières*

<b>Introduction Générale</b>	<b>01</b>
<b><i>Chapitre I : Généralités Sur L'évaporation à Partir Des Plans d'eau (EP)</i></b>	<b>03</b>
I.1. Introduction	04
I.2. Notions de base sur l'évaporation à partir des plans d'eau	04
I.3. Facteurs climatiques influençant l'évaporation	05
I.3.1. La Température de l'air	05
I.3.2. L'humidité de l'air	05
I.3.3. La radiation solaire	05
I.3.4. La vitesse du vent	05
I.3.5. Les précipitations	06
I.4. Les méthodes d'estimation de l'évaporation	06
I.4.1. Les méthodes directes	06
I.4.1.1. Les atmomètres et évaporimètres	06
I.4.1.2. Les bacs évaporatoires	07
I.4.2. Les méthodes indirectes ou empiriques	08
I.4.2.1. Méthodes basées sur le transfert de masse	09
I.4.2.2. Méthodes basées sur le rayonnement	09
<b><i>Chapitre II : Présentation de la Zone d'Étude et Description de la Base de Données Utilisée</i></b>	<b>10</b>
II.1. Introduction	11
II.2. Présentation et description des données utilisées	11
II.2.1. Situation géographique des stations climatiques utilisées	11
II.2.2. Statistiques descriptives	12
II.3. Evaluation des performances des modèles	13
II.4. Conclusion	16
<b><i>Chapitre III : Présentation des Modèles de Machine Learning (ML)</i></b>	<b>17</b>
III.1. Introduction	18
III.2. Concepts de base de l'intelligence artificielle	18
III.3. Historique de l'intelligence artificielle	19
III.4. Concepts de base de machine learning	19
III.5. Les réseaux de neurones artificielles	20
III.5.1. Le neurone biologique	20
III.5.2. Le Neurone Formel.	21
III.5.3. Le Neurone Artificiel	21

III.5.4. Le perceptron	22
III.5.5. Réseaux de Neurones	22
III.5.6. Le Perceptron Multicouche (MLPNN)	22
III.5.7. Le Réseau de Neurone de Régression Généralisée (GRNN)	23
III.6. La Régression linéaire multiple (MLR)	23
III.7. Apprentissage des réseaux de neurones	24
III.8. Répartition des données & apprentissage et validation	25
III.9. Développement des modèles sous la plateforme ANACONDA	25
III.9.1. Présentation de la plateforme ANACONDA	25
III.9.2. Présentation de l'environnement de développement Spyder	26
III.9.3. Développement des modèles MLR sous Excel	27
III.10. Conclusion	28
<b><i>Chapitre IV: Résultats et Interprétation</i></b>	<b>29</b>
IV.1. Introduction	30
IV.2. Modélisation de l'EP à Pas de Temps Journalière & Station de Constantine	30
IV.3. Modélisation de l'EP à Pas de Temps Journalière & Station de Mila	36
IV.4. Modélisation de l'EP à Pas de Temps Journalière & Station de Guelma	41
IV.5. Modélisation de l'EP à Pas de Temps Journalière & Station de Sétif	46
IV.6. Conclusion	51
<b><i>Chapitre V: Conclusion Générale</i></b>	<b>52</b>

## *Liste des Abréviations*

**EP** : L'évaporation.

**IA** : d'intelligence artificielle.

**ONM** : L'office national de la météorologie.

**ANRH** : l'agence nationale des ressources hydrauliques.

**OMM** : L'organisation Météorologique Mondiale.

**R** : le coefficient de corrélation linéaire.

**CV** : le coefficient de variation.

**RMSE** : la racine carrée de l'erreur quadratique moyenne.

**MAE** : la moyenne des erreurs.

**NSE** : le critère d'efficacité de Nash-Sutcliffe.

**KGE** : efficacité de Kling-Gupta.

**PBIAS** : biais de pourcentage.

**ML** : Machine Learning.

**RNA** : Les réseaux de neurones artificiels.

**MLPNN** : Multilayer Perceptron neural network.

**GRNN** : Le Réseau de Neurone de Régression Généralisée.

**MLR** : La Régression linéaire multiple.

**RS** : Radiation solaire global.

**Tmax** : la température de l'air maximale.

**Tmin** : la température de l'air minimale.

**H%** : L'humidité relative de l'air.

**U2** : la vitesse du vent.

## 1 **Introduction Générale :**

2  
3 L'évaporation (EP) est une composante principale du cycle hydrologique et son  
4 estimation est primordiale et d'une grande importance. Une précise estimation de l'évaporation  
5 entre dans le cadre de la planification et la conception de nombreux projets de ressources en eau  
6 comme l'irrigation, les barrages, prévision du débit des rivières, approvisionnement en eau, etc.  
7 Traditionnellement, l'évaporation est déterminée à l'aide de : (i) les mesures directes par les bacs  
8 d'évaporation, (ii) la combinaison des méthodes de bilan énergétique et de transfert de masse,  
9 (iii) les formules empiriques, (iv) et les techniques à base d'intelligence artificielle (IA).

10  
11 Le processus d'évaporation (EP) est fortement non linéaire, and de nombreux  
12 chercheurs ont proposés des formules empirique et méthodes pour estimer l'évaporation à partir  
13 des plans d'eau. Les méthodes empiriques nécessitent des données intensives, et aussi demande  
14 des mesures de nombreuses variables climatiques comme ; le rayonnement solaire, durée  
15 d'ensoleillement, la vitesse du vent, l'humidité relative, et d'autres variables. Bien qu'il soit  
16 possible de mesurer l'évaporation en utilisant les méthodes directes, il est difficile de placer et  
17 d'entretenir les bacs d'évaporation. Donc, il s'avère important de disposer des moyens pratiques  
18 pour estimer la quantité de EP dans une station sans recours à l'utilisation des bacs pour les  
19 hydrologues, météorologues et agriculteurs. Cette situation à motiver la recherche d'autres  
20 techniques alternatives pour estimer l'EP avec une précision acceptable. Durant les dernières  
21 années, le recours à l'utilisation des techniques à base d'intelligence artificielles, et surtout les  
22 réseaux de neurones artificiel (ANN) pour la modélisation de différentes composantes  
23 climatiques à conduit à la proposition et le développement de plusieurs modèles mathématiques.  
24 Précisément, les techniques à base d'intelligence artificielles ont été largement utilisées dans le  
25 domaine des ressources en eaux et en particulier pour la modélisation de l'évaporation et  
26 l'évapotranspiration.

27  
28 Le présent travail réaliser dans le cadre de la préparation de mémoire de master en  
29 Aménagement Hydroagricole, entre dans le contexte de la modélisation de l'évaporation à partir  
30 des plans d'eau par les techniques à base d'intelligence artificielles. On cherche à répondre à trois  
31 objectifs. Premièrement, développés des modèles mathématiques pour estimation de l'EP à l'aide

32 de diverses combinaisons de mesures journalières de plusieurs variables climatiques : humidité  
33 de l'aire, radiation solaire, température maximale et minimale de l'aire, la vitesse du vent ainsi  
34 que l'EP mesurés à partir du bac d'évaporation. Deuxièmement, nous avons essayé de mettre en  
35 lumière l'efficacité des modèles proposés en tenant compte de plusieurs combinaisons de  
36 variables climatiques d'entrées. Finalement, une évaluation numérique et graphique des modèles  
37 développés avec une comparaison entre plusieurs algorithms. Nous avons adopté le plan de travail  
38 suivant :

39

40 1. On commence par une introduction générale pour exposé la problématique étudiée.

41 2. Dans le premier chapitre nous avons présenté des généralités sur le cycle hydrologique, les  
42 différents variables climatiques, ainsi que les concepts de base d'évaporation EP.

43 3. Dans le 2 ème chapitre nous avons présenté les données climatiques utilisées pour le  
44 développement des modèles, ainsi que une description sommaire des stations climatiques  
45 sélectionné dans les présentes études.

46 4. Les concepts de base de l'intelligence artificielle ainsi que les modèles à base de réseau de  
47 neurone artificiel présente en détail dans le chapitre 3.

48 5. Le 4 ème et dernier chapitre et réserver à la présentation détaillée des résultats obtenus par les  
49 différents modèles, ainsi qu'une évaluation et comparaison à base de critère numérique et  
50 graphique.

51 6. Enfin une conclusion générale.

52

53

54

55

56

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29  
30  
31  
32  
33  
34

***Chapitre I: Généralités Sur L'évaporation à Partir Des  
Plans d'eau (EP)***

---

## 35 **I.1.Introduction**

36 L'évaporation à partir des surfaces d'eau est le phénomène par lequel le liquide se  
37 transforme en vapeur(bennis saad.,2004) À l'échelle continentale, les continents s'évaporent  
38 une fraction de leurs précipitations allant jusqu'à 55%pour l'Amérique du nord etl'Asie, à  
39 75%pour le continent africain. Cela montre à quel point ce processus est un élément  
40 fondamental du bilan hydrique de par les volumes d'eau mis en jeu mais aussi de par son  
41 influence sur la circulation climatique mondiale. Même à une échelle plus petite,  
42 l'évaporation d'un lac ou d'une retenue à l'amont jouer un rôle significatif.L'évaporation joue  
43 un rôle déterminant dans le bilan hydrologique et présente un intérêt pratique évident,  
44 puisqu'elle est responsable des pertes de volumes d'eau (des barrages, des lacs etc.) parfois  
45 considérables.(boutoutaou,2011)

46

## 47 **I.2. Notions de base sur l'évaporation à partir des plans d'eau**

48 De toutes les données climatologiques, l'évaporation des plans d'eau en Algérie reste le plus  
49 souvent absente dans les bulletins et les atlas climatologiques, publiées annuellement par  
50 l'office national de la météorologie. Par manque de données, sa détermination est basée sur  
51 une analyse sommaire de quelques éléments météorologiques (insolation, température, etc.),  
52 qui reste en général une évaluation grossière et manque de précision. En hydrologie,  
53 l'évaporation présente un intérêt pratique évident, puisqu'elle est responsable des pertes de  
54 volumes d'eau (des barrages des lacs etc.), parfois considérables. L'établissement par exemple  
55 d'un bilan hydrique d'une réserve d'eau d'un barrage, d'un chott ou d'un lac exige la  
56 connaissance de l'évaporation. La valeur de cette dernière est très nécessaire aussi pour la  
57 conception des bassins de lagunage dans l'épuration des eaux usées. En Algérie, la mesure de  
58 l'évaporation est confiée aux services de l'office national de la météorologie (ONM) et aux  
59 services de l'agence nationale des ressources hydrauliques (ANRH). La détermination de la  
60 valeur de l'évaporation des plans d'eau en Algérie est effectuée donc à partir des stations  
61 météorologiques équipées de bacs d'évaporation de ces deux organismes (ONM et ANRH).  
62 En absence de ces bacs, elle est déterminée par analogie avec les plans d'eau qui sont toujours  
63 mesurés. L'erreur liée à l'évaluation par analogie, peut atteindre des valeurs  
64 considérables.Quant aux stations météorologiques (bacs d'évaporation), qui offrent de bons  
65 résultats, elles sont malheureusement limitées en nombre et elles ne couvrent que quelques  
66 régions du pays.(Boutoutaou et al .,2011)

67

68

69

70

71

72

73

### 74 **I.3. Facteurs climatiques influençant l'évaporation**

75 On appelle les facteurs météorologiques tous les paramètres qui caractérisent l'état de  
76 l'atmosphère au voisinage de la surface évaporant de même que son aptitude provoque  
77 l'évaporation. Ces paramètres sont facilement mesurés à l'aide des instruments installés à  
78 proximité de la retenue, où nous trouvons la station climatologique.

#### 79 **I.3.1. La Température de l'air**

80 La température de l'air constitue un paramètre essentiel dans le processus  
81 d'évaporation. Elle influence directement sur la température de l'eau et sur la tension de  
82 vapeur saturante de l'eau(Guezel et al,2018). La température de l'air est la plupart du temps  
83 mesurée par un thermomètre situé dans un abri météorologique, à l'abri des radiations  
84 solaires. Ce paramètre est disponible en valeurs horaires ou en moyennes journalières ou  
85 mensuelles.

#### 86 **I.3.2. L'humidité de l'air**

87 L'humidité relative de l'air est un état de climat qui représente le pourcentage de l'eau  
88 existant dans l'atmosphère, elle a des effets sur le processus d'évaporation et peut s'exprimer  
89 par la loi de Dalton(Sahraoui, 2016).Elle est utilisée dans beaucoup de formules et c'est une  
90 donnée mesurée au niveau des stations météorologiques

#### 91 **I.3.3. La radiation solaire**

92 Le rayonnement solaire est l'élément moteur des conditions météorologiques et climatiques,  
93 et par voie de conséquence, du cycle hydrologique. Il existe plusieurs appareils de mesure du  
94 rayonnement solaire (pyrhéliomètre, pile thermoélectrique... etc.). ), (Nedjima,2019)

#### 96 **I.3.4. La vitesse du vent**

97 Le vent joue un rôle essentiel sur l'évaporation car il permet le renouvellement des  
98 masses d'air non saturées à la surface de la retenue, et maintient ainsi un certain pouvoir  
99 évaporant de l'air. La mesure du vent est facilement accessible soit auprès de météo Algérie,  
100 soit auprès des aérodromes ou aéroports.(Vachala, 2008)

#### 101 **I.3.5. Les précipitations**

102 Les précipitations constituent un phénomène qui décrit le transfert de l'eau, dans une  
103 phase liquide (pluie) ou solide (neige, grêle), entre l'atmosphère et le sol. Au-dessus des  
104 continents, les précipitations représentent l'élément le plus important du cycle hydrologique,  
105 leur volume étant supérieure à celui des autres composantes. D'après le principe de  
106 conservation de la masse et en considérant l'échelle de la planète pendant une période de  
107 temps suffisamment longue, les précipitations sont égales à l'évaporation. (Lamas, 1993).

## 108 I.4. Les méthodes d'estimation de l'évaporation


### 109 I.4.1. Les méthodes directes

110 Les mesures directes sont effectuées par des appareils, plus ou moins normalisés,  
 111 soumis aux phénomènes évaporatoires, qui mesurent une variation de quantité d'eau. On  
 112 recense principalement deux types d'appareils, les atmomètres et évaporimètres et les bacs  
 113 évaporatoires.

#### 114 I.4.1.1. Les atmomètres et évaporimètres

115 Les atmomètres et évaporimètres mesurent le pouvoir évaporateur de l'air ou l'évaporation  
 116 latente, définie comme l'évaporation maximale d'une surface saturée, plane, horizontale, noire  
 117 et exposée aux conditions météorologiques du milieu étudié. (Arnaud and Lavabre(1999)).

118 Plusieurs appareils ont été développés à cet effet, l'évaporimètre Piche, l'évaporimètre de  
 119 Livingstone, l'atmomètre de Bellani, etc. Cependant ces appareils sont peu adaptés à la mesure  
 120 de l'évaporation des surfaces d'eau libre. En effet, ils sont souvent situés dans des abris  
 121 météorologiques et ne prennent pas en compte tous les paramètres atmosphériques (comme le  
 122 vent, le degré d'insolation...), ainsi que l'inertie thermique du volume d'eau. Leur  
 123 utilisation première est la mesure de l'évapotranspiration et non l'évaporation d'une surface  
 124 d'eau libre. (Aldomany 2017).



125  
 126  
 127 **Figure I.1.** L'atmomètre de Bellani (Aldomany 2017).  
 128  
 129  
 130  
 131  
 132  
 133  
 134

135 **I.4.1.2. Les bacs évaporatoires**

136 Les bacs évaporatoires sont conçus pour prendre en compte tous les phénomènes  
 137 atmosphériques influençant l'évaporation, ainsi que l'inertie thermique de la masse d'eau. Les  
 138 bacs peuvent être de différentes tailles, formes, matériaux, et positionnements (enterré ou  
 139 flottant à la surface du plan d'eau). On mesure une quantité d'eau perdue par évaporation.  
 140 Tous les paramètres cités précédemment vont influencer la mesure et il sera nécessaire de les  
 141 corriger à l'aide de coefficients. Plus les bacs vont être imposants, plus ils se rapprocheront de  
 142 la réalité. L'organisation Météorologique Mondiale (OMM) a recensé bon nombre de bacs  
 143 (WMO, 1994). Les plus utilisés sont les suivants:

- 144 • Le bac de classe A, développé par le Weather Bureau. Bac rond de 122cm de  
 145 diamètre, 25.4cm de profondeur. Il est posé à 18cm au-dessus du sol et l'eau à  
 146 l'intérieur du bac doit affleurer à 5-8cm du bord. Étant petit, il est soumis à un  
 147 problème d'inertie thermique trop faible.



148 **Figure I.2.** Le bac de classe A (Boutoutaou, 2011)

- 151 • Le bac Colorado, est un bac carré de 91.4cm de côté, et de 46 à 91cm de profondeur.  
 152 Il est enterré de manière à ce que son rebord soit à 10cm au-dessus de la surface du  
 153 sol. De fait, il représente mieux l'inertie thermique. Il existe des variantes du bac  
 154 Colorado, notamment la version ORSTOM, les bacs Russe, GGI 3000, et le bac de  
 155 20m<sup>2</sup>, sont aussi très utilisés. Bacs circulaires enterrés, à base conique de 62cm de  
 156 diamètre et 61cm de profondeur pour le premier, et 5m de diamètre et 2m  
 157 de profondeur pour le deuxième.



158 **Figure I.3.** Le bac Colorado (Boutoutaou, 2011)

- 160 • Les bacs flottants sont partiellement immergés à la surface de l'eau. Cette mesure est  
 161 la plus représentative des conditions d'évaporation de la surface d'eau libre mais est  
 162 très difficile à mettre en œuvre et très coûteuse.



163 **Figure I.4.** Le bac flottant (Aldomany, 2017)

164 L'Evaporation & Concept Généraux communément utilisés pour mesurer cinq modèles  
 165 différents et la liste va continuer à En général, les bacs d'évaporation sont des appareils  
 166 constitués d'un bassin ou d'une cuve d'assez grandes dimensions, dans lequel on mesure  
 167 l'abaissement du niveau de l'eau sous l'action de l'évaporation. Au contraire des premiers  
 168 bacs utilisés par Halley, , où les dimensions sont petites (voir très petites), les bacs  
 169 d'évaporation ont des dimensions plus grandes. Certains sont carrés, d'autres  
 170 cylindriques; certains sont e que l'eau soit sensiblement au même niveau que le sol. Les  
 171 bacs d'évaporation sont parfois installés sur des plates-formes flottantes ancrées sur des  
 172 lacs ou d'autres plans d'eau. La raison principale pour fabriquer ces er à la mesure directe  
 173 de l'évaporation d'une surface d'eau. Parmi 2017): de 122cm de diamètre, du sol et l'eau à  
 174 l'intérieur du bac doit est un bac carré de 91.4 cm de côté, et de 46 à 91cm de profondeur.  
 175 Il est de la surface du sol. Il existe Aldomany 2017). sont aussi très utilisés. Bacs  
 176 circulaires enterrés, à base conique de 62cm de diamètre et 61cm de profondeur pour le  
 177 premier, et 5m Les bacs flottants sont partiellement immergés à la surface de l'eau. Cette  
 178 mesure est représentative des conditions d'évaporation de la surface d'eau libre mais est  
 179 très aref. (Stan et al. 2016).

#### 182 183 **I.4.2. Les méthodes indirectes ou empiriques**

184 Les mesures indirectes reposent sur des modèles empiriques, qui sont fonction de  
 185 variables climatiques plus ou moins nombreuses et plus ou moins faciles à mesurer. Il existe  
 186 de nombreuses formules de calcul de l'évaporation. Certaines sont plus ou moins complexes.  
 187 Les formulations ayant été établies pour la plupart dans la première moitié du XXème siècle, il  
 188 faut faire attention aux unités qui n'étaient pas normalisées comme aujourd'hui. Les formules  
 189 ci-après sont écrites dans leur version d'origine et les coefficients ne sont pas  
 190 modifiés. (vachala, 2008)

191  
192  
193  
194

195 **I.4.2.1. Méthodes basées sur le transfert de masse**

196 Ces méthodes sont très faciles à mettre en œuvre car il ne faut que la température et le  
197 vent comme paramètres d'entrée (la tension de vapeur saturante peut aussi être utile mais n'est  
198 pas indispensable car elle peut être approchée par une formule utilisant la température du point  
199 de rosée). Parmi les formules relatives à cette catégorie on peut citer : la formule de Dalton, la  
200 formule de Fitzgerald, la formule de Meyer, la formule de Horton et la formule de Rohwer.

201

202 **I.4.2.2. Méthodes basées sur le rayonnement**

203 L'approche basée sur le rayonnement est moins évidente que l'approche basée sur le  
204 transfert de masse car elle utilise des paramètres plus difficilement mesurables. Parmi Les  
205 formules de cette catégorie on peut citer: la formule de Makkink, la formule de Turc, la  
206 formule de Priestley, la formule de Hargreaves, la formule de Linacre, la formule de Abtew.

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29

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

---

## 30 II.1. Introduction

31 L'objectif de notre travail est la modélisation de l'évaporation (EP:mm) en fonction des  
 32 variables climatiques. Nous disposons pour la modélisation de l'EP de cinq variables climatiques:  
 33 la température maximale ( $T_{max}$ : °C), la température minimale ( $T_{min}$ : °C), la vitesse du vent ( $U_2$ :  
 34 m/s), l'humidité relative (H: %) et la radiation solaire (RS: MJ/m<sup>2</sup>).

## 35 II.2. Présentation et description des données utilisées

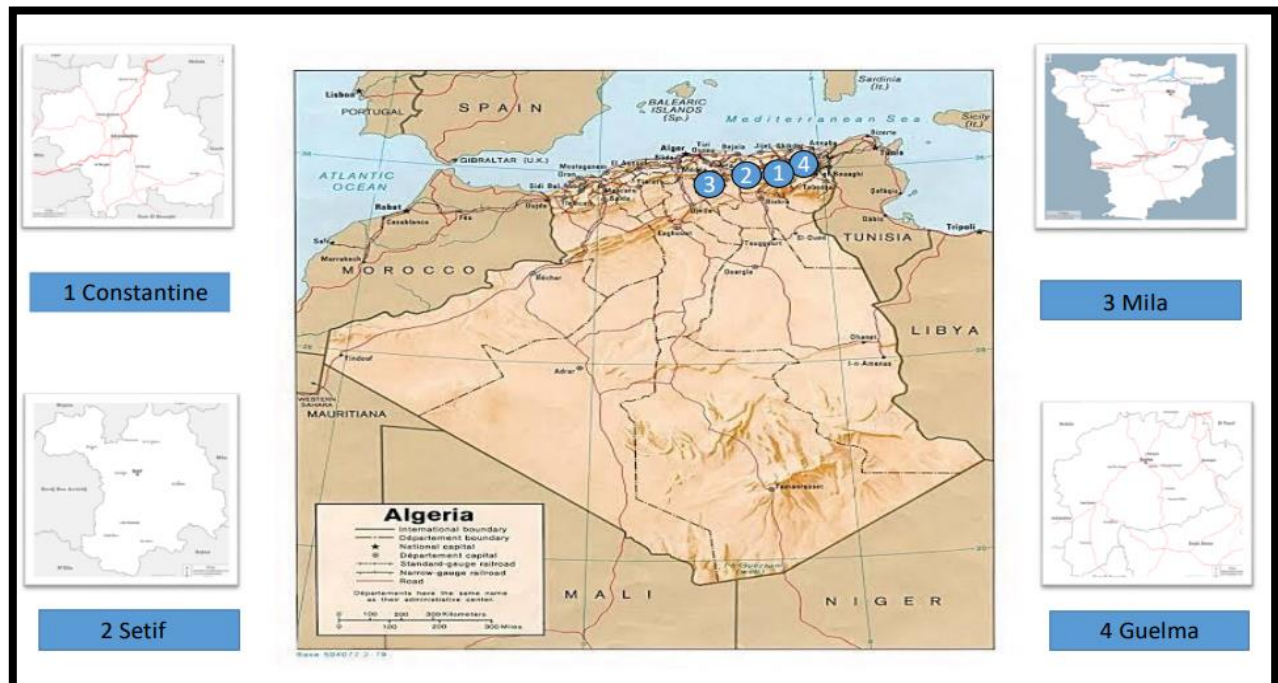
### 36 II.2.1. Situation géographique des stations climatiques utilisées

37 La présente étude est basée sur les données collectées au niveau de quatre stations: Constantine,  
 38 Guelma, Mila et Setif. Les coordonnées des stations sont reportées dans le **Tableau II.1**. La situation  
 39 géographique des quatre stations est représentée sur la **Figure II.1**.

40 **Tableau II.1. Présentation des sites utilisés durant la modélisation de L'évaporation**

Stations	Longitude (°)	Latitude (°)	Altitude (m)	Périodes	Durée (ans)	Jours
Constantine	6° 52' 29.999"	36° 22' 28.56"	0730	2004-2013	10	3650
Guelma	7° 30' 00.000"	36° 22' 28.88"	0314	2004-2013	10	3650
Mila	6° 15' 00.000"	36° 22' 28.56"	1003	2004-2013	10	3650
Setif	5° 18' 45.000"	36° 22' 28.56"	1094	2004-2013	10	3650

41



42

43

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

## 44 II.2.2. Statistiques descriptives


45 Pour chaque station, nous avons calculée les paramètres statiques reportés dans le Tableau II.2,  
 46 sur lequel nous avons: la valeur maximale ( $X_{max}$ ), la valeur moyenne ( $X_{mean}$ ), la valeur minimale  
 47 ( $X_{min}$ ), l'écart type ( $S_x$ ), le coefficient de corrélation linéaire ( $R$ ), et le coefficient de variation ( $C_v$ ).

48

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

Modélisation de l'humidité relative								
Stations	Variables	Unité	$X_{mean}$	$X_{max}$	$X_{min}$	$S_x$	$C_v$	$R$
Constantine	$T_{max}$	°C	22.337	44.969	0.071	9.960	2.305	0.929
	$T_{min}$	°C	9.387	28.207	-6.125	6.653	1.411	0.794
	$U_2$	m/s	1.839	6.757	0.512	0.581	3.164	0.201
	HR	%	66.754	100.00	8.581	21.274	3.138	-0.878
	RS	MJ/m <sup>2</sup>	17.545	32.191	0.320	8.876	1.977	0.875
	EP	mm	5.008	17.265	0.467	3.410	1.469	1.000
Guelma	$T_{max}$	°C	22.559	48.762	1.419	9.721	2.321	0.937
	$T_{min}$	°C	9.852	27.772	-4.804	6.228	0.632	0.753
	$U_2$	m/s	2.626	8.916	0.795	0.937	0.357	-0.882
	HR	%	67.209	99.635	8.767	19.794	0.295	-0.282
	RS	MJ/m <sup>2</sup>	17.052	32.190	0.414	9.053	0.531	0.886
	EP	mm	5.191	21.238	0.422	3.550	0.684	1.000
Mila	$T_{max}$	°C	22.267	45.709	-0.519	9.757	2.282	0.928
	$T_{min}$	°C	9.341	28.052	-5.572	6.727	1.388	0.789
	$U_2$	m/s	1.746	6.388	0.523	0.546	3.195	0.241
	HR	%	66.340	99.805	8.653	21.539	3.079	-0.876
	RS	MJ/m <sup>2</sup>	17.621	32.270	0.317	0.317	55.542	0.878
	EP	mm	5.013	16.632	0.491	3.375	1.485	1.000
Sétif	$T_{max}$	°C	20.265	42.559	-2.737	9.845	2.058	0.932
	$T_{min}$	°C	8.238	26.185	-7.179	6.637	1.241	0.774
	$U_2$	m/s	1.749	6.255	0.559	0.586	2.982	0.101
	HR	%	68.773	100.647	9.743	22.609	3.041	-0.886
	RS	MJ/m <sup>2</sup>	17.050	32.360	0.390	9.084	1.876	0.878
	EP	mm	4.652	16.152	0.414	3.277	1.419	1.000

50



51  
52 Figure II.2. Matrice de corrélation des différentes variables pour les quatre stations climatiques.

### 53 II.3. Évaluation des performances des modèles

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

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

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

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

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

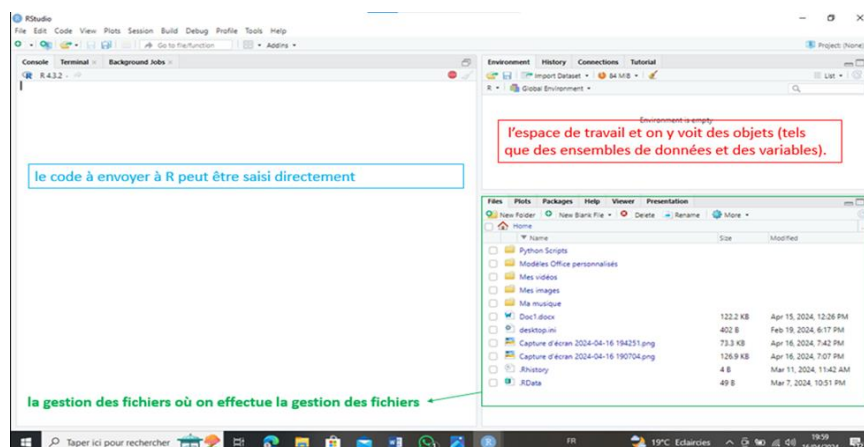
58  $\overline{X}_{obs}$  et  $\overline{X}_{cal}$  : les valeurs moyennes observées et calculées, respectivement;  $X_{obs,i}$  et  $X_{cal,i}$  : Les  
 59 valeurs observées et calculées, respectivement;  $N$  : Le nombre total des observations (nombre  
 60 d'individus).

61  
 62 Pour calculer les quatre indices, nous avons utilisées la fonction HydroGOF développé sous  
 63 le logiciel RStudio. HydroGOF Fait probablement référence au package Hydrological Goodness-  
 64 of-Fit (HydroGOF) dans R, qui est utilisé pour évaluer les performances des modèles  
 65 hydrologiques. Ce logiciel fournit diverses mesures statistiques permettant d'évaluer dans quelle  
 66 mesure un modèle hydrologique s'adapte aux données observées. Le package HydroGOF  
 67 comprend généralement des fonctions de calcul de métriques telles que: Efficacité de Nash-  
 68 Sutcliffe (NSE), efficacité de Kling-Gupta (KGE), biais de pourcentage (PBIAS), erreur  
 69 quadratique moyenne (RMSE), erreur relative absolue (MAE), coefficient de corrélation (R), etc.  
 70 Pour sélectionner le package HydroGOF dans RStudio, on doit d'abord l'installer. Vous pouvez  
 71 l'installer à partir de CRAN à l'aide de la commande suivante:

```
R                                                                    Copy code
install.packages("hydroGOF")
```

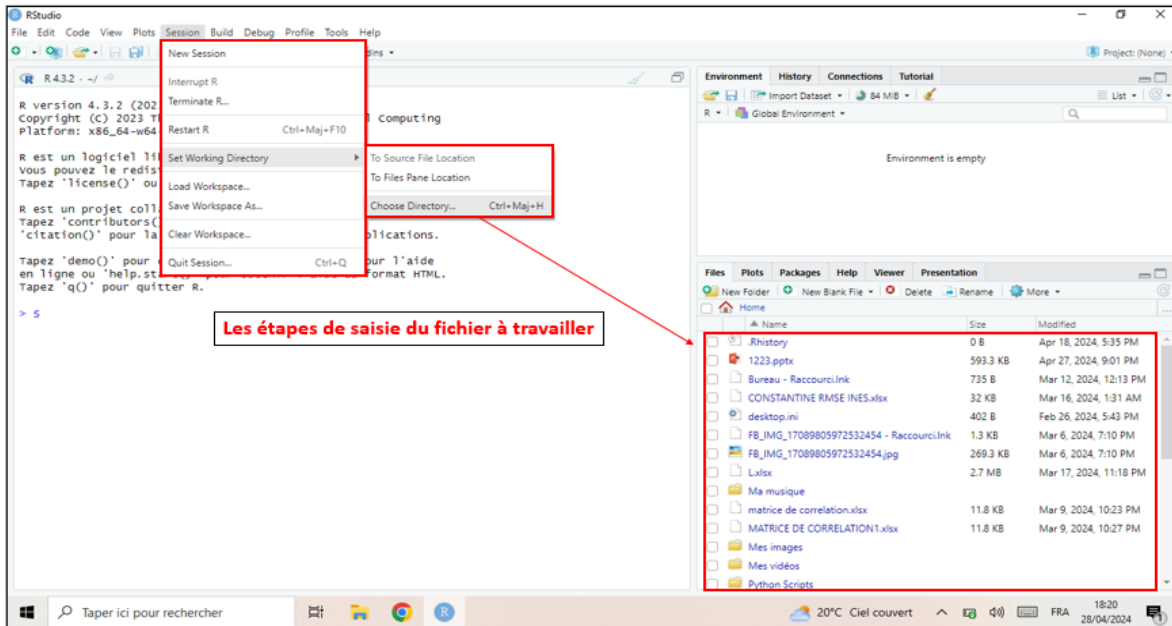
72  
 73 Figure II.3. Installation de la fonction HydroGOF.

74 Une fois installée, vous pouvez charger le paquetage dans votre session RStudio à l'aide de  
 75 la fonction Library. Ainsi, toutes les fonctions du package HydroGOF seront disponibles pour une  
 76 utilisation dans votre environnement RStudio. Vous pouvez maintenant commencer à utiliser des  
 77 fonctions telles que (NSE), (RMSE), (MAE), (R) etc., qui sont couramment utilisées pour évaluer  
 78 les performances des modèles hydrologiques. L'interface de RStudio se présente comme suit.



79  
 80 Figure II.4. Présentation de la plateforme RStudio.

81 Afin de déterminer les modèles sur RStudio, les étapes sont: Ouvrir RStudio, Appuyez sur Session,  
 82 puis sur Set Working Directory, puis sur Choose Directory (Figure II.5).



83

Figure II.5. Les étapes de calcul sous RStudio.

84

85

86 Une fois terminer, on affiche les résultats de calculs et on enregistre le fichier. Pour le  
 87 développement des modèles, nous avons comparés entre plusieurs combinaisons des variables d'entrée  
 88 et en totale 12 modèles ont été développés (Tableau II.3).

89 Tableau II.3. Structure des modèles utilisés

MLR	MLPNN	GRNN	Input combination	Output
MLR1	MLPNN1	GRNN1	$T_{max}, T_{min}, U_2, H\%, SR$	EP
MLR2	MLPNN2	GRNN2	$T_{min}, U_2, H\%, SR$	EP
MLR3	MLPNN3	GRNN3	$T_{max}, T_{min}, U_2, H\%$	EP
MLR4	MLPNN4	GRNN4	$T_{max}, T_{min}, U_2, SR$	EP
MLR5	MLPNN5	GRNN5	$T_{max}, T_{min}, U_2,$	EP
MLR6	MLPNN6	GRNN6	$T_{max}, T_{min}, H\%$	EP
MLR7	MLPNN7	GRNN7	$T_{max}, T_{min}, SR$	EP
MLR8	MLPNN8	GRNN8	$U_2, H\%, SR$	EP
MLR9	MLPNN9	GRNN9	$T_{max}, T_{min}$	EP
MLR10	MLPNN10	GRNN10	$H\%, SR$	EP
MLR11	MLPNN11	GRNN11	$T_{max}, U_2$	EP
MLR12	MLPNN12	GRNN12	$T_{max}, H\%$	EP

90

91

## 92 **II.4. Conclusion**

93           Pour la modélisation de l'évaporation à partir des plan d'eau, nous avons utilisé les données  
94 collectées au niveau de quatre stations. Pour chaque station nous avons utilisé plusieurs variables  
95 climatiques et en total, nous avons comparés entre douze modèles. Pour la comparaison entre les  
96 modèles, nous avons calculés quatre indices de performances avec le logiciel RStudios et la  
97 fonction HydroGOF.

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29

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

---

### 1 **III.1. Introduction**

2 Le domaine de l'intelligence artificielle (IA) connaît de nos jours une évolution  
3 majeure. Il est en train de bouleverser plusieurs domaines, tel que la santé, le transport, le  
4 multimédia, l'industrie automobile avec les voitures autonomes, l'industrie aérospatiale,  
5 l'industrie biomécanique, les secteurs de finance, d'économie et de marketing, l'éducation.  
6 Comme son nom l'indique l'intelligence artificielle est une intelligence acquise par des  
7 machines dans le but de reproduire les comportements des humains. L'apprentissage  
8 automatique (appelé Machine Learning en anglais), est un sous-ensemble de l'Intelligence  
9 Artificielle, son principal objectif est d'offrir des techniques pour développer cette  
10 intelligence. L'apprentissage automatique est une science qui consiste à concevoir et  
11 développer des algorithmes permettant à donner à l'ordinateur ou à une machine la capacité  
12 d'apprendre à partir des données d'exécuter des taches complexe sans avoir été explicitement  
13 programmé. Ces algorithmes ont la particularité, au fil d'un processus appelé 'entraînement  
14 ou apprentissage d'ajuster leur modèle et leurs comportements en fonctions des résultats  
15 observé(Bourougaa et Seridi., 2020).

16

### 17 **III.2. Concepts de base de l'intelligence artificielle**

18 L'intelligence Artificielle se définirait comme étant « l'ensemble des théories et de  
19 techniques mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence  
20 ». Ce serait, des ordinateurs ou des machines dotées de programmes capables de  
21 performances similaires à l'intelligence humaine, ou même, amplifiées par la technologie. Ces  
22 machines sont en mesure de: raisonner, traiter de grandes quantités de données, discerner des  
23 modèles indétectables par l'œil d'un humain, comprendre et analyser ces modèles, interagir  
24 avec l'homme, apprendre progressivement, et améliorer continuellement ses performances.  
25 Les utilisations de l'IA aujourd'hui peuvent être regroupées en 3 catégories principales:  
26 l'identification, la prédiction et la génération de données. Parmi ces applications de l'IA, on  
27 retrouve notamment les notions de machine learning, ainsi que celles de Deep learning. L'IA  
28 s'applique aujourd'hui dans plusieurs domaines.

29

30

31

32

### 1 III.3. Historique de l'intelligence artificielle

2 L'histoire de l'intelligence artificielle débute en 1943, avec la publication de l'article «  
 3 *A Logical Calculus of Ideas Immanent in Nervous Activity* » par Warren McCulloch et  
 4 Walter Pitts. Dans ce document, les scientifiques présentent le premier modèle mathématique  
 5 pour la création d'un réseau de neurones. Par la suite, en 1950, Snarc, le premier ordinateur à  
 6 réseau de neurones, sera créé par deux étudiants de Harvard : Marvin Minsky et Dean  
 7 Edmonds. La même année, Alan Turing publie le Turing Test qui sert encore pour évaluer les  
 8 IA. De ce test découlent les fondations de l'intelligence artificielle, de sa vision et de ses  
 9 objectifs : répliquer ou simuler l'intelligence humaine dans les machines. Mais ce n'est qu'en  
 10 1956, que le terme d'intelligence artificielle sera prononcé pour la première fois, durant la  
 11 conférence « Dartmouth Summer Research Project on Artificial Intelligence. » de John  
 12 McCarthy. Lors de cet événement, les chercheurs présentent les objectifs et la vision de l'IA.  
 13 Beaucoup considèrent cette conférence comme la véritable naissance de l'intelligence  
 14 artificielle telle qu'elle est connue.Plusieurs années s'écoulent et les travaux sur l'intelligence  
 15 artificielle continuent. En 1959, Arthur Samuel invente le terme de Machine Learning en  
 16 travaillant chez IBM. En 1989, le français Yann LeCun met au point le premier réseau de  
 17 neurones capable de reconnaître des chiffres écrits à la main, cette invention sera à l'origine  
 18 du développement du Deep learning.Et c'est dix ans plus tard, en 1997, qu'un événement  
 19 majeur marque l'histoire de l'IA. Le système Deep Blue d'IBM triomphe du champion du  
 20 monde d'échecs Gary Kasparov. Pour la première fois, la machine a vaincu l'homme

21

### 22 III.4. Concepts de base de machine learning

23 L'apprentissage automatique ("*machine learning*" en anglais) correspond à  
 24 l'élaboration et à l'utilisation de systèmes informatiques capables d'apprendre à base  
 25 d'algorithmes mathématiques et de modèles statistiques sur des jeux de données, sans règles  
 26 spécifiques. L'apprentissage automatique se décompose en deux phases: la première est la  
 27 phase d'apprentissage de la machine et la seconde est l'utilisation du modèle créé par la  
 28 machine pour exécuter une tâche.La phase d'apprentissage consiste à fournir des données au  
 29 système informatique pour qu'il les analyse et en tire un modèle. Le modèle doit lui permettre  
 30 d'exécuter la tâche souhaitée sans qu'un humain n'ait eu besoin de la coder pour la  
 31 machine.La seconde phase consiste à utiliser le modèle conçu par la machine pour exécuter  
 32 une tâche bien définie. Les exemples les plus populaires sont la traduction de document et la

1 reconnaissance d'un élément spécifique dans une photographie. Il existe différents types  
2 d'apprentissages automatiques:

- 3 • L'apprentissage supervisé, qui consiste à encadrer l'apprentissage de la machine par le  
4 biais d'un corpus d'apprentissage annoté;
- 5 • L'apprentissage non-supervisé, qui consiste à fournir un corpus d'apprentissage non  
6 annoté à la machine et à les traiter une seule fois
- 7 • L'apprentissage profond ("*Deep learning*" en anglais), qui consiste à fournir un corpus  
8 d'apprentissage non annoté à la machine qui l'analysera à plusieurs reprises.

9


### 10 **III.5. Les réseaux de neurones artificielles**

11 Les réseaux de neurones artificiels (RNA) consistent en un ensemble d'outils et de  
12 méthodes de calcul. Ils sont caractérisés par leur capacité d'apprentissage, de généralisation,  
13 de mémorisation, de classification, d'adaptation et de décision. Ils sont appliqués dans divers  
14 domaines, tel que la reconnaissance de formes, le contrôle et la robotique. En maintenance  
15 industrielle, les réseaux de neurones sont utilisés pour résoudre les problèmes du diagnostic  
16 par la classification automatique des signaux et des formes correspondantes aux différents  
17 états de fonctionnements normaux et anormaux des machines (Ouguissi et al., 2019). Les  
18 réseaux de neurones artificiels (ANN) sont des modèles mathématiques non linéaires de type  
19 « boîte noire », ils constituent une nouvelle approche de traitement de l'information.

20

#### 21 **III.5.1. Le neurone biologique**

22 Un neurone biologique est composé de quatre éléments principaux : le corps cellulaire, les  
23 dendrites, l'axone, et les synapses (Bourougaa et Seridi, 2020).



24

25

**Figure III.1.** Schéma d'un Neurone biologique (Bourougaa et Seridi, 2020)

26


27

28

### 1 III.5.2. Le Neurone Formel.

2 Est un processeur très simple imitant grossièrement la structure et le fonctionnement  
 3 d'un neurone biologique, la première version du neural formel est celle de McCulloch et Pitts  
 4 qui est largement utilisée .(Gérard,1998)Un neurone formel est un opérateur effectuant la  
 5 somme pondérée de ses entrées externes puis elle s'active suivant la valeur de cette  
 6 sommation pondérée puis modulée par une fonction d'activation(Bernard, 1996).

7



8  
9


**Figure III.2.** Schéma d'un Neurone formel(Zitouni et Hamdi, 2021).

10

### 11 III.5.3. Le Neurone Artificiel

12 L'élément de base d'un réseau de neurones est, bien entendu, le neurone artificiel. Un  
 13 neurone qui contient deux éléments principaux: un ensemble de poids associés aux  
 14 connexions du neurone, et une fonction d'activation.Les valeurs d'entrée sont multipliées par  
 15 leur poids correspondant et additionnées pour obtenir la somme S.Cette somme devient  
 16 l'argument de la fonction d'activation. Le choix de la fonction d'activation dépend de  
 17 l'application. Une entrée spéciale est pratiquement toujours introduite pour chaque neurone.  
 18 Cette entrée, normalement appelée biais (bias en anglais), sert pour déplacer le pas de la  
 19 fonction d'activation sur l'axe S. La valeur de cette entrée est toujours 1 et le déplacement  
 20 dépend alors seulement du poids de cetentrée spéciale(Bennecib,2009).

21  
22  
23  
24



**FigureIII.3.**Schéma d'un Neurone artificiel(Zitouni et Hamdi, 2021).

### 1 **III.5.4. Le perceptron**

2 Inventé en 1957 par Frank Rosenblatt au laboratoire aéronautique de Cornell, un  
3 perceptron se base sur les tout premiers concepts des neurones artificiels. Un perceptron  
4 désigne un réseau de neurones artificiels qui permet à l'ordinateur d'apprendre grâce à de  
5 nouvelles données. Considéré comme le réseau de neurones artificiels le plus simple, le  
6 perceptron est un outil qui réalise des calculs dans le but de détecter certains modèles de  
7 tendances ou des caractéristiques dans les données d'entrée. C'est en effet grâce à cet  
8 algorithme que les neurones artificiels apprennent et traitent les éléments qui composent un  
9 ensemble de données. Cet algorithme joue un rôle important dans les projets de Machine  
10 Learning ([Alizé, 2023](#)).

### 11 **III.4.6. Réseaux de Neurones**

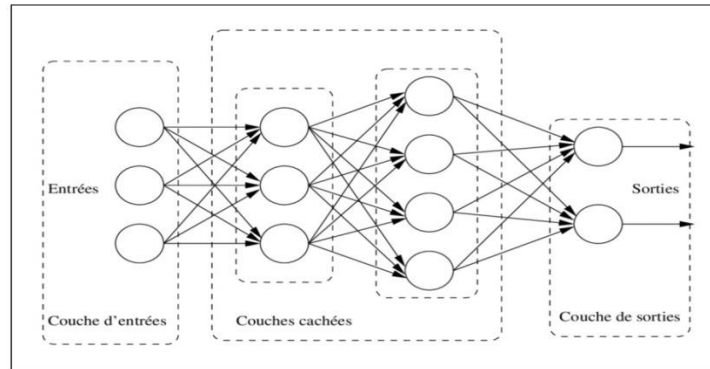
12 Un réseau de neurones se compose de neurones qui sont interconnectés de façon à ce  
13 que la sortie d'un neurone puisse être l'entrée d'un ou plusieurs autres neurones. Ensuite il y a  
14 des entrées de l'extérieur et des sorties vers l'extérieur. On donne huit composants principaux  
15 d'un réseau de neurones: un ensemble de neurones, un état d'activation pour chaque  
16 neurone, une fonction de sortie pour chaque neurone, un modèle de connectivité entre les  
17 neurones, une règle de propagation pour propager les valeurs d'entrée à travers le réseau vers  
18 les sorties, une règle d'activation pour combiner les entrées d'un neurone, une règle  
19 d'apprentissage, et un environnement d'opération (le système d'exploitation, par exemple). Le  
20 comportement d'un réseau et les possibilités d'application dépendent complètement de ces  
21 huit facteurs et le changement d'un seul d'entre eux peut changer le comportement du réseau  
22 complètement ([Bennecib, 2009](#)).

23

### 24 **III.4.7. Le Perceptron Multicouche (MLPNN)**

25 Un Perceptron multicouches (MLPNN pour Multilayer Perceptron neural network)  
26 peut être vu comme un ensemble d'unités de traitement, appelés nœuds ou neurones, reliées  
27 entre elles par des connections pondérées. Les poids de ces connections étant les paramètres  
28 du modèle. Ces neurones et ces connections sont organisés en couches : (i) La première  
29 couche est appelée couche d'entrée, (ii) la dernière est appelée couche de sortie et (iii) la ou  
30 les couches du milieu sont appelées couches cachées. Les neurones de ces couches cachées,  
31 ainsi que ceux de la couche de sortie appliquent deux traitements: (i) une combinaison linéaire  
32 de leurs entrées (dont les poids sont des paramètres du réseau), suivie par (ii) une fonction


1 non-linéaire appelée fonction d'activation. Les deux fonctions les plus courantes sont la  
 2 tangente hyperbolique et la fonction sigmoïde(Baccouche, 2013).



3  
 4 **Figure III.4.** Le perceptron multicouche (MLPNN)  
 5

### 6 **III.4.8. Le Réseau de Neurone de Régression Généralisée (GRNN)**

7 Un réseau neuronal de régression généralisée (GRNN) est un réseau basé sur les  
 8 probabilités. Les GRNN effectuent une régression où la variable cible est continue. La Figure  
 9 III.5 montre un graphique GRNN pour prédire l'irradiation solaire. Le réseau se compose des  
 10 couches d'entrée, de masque et de sortie. La couche d'entrée contient un neurone pour chaque  
 11 variable de prédiction(Oguissiet Almaoui,2019).



12  
 13 **Figure III.4.** Le réseau de neurones de type GRNN  
 14

### 15 **III.5. La Régression linéaire multiple (MLR)**

16 La régression linéaire multiple (MLR) est une technique statistique qui consiste à utiliser deux  
 17 variables indépendantes ou plus pour prédire ou expliquer le résultat d'une seule variable  
 18 dépendante en modélisant la relation linéaire entre elles. La formule de la régression linéaire  
 19 multiple est la suivante:


$$20 \quad Y = a + b_1X_1 + b_2X_2 + b_3X_3 + b_tX_t + u$$

1 Où  $Y$  = la variable que vous essayez de prédire (variable dépendante),  $X$  = les variables que  
 2 vous utilisez pour prédire (variables indépendantes),  $a$  = l'interception,  $b$  = les coefficients de  
 3 la régression linéaire, et  $u$  = le résidu de régression

4

### 5 III.5. Apprentissage des réseaux de neurones

6 L'apprentissage est une phase de développement d'un réseau de neurones durant  
 7 laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré.  
 8 On distingue plusieurs types d'apprentissage, les plus fréquemment rencontrés dans la  
 9 littérature sont l'apprentissage supervisé et l'apprentissage non supervisé. L'apprentissage  
 10 supervisé ne peut être utilisé que lorsque les combinaisons d'entrées-sorties désirées sont  
 11 connues. L'ajustement des poids est fait directement à partir de l'erreur, soit la différen  
 12 ce entre la sortie obtenue par le RNA et la sortie désirée.



13

14


**Figure III.5.** Apprentissage supervisé (Zitouni et Hamdi ,2021)

15

16 Pour l'apprentissage non supervisé, il n'y a pas de connaissances a priori des sorties  
 17 désirées pour des entrées données. En fait, c'est de l'apprentissage par exploration où  
 18 l'algorithme d'apprentissage ajuste les poids des liens entre neurones de façon à maximiser la  
 19 qualité de classification des entrées (Zitouni et Hamdi, 2021).

20

21



22

23

24

25

**Figure III.6.** Apprentissage non supervisé (Zitouni et Hamdi ,2021)

### III.6.Répartition des données & apprentissage et validation

Toute modélisation nécessite des phases de paramétrisation et de vérification du modèle qui, en plus des variables d'entrée, font appel à des chroniques de mesures de certaines variables de sortie. On distingue:

- Le Calage ou apprentissage (Training): L'ajustement des paramètres est généralement assuré par la stratégie d'apprentissage (70% des données).
- La validation: l'étape de de vérification de l'ajustement du modèle (30% des données).

### III.7.Développement des modèles sous la plateforme ANACONDA

#### III.7.1. Présentation de la plateforme ANACONDA

Anaconda est un outil en distribution libre et open source destiné à la programmation Python et R. Il est véritablement utilisé en science de données, machine learning et l'intelligence artificielle car il contient plusieurs packages nécessaires dans ce domaine notamment Python, Numpy, Panda, Jupyter, etc. Et comme le langage Python, il est multiplateforme.

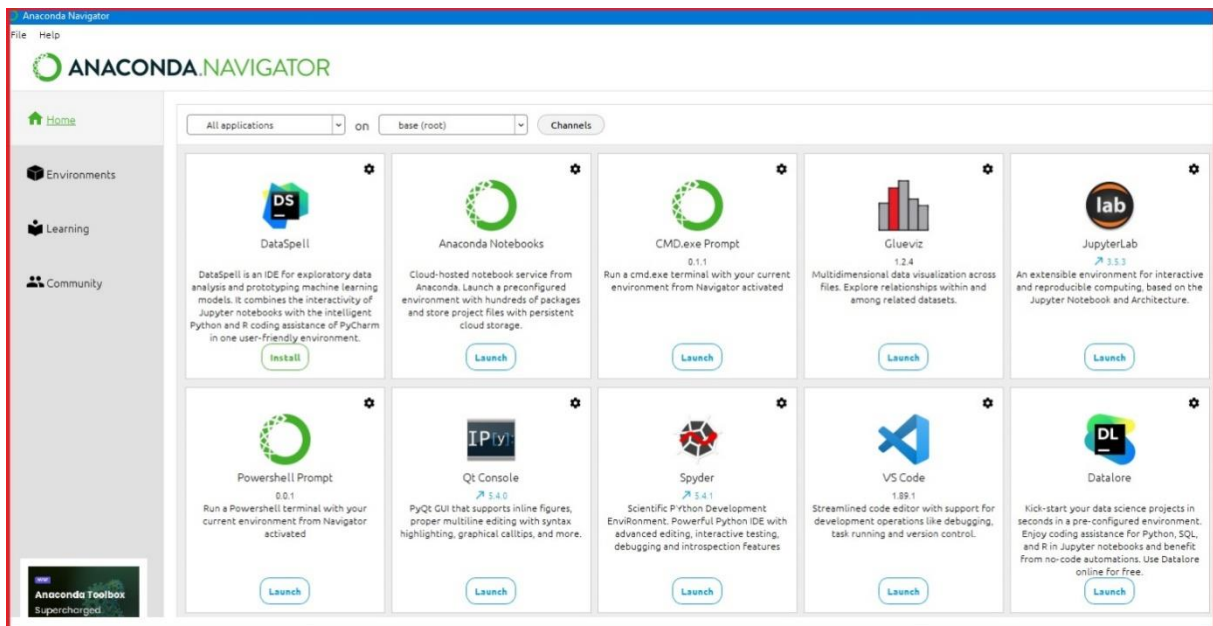


Figure III.7. Présentation de la plateforme Anaconda

## 1 III.7.2. Présentation de l'environnement de développement Spyder

2 Spyder est un environnement scientifique puissant écrit en Python, pour Python, et  
 3 conçu par et pour des scientifiques, ingénieurs et analystes de données. Il offre une  
 4 combinaison unique des fonctionnalités avancées d'édition, d'analyse, de débogage et de  
 5 profilage d'un outil de développement complet avec l'exploration de données, l'exécution  
 6 interactive, l'inspection approfondie et les belles capacités de visualisation d'un logiciel  
 7 scientifique (Aib, 2019).

```

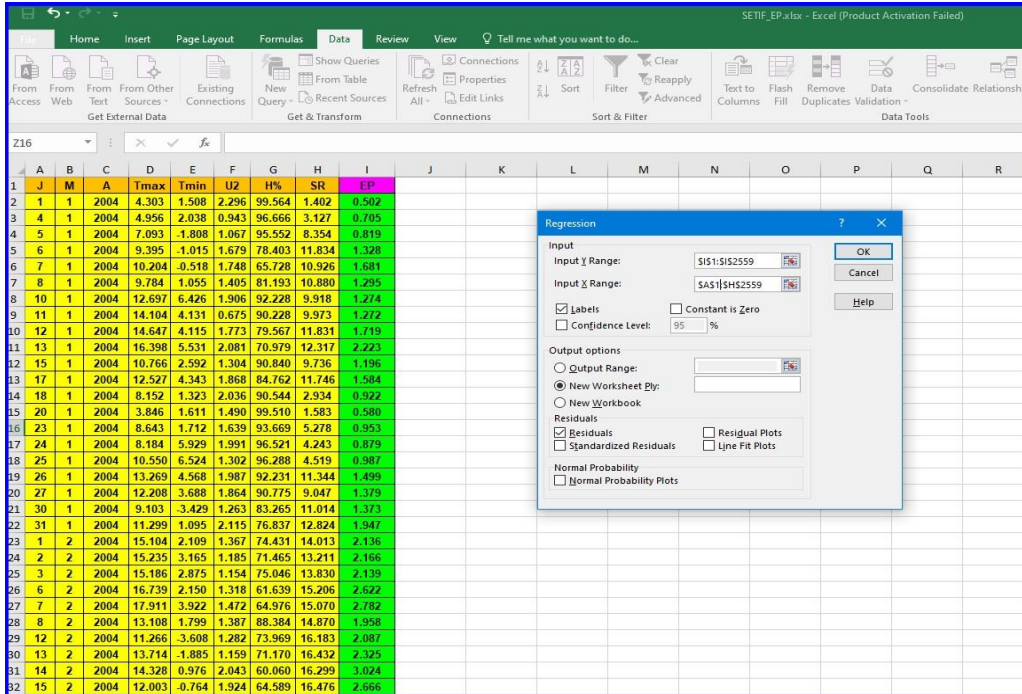
1 import pandas
2 from sklearn.neural_network import MLPRegressor
3
4 #The 'activation' {'logistic', 'identity', 'tanh', 'relu'}.
5
6
7 X1=pandas.read_excel('CONSTANTINE_MLPNN.xlsx', sheet_name='TRAINING', usecols='D, E
8 Y1=pandas.read_excel('CONSTANTINE_MLPNN.xlsx', sheet_name='TRAINING', usecols='I')
9 X2=pandas.read_excel('CONSTANTINE_MLPNN.xlsx', sheet_name='VALIDATION', usecols='D, E
10 Y2=pandas.read_excel('CONSTANTINE_MLPNN.xlsx', sheet_name='VALIDATION', usecols='I')
11
12 X_Training = X1
13 X_Validation = X2
14 Y_Training = Y1
15 Y_Validation = Y2
16
17 MLPNN = MLPRegressor(hidden_layer_sizes=(100), activation='tanh',
18 solver='adam', alpha=0.0001, batch_size='auto',
19 learning_rate='constant', learning_rate_init=0.001,
20 power_t=0.5, max_iter=200, shuffle=True,
21 random_state=None, tol=0.0001, verbose=False,
22 warm_start=False, momentum=0.9,
23 nesterovs_momentum=True, early_stopping=False,
24 validation_fraction=0.1,
25 beta_1=0.9, beta_2=0.999,
26 epsilon=1e-08, n_iter_no_change=10, max_fun=15000)
27
28 MLPNN.fit(X_Training, Y_Training)
29
30 y1_pred = MLPNN.predict(X_Training)
31 y2_pred = MLPNN.predict(X_Validation)
  
```

8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20

Figure III.8. Présentation de l'environnement de développement Spyder

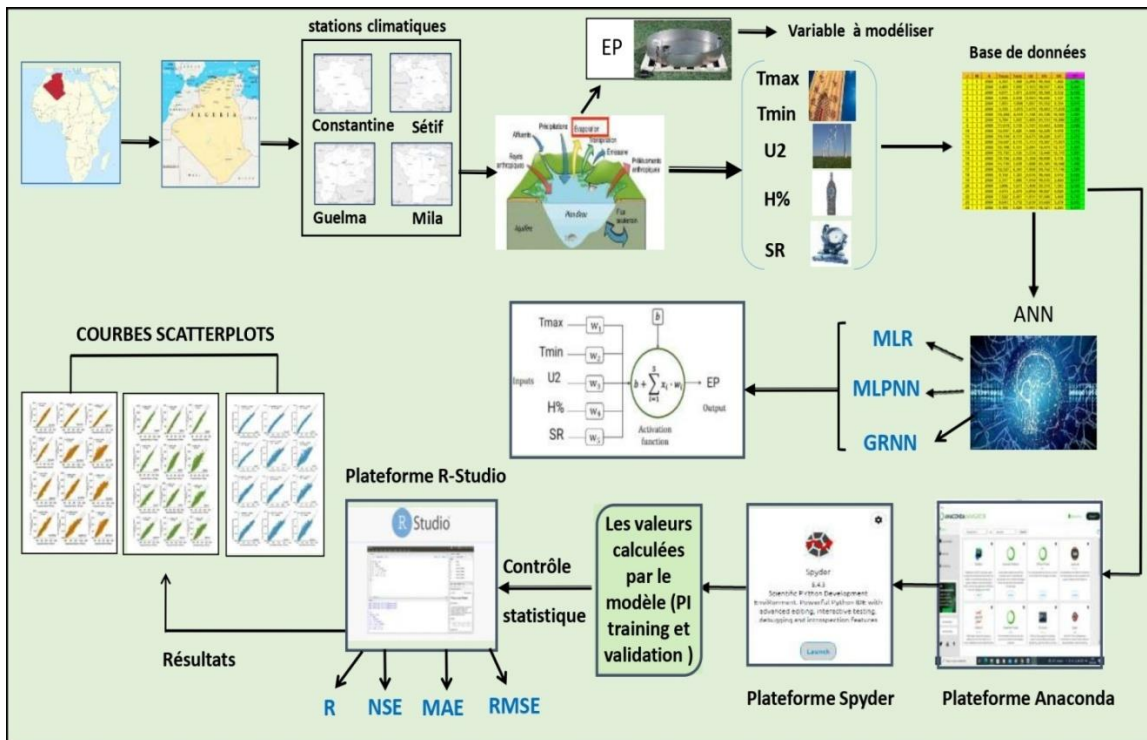
1 **III.7.3. Développement des modèles MLR sous Excel**

2 Pour développer les modèles à base de regression linéaire multiple (MLR) nous avons  
 3 utilisé le tableur Excel. Avec Excel, l'utilisation de la fonction regression est simple (Figure  
 4 III.9). Il faut indiquer la variable à modéliser Y et les variables à utiliser comme inputs.



5  
6

**Figure III.9.**Développement des modèles MLR sous Excel



7  
8  
9

**Figure III.10.**Organigramme général des différentes étapes de modélisation de l'évaporation.

## 1 **III.8. Conclusion**

2            Dans le présent chapitre nous avons exposés les notions de base de la modélisation par  
3 les techniques à base d'intelligence artificiels, en particulier par les réseaux de neurones  
4 artificiels. Nous avons utilisé deux modèles: les MLPNN et les GRNN, avec un troisième  
5 modèle à base de régression linéaire multiple (MLR). Nous avons aussi présenté brièvement  
6 la plate form Anaconda et Spyder utilisé pour le développement des modèles avec le langage  
7 Python. Le chapitre suivant sera consacré à la discussion des résultats obtenus au niveau de  
8 chaque station.

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29  
30  
31  
32

---

***Chapitre IV: Résultats et Interprétation***

---

## 33 IV.1. Introduction

34 Nous présentons dans ce chapitre les résultats obtenus par les techniques de réseaux de  
 35 neurones artificielle et la regression linéaire déjà définis au chapitre précédent sous les  
 36 abréviations (MLPNN, GRNN et MLR) pour l'estimation de l'évaporation (EP), au sein des  
 37 quatre stations climatiques objet de la présente étude. Pour l'implémentation des modèles à base  
 38 de l'IA, le langage de programmation **Python** a été utilisé. En utilisant les trois types de modèles,  
 39 nous avons testés plusieurs combinaisons, et au totale douze (12) variantes de modèles; à savoir:  
 40 les modèles à cinq variables d'entrée: un seul modèle, les modèles à quatre variables d'entrée:  
 41 trios modèles; les modèles à trois variables d'entrées: quatre modèles; les modèles à deux  
 42 variables d'entrées: quatre modèles. Pour les douze combinaisons cités, l'évaporation (EP)  
 43 représente la sortie de chacun d'eux. Les résultats sont présentés séparément pour chaque station  
 44 dans **les tableaux IV.1-4**. En plus des résultats numériques, nous présenterons des résultats  
 45 graphiques pour chaque station sous forme de courbes Scatterplots (**Figures IV.1-12**).

46

## 47 IV.2. Modélisation de l'EP à Pas de Temps Journalière & Station de Constantine

48

49 Au niveau de la station de Constantine (**Tableau IV.1, Figures IV.1-3**), d'une façon  
 50 générale, les performances des modèles varient entre bonnes à excellentes. Les modèles MLPNN  
 51 ont donné des valeurs de R et NSE allant de  $\approx 0.990$  à  $\approx 0.920$  (moyenne  $\approx 0.968$ ), et  $\approx 0.990$  à  
 52  $\approx 0.840$  (moyenne  $\approx 0.937$ ), les modèles GRNN ont donné des valeurs de R et NSE allant de  
 53  $\approx 0.990$  à  $\approx 0.920$  (moyenne  $\approx 0.966$ ) et de  $\approx 0.990$  à  $\approx 0.850$  (moyenne  $\approx 0.936$ ), tandis que les  
 54 valeurs obtenues à l'aide des modèles MLR allant de  $\approx 0.980$  à  $\approx 0.910$  (moyenne  $\approx 0.957$ ) et de  
 55  $\approx 0.960$  à  $\approx 0.820$  (moyenne  $\approx 0.911$ ). Le modèle GRNN2 qui utilise la deuxième combinaison avec  
 56 quatre variables climatiques d'entrée ( $T_{\min}$ ,  $U_2$ , H%, SR) est le plus performant au niveau de la  
 57 station de Constantine, avec des indices numériques de l'ordre de ( $R \approx 0.990$ ,  $NSE \approx 0.990$ ,  
 58  $RMSE \approx 0.370$ ,  $MAE \approx 0.260$ ), et avec l'inclusion de la température maximale ( $T_{\max}$ ) (la première  
 59 combinaison), les performances se dégradent, et nous obtenons des diminution des performances  
 60 en termes de R, NSE, RMSE et MAE avec des taux de l'ordre de 4.211%, 10.000%, 65.741% et  
 61 68.293%, respectivement, ce qui nous permet de conclure que l'utilisation de la  $T_{\max}$  comme  
 62 entrée des différents modèles ne permet pas d'améliorer les Performances.

63 **Table IV.1.** Performances des différents modèles: Station de Constantine

Models	Training				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLR1	0.980	0.960	0.660	0.520	0.980	0.960	0.660	0.530
MLR2	0.980	0.950	0.750	0.600	0.980	0.950	0.750	0.600
MLR3	0.980	0.960	0.660	0.530	0.980	0.960	0.660	0.540
MLR4	0.980	0.950	0.730	0.570	0.980	0.950	0.730	0.570
MLR5	0.940	0.890	1.140	0.930	0.950	0.890	1.110	0.920
MLR6	0.900	0.810	1.470	1.190	0.910	0.820	1.460	1.190
MLR7	0.970	0.940	0.810	0.650	0.970	0.940	0.820	0.660
MLR8	0.960	0.910	0.990	0.820	0.960	0.910	1.000	0.840
MLR9	0.980	0.960	1.660	0.520	0.940	0.870	1.210	0.890
MLR10	0.960	0.910	1.010	0.840	0.950	0.910	1.020	0.850
MLR11	0.940	0.880	1.160	0.950	0.940	0.890	1.120	0.930
MLR12	0.930	0.870	1.210	0.980	0.940	0.880	1.160	0.950
MLPNN1	0.990	0.980	0.430	0.310	0.990	0.980	0.450	0.330
MLPNN2	0.990	0.980	0.430	0.330	0.990	0.980	0.430	0.330
MLPNN3	0.990	0.990	0.410	0.300	0.990	0.990	0.420	0.310
MLPNN4	0.990	0.980	0.490	0.360	0.990	0.980	0.500	0.360
MLPNN5	0.950	0.900	1.060	0.810	0.950	0.910	1.040	0.810
MLPNN6	0.920	0.840	1.380	0.110	0.920	0.840	1.380	1.100
MLPNN7	0.980	0.970	0.610	0.460	0.980	0.970	0.620	0.460
MLPNN8	0.970	0.950	0.780	0.600	0.980	0.950	0.760	0.580
MLPNN9	0.940	0.880	1.160	0.890	0.950	0.890	1.120	0.860
MLPNN10	0.970	0.940	0.810	0.630	0.970	0.950	0.790	0.620
MLPNN11	0.950	0.910	1.030	0.810	0.960	0.910	1.000	0.790
MLPNN12	0.940	0.880	1.170	0.900	0.940	0.890	1.130	0.880
GRNN1	0.950	0.900	0.090	0.830	0.950	0.900	1.080	0.820
GRNN2	1.000	0.990	0.290	0.220	0.990	0.990	0.370	0.260
GRNN3	1.000	0.990	0.290	0.210	0.990	0.990	0.400	0.270
GRNN4	1.000	0.990	0.290	0.220	0.990	0.990	0.400	0.280
GRNN5	0.970	0.930	0.890	0.670	0.960	0.920	0.940	0.720
GRNN6	0.930	0.860	1.280	1.010	0.920	0.850	1.340	1.050
GRNN7	0.990	0.980	0.490	0.370	0.980	0.970	0.620	0.440
GRNN8	0.980	0.960	0.720	0.550	0.980	0.950	0.740	0.570
GRNN9	0.950	0.900	1.100	0.830	0.950	0.900	1.080	0.820
GRNN10	0.970	0.950	0.770	0.590	0.970	0.950	0.770	0.590
GRNN11	0.960	0.920	0.970	0.750	0.960	0.920	0.970	0.760
GRNN12	0.950	0.900	1.090	0.830	0.950	0.900	1.080	0.820

64

65 Le modèle le moins performant au niveau de la station est le modèle MLR6, avec des  
66 indices numériques de l'ordre de ( $R \approx 0.910$ ,  $NSE \approx 0.820$ ,  $RMSE \approx 1.460$ ,  $MAE \approx 1.190$ ), et avec des  
67 taux de réductions par rapport au meilleur modèle de la station (GRNN2) de l'ordre de 8.791%,  
68 20.732%, 74.658% et 78.151% en termes de R, NSE, RMSE et MAE, respectivement. D'une

69 façon générale, les modèles à cinq et quatre variables climatiques d'entrée (la première à la  
70 quatrième combinaison) assurent des meilleures performances, par contre, tous les modèles basés  
71 sur la sixième combinaison ( $T_{\max}$ ,  $T_{\min}$ , H%) garantit les faibles performances au niveau de la  
72 station. Par les modèles à deux entrées (la dixième à la douzième combinaison), les performances  
73 obtenues pour chaque modèle sont proches les uns des autres, avec une certaine supériorité des  
74 modèles basés sur la dixième combinaison (H%, SR). Les modèles ont été comparés d'une façon  
75 graphique, comme le montrent les figures IV.1, IV.2, et IV.3. Les Scatterplots des valeurs  
76 calculées et mesurées de l'EP durant la phase de validation pour tous les modèles, nous permet de  
77 conclure que les données étaient moins dispersées (forte corrélation) en utilisant les quatre  
78 premières combinaisons, à l'exception de modèle GRNN1. Par contre, la sixième combinaison a  
79 donné les données les plus dispersées (faible corrélation).

80

81

82




Figure IV.1. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles MLR

83  
84  
85  
86  
87

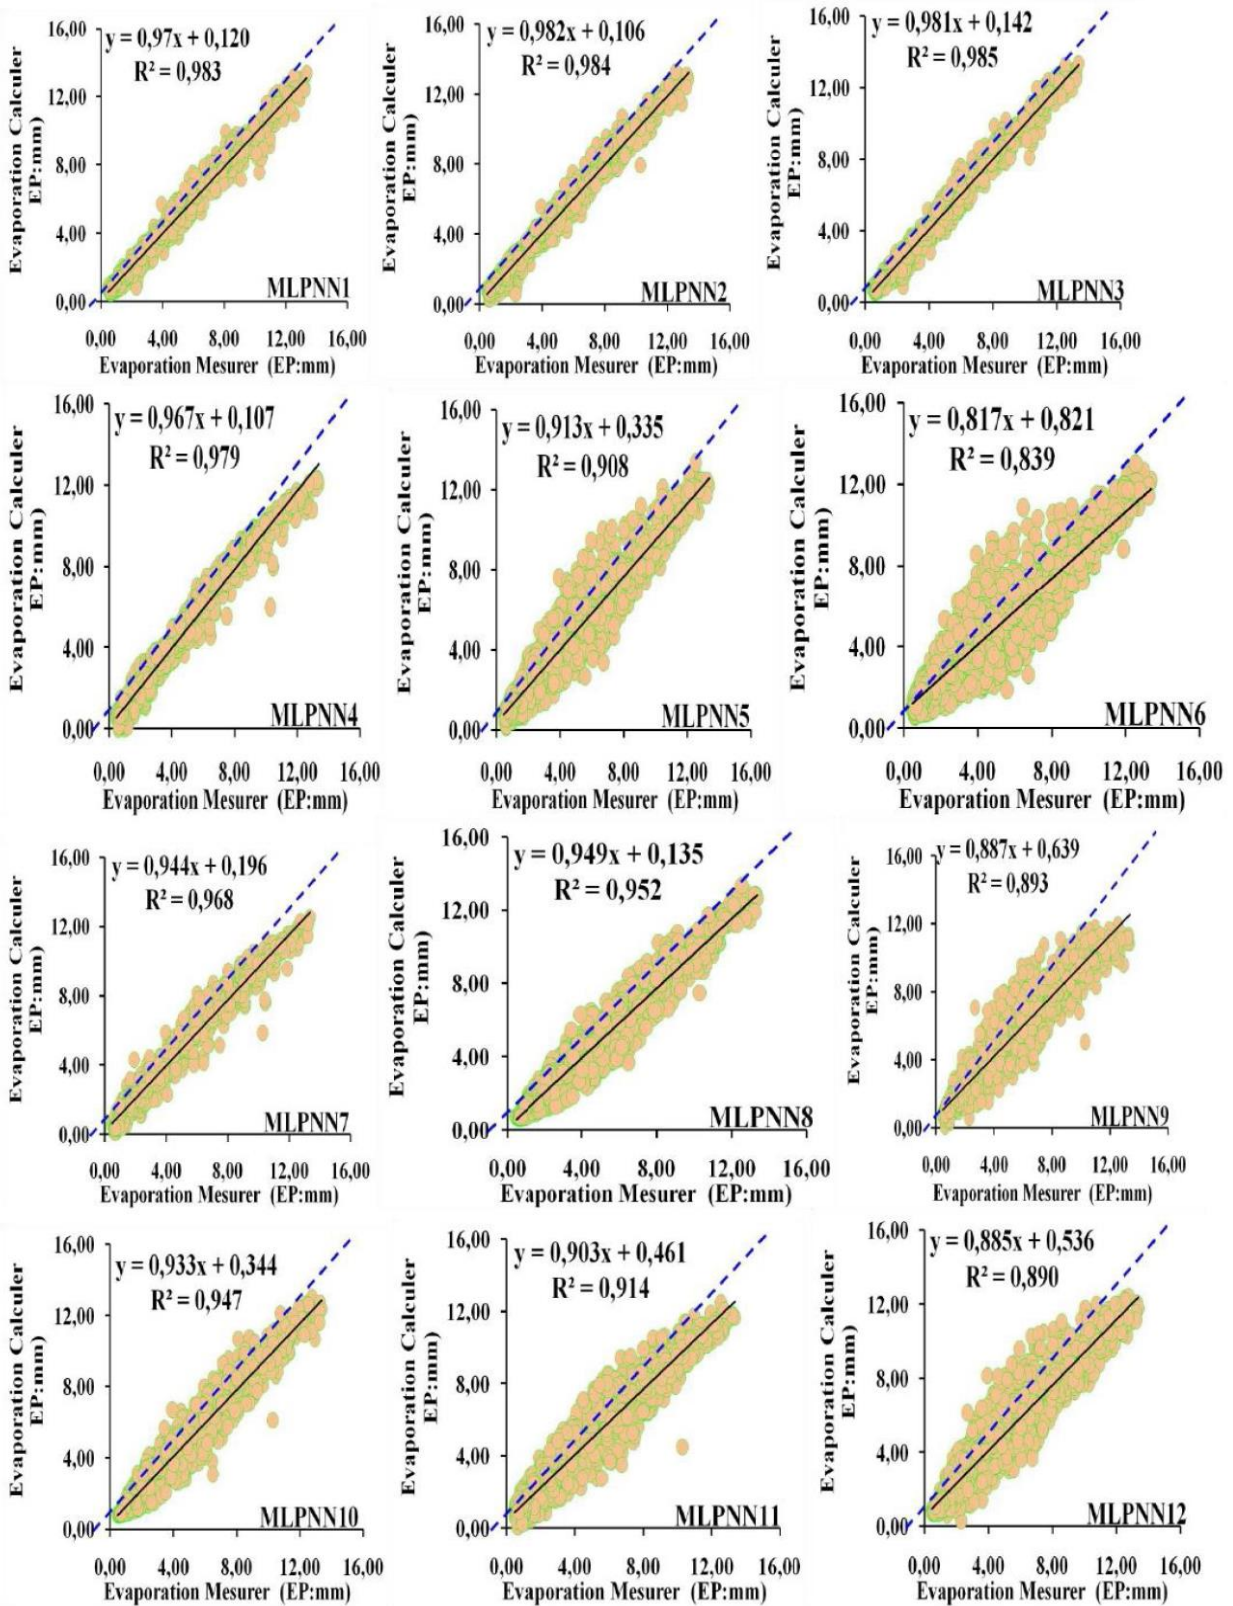



Figure IV.2. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles MLPNN

88  
89  
90



**Figure IV.3.** Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Constantine & modèles GRNN

91  
92  
93

### 94 IV.3. Modélisation de l'EP à Pas de Temps Journalière & Station de Mila

95

96 Pour la station de Mila (Tableau IV.2, Figures IV.4-6), d'une façon générale, les résultats

97 obtenus étaient similaires par rapport à la station de Constantine. Avec tous les modèles, les

98 performances varient entre bonnes à excellentes, avec une supériorité des modèles à base d'IA

99 (MLPNN et GRNN). Le meilleur modèle au niveau de la station est le GRNN1 qui utilise la

100 première combinaison d'entrée ( $T_{\max}$ ,  $T_{\min}$ ,  $U_2$ ,  $H\%$ ,  $SR$ ), avec des indices de l'ordre de

101 ( $R \approx 0.990$ ,  $NSE \approx 0.990$ ,  $RMSE \approx 0.300$ ,  $MAE \approx 0.230$ ). Par contre les faibles performances sont

102 obtenues avec le modèle MLR6 qui utilise trois variables climatiques ( $T_{\max}$ ,  $T_{\min}$ ,  $H\%$ ) avec des

103 indices numériques de l'ordre de ( $R \approx 0.900$ ,  $NSE \approx 0.800$ ,  $RMSE \approx 1.490$ ,  $MAE \approx 1.200$ ).

104 Premièrement, en utilisant cinq variables climatiques, le modèles MLPNN1 ( $R \approx 0.990$ ,

105  $NSE \approx 0.980$ ,  $RMSE \approx 0.470$ ,  $MAE \approx 0.360$ ) a donné des performances légèrement inférieures par

106 rapport au modèle GRNN1 avec des taux de reduction en termes de R, NSE, RMSE et MAE de

107 l'ordre de 0.000%, 1.020%, 36.170% et 36.111%, respectivement. Par contre, le modèle MLR1

108 ( $R \approx 0.950$ ,  $NSE \approx 0.900$ ,  $RMSE \approx 1.070$ ,  $MAE \approx 0.820$ ) a donné des performances inférieures avec

109 des taux de reduction en termes de R, NSE, RMSE et MAE de l'ordre de 4.211%, 10.000%,

110 71.963% et 71.951%, respectivement, par rapport au GRNN1. Pour les modèles basés sur quatre

111 variables d'entrées (la deuxième, la troisième et la quatrième combinaison), les modèles MLR ont

112 donné des performances meilleures que le MLR1, avec des valeurs de R de 0.980 et des valeurs

113 de NSE de (0.960 et 0.950). Par contre, les modèles à base d'IA ont donné des performances

114 similaires à celle de la première combinaison, à l'exception du modèle GRNN3 qui donne des

115 faibles résultats ( $R \approx 0.960$ ,  $NSE \approx 0.920$ ,  $RMSE \approx 0.940$ ,  $MAE \approx 0.710$ ). De plus, en n'utilisant que

116 trois variables d'entrée, (la cinquième à la huitième combinaison), le modèle MLR7 ( $T_{\max}$ ,  $T_{\min}$ ,

117  $SR$ ) assure des performances meilleures que le MLR1, et les taux d'amélioration des

118 performances en termes de R, NSE, RMSE et MAE sont de l'ordre de (2.105%, 5.556%

119 28.037%, 24.390%), respectivement. Par contre, les modèles MLPNN et GRNN à quatre

120 variables d'entrées assurent des résultats légèrement inférieurs par rapport aux modèles MLPNN1

121 et GRNN1, à l'exception du modèle MLPNN6 ( $T_{\max}$ ,  $T_{\min}$ ,  $H\%$ ) qui donne des performances

122 meilleures que le MLPNN1.


123

124 **Table IV.2.** Performances des différents modèles: Station de Mila

Models	Training				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLR1	0.980	0.960	0.650	0.520	0.950	0.900	1.070	0.820
MLR2	0.980	0.950	0.740	0.590	0.980	0.950	0.730	0.590
MLR3	0.980	0.960	0.650	0.520	0.980	0.960	0.690	0.550
MLR4	0.980	0.960	0.710	0.560	0.980	0.960	0.690	0.540
MLR5	0.940	0.890	1.140	0.930	0.940	0.880	1.150	0.940
MLR6	0.900	0.810	1.480	1.190	0.900	0.800	1.490	1.200
MLR7	0.970	0.950	0.780	0.630	0.970	0.950	0.770	0.620
MLR8	0.960	0.920	0.970	0.810	0.960	0.910	0.970	0.810
MLR9	0.930	0.870	1.240	1.000	0.930	0.860	1.230	1.000
MLR10	0.960	0.920	0.980	0.820	0.960	0.910	0.990	0.820
MLR11	0.940	0.880	1.150	0.950	0.940	0.880	1.160	0.950
MLR12	0.940	0.880	1.200	0.970	0.930	0.870	1.200	0.970
MLPNN1	0.990	0.980	0.450	0.340	0.990	0.980	0.470	0.360
MLPNN2	0.990	0.980	0.430	0.340	0.990	0.980	0.450	0.350
MLPNN3	0.990	0.990	0.400	0.310	0.990	0.980	0.420	0.330
MLPNN4	0.990	0.980	0.500	0.390	0.990	0.980	0.490	0.390
MLPNN5	0.950	0.900	1.060	0.830	0.950	0.890	1.100	0.850
MLPNN6	0.990	0.980	0.470	0.330	0.990	0.980	0.470	0.340
MLPNN7	0.990	0.980	0.480	0.340	0.990	0.980	0.480	0.360
MLPNN8	0.970	0.950	0.770	0.590	0.970	0.950	0.770	0.610
MLPNN9	0.940	0.890	1.140	0.870	0.940	0.880	1.150	0.880
MLPNN10	0.970	0.940	0.810	0.640	0.970	0.940	0.810	0.640
MLPNN11	0.950	0.910	1.020	0.800	0.950	0.900	1.050	0.830
MLPNN12	0.940	0.880	1.150	0.900	0.940	0.880	1.170	0.900
GRNN1	1.000	1.000	0.230	0.170	0.990	0.990	0.300	0.230
GRNN2	1.000	0.990	0.280	0.220	0.990	0.990	0.350	0.270
GRNN3	0.980	0.950	0.730	0.250	0.960	0.920	0.940	0.710
GRNN4	1.000	0.990	0.290	0.220	0.990	0.990	0.360	0.270
GRNN5	0.970	0.940	0.810	0.600	0.960	0.920	0.960	0.730
GRNN6	0.960	0.920	0.980	0.740	0.950	0.890	1.090	0.810
GRNN7	0.990	0.980	0.490	0.340	0.990	0.980	0.490	0.350
GRNN8	0.980	0.960	0.710	0.540	0.970	0.950	0.740	0.570
GRNN9	0.950	0.900	1.070	0.810	0.940	0.890	1.110	0.840
GRNN10	0.970	0.950	0.760	0.850	0.970	0.950	0.760	0.590
GRNN11	0.960	0.920	0.960	0.740	0.950	0.910	1.020	0.790
GRNN12	0.950	0.900	1.080	0.830	0.940	0.890	1.130	0.860

125  
126 Enfin, et pour les modèles n'ayant que deux variables d'entrée (la neuvième à la douzième  
127 combinaison), des faibles performances sont obtenues par rapport au modèles à cinq variables  
128 d'entrées, à l'exception du modèle MLR10 (H%, SR), qui assure des performances meilleures que  
129 le MLR1, et les taux d'amélioration des performances en termes de R, NSE, RMSE et MAE sont

130 de l'ordre de (1.053%, 1.111% 7.477%, 0.00%), respectivement. La représentation graphique  
 131 (Figures IV.4, IV.5, et IV.6) montre la même tendance que les résultats numériques, le modèle  
 132 GRNN1 est le modèle qui donne les données de l'EP les moins dispersées, par contre, le modèle  
 133 MLR6 a donné les données les plus dispersées.



134

135 **Figure IV.4.** Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation:  
 136 Station de Mila & modèles MLR

137




Figure IV.5. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Mila & modèles MLPNN

139  
140  
141  
142

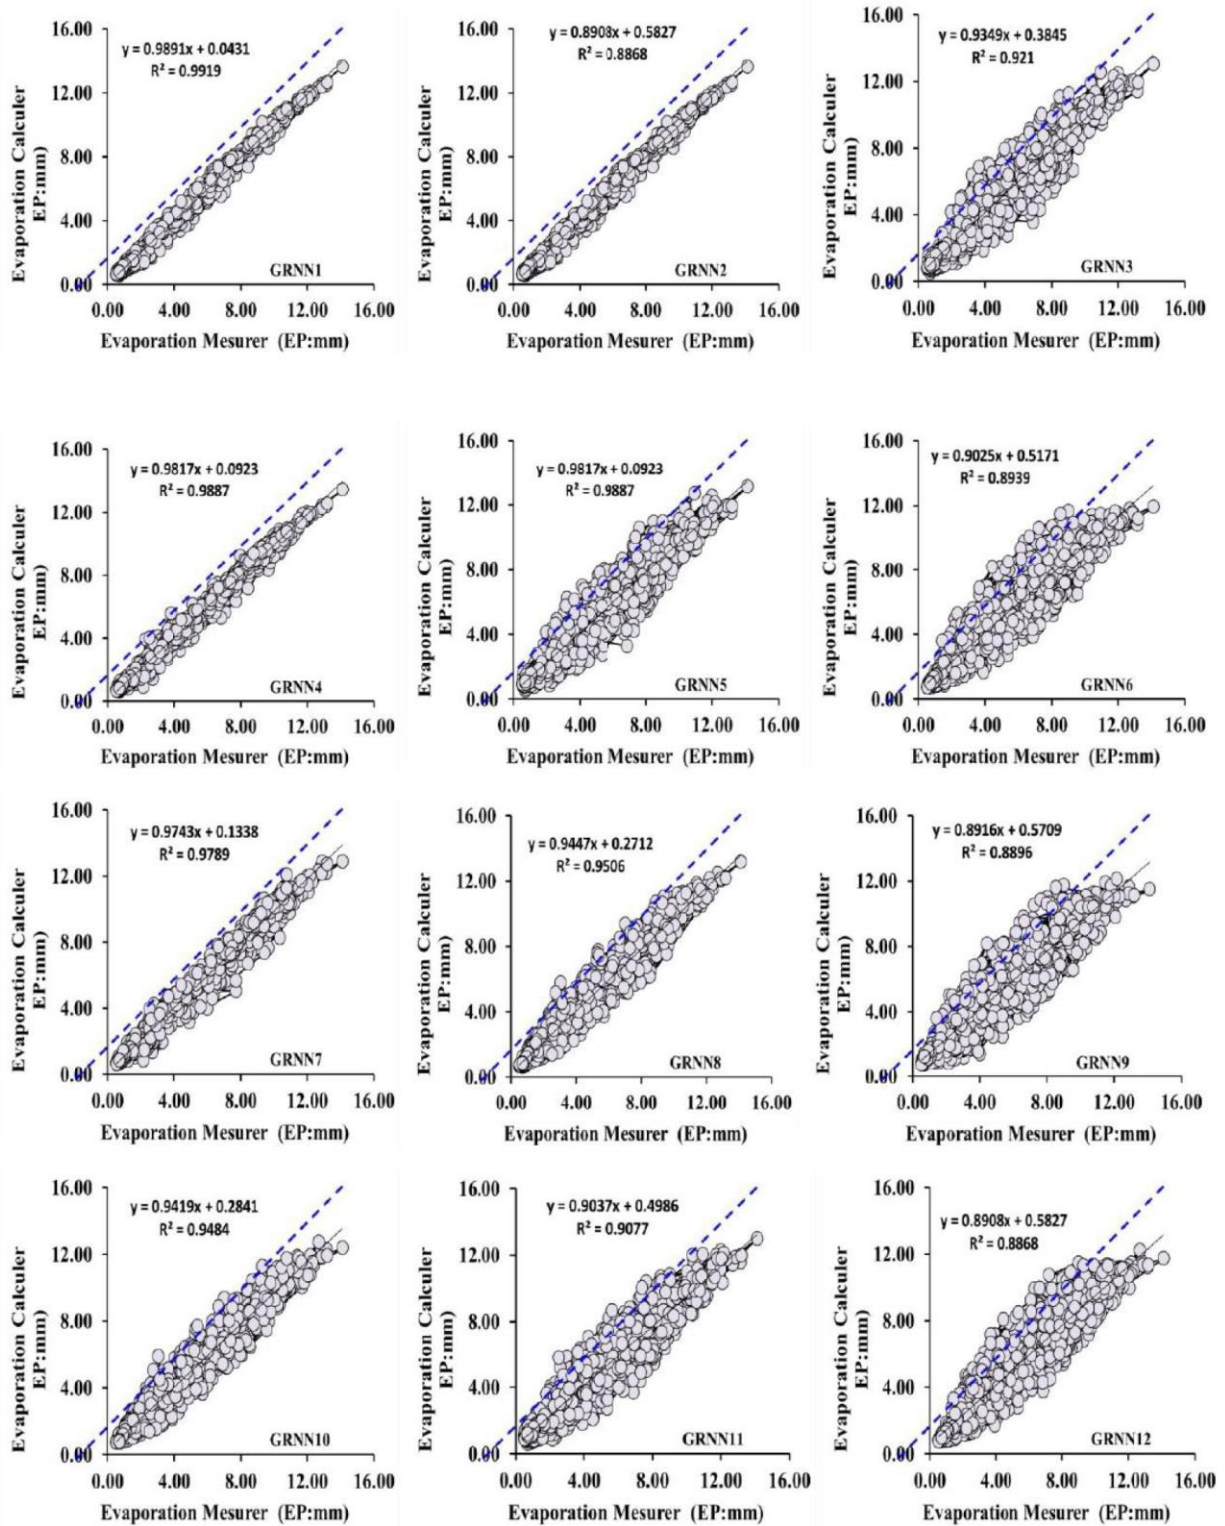


Figure IV.6. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Mila & modèles GRNN


#### 148 **IV.4. Modélisation de l'EP à Pas de Temps Journalière & Station de Guelma**

149 Pour la station de Guelma (Tableau IV.3, Figures IV.7-9), d'une façon générale, les  
 150 performances des modèles étaient similaires par rapport aux stations précédentes. Les moyennes  
 151 des valeurs de R et NSE sont de l'ordre de (0.953 et 0.910), (0.964 et 0.933), (0.969 et 0.940),  
 152 pour les modèles MLR, MLPNN et GRNN, respectivement. Les meilleurs résultats au niveau de  
 153 la station sont obtenus avec les modèles à cinq et quatre variables d'entrée (la première à la  
 154 quatrième combinaison). Pour les modèles MLR, le modèle MLR1 qui utilise tous les variables  
 155 climatiques ( $T_{max}$ ,  $T_{min}$ ,  $U_2$ ,  $H\%$ ,  $SR$ ) est le plus performant, avec des indices numériques de  
 156 l'ordre de ( $R \approx 0.980$ ,  $NSE \approx 0.960$ ,  $RMSE \approx 0.660$ ,  $MAE \approx 0.510$ ), suivi par le modèle MLR3  
 157 ( $R \approx 0.980$ ,  $NSE \approx 0.960$ ,  $RMSE \approx 0.670$ ,  $MAE \approx 0.510$ ), suivi par le modèle MLR2 ( $R \approx 0.980$ ,  
 158  $NSE \approx 0.960$ ,  $RMSE \approx 0.720$ ,  $MAE \approx 0.560$ ), suivi par le modèle MLR4 ( $R \approx 0.970$ ,  $NSE \approx 0.950$ ,  
 159  $RMSE \approx 0.782$ ,  $MAE \approx 0.580$ ). Les faibles résultats des modèles MLR sont obtenus avec le modèle  
 160 MLR6 ( $R \approx 0.900$ ,  $NSE \approx 0.820$ ,  $RMSE \approx 1.490$ ,  $MAE \approx 1.230$ ) qui utilise trois variables d'entrée  
 161 ( $T_{max}$ ,  $T_{min}$ ,  $H\%$ ), et les taux de réduction des performances entre ce modèle et le meilleur modèle  
 162 MLR (MLR1) sont de l'ordre de (8.889%, 17.073%, 55.705%, 58.537%) en terme de R, NSE,  
 163 RMSE et MAE, respectivement. Pour les modèles MLPNN, nous obtenons des résultats meilleurs  
 164 que les modèles MLR, et le modèle MLPNN3 qui utilise la troisième combinaison d'entrée ( $T_{max}$ ,  
 165  $T_{min}$ ,  $U_2$ ,  $H\%$ ) assure les meilleures performances ( $R \approx 0.990$ ,  $NSE \approx 0.990$ ,  $RMSE \approx 0.420$ ,  
 166  $MAE \approx 0.310$ ), ce qui explique l'effet mineur de la radiation solaire ( $SR$ ). Les taux d'amélioration  
 167 en termes de RMSE et MAE, par rapport au modèle MLPNN1 sont de l'ordre de 6.667% et  
 168 3.125%, respectivement. Pour qui est des faibles performances, elles sont assurées par le modèle  
 169 MLPNN6 ( $R \approx 0.910$ ,  $NSE \approx 0.830$ ,  $RMSE \approx 1.430$ ,  $MAE \approx 1.170$ ), avec des réduction des taux en  
 170 termes de R, NSE, RMSE et MAE de l'ordre de 8.791%, 19.277%, 70.629% et 73.504%,  
 171 respectivement, par rapport au meilleur modèle (MLPNN3). Pour les modèles GRNN, nous  
 172 obtenons des résultats similaires à celle obtenus par les modèles MLPNN et meilleure à celle  
 173 obtenus par les modèles MLR. Le meilleur modèle au niveau de la station est le GRNN1 qui  
 174 utilise la première combinaison d'entrée ( $T_{max}$ ,  $T_{min}$ ,  $U_2$ ,  $H\%$ ,  $SR$ ) avec des indices numériques de  
 175 ( $R \approx 0.990$ ,  $NSE \approx 0.990$ ,  $RMSE \approx 0.320$ ,  $MAE \approx 0.230$ ), et avec des taux d'amélioration en termes de  
 176 R, NSE, RMSE et MAE de 10.000%, 20.732%, 78.523% et 81.301%, respectivement, par rapport  
 177 au faible modèle au niveau de la station (MLR6). Pour qui est des faibles performances, elles sont  
 178 assurées par le modèle GRNN6 ( $R \approx 0.920$ ,  $NSE \approx 0.840$ ,  $RMSE \approx 1.370$ ,  $MAE \approx 1.080$ ), avec des

179 réduction des taux en termes de R, NSE, RMSE et MAE de l'ordre de 7.609%, 17.857%,  
 180 76.642% et 78.704%, respectivement, par rapport au meilleur modèle (GRNN1). La  
 181 comparaison graphique (Figures IV.7-9), montre la supériorité des modèles utilisant les quatre  
 182 premières combinaisons d'entrées.

183 **Table IV.3.** Performances des différents modèles: Station de Guelma

Models	Training				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLR1	0.980	0.960	0.680	0.530	0.980	0.960	0.660	0.510
MLR2	0.980	0.950	0.760	0.590	0.980	0.960	0.720	0.560
MLR3	0.980	0.960	0.690	0.530	0.980	0.960	0.670	0.510
MLR4	0.970	0.950	0.820	0.620	0.970	0.950	0.782	0.580
MLR5	0.950	0.900	1.110	0.910	0.950	0.890	1.140	0.920
MLR6	0.910	0.830	1.460	1.190	0.900	0.820	1.490	1.230
MLR7	0.960	0.920	1.000	0.780	0.960	0.920	0.960	0.760
MLR8	0.950	0.910	1.060	0.870	0.950	0.910	1.040	0.950
MLR9	0.940	0.880	1.230	0.960	0.930	0.870	1.250	0.990
MLR10	0.950	0.910	1.090	0.890	0.950	0.910	1.060	0.860
MLR11	0.950	0.900	1.150	0.940	0.940	0.890	1.170	0.950
MLR12	0.940	0.890	1.170	0.940	0.940	0.880	1.200	0.970
MLPNN1	0.990	0.990	0.420	0.290	0.990	0.980	0.450	0.320
MLPNN2	0.990	0.980	0.450	0.330	0.990	0.980	0.450	0.340
MLPNN3	0.990	0.990	0.400	0.290	0.990	0.990	0.420	0.310
MLPNN4	0.990	0.970	0.590	0.430	0.990	0.970	0.570	0.420
MLPNN5	0.960	0.920	1.010	0.790	0.950	0.910	1.050	0.830
MLPNN6	0.920	0.850	1.400	1.130	0.910	0.830	1.430	1.170
MLPNN7	0.970	0.950	0.810	0.590	0.980	0.950	0.780	0.570
MLPNN8	0.970	0.950	0.800	0.620	0.970	0.950	0.800	0.620
MLPNN9	0.950	0.900	1.130	0.840	0.940	0.890	1.140	0.860
MLPNN10	0.970	0.940	0.850	0.650	0.970	0.940	0.830	0.640
MLPNN11	0.960	0.920	1.030	0.800	0.950	0.910	1.040	0.820
MLPNN12	0.950	0.900	1.140	0.870	0.940	0.890	1.160	0.900
GRNN1	1.000	1.000	0.210	0.150	0.990	0.990	0.320	0.230
GRNN2	1.000	0.990	0.280	0.200	0.990	0.990	0.380	0.280
GRNN3	1.000	0.990	0.300	0.220	0.990	0.990	0.380	0.280
GRNN4	1.000	0.990	0.340	0.250	0.990	0.980	0.450	0.330
GRNN5	0.970	0.950	0.810	0.620	0.960	0.920	0.960	0.730
GRNN6	0.940	0.880	1.230	0.970	0.920	0.840	1.370	1.080
GRNN7	0.980	0.960	0.680	0.500	0.980	0.950	0.740	0.540
GRNN8	0.980	0.960	0.720	0.550	0.980	0.950	0.760	0.580
GRNN9	0.950	0.910	1.080	0.810	0.950	0.900	1.120	0.850
GRNN10	0.980	0.950	0.780	0.600	0.970	0.950	0.800	0.610
GRNN11	0.970	0.930	0.930	0.720	0.960	0.920	1.000	0.790
GRNN12	0.960	0.920	1.030	0.780	0.950	0.900	1.110	0.850



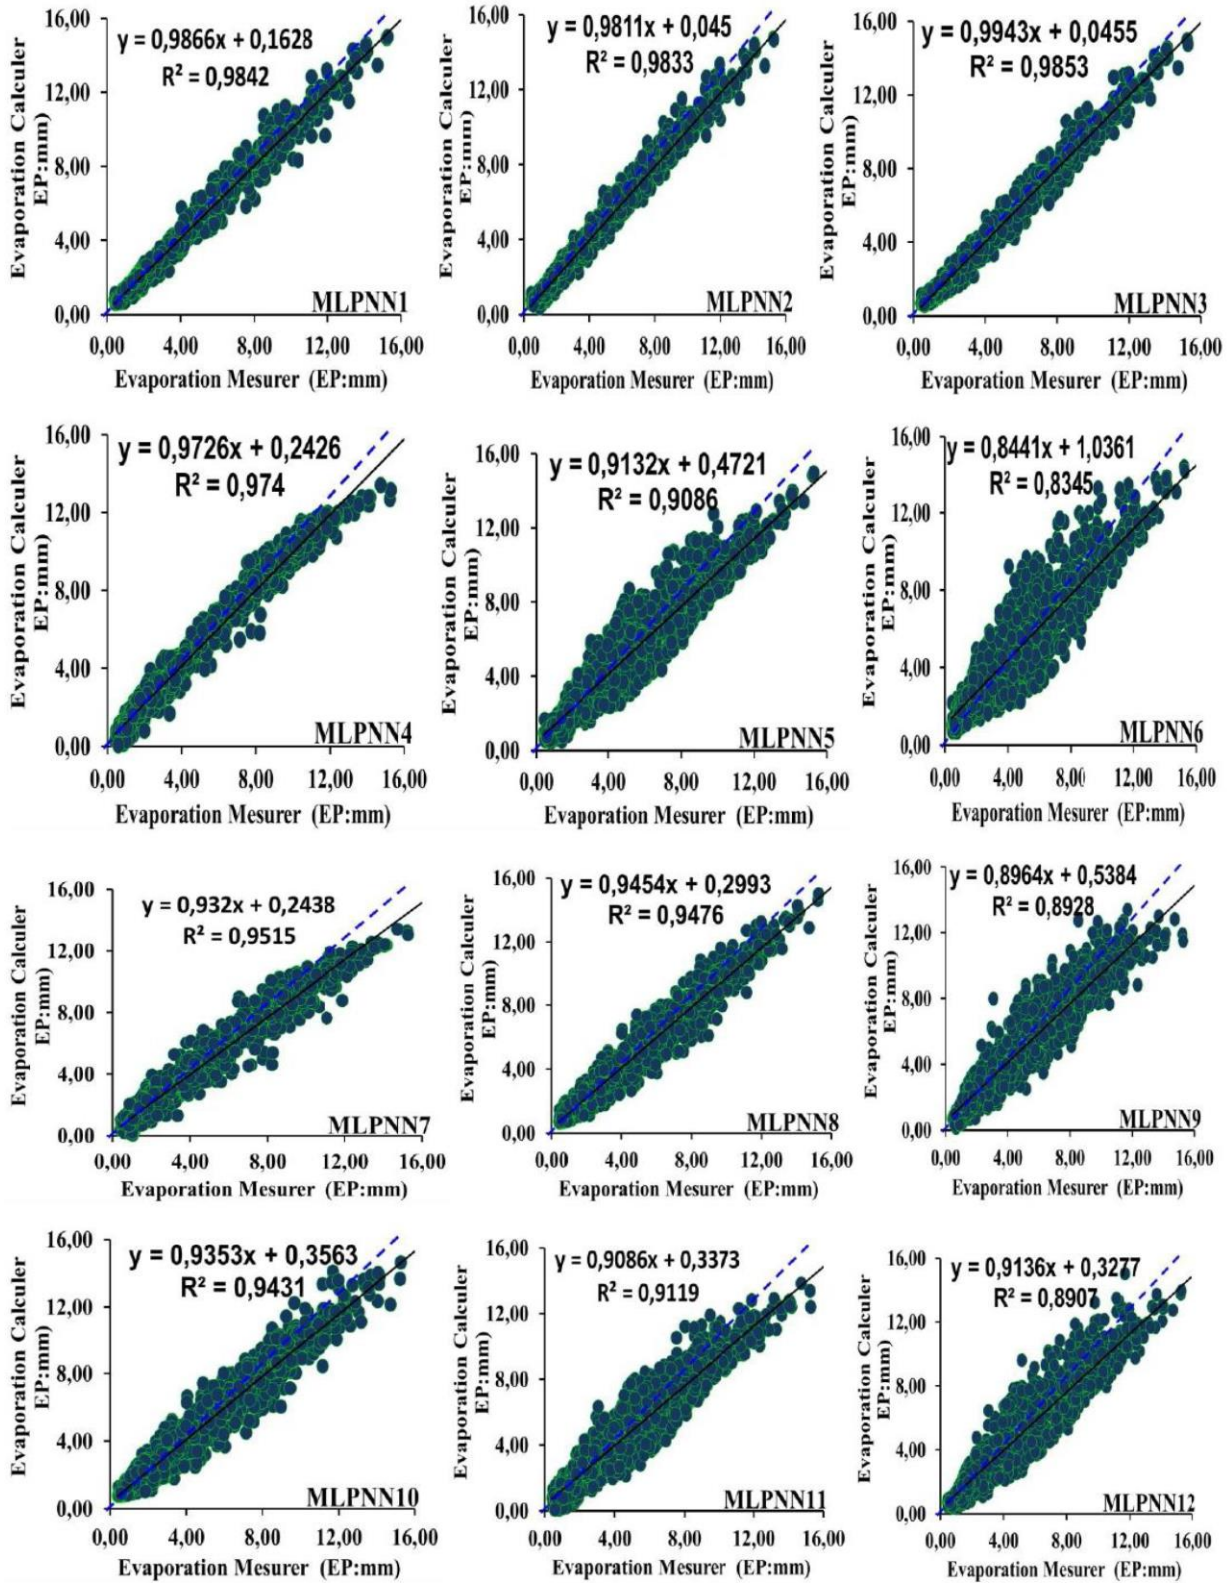
185

186

187

188

**Figure IV.7.** Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Guelma & modèles MLR



**Figure IV.8.** Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Guelma & modèles MLPNN

189  
190  
191  
192

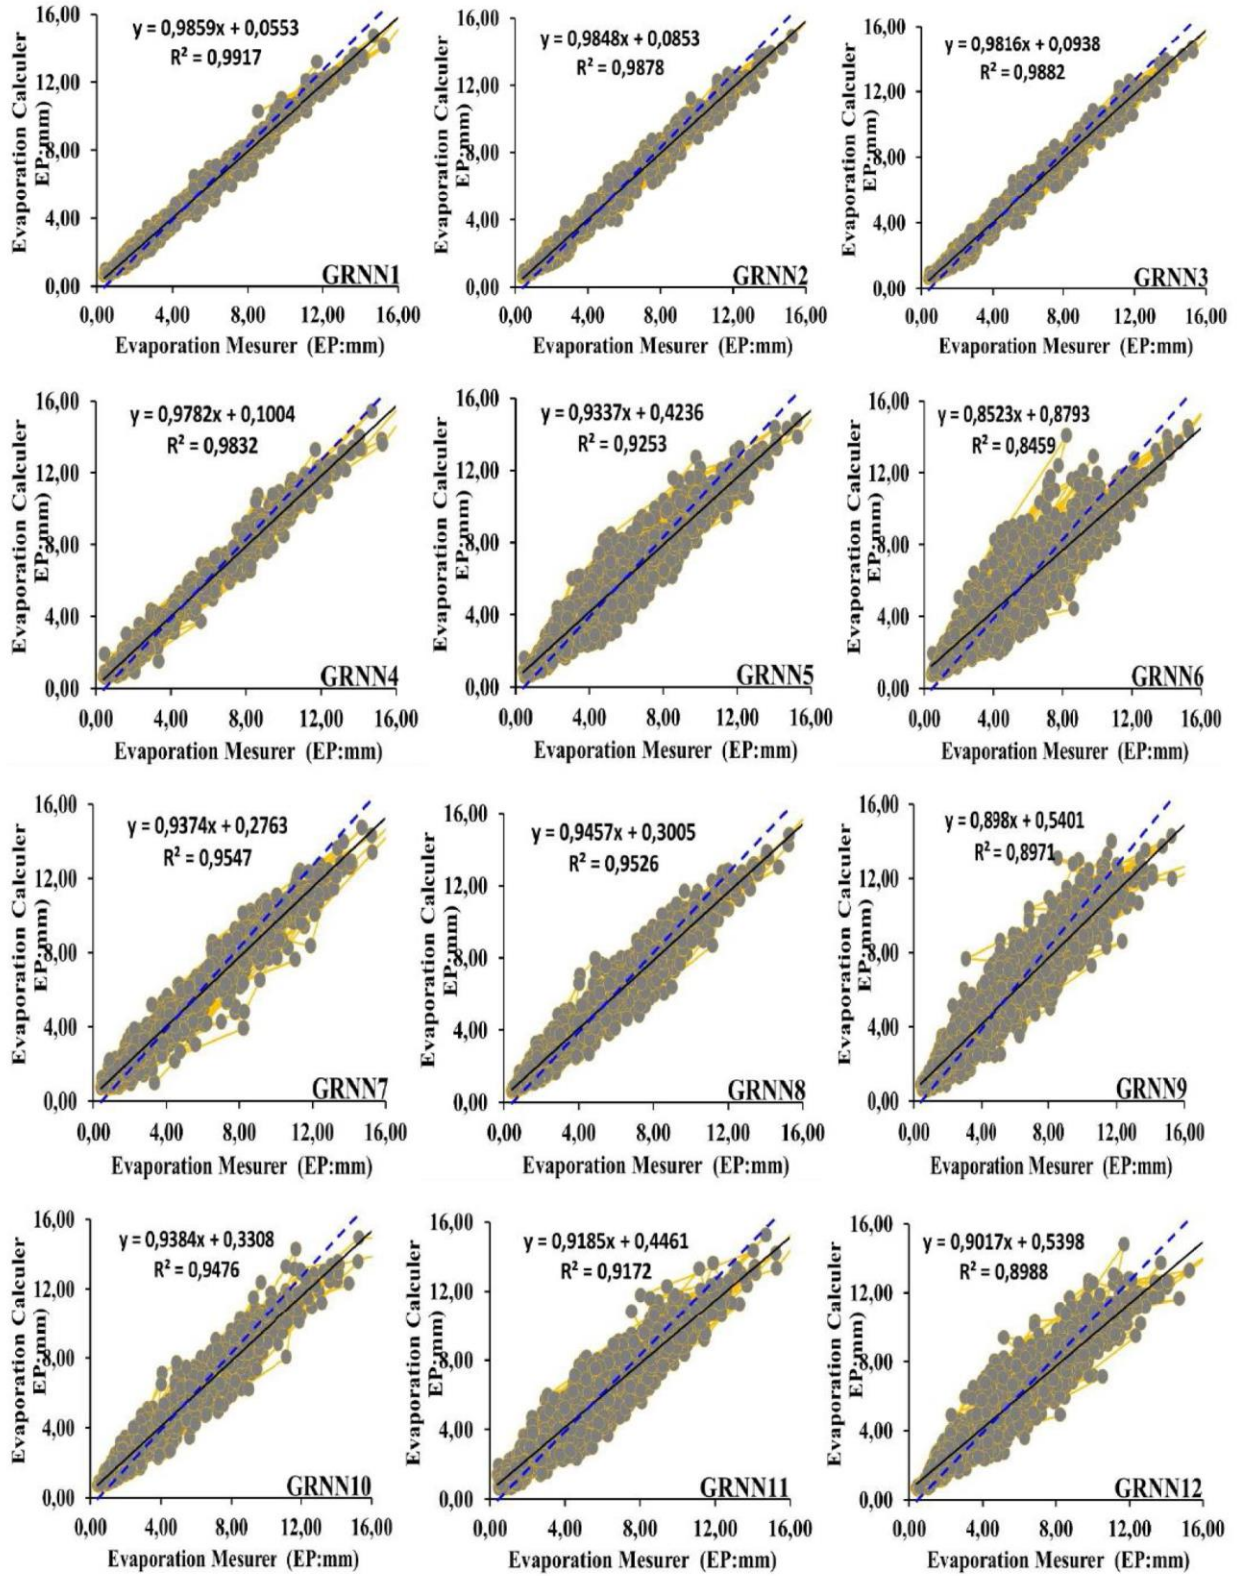


Figure IV.9. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Guelma & modèles GRNN

193  
194  
195  
196

#### 197 **IV.5. Modélisation de l'EP à Pas de Temps Journalière & Station de Sétif**

198 Au niveau de la station de Sétif (Tableau IV.4, Figures IV.10-13), les performances  
 199 obtenues sont plus proche à celle des stations précédentes. Les résultats varient d'un modèle à  
 200 l'autre et selon le nombre de variables d'entrée utilisées. Premièrement, en utilisant la première  
 201 combinaison avec cinq variables d'entrées ( $T_{max}$ ,  $T_{min}$ ,  $U_2$ ,  $H\%$ ,  $SR$ ), les modèles MLPNN1,  
 202 MLPNN1 et GRNN1 assurent les meilleurs résultats, et le GRNN1 est le modèle le plus  
 203 performant au niveau de la station de Sétif ( $R \approx 0.990$ ,  $NSE \approx 0.990$ ,  $RMSE \approx 0.330$ ,  $MAE \approx 0.230$ ).  
 204 Avec les modèles utilisant quatre variables d'entrée (la deuxième à la quatrième combinaison),  
 205 les résultats obtenus sont proche les uns des autres avec des différences négligeables entre les  
 206 modèles, les moyennes des valeurs de R et NSE pour les modèles MLR, MLPNN et GRNN à  
 207 quatre variables d'entrée sont de l'ordre de (0.980 et 0.960), (0.990 et 0.980) et (0.990 et 0.990),  
 208 respectivement, ce qui nous conduit à conclure que l'effet des trios variables  $T_{max}$ ,  $U_2$  et  $H\%$  est  
 209 similaire. Pour les modèles utilisant trois variables d'entrée (la cinquième à la huitième  
 210 combinaison), les performances de tous les modèles se sont dégradées, et avec la sixième  
 211 combinaison ( $T_{max}$ ,  $T_{min}$ ,  $H\%$ ) nous obtenons les faibles performances au niveau de la station  
 212 avec des indices numériques de ( $R \approx 0.900$ ,  $NSE \approx 0.820$ ,  $RMSE \approx 1.420$ ,  $MAE \approx 1.120$ ), ( $R \approx 0.910$ ,  
 213  $NSE \approx 0.840$ ,  $RMSE \approx 1.340$ ,  $MAE \approx 1.060$ ) et ( $R \approx 0.920$ ,  $NSE \approx 0.850$ ,  $RMSE \approx 1.270$ ,  $MAE \approx 0.990$ )  
 214 pour le MLR6, MLPNN6 et GRNN6, respectivement, et il est clair que les performances se sont  
 215 significativement dégradés par rapport aux meilleurs modèles, avec une dégradation des  
 216 performances en termes de R, NSE, RMSE et MAE de (8.889%, 17.073%, 56.338%, 55.357%),  
 217 (8.791%, 16.667%, 67.164%, 70.755%), (7.609%, 16.471%, 74.016% 76.768%), pour les  
 218 modèles MLR, MLPNN et GRNN, respectivement. Pour les modèles utilisant deux variables  
 219 d'entrée (la neuvième à la douzième combinaison), les performances étaient similaires à celle  
 220 obtenues avec les modèles à trois variables d'entrée, et les moyennes en termes de R et NSE pour  
 221 les modèles à deux entrée sont de (0.945, 0.895), (0.955, 0.913), (0.960, 0.923), par rapport aux  
 222 moyennes obtenues par les modèles à trois variables d'entrée (0.945, 0.893), (0.955, 0.915),  
 223 (0.960, 0.925), pour les modèles MLR, MLPNN et GRNN, respectivement. Le meilleur résultat  
 224 obtenu avec les modèles à deux entrées est assuré par la dixième combinaison ( $H\%$ ,  $SR$ ), avec  
 225 des indices numériques de ( $R \approx 0.960$ ,  $NSE \approx 0.920$ ,  $RMSE \approx 0.930$ ,  $MAE \approx 0.720$ ), ( $R \approx 0.970$ ,  
 226  $NSE \approx 0.950$ ,  $RMSE \approx 0.760$ ,  $MAE \approx 0.590$ ) et ( $R \approx 0.970$ ,  $NSE \approx 0.950$ ,  $RMSE \approx 0.750$ ,  $MAE \approx 0.580$ )  
 227 pour le MLR10, MLPNN10 et GRNN10 respectivement.

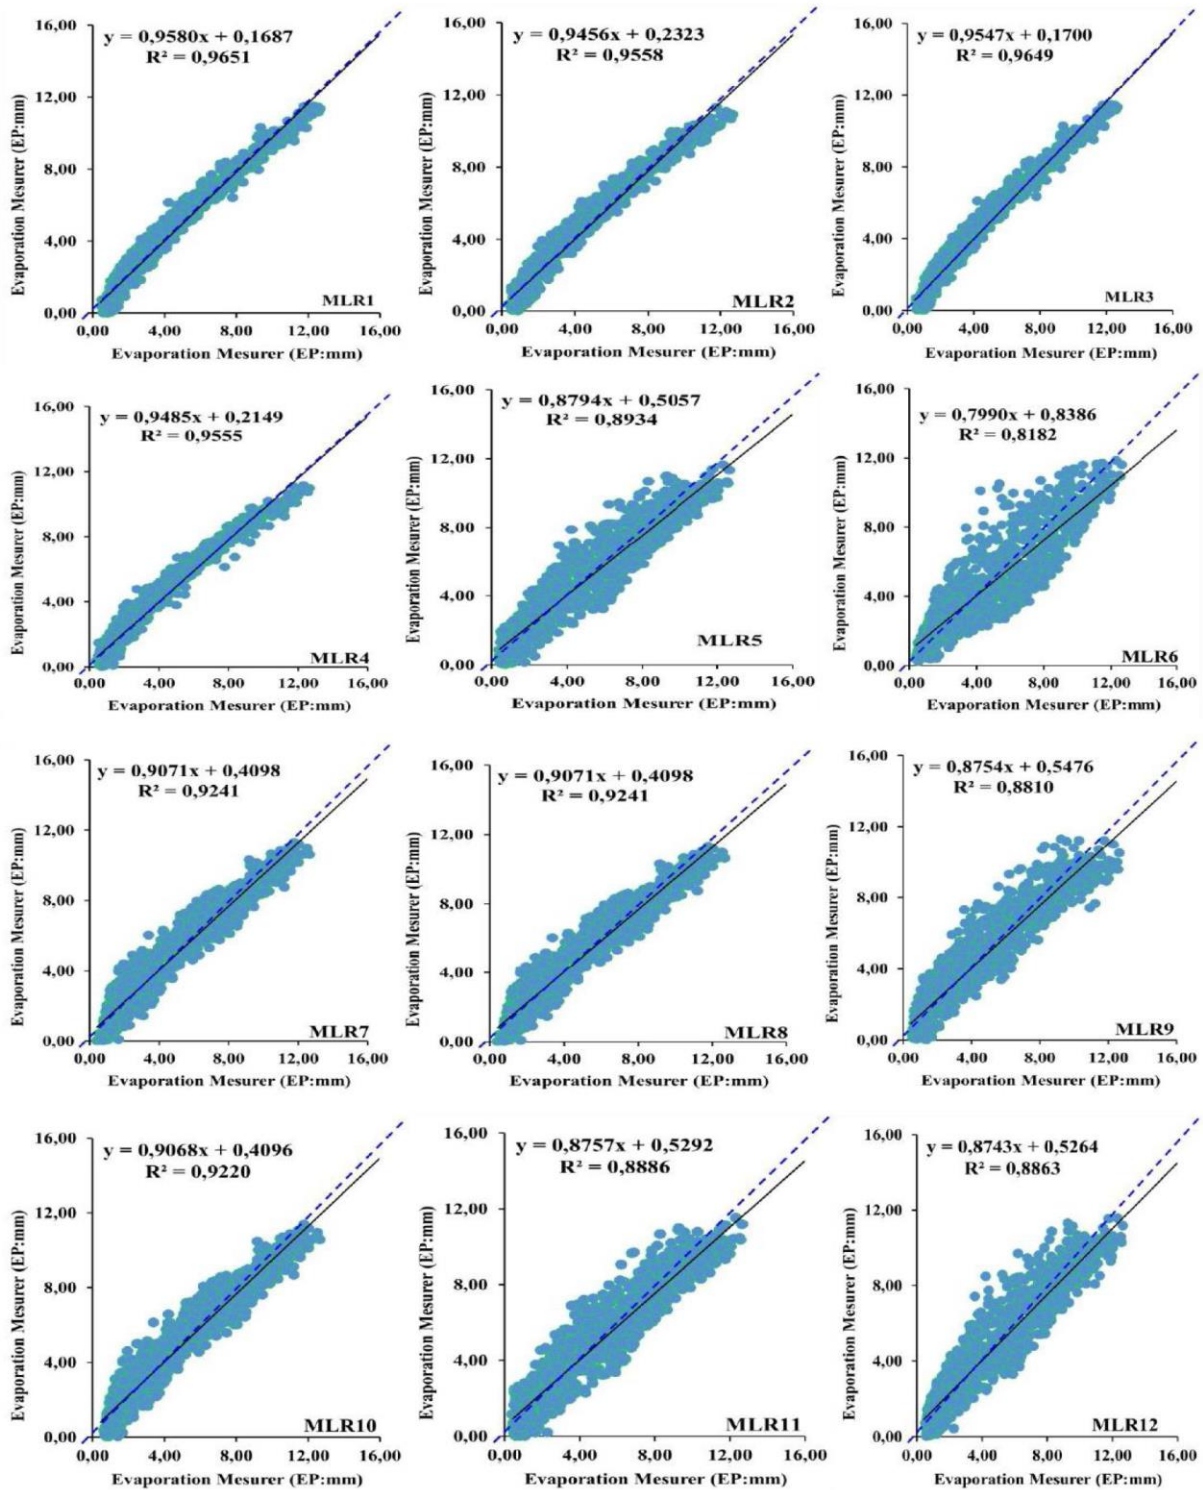
228 **Table IV.4.** Performances des différents modèles: Station de Sétif

Models	Training				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLR1	0.980	0.960	0.620	0.500	0.980	0.960	0.620	0.500
MLR2	0.980	0.950	0.710	0.570	0.980	0.960	0.700	0.550
MLR3	0.980	0.960	0.620	0.510	0.980	0.960	0.620	0.500
MLR4	0.980	0.950	0.700	0.560	0.980	0.960	0.700	0.550
MLR5	0.940	0.890	1.090	0.890	0.950	0.890	1.080	0.890
MLR6	0.900	0.820	1.400	1.110	0.900	0.820	1.420	1.120
MLR7	0.970	0.940	0.770	0.620	0.970	0.940	0.780	0.640
MLR8	0.960	0.920	0.930	0.780	0.960	0.920	0.910	0.760
MLR9	0.940	0.880	1.150	0.920	0.940	0.880	1.140	0.910
MLR10	0.960	0.920	0.940	0.780	0.960	0.920	0.930	0.720
MLR11	0.940	0.880	1.120	0.920	0.940	0.890	1.110	0.910
MLR12	0.940	0.880	1.120	0.900	0.940	0.890	1.120	0.900
MLPNN1	0.990	0.990	0.390	0.280	0.990	0.980	0.440	0.310
MLPNN2	0.990	0.980	0.420	0.330	0.990	0.980	0.430	0.330
MLPNN3	0.990	0.990	0.380	0.290	0.990	0.980	0.420	0.312
MLPNN4	0.990	0.980	0.440	0.320	0.990	0.980	0.470	0.340
MLPNN5	0.950	0.900	1.040	0.800	0.950	0.900	1.060	0.810
MLPNN6	0.910	0.830	1.330	1.040	0.910	0.840	1.340	1.060
MLPNN7	0.990	0.970	0.550	0.410	0.980	0.970	0.590	0.430
MLPNN8	0.970	0.950	0.750	0.570	0.980	0.950	0.740	0.560
MLPNN9	0.950	0.900	1.040	0.780	0.950	0.900	1.060	0.780
MLPNN10	0.970	0.940	0.770	0.590	0.970	0.950	0.760	0.590
MLPNN11	0.950	0.910	1.000	0.780	0.960	0.910	0.980	0.780
MLPNN12	0.940	0.890	1.100	0.850	0.940	0.890	1.100	0.850
GRNN1	1.000	1.000	0.220	0.160	0.990	0.990	0.330	0.230
GRNN2	1.000	0.990	0.250	0.190	0.990	0.990	0.350	0.270
GRNN3	1.000	0.990	0.280	0.210	0.990	0.990	0.380	0.270
GRNN4	1.000	0.990	0.290	0.210	0.990	0.990	0.380	0.270
GRNN5	0.970	0.930	0.850	0.640	0.960	0.930	0.900	0.700
GRNN6	0.930	0.860	1.210	0.930	0.920	0.850	1.270	0.990
GRNN7	0.990	0.980	0.480	0.350	0.980	0.970	0.600	0.430
GRNN8	0.980	0.960	0.680	0.520	0.980	0.950	0.720	0.550
GRNN9	0.950	0.910	0.990	0.750	0.950	0.900	1.020	0.760
GRNN10	0.970	0.950	0.740	0.570	0.970	0.950	0.750	0.580
GRNN11	0.960	0.920	0.930	0.710	0.960	0.920	0.950	0.740
GRNN12	0.960	0.930	0.930	0.710	0.960	0.920	0.950	0.740

229

230

231



**Figure IV.10.** Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Sétif & modèles MLR

232  
233  
234  
235  
236  
237

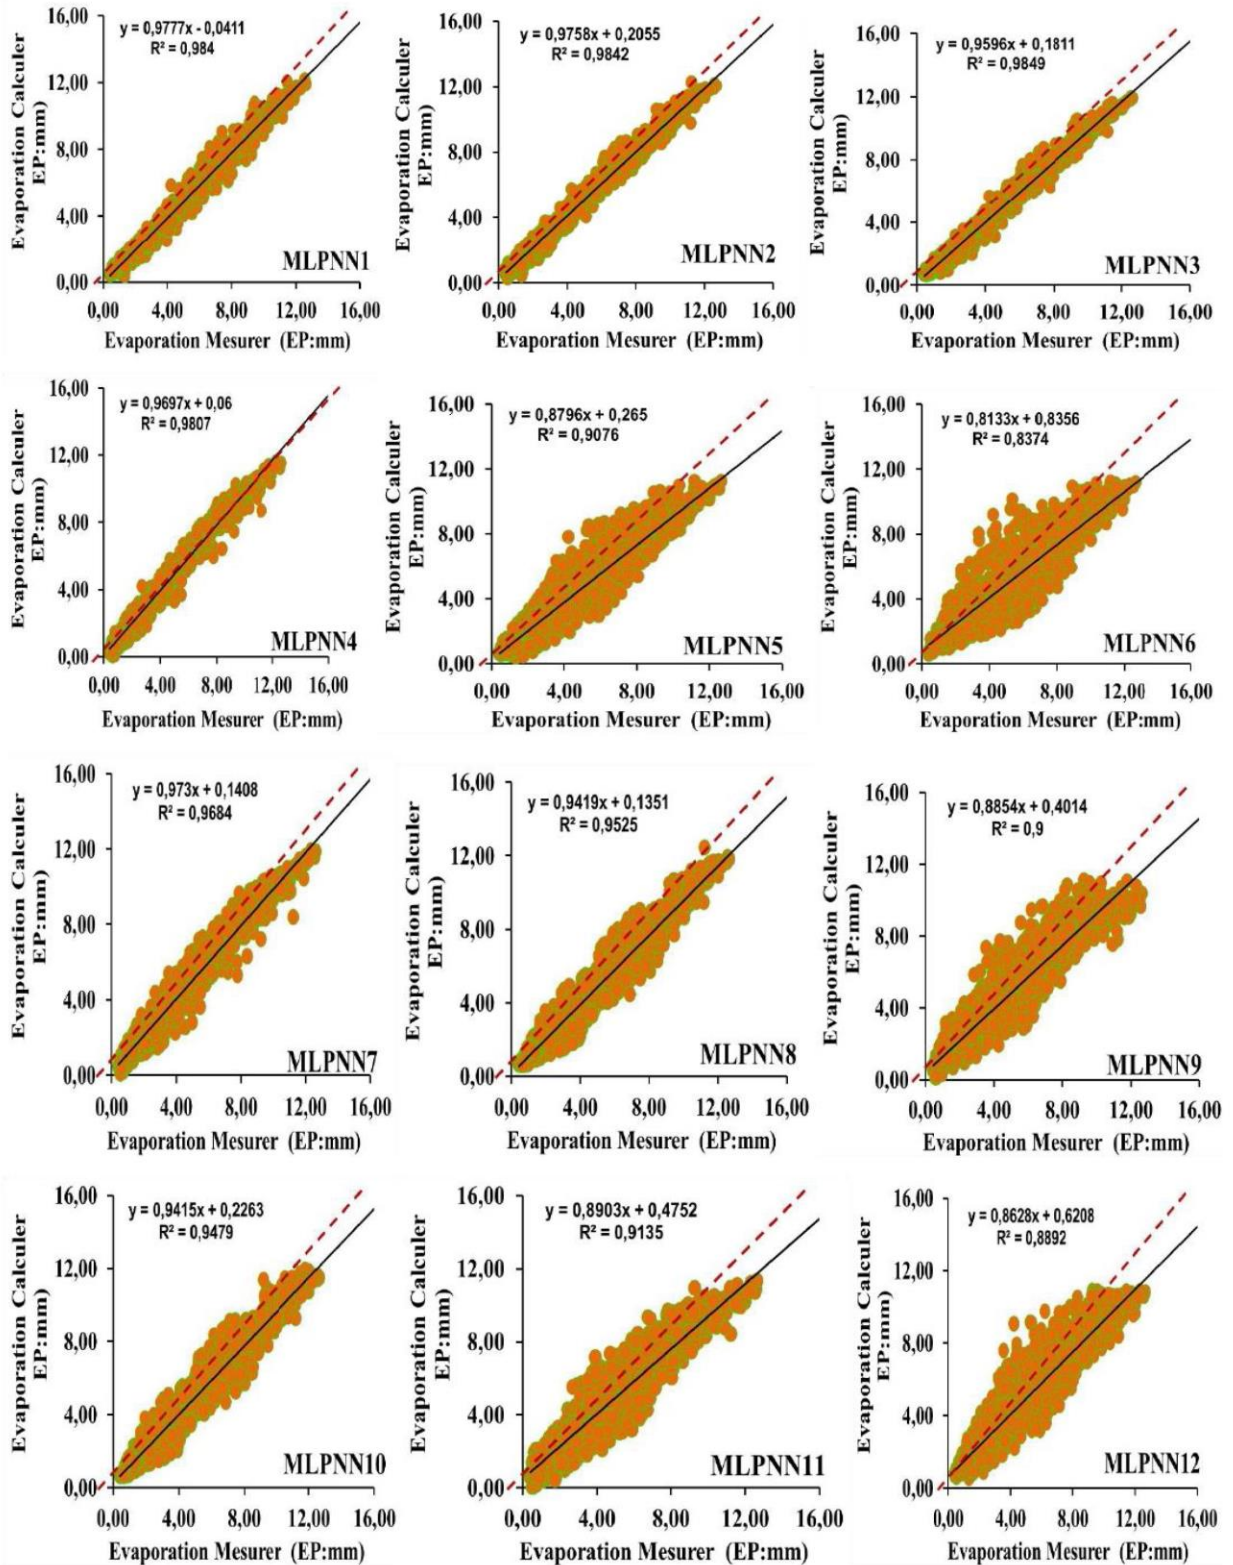


Figure IV.11. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Sétif & modèles MLPNN

238  
239  
240  
241

242

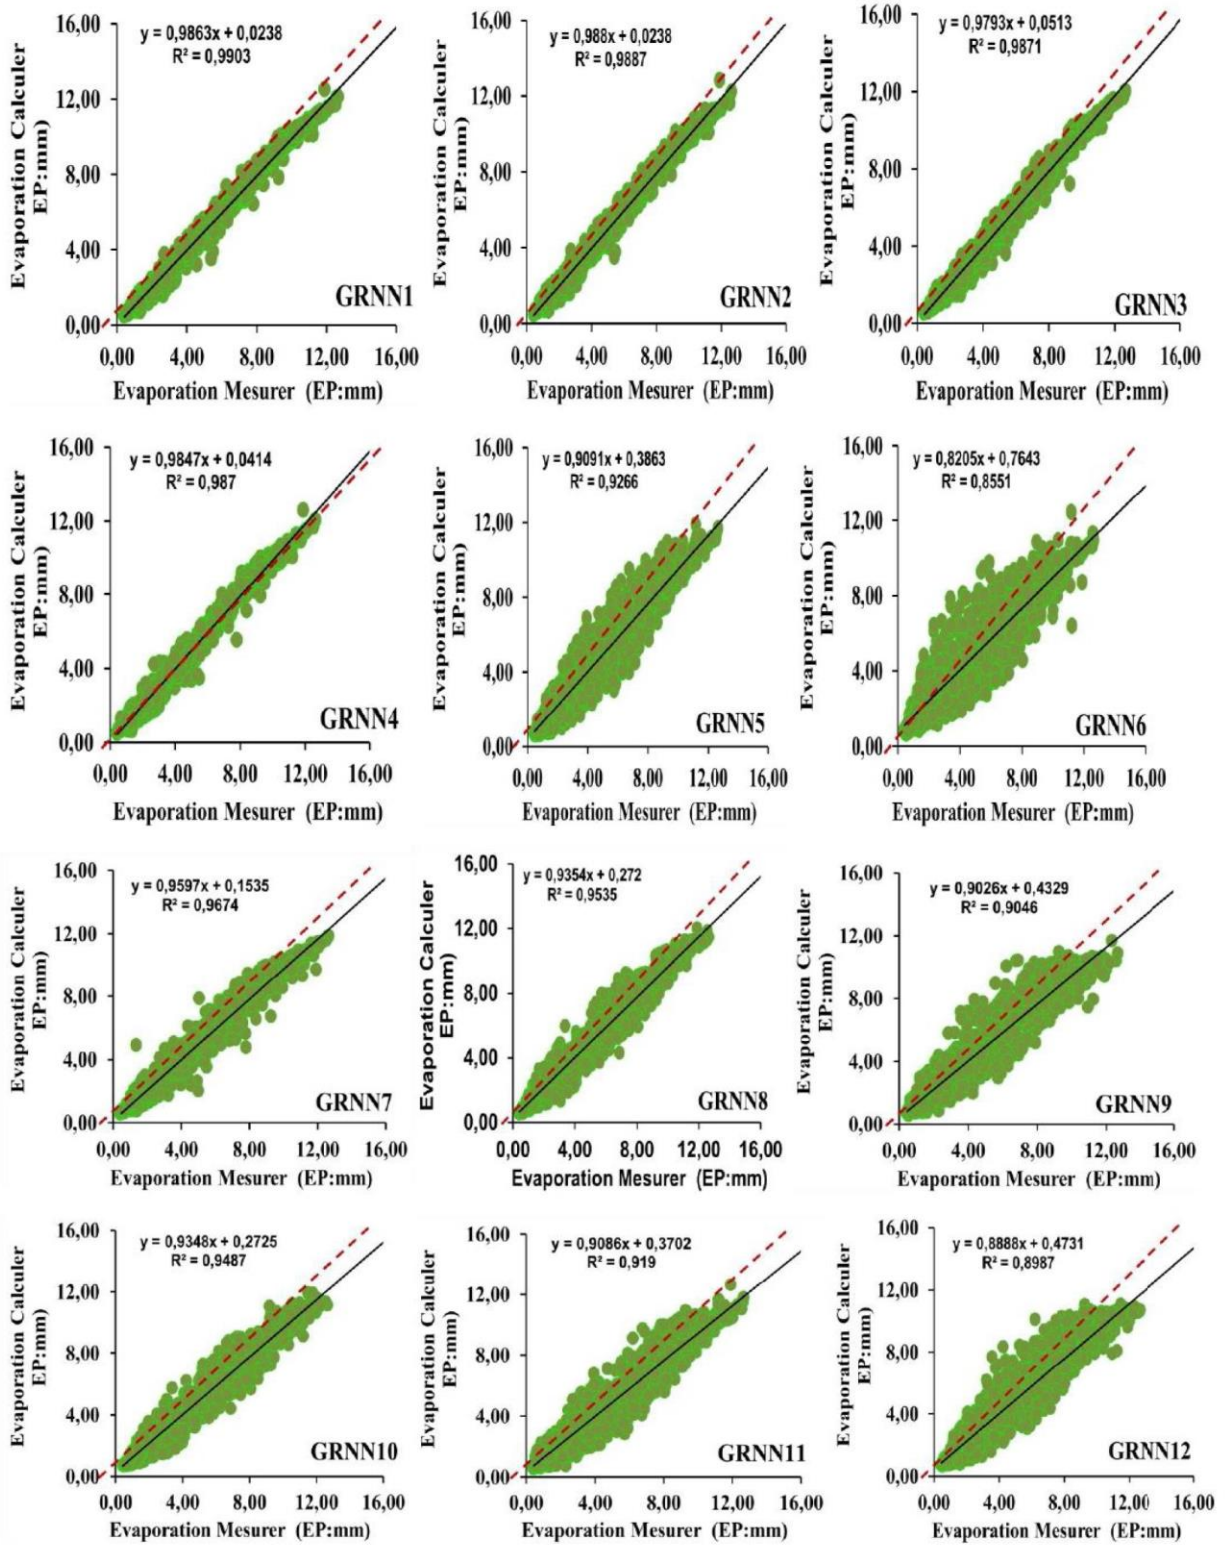


Figure IV.12. Scatterplots des valeurs mesurées et calculées de l'EP en phase de validation: Station de Sétif & modèles GRNN

243  
244  
245  
246

## 247 **IV.6. Conclusion**

248 À travers le présent chapitre, nous avons présenté et discuté les résultats de modélisation  
249 de l'évaporation (EP) obtenus par la technique de régression linéaire et deux modèles  
250 d'intelligences artificielle au niveau de quatre stations, à savoir: Constantine, Mila, Guelma et  
251 Sétif. Nous avons utilisé douze combinaisons d'entrée, ayant cinq, quatre, trois et deux variables  
252 d'entrées. À la lumière des résultats obtenus, on peut conclure ce qui suit:

- 253 *i-* En générale, les résultats que nous avons obtenus étaient bonnes à excellence, malgré que,  
254 les performances fluctuent d'une station à l'autre.
- 255 *ii-* Dans la majorité des cas, les résultats obtenus avec les modèles des réseaux de neurones  
256 artificielles (MLPNN et GRNN) étaient meilleurs que les modèles MLR.
- 257 *iii-* Généralement, les résultats obtenus avec les modèles MLPNN et GRNN sont proches les  
258 uns des autres.
- 259 *iv-* Avec uniquement deux et trois variables d'entrée, nous avons obtenus des bons résultats  
260 pour plusieurs modèles.
- 261 *v-* Les facteurs les plus influents les performances de la modélisation de l'EP sont  
262 principalement les deux températures maximale ( $T_{\max}$ ) et minimale ( $T_{\min}$ ) et la radiation  
263 solaire (SR).

## 1 *Conclusion Générale :*

2 L'évaporation est l'une des composantes les plus importantes qui exprime les pertes  
3 d'eau sur tout type de surfaces. Dans cette étude, l'évaporation à partir des plans d'eau libre est  
4 étudiée afin de quantifier les quantité d'eau qui seront disponible dans les réservoirs. C'est crucial  
5 pour la gestion de l'eau au niveau des barrages à des fins d'irrigation, de contrôle des crues,  
6 production d'énergie, et eau potable. L'évaporation à partir des plans d'eau mesurée par les bac  
7 d'évaporation (EP) est un indicateur de la demande d'évaporation atmosphérique, et des  
8 tendances à la hausse ont été signalée dans de nombreuses régions dans le monde au cours des  
9 dernières décennies, ce qui reflète un changement climatique remarquable. Il est important de  
10 comprendre comment l'EP change dans le temps et dans l'espace et de déterminer les principales  
11 causes et la facteurs climatiques intervenant. L'interaction entre l'évaporation et plusieurs  
12 variables climatiques permet un contrôle continue et prendre les decision nécessaire pour une  
13 meilleure gestion des ressources en eau. Cette étude a été basée sur des données climatiques  
14 quotidiennes de 4 stations météorologiques à travers l'Algérie. Les variables climatiques inclus :  
15 EP mesuré avec les bacs class A standard, radiation solaire global (RS), la température de l'air  
16 maximale et minimale (Tmax, Tmin), l'humidité relative de l'aire (H%) et la vitesse du vent (U2).

17  
18 Nous avons essayé de proposer des modèles à base d'intelligence artificielle pour la  
19 modélisation de l'évaporation journalière et de quantifier les contributions des différentes  
20 variables climatiques. Nous avons utilisé trois modèles : deux à base de réseaux de neurones  
21 artificielles, i.e., le MLPNN et le GRNN, et un modèle à base de régression linéaire multiple  
22 (MLR). Nous avons comparé entre douze (12) modèles ayant différent combinaisons de variables  
23 d'entrées, et des évaluations graphiques et numérique ont été conduites en utilisant quatre  
24 indices : R, NSE, RMSE, et MAE. À la lumière des résultats obtenus on peut conclure ce qui  
25 suit :

- 26
- 27 1. La modélisation par les modèles ANN est une approche intéressante pour établir des  
28 modèles d'estimation de L'EP.
  - 29 2. Par conséquent, dans cette étude, nous avons testé deux modèles, ce qui nous a permet  
30 de mieux comprendre les variations d'EP et les facteurs climatiques qui ont le plus  
31 d'influence.

32 3. Les résultats obtenus ont révélé que la troisième combinaison d'entrée comprenant la  
33 température de l'air, la vitesse du vent, le rayonnement solaire et les enregistrements  
34 d'humidité ont donné des résultats prometteurs.

35 4. Néanmoins, la combinaison de la température de l'air et du rayonnement solaire a  
36 permet de mieux améliorer les résultats.

37 5. Les modèles à base de réseaux de neurones artificielle ont donnée de résultats meilleure  
38 que les modèles à base de régression linéaire multiple (MLR) au niveau de tous les stations.

39 6. La présente étude a utilisé les données de quatre stations pour modéliser l'évaporation  
40 quotidiennes. Des investigations supplémentaires pourraient être nécessaires utiliser des  
41 données provenant d'autres stations ayant de climat différent pour évaluer la généralisabilité  
42 des modèles et pour renforcer les résultats actuels.

43

44

45

46

47

48

49

50

51

52

53

## Références Bibliographiques :

1. Benis, S. (2009). « Hydraulique et hydrologie », 2<sup>ème</sup> édition (Revue et Augmentée), presse de l'université du Québec. Québec, Canada.
2. Boutoutaou D. (2011). Notion sur l'évaporation des plans d'eau (Barrage, Lac, Cours d'eau, Chott, Sebkha, etc) en Algérie. Laboratoire d'Exploitation et Valorisation des Ressources Naturelles en Zones Arides. Université Kasdi Merbah Ouargla, 296p et 299p.
3. Boutoutaou D., Saker M., daddi Bouhoun M., Saggai S., Ould el hadj M. Laboratoire d'Exploitation et Valorisation des Ressources Naturelles en Zones Arides. Laboratoire de protection des écosystèmes en zones arides et semi-arides Université Kasdi Merbah Ouargla.
4. Guezal, Yet Miloudi, T. (2018). Nouveau modèle numérique d'estimation du taux d'évaporation du barrage réservoir – Brizina-El-Bayadh. Mémoire de Master. Université Echahide Hamma Lakhdar, d'El-Oued, Algérie.
5. Sahraoui, B. (2016). Diagnostic et réhabilitation d'un forage du complexe Terminal et ses équipements cas du barrage. Mémoire Master. Université de Echahide Hamma Lakhdar. El-Oued. Algérie, 14p.
6. Nedjima, R. (2019). Elaboration d'un modèle numérique pour l'estimation de l'évaporation à partir des données climatiques limitées : cas du barrage réservoir foug el - guiss- khenc. Faculté de Technologie. Département d'Hydraulique et de Génie Civil. Université d'el-oued. 100p.
7. Vachala, S. (2008). Évaporation sur les retenues EDF du sud de la France. Mémoire de Master. Université Pierre et Marie Curie. Paris. France.
8. Llamas J., (1993), Hydrologie générale (Principe et applications), éditeur gaëtan morin, Canada. (527p).
9. Arnaud P., Lavabre J. (1999). Etude de l'évaporation sur la retenue de Serre-Ponçon. Cemagref, Aix-en-Provence, 33pp.
10. Aldomany, M. (2017). L'évaporation dans le bilan hydrologique des étangs du centre-Ouest de la France ( Brenne et Limousin) thèse de Doctorat Université d'Orléans. 332p.
11. OMM. (1994). Guides des Pratiques Hydrologiques Acquisition et Traitement des Données, Analyses, Prévision et Autres Applications. Cinquième édition, Organisation Météorologique mondiale, OMM-N°168.
12. Bourougaa et Seridi. (2020). Application des réseaux de neurone pour la classification des Données. Mémoire de Master académique. Faculté des Sciences et de la Technologie. Département de Génie Electrotechnique et Automatique. université 8 Mai 1945 Guelma 78p.
13. Dibiaggio, L., Nesta, L., Keita, M. (2022). L'intelligence artificielle. Technologies et acteurs clés. Edition. 146p

14. Ouguissi. M., Almaoui. A. (2019). Prédiction de rayonnement solaire journalière par réseau de neurone. Mémoire de Master académique .Faculté des Sciences Appliquées. Département de Génie Électrique .université Kasdi Merbah Ouargla.71p.
15. Gérard.D.(1998).Reducing the complexity of neural Nets for industrial application and biological models .Neuronal information processing From biological Data to modeling and application ( world scientific).
16. Bernard.G.(1996). Application des réseaux de neurones artificiels a la reconnaissance au de caractère manuscrit . thèse de Doctorat.Faculté Polytechnique de Mons.
17. Bennecib.K.(2009).Comportement de quelques phénols, polluants potentiels de l'environnement. Mémoire de Magistère en chimie analytique. Faculté des Sciences. Département de Chimie. Université Badji Mokhtar Annaba.86p.
- 18.Zitouni.B et Hamdi.M (2021).Application des réseaux de neurones artificielsdans le contrôle de la tension des réseaux de distribution intelligents. Mémoire de Master académique.Faculté des Sciences Appliquées. Département de Génie Electrique. université Kasdi Merbah Ouargla.56p.
- 19.Baccouch.M.(2013). Apprentissage neuronal de caractéristiques spatio-temporelles pour la classification automatique de séquences vidéo. Thèse de l'Institut National des Sciences Appliquées de Lyon.193p.
20. Aib.B.(2019). Vers une détermination des vrais influenceurs sur les réseaux sociaux. Mémoire de Fin d'études Master. Faculté des Mathématiques, d'Informatique et des Sciences de la matière Département d'Informatique. Université de 8 Mai 1945 – Guelma .57p

#### **Webgraphie :**

- 1.[https://datascientest.com/intelligence-artificielle-definition#:~:text=L'histoire%20de%20l'intelligence%20artificielle%20d%C3%A9bute%20en%201943%2C,d'un%20r%C3%A9seau%20de%20neurones](https://datascientest.com/intelligence-artificielle-definition#:~:text=L%27histoire%20de%20l%27intelligence%20artificielle%20d%27%C3%A9bute%20en%201943%2C,d'un%20r%C3%A9seau%20de%20neurones)
- 2.<https://www.hubi.ai/blogfr/concepts-cles-machine-learning/>
- 3.<https://www.jedha.co/formation-ia/algorithm-perceptron>
- 4.<https://www.voxco.com/fr/blog/regression-lineaire-multiple/>
- 5.<https://elearning-facsci.univ-annaba.dz/user/view.php?id=8209&course=1>
- 6.<https://www.data-transitionnumerique.com/anaconda-python/>.

**Nom et prénom : CHAIB Gouzlane**

**Nom et prénom : BOUZENTAL Ilhem**

**Nom et prénom : LOUZAT Abir**

**Nom et prénom : BOUGHAGHA Inès**

---

**Titre :** Modélisation de l'évaporation à partir des plans d'eau (EP) par les Algorithms du Machine Learning: Développement Sur les plates Forme Anaconda & Spyder et R-Studio.

**Résumé :**

Au cours des dernières années, l'intérêt pour l'utilisation de modèles d'intelligence artificielle a considérablement augmenté et leurs applications se sont étendues pour inclure tout ce qui est lié à la vie quotidienne de l'homme. Dans le domaine de l'irrigation et des sciences agricoles, le besoin croissant d'introduire et de proposer ces modèles est devenu inévitable. Cette étude s'inscrit dans le cadre de la préparation d'un mémoire de fin d'études (Master II) en Aménagement Hydro-Agricole. Elle vise à développer des modèles mathématiques et à les améliorer pour calculer l'évaporation à partir des plans d'eau, qui est un élément essentiel du cycle hydrologique. Pour cela nous avons utilisé deux modèles de réseaux de neurones artificiels: (i) le Multilayer Perceptron Neural Network (MLPNN), (ii) Generalized Regression Neural Network (GRNN), et en comparant les résultats avec (iii) le modèle de régression linéaire multiple (MLR). Pour développer ces modèles, nous avons utilisé des données climatiques provenant de quatre stations : Constantine, Sétif, Guelma et Mila. Au niveau de chaque station, nous avons collecté une base de données contenant des mesures quotidiennes enregistrées durant la période allant de 2004 à 2013, comprenant les variables suivantes: (i) température maximale ( $T_{max}$ ), (ii) température minimale ( $T_{min}$ ), (iii) vitesse du vent ( $U_2$ ), (iv) humidité relative (H%), (v) rayonnement solaire (SR). Ces variables ont été utilisées comme entrées pour modéliser l'évaporation (EP). La base de données a été divisée en deux parties: 70% pour l'apprentissage et 30% pour évaluer la capacité des modèles à prédire correctement l'évaporation quotidienne (validation). Nous avons utilisé un ensemble de critères de performances numériques pour la validation et l'évaluation des modèles: (i) Coefficient de corrélation (R), (ii) Coefficient de Nash-Sutcliffe efficiency (NSE), (iii) erreur absolue moyenne (MAE), (iv) racine carrée de l'erreur quadratique moyenne (RMSE). Afin d'étudier l'impact des différentes variables sur la réponse des modèles, nous avons comparé 12 modèles avec différentes combinaisons de variables climatiques. Les résultats ont démontré la capacité des réseaux de neurones artificiels à calculer l'évaporation (EP) avec une excellente précision, surpassant le modèle de régression linéaire. Les calculs étaient hautement prédictifs, avec des R et des NSE compris entre 0.97 et 0.99. Ces résultats sont très encourageants et ouvrent des perspectives futures prometteuses.

**Mots-Clés :** l'évaporation à partir des plans d'eau, modèles d'intelligence artificielle, MLPNN, GRNN, stations météorologiques, variables climatiques, apprentissage, validation.

## ملخص:

خلال السنوات الأخيرة زاد بشكل كبير الاهتمام باستعمال نماذج الذكاء الاصطناعي وتوسعت استعمالاتها لتشمل كلما يرتبط بالحياة اليومية للإنسان، ففي مجال الري والعلوم الزراعية أصبحت الحاجة المتزايدة لإدخال واقتراح هذه النماذج حتمية لا مفر منها. تدخل هذه الدراسة في اطار تحضير مذكرة نهاية التخرج تخصص ماستر تهيئة مائية -فلاحية و التي تهدف الى اعداد نماذج رياضية و تطويرها لحساب التبخر من المساحات المائية الذي يعتبر مكونا أساسيا في الدورة الهيدرولوجية . من اجل ذلك قمنا باستعمال نموذجان من الشبكات العصبية الاصطناعية وهما: (i) الشبكة العصبية متعددة الطبقات (ANN)، (ii) شبكة الانحدار العصبي المعمم (GRNN) مع مقارنة النتائج ب (iii) نموذج الانحدار الخطي (MLR). من اجل تطوير هذه النماذج الرياضية استعملنا معطيات مناخية تخص اربع محطات وهي قسنطينة ، سطيف ، قالمة ،ميلة على مستوى كل محطة قمنا بجمع قاعدة بيانات تحتوي على قياسات يومية و التي توافق الفترة الممتدة من (2004- 2013) و تتمثل في المتغيرات التالية: (i) درجة الحرارة القصوى ( $T_{max}$ )، (ii) درجة الحرارة الدنيا ( $T_{min}$ )، (iii) سرعة الرياح ( $U_2$ )، (iv) الرطوبة النسبية ( $H\%$ )، (v) الاشعاع الشمسي (SR) والتي استعملت كنماذج لنمذجة التبخر (EP). قسمت قاعدة البيانات الى قسمين % 70 من اجل تدريب و تطوير النموذج (Apprentissage) و% 30 من اجل تقييم قدرة النموذج على التنبؤ الصحيح بالتبخر اليومي (Validation). قمنا باستعمال مجموعة من معايير التحقق الاحصائي والتي تمثل في: (i) معامل الارتباط (R)، (ii) معامل الكفاءة (NSE)، (iii) متوسط الخطأ المطلق (MAE)، (iv) الجذر التربيعي لمربع الخطأ (RMSE). من اجل التعرف على تأثير مختلف المتغيرات على استجابة النموذج الرياضي قارنا ما بين 12 نموذج بتشكيلات مختلفة من المتغيرات المناخية . اثبتت النتائج المتحصل عليها قدرة الشبكات الاصطناعية على حساب التبخر (EP) بدقة ممتازة وتجاوزت نموذج المنحدر الخطي وكانت الحسابات ذات دقة تنبؤية عالية حيث وصل معامل الارتباط (R) ومعامل الكفاءة (NSE) ما بين (0.99, 0.97) (تعتبر النتائج المتحصل عليها جد مشجعة و تفتح آفاق مستقبلية و اعدة

**الكلمات المفتاحية:** التبخر من المساحات المائية ، نماذج الذكاء الاصطناعي ، محطات مناخية متغيرات مناخية، تدريب النموذج ، تقييم النموذج .