

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

"الجمهورية الجزائرية الديمقراطية الشعبية"

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY
UNIVERSITE BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Faculté des Sciences de l'Ingéniorat
Département d'Hydraulique

Année : 2019-2020

THESE

Présentée En vue de l'obtention du diplôme de Doctorat en Hydraulique

Contribution à la modélisation de l'évaporation à partir des barrages réservoirs par le biais de l'intelligence artificielle : Application au nord de l'Algérie

Option Hydraulique

Par

Mr. SEBBAR ABDERRAZEK

Devant le jury

Président	: Pr.	AMARCHI Hocine	UNIV. Badji Mokhtar, Annaba
Rapporteur	: Pr.	HEDDAM Salim	UNIV. 20 Août 1955 Skikda
Co-Rapporteur:	Pr.	DJEMILI Lakhdar	UNIV. Badji Mokhtar, Annaba
Examineur	: Pr.	HOUICHI Larbi	UNIV. Batna 2
Examineur	: MCA.	LAOUACHERIA Fares	UNIV. Badji Mokhtar, Annaba
Examineur	: MCA.	ZEGHADNIA Lotfi	UNIV. Cherif Messaâdia, Souk-Ahras

Remerciements

Et voilà ! Les meilleures choses ont une fin.

Au terme de ce modeste travail, je remercie ALLAH, le tout puissant, le miséricordieux pour m'avoir aidé à réaliser ce travail.

Ce ne sont pas des mots si personnels soient-ils qui arriveront à exprimer ma gratitude et mes remerciement et ma reconnaissance à tous ceux qui m'ont aidé à réaliser ce modeste travail.

*Tout d'abord, Je voudrai exprimer ma profonde gratitude à mon directeur de thèse **Pr. Heddám Salim**, de m'avoir encadré, guidé par ses conseils pour la réalisation de ce travail., et surtout par ses grandes qualités humaines. Judicieux et sa vision à long terme.*

*Mes vifs remerciements vont également à mon co-encadrant, **Pr. Djemíli Lakhdar** Professeurs à l'université d'ANNABA pour son aide et son encouragement.*

J'adresse également mes sincères remerciements aux membres du jury qui ont accepté d'évaluer se travail et malgré leur occupations, ils ont eu le temps d'évaluer ce travail et nous faire part de leurs critiques qui ne feront qu'améliorer la qualité de ce travail. Je cite en particulier :

*Pr. Amarchí Hocíne Université d'Annaba
Pr. Houíchí Larbí Université de Batna 2
Dr. Laaouchría Fares Université d'Annaba
Dr. Zeghadnia Lotfi Université de Souk Ahras*

Mes gratitudes vont aussi à tous mes enseignants et mes collègues durant mon cursus universitaire.

Mes sincères remerciements s'adressent aux directeurs des barrages zones nord est d'Algérie qui nous ont porté aide pour l'acquisition des données hydro-climatiques suet les mesures de l'évaporation.

De même, je remercie tous ceux qui ont participé de près ou de loin à la réalisation de ce travail.



Dédicaces

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

- *Mes chers parents pour tous les sacrifices qu'ils ont consentis, pour tous les encouragements ainsi que pour leur soutien qui m'a permis de mener à terme le travail en question.*

Je le dédie également à:

- *Ma femme et mes enfants pour leur encouragement, patience et compréhension ;*
- *Mes chers frères, sœurs et gendres ;*
- *Toute ma grande famille et tous mes proches.*
- *Mes amis et mes collègues de travail.*



ملخص

يعتبر التبخر مكوناً أساسياً في الدورة الهيدرولوجية، وهو يلعب دوراً مؤثراً في تطوير وإدارة الموارد المائية. تهدف هذه الدراسة إلى بناء نموذج رياضي لتقدير ونمذجة التبخر الإنائي Epan اليومي و الشهري على مستوى خزانات السدود المتواجدة في الشمال الشرقي بالجزائر باستخدام الذكاء الاصطناعي (IA) كأداة قوية لزيادة القدرة على التنبؤ بالعلاقات الخطية وغير الخطية في المشاكل الهندسية المعقدة و كذا مقارنة النتائج المتحصل عليها ومن بينها الشبكات العصبية الاصطناعية (ANN)، و نظام الاستدلال الضبابي (ANFIS) وشعاع الدعم الآلي (SVM)، وقد اعتمدت الدراسة من أجل ذلك على القيم اليومية و الشهرية لدرجة حرارة الهواء الصغرى (T_{min}) و القصوى (T_{max})، الرطوبة النسبية (H%) و سرعة الرياح (U) كمداخلات، ومن ثم دراسة تأثير إضافة معامل الزمن (اليوم و الشهر) على تقدير التبخر. كما استُخدمت بيانات التبخر الإنائي Epan اليومي و الشهري المقيسة بوساطة حوض التبخر الأميركي صنف A كمخرجات مأمولة لغرض التحقق من صحة أداء الشبكة. بني النموذج الرياضي باستخدام برنامج الماتلاب كأداة للبرمجة ، كما استُخدمت خوارزمية الانتشار العكسي للخطأ في عملية تدريب وتحقيق الشبكة مع تغيير طرائق التدريب وعدد الطبقات الخفية وعدد العصبونات و دوال التنفيع المستخدمة في كل طبقة منها. أظهرت النتائج القدرة الجيدة لنماذج الذكاء الاصطناعي على التنبؤ بقيم التبخر Epan الإنائي اليومي و الشهري بدقة عالية في منطقة الدراسة اعتماداً على معايير الأداء بما في ذلك ، معامل الارتباط (R)، و معامل ويلموت (d) ، وجذر متوسط مربعات الأخطاء (RMSE) ومقياس متوسط الأخطاء المطلقة (MAE). وبهذا فان الدراسة توصي باستخدام تقنية الذكاء الاصطناعي كأداة لنمذجة التبخر اليومي و الشهري في الشمال الشرقي بالجزائر.

الكلمات المفتاحية: الذكاء الاصطناعي ، الشبكات العصبية الاصطناعية، نظام الاستدلال الضبابي، شعاع الدعم الآلي، نمذجة، التنبؤ، التبخر الإنائي، خزانات السدود، شمال الجزائر.

Abstract

E evaporation process plays an important role in the hydrological cycle and water balance, where the computation of the amount of evaporated water is considered one of the more practical issues of interest to the modern hydrological studies. Over the years, artificial intelligence techniques have been applied as a powerful tool to increase the predictability of linear and non-linear relationships for several complex engineering problems. This study is aiming at building a mathematical models for modelling daily and monthly evaporation E_{pan} from dams reservoir in the North-East region of Algeria, based on four metrological variables namely, minimal and maximal temperatures (T_{min} , T_{max}), relative humidity ($H\%$), and wind speed (U_2), using artificial intelligence techniques. Artificial intelligence techniques used in the present study contains three branches. The first branch is the artificial neural networks (ANN), the second branch is the so-called adaptive neuro-fuzzy inference systems (ANFIS), and finally the third branch is the support vector machine (SVM). In addition to the four climatic variables, the periodicity as represented by the day and the month number was examined in order to show its effect on the models accuracy. The mathematical models was developed using the Matlab software as a programming tool, using the daily and monthly value of the above variables as model inputs, and the evaporation measured from the American pan class A used as the model output. The study found that the artificial intelligence techniques were able to predict the daily and monthly evaporation E_{pan} with high accuracy, based on the statistical performance criteria especially the correlation coefficient (R), Wilmot's Index (d), root mean square error (RMSE) and mean absolute error (MAE).

Keywords: Modeling, Evaporation, Artificial intelligence, Artificial neural networks (ANN), Adaptive neuro-fuzzy inference systems (ANFIS), Support vector machine (LSSVM), reservoir dams, Algeria.

Résumé

*L'*évaporation joue un rôle important dans le cycle hydrologique et le bilan hydrique, où l'estimation de la quantité d'eau évaporée est considérée comme l'une des questions ayant le plus d'intérêt pour les études hydrologiques modernes. La présente étude vise à développer des modèles mathématiques pour l'estimation de l'évaporation E_{pan} à partir des barrages-réservoirs dans la région Nord-Est de l'Algérie, mesurée à partir du bac américain classe A, par les techniques à base d'intelligence artificielle, à savoir les réseaux de neurones artificiels (ANN), les systèmes Neuro-flous type ANFIS (les systèmes d'inférence floue à base de réseaux de neurones adaptatifs), et les machines à vecteurs de support (SVM). Quatre variables climatiques ont été sélectionnées comme entrées des modèles: les températures maximale et minimale (T_{min} , T_{max}), l'humidité relative (H%), et la vitesse du vent (U_2). En plus, la périodicité représentée par le numéro du jour et du mois, a été ajouté aux entrées pour tester son effet sur les performances des modèles développés. Les modèles ont été développés sous le logiciel Matlab en tant qu'outil de programmation. L'étude a révélé que l'intelligence artificielle permet une estimation robuste de l'évaporation journalière et mensuelle E_{pan} avec une grande précision dans la zone d'étude, tout en tenant compte des critères de performances statistiques communément utilisés, notamment le coefficient de corrélation (R), l'indice de Wilmmot (d), l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne (MAE). Cette étude recommande d'utiliser les approches d'intelligence artificielle pour modéliser l'évaporation E_{pan} à différents pas de temps dans le Nord-Est de l'Algérie.

Mots-clés: Modélisation, Evaporation, Intelligence artificielle, Réseaux de Neurones Artificiels (ANN), Neuro-flous (ANFIS), machines à vecteurs de support (SVM), Barrage réservoirs, Nord de l'Algérie.

Liste des abréviations

E_{pan}: l'évaporation dans le bac
ANN: Artificial neural networks
H%: l'humidité relative
U₂: vitesse du vent (m/s)
T_{max}: Température maximale de l'air (C°)
T_{min}: Température minimale de l'air (C°)
RNA: Réseaux de neurones artificiels
GP: Génétique Programming,
WNN: Wavelet neural network,
LGP: Linear genetic programming,
FGP: Fuzzy genetic,
WR: Wavelet regression,
ENN: Evolutionary neural networks,
MVRVM: Multivariate Relevance Vector Machine,
GEP: Gene-expression programming,
SVM: Support vector machines,
MLR: Multiple linear regressions,
GT: Gamma test,
SOM: Kohonen Self-Organizing Map,
LSSVM: Least squares support vector machine,
MFGA: Mamdani Fuzzy genetic approach,
SFGA: Sugeno Fuzzy genetic approach,
WNN: Wavelet neural network,
ONM: Office National de la Météorologie
PMC: Perceptron multicouche
MLPNN: Multi layer perceptron neural network
RBFNN: Radial basis function neural network
GRNN: Generalized regression neural network
ANFIS: adaptive neuro-fuzzy inference systems
ANRH: Agence National des Ressources Hydrauliques
R: correlation coefficient
d: Wilmot's Index
RMSE: root mean square error
MAE: mean absolute error
IA: intelligence artificielles

Liste des figures

Chapitre I: L'évaporation & Concept Généraux

Figure I.1	Cycle hydrologique globale	04
Figure I.2	L'atmomètre de Bellain	07
Figure I.3	Le bac classe A barrage Bougous El Taref.	08
Figure I.4	Le bac GGI-3000 et Bac flottant	08

Chapitre II: Présentation Des Modèles A Base D'intelligence Artificielle

Figure II.1	Le Neurone biologique	17
Figure II.2	Modèle non-linéaire d'un neurone formel	18
Figure II.3	Quelques types des fonctions d'activations	19
Figure II.4	Réseau de neurones non boucles	20
Figure II.5	Réseau de neurone bouclé	20
Figure II.6	Organigramme de conception d'un réseau de Neurones.	22
Figure II.7	Structure du perceptron Multicouches (MLPNN)	23
Figure II.8	Architecture détaillé d'un Réseaux de neurones RBFNN	24
Figure II.9	Architecture détaillé d'un réseau de neurones GRNN	25
Figure II.10	Architecture détaillé d'un modèle ANFIS	28
Figure II.11	Un exemple de classification par SVM	29
Figure II.12	Architecture des SVR	31

Chapitre III: Présentation De La Zone D'étude & Traitement Des Données

Figure III.1	Localisation de la région d'étude	33
Figure III.2	Les grandes unités physiques de l'Est-Algérien	34
Figure III.3	Situation géographiques des barrages retenus	36

Chapitre IV: modélisation de l'évaporation E_{pan} au pas de temps journalier par les techniques a base d'intelligence artificielle

Figure IV.1	Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Chafia, phase de test.	54
Figure IV.2	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Chafia, phase de test.	56

Figure IV.3	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Beni Zid, phase de test.	61
Figure IV.4	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Beni Zid, phase de test.	65
Figure IV.5	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.	67
Figure IV.6	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.	70
Figure IV.7	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage <i>El Agram</i> , phase de test.	74
Figure IV.8	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage <i>El Agram</i> , phase de test.	77
Figure IV.9	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Hammam Grouz, phase de test.	80
Figure IV.10	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Hammam Grouz, phase de test.	82
Figure IV.11	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage <i>Bouhamdane</i> , phase de test.	85
Figure IV.12	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage <i>Bouhamdane</i> , phase de test.	88
Figure IV.13	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Ain Zada, phase de test.	91
Figure IV.14	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Ain Zada, phase de test.	93

Chapitre V: Modélisation de l'évaporation E_{pan} au pas de temps mensuel par les techniques a base d'intelligence artificielle

Figure V.1	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Chafia, phase de test.	99
Figure V.2	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Chafia, phase de test.	100
Figure V.3	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Beni Zid, phase de test.	104
Figure V.4	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Beni Zid, phase de test.	105
Figure V.5	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Zit Emba, phase de test.	109
Figure V.6	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Zit Emba, phase de test.	110
Figure V.7	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>El Agram</i> , phase de test.	113
Figure V.8	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>El Agram</i> , phase de test.	115
Figure V.9	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Hammam Grouz, phase de test.	118

Figure V.10	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Hammam Grouz, phase de test.	120
Figure V.11	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>Bouhamdane</i> , phase de test.	122
Figure V.12	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>Bouhamdane</i> , phase de test.	123
Figure V.13	<i>Scatterplot</i> des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>Ain zada</i> phase de test.	126
Figure V.14	Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage <i>Ain Zada</i> , phase de test.	127

Liste des tableaux

Chapitre II: Présentation des modèles a base d'intelligence artificielle

Tableau II.1.	Fonctions d'activation comparées au seuil θ .	18
---------------	--	----

Chapitre III: Présentation de la zone d'étude & traitement des données

Tableau III.1.	Présentation des Barrages Réservoirs	36
Tableau III.2.	Taille de la base de données utilisée	36
Tableau III.3.	Variabes climatiques utilisées	37
Tableau III.4.	Paramètres statistiques de la base de données utilisée (journalières)	38
Tableau III.5.	Paramètres statistiques de la base de données utilisée (mensuels)	39
Tableau III.6.	Ordre de présentation des différentes variables climatiques	42
Tableau III.7.	Nombre de scénarios testés pour chaque type de modèle	43
Tableau III.8.	Meilleurs Mask obtenus par la technique GT au pas de temps journalier	43
Tableau III.9.	Résultats correspondant au meilleur Mask au pas de temps journalier.	43
Tableau III.10.	Meilleurs Mask obtenus par la technique GT au pas de temps mensuel	44
Tableau III.11.	Résultats correspondant meilleur Mask au pas de temps mensuel	44
Tableau III.12.	Structure des modèles utilisés.	45

Chapitre IV: Modélisation de l'évaporation E_{pan} au pas de temps journalier par les techniques a base d'intelligence artificielle

Tableau IV.1.	Répartition de la base de données utilisée au pas de temps journalier	47
Tableau IV.2.	Performances des modèles journaliers au niveau du Barrage Chafia	57
Tableau IV.3.	Résultats récapitulatif des meilleures modèles pour barrage Chafia	56
Tableau IV.4.	Performances des modèles journaliers au niveau du Barrage Beni Zid	63
Tableau IV.5.	Résultats récapitulatif des meilleures modèles pour barrage Beni Zid	66
Tableau IV.6.	Performances des modèles journaliers au niveau du Barrage Zit Emba	71
Tableau IV.7.	Résultats récapitulatif des meilleures modèles pour barrage Zit Emba	72
Tableau IV.8.	Performances des modèles journaliers au niveau du Barrage <i>El Agram</i>	75
Tableau IV.9.	Résultats récapitulatif des meilleures modèles pour barrage <i>El Agram</i>	78
Tableau IV.10.	Performances des modèles journaliers au niveau du Barrage Hammam Grouz	83
Tableau IV.11.	Résultats récapitulatif des meilleures modèles pour barrage Hammam Grouz	84
Tableau IV.12.	Performances des modèles journaliers au niveau du Barrage <i>Bouhamdane</i>	89
Tableau IV.13.	Résultats récapitulatif des meilleures modèles pour barrage <i>Bouhamdane</i>	90
Tableau IV.14.	Performances des modèles journaliers au niveau du Barrage Ain Zada	94
Tableau IV.15.	Résultats récapitulatif des meilleures modèles pour barrage Ain Zada	95

Chapitre V: Modélisation de l'évaporation E_{pan} au pas de temps mensuel par les techniques à base d'intelligence artificielle

Tableau V.1.	Répartition de la base de données utilisée au pas de temps journalier	98
Tableau V.2.	Performances des modèles mensuels au niveau du Barrage Chafia	101
Tableau V.3.	Résultats récapitulatif des meilleures modèles pour barrage Chafia	103
Tableau V.4.	Performances des modèles mensuels au niveau du Barrage Beni Zid	106
Tableau V.5.	Résultats récapitulatif des meilleures modèles pour barrage Beni Zid	108
Tableau V.6.	Performances des modèles mensuels au niveau du Barrage Zit Emba	111
Tableau V.7.	Résultats récapitulatif des meilleures modèles pour barrage Zit Emba	112
Tableau V.8.	Performances des modèles mensuels au niveau du Barrage <i>El Agram</i>	114
Tableau V.9.	Résultats récapitulatif des meilleures modèles pour barrage <i>El Agram</i>	117
Tableau V.10.	Performances des modèles mensuels au niveau du Barrage Hammam Grouz	119
Tableau V.11.	Résultats récapitulatif des meilleures modèles pour barrage Hammam Grouz	121
Tableau V.12.	Performances des modèles mensuels au niveau du Barrage <i>Bouhamdane</i>	124
Tableau V.13.	Résultats récapitulatif des meilleures modèles pour barrage <i>Bouhamdane</i>	125
Tableau V.14.	Performances des modèles journaliers au niveau du Barrage Ain Zada	128
Tableau V.15.	Résultats récapitulatif des meilleures modèles pour barrage Ain Zada	129

Table des matières

<i>Introduction générale</i>	01
-------------------------------------	-----------

<i>Chapitre I : L'évaporation & Concept Généraux</i>	03
---	-----------

I.1.Introduction	04
I.2.Notions liées à l'évaporation	04
I.3. Facteurs météorologiques conditionnant l'évaporation	05
I.3.1.La Température	05
I.3.2.L'humidité de l'air	06
I.3.3.Le rayonnement solaire	06
I.4. Facteurs physique conditionnant l'évaporation	06
I.5. Classification des différentes Méthodes d'estimation de l'Epan	07
I.5.1.Les méthodes directes	07
I.5.1.1. Les atmomètres et évaporimètres	07
I.5.1.2. Les bacs évaporatoires	08
I.5.2. Les méthodes indirectes ou empiriques	09
I.5.3. Les méthodes à base d'Intelligence Artificielles (IA)	09
I.5.3.1. Application des modèles à base des ANN pour la modélisation de l'Epan	10
I.5.3.2.Application des SVM pour la modélisation de l'Epan	12
I.5.3.3. Application des Réseaux d'Ondelettes pour la modélisation de l'E _{pan}	12
I.5.3.4. Application des modèles ANFIS pour la modélisation de l'Epan	13
I.5.3.5. Application des Algorithmes Evolutionnaires pour la modélisation de	13
I.6. Conclusion	14

<i>Chapitre II : présentation des modèles a base d'intelligence</i>	15
--	-----------

II.1. L'Intelligence Artificielle	16
II.1.1.Historique	16
II.1.2.Définition	16
II.2. Les Réseaux de Neurones Artificiels	16
II.2.1.Introduction	16
II.2.2. Historique des Réseaux de Neurones Artificiels	16
II.2.3. Neurones biologique	17
II.2.4. Le Neurone Artificiel	17
II.2.4.1.Définitions	19
II.2.5.Architecture des Réseaux de Neurones	19
II.2.5.1. Les Réseaux de Neurones non Bouclés	20
II.2.5.2. Les Réseaux de Neurones Bouclés	20
II.2.6. Apprentissage des Réseaux de Neurones	20
II.2.6.1. Apprentissage Supervisé	21
II.2.6.2. Apprentissage non Supervisé	21

II.2.6.3. Apprentissage Renforcé	21
II.2.7. Algorithme de <i>Rétro-Propagation</i>	21
II.3. Conception d'un Réseau de Neurones Artificiels	22
II.4. Les perceptrons Multicouches MLPNN	22
II.5. Les Réseaux de Neurones à Fonctions de base Radiales (RBFNN)	23
II.5.1. Présentation des RBFNN	23
II.6. Réseaux de neurones à fonction de régression générale (GRNN)	25
II.7. Les modèles ANFIS	26
II.8. Les Machines A Vecteurs De Support (SVM)	28
II.8.1. Introduction	28
II.8.2. Les SVM pour la Régression (SVR)	30
II.9. Conclusion	31

Chapitre III : Présentation de la Zone D'étude & traitement des données

III.1. Présentation de la Région d'Etude	33
III.1.1. Situation Géographique	33
III.1.2. Les Aspects Topographiques	33
III.1.3. Le Réseau Hydrographique et Climat	34
III.1.4. Le Climat	34
III.1.4.1. La pluviosité	35
III.1.4.2. Les Températures	35
III.2. Présentation et Description de la base de Données Utilisée	35
III.2.1. Introduction	35
III.2.2. Situation Géographique des Barrages et Stations Climatiques	35
III.3. Analyse Statistique des données	37
III.3.1. Statistiques Descriptives	37
III.3.2. La technique Gamma Test (GT)	39
III.3.2.1. Introduction	39
III.3.2.2. L'implémentation de la technique Gamma Test	40
III.3.2.3. Formulation mathématique de la Technique Gamma Test	40
III.3.2.4. Analyse des données à l'aide de la Technique GT	42
III.3.2.5. Application de la Technique GT avec quatre (04) variables	42
III.3.2.6. Résultats obtenues par la Technique GT	43
III.3.2.6.1. Résultats obtenues au pas de temps journalier	43
III.3.2.6.2. Résultats Trouvées au pas de Temps Mensuelle	44
III.3.2.7. Structures des Modèles Sélectionnés	45
III.4. Conclusion	45

Chapitre IV : Modélisation de l'évaporation E_{pan} au pas de temps journalier par les techniques à base d'intelligence artificielle 46

IV.1. Introduction	47
IV.2. Critères de validation et de performances des modèles	47
VI.3. La mise en œuvre des différents modèles	49
IV.4. Résultats de l'application des modèles et analyse comparative	64
IV.4.1. Résultats de la modélisation pour le Barrage Chafia	51
IV.4.1.1. Résultats récapitulatif des différents modèles pour barrage Chafia	58
IV.4.2. Résultats de la modélisation pour le Barrage Beni Zid	59
IV.4.2.1. Résultats récapitulatif des différents modèles pour barrage Beni Zid	65
IV.4.3. Résultats de la modélisation pour le Barrage Zit Emba	66
IV.4.3.1. Résultats récapitulatif des différents modèles pour barrage Zit Emba	72
IV.4.4. Résultats de la modélisation pour le Barrage <i>El Agram</i>	72
IV.4.4.1. Résultats récapitulatif des différents modèles pour barrage <i>El Agram</i>	78
IV.4.5. Résultats de la modélisation pour le Barrage Hammam Grouz	78
IV.4.5.1. Résultats récapitulatif des différents modèles pour barrage Hammam	84
IV.4.6. Résultats de la modélisation pour le Barrage <i>Bouhamdane</i>	84
IV.4.6.1. Résultats récapitulatif des différents modèles pour barrage <i>Bouhamdane</i>	90
IV.4.7. Résultats de la modélisation pour le Barrage Ain Zada	90
IV.4.7.1. Résultats récapitulatif des différents modèles pour barrage Ain Zada	95
IV.5. conclusion	95

Chapitre V : Modélisation de l'évaporation E_{pan} au pas de temps mensuel par les techniques à base d'intelligence artificielle 97

V.1. Introduction	98
V.2. Résultats de l'application des modèles et analyse comparative	98
V.2.1. Résultats de la modélisation pour le Barrage Chafia	98
V.2.1.1. Résultats récapitulatif des différents modèles pour barrage Chafia	102
V.2.2. Résultats de la modélisation pour le Barrage Beni Zid	103
V.2.2.1. Résultats récapitulatif des différents modèles pour barrage Beni Zid	107
V.2.3. Résultats de la modélisation pour le Barrage Zit Emba	108
V.2.3.1. Résultats récapitulatif des différents modèles pour barrage Zit Emba	112
V.2.4. Résultats de la modélisation pour le Barrage <i>El Agram</i>	112
V.2.4.1. Résultats récapitulatif des différents modèles pour barrage <i>El Agram</i>	116

V.2.5. Résultats de la modélisation pour le Barrage Hammam Grouz	117
V.2.5.1. Résultats récapitulatif des différents modèles pour barrage Hammam Grouz	120
V.2.6. Résultats de la modélisation pour le Barrage <i>Bouhamdane</i>	121
V.2.6.1. Résultats récapitulatif des différents modèles pour barrage <i>Bouhamdane</i>	125
V.2.7. Résultats de la modélisation pour le Barrage Ain Zada	125
V.2.7.1. Résultats récapitulatif des différents modèles pour barrage Ain Zada	129
V.3. Conclusion	130

<i>Conclusion générale</i>	131
-----------------------------------	-----

<i>Référence bibliographique</i>	134
---	-----

Introduction générale

L'eau, une des plus importantes ressources naturelles, doit être protégée de manière à garantir de façon durable son équilibre entre les besoins et les utilisations. Le développement durable des activités humaines s'appuie, en particulier, sur une gestion intégrée des eaux. Une gestion efficace et durable des eaux ne se limite pas à garantir, en moyenne, une quantité et une qualité suffisantes pour les demandes humaines (eau potable, industrielle, d'irrigation,...) et pour les besoins des milieux naturels; elle doit aussi prendre en compte la manifestation des événements extrêmes, tels que les étiages et les crues. La quantité et la qualité des ressources en eau disponibles posent des problèmes de plus en plus complexes et difficiles à résoudre. La consommation d'eau augmente considérablement et la pénurie se fait sentir dans de nombreux pays en voie de développement. Une gestion intégrée des ressources en eau s'impose donc pour accompagner un développement durable qui puisse concilier le développement socio-économique et la préservation de l'environnement. Chaque année, plus de 250 nouveaux barrages réservoirs sont construits dans le monde, reflétant l'importance donnée à ces ouvrages de stockage par les gouvernements et ceci malgré leurs effets néfastes sur les écosystèmes (Dams 2000).

A l'instar des pays de la rive Sud du bassin méditerranéen, l'Algérie, pays à climat essentiellement semi-aride à aride dans la majeure partie de son territoire, est confronté au problème du développement et de la gestion durable de ses ressources en eau. En effet, bien que disposant d'importantes chaînes de montagnes, d'une large ouverture maritime et par une grande disparité géographique, ces ressources en eau sont limitées vis à vis d'une forte demande qui résulte de la croissance démographique, de l'amélioration des conditions de vie, du développement des différentes industries et de l'extension de l'irrigation. L'Algérie compte actuellement 75 barrages d'une capacité totale de 6.50 milliards de mètres cubes. Le gouvernement entend faire passer à 139 le nombre total de barrages en Algérie d'ici 2030, et, ce faisant, atteindre une capacité de stockage de près de 12 milliards de mètres cubes sur l'ensemble du pays (MRE 2019).

Le phénomène de l'évaporation des lacs de barrages en Algérie est considérable. Une perte de volume très élevée est enregistrée annuellement. Elle tient elle-même à plusieurs facteurs parmi lesquels le vent, l'insolation et la température. Plus la durée de la saison sèche est longue plus l'importance de l'évaporation est forte. On mesure alors, l'importance de cet élément quand on sait que, même dans les régions les plus humides, il existe une saison sèche d'une durée de plus de trois mois, qui tarit les écoulements, et exclut les cultures sans irrigation. Ce qui ressort clairement des quelques stations relevées plus bas et qui montrent que l'évaporation croît sensiblement du Nord au Sud. Cette évaporation est donc importante à la surface des lacs et notamment les retenues des barrages et des réservoirs à ciel ouvert. Ce pouvoir évaporatoire est illustré par la diminution des stocks au niveau des barrages, pendant la période chaude notamment.

La construction et l'exploitation d'un barrage réservoir exige la connaissance de l'évaporation en surface libre, qui intervient dans le calcul de la régularisation des apports, pour le dimensionnement du barrage, et dans les calculs du bilan hydrique de la retenue pendant l'exploitation. Il existe plusieurs méthodes de calcul de l'évaporation. Les plus connues entre elles, sont: (i) les mesures directes sont effectuées par des appareils, plus ou

moins normalisés, soumis aux phénomènes évaporatoires, qui mesurent une variation de la quantité d'eau. On recense principalement deux types d'appareils, les atmomètres, évaporimètres et les bacs évaporatoires (Vachala 2008), (ii) les méthodes indirectes ou méthodes hydrométéorologiques, basée sur la loi physique de Dalton. Les valeurs numériques de cette méthode sont des données standards qui sont toujours disponibles dans les atlas et les bulletins météorologiques de l'Office National de la Météorologie, et (iii) les méthodes indirectes à base d'intelligence artificielles. Il existe plusieurs types de modèles à base d'intelligence artificielles: (i) les réseaux de neurones artificiels (ANN), (ii) les modèles Neuro-floues, (iii) les modèles à base de machines à vecteurs de supports (SVM), (iv) les modèles utilisant les séries temporelles ou chronologiques, (v) les modèles utilisant Les algorithmes évolutionnaires et (vi) les modèles à base de réseaux de neurones combinées avec les réseaux d'ondelettes.

Cette thèse s'inscrit dans le domaine de la modélisation de l'évaporation et de sa représentation à l'échelle des barrages réservoirs. Notre objectif principal est de modéliser l'évaporation journalière et mensuelle de sept grands barrages réservoirs situés en climat semi-aride Nord-Est de l'Algérie, à l'aide des méthodes à base de l'intelligence artificielles. Afin de répondre aux objectifs de cette recherche, le travail a été organisé et présenté en cinq chapitres comme suit:

- Le premier chapitre est consacré à une étude bibliographique sur les concepts généraux de l'évaporation des eaux de surface, les facteurs physiques et météorologiques conditionnant l'évaporation, les différentes méthodes de mesures et un état de l'art sur les modèles déjà existants sur la modélisation de l'évaporation.
- Dans le deuxième chapitre, les modèles à base d'intelligence artificielle utilisées dans le cadre de cette thèse, à savoir les réseaux de neurones artificiels (ANN), le système d'inférence floue à base de réseau adaptif (ANFIS), et les machine à supports de vecteurs (SVM) sont présentées. Cette présentation concerne les notions utilisées dans ces modèles, leurs principes de fonctionnement, fondement mathématique et leurs liaisons avec la modélisation de l'évaporation.
- Le troisième chapitre est consacré à la description générale de la région d'étude qui comprend la situation géographique des différents barrage réservoirs étudiés à l'échelle du Nord-Est de l'Algérie, présentation des caractéristiques géologiques et climatologiques (aperçu sur le climat) de la zone d'étude, l'analyse statistique et le traitement des données climatiques utilisées. Enfin, nous avons présenté l'outil Gamma Test (GT) utilisé dans la sélection des variables pertinentes dans la construction des modèles.
- Le quatrième chapitre est consacré à l'analyse des résultats obtenus au pas de temps journalier par les différents modèles.
- Le cinquième chapitre est consacré à l'analyse des résultats obtenus au pas de temps mensuelle par les différents modèles.
- Enfin, nous terminons avec une conclusion générale, qui englobe les principales démarches effectuées et les résultats obtenus par cette étude.

Chapitre I: L'Evaporation & Concept Généraux

I.1. Introduction

L'évaporation (E_{pan}) est le processus par lequel un élément passe de l'état liquide à l'état de vapeur dont les principales sources sont les plans d'eau et la couverture végétale. Dans le contexte du cycle de l'eau, cela suppose un processus complémentaire qui est la condensation de la vapeur d'eau contenue dans l'atmosphère. Le principal facteur qui favorise l'évaporation est la radiation solaire. A l'échelle du globe, évaporation et précipitations se compensent annuellement (sauf lors des phases de changements climatiques qui touchent les stocks de glace polaire). L'évaporation océanique paraît être le facteur le plus important du cycle. Chaque année, ce sont (Koli 2016):

1. 430 000 km³ d'eau qui sont restitués à l'atmosphère; dont 52% par le pacifique, 24/24% par l'Atlantique et l'Indien;
2. Par contre, l'évaporation et l'évapotranspiration continentale donnent 75000 km³ d'eau.

L'évaporation est une phase essentielle du cycle de l'eau à partir des océans et mers, elle est la source d'eau pour les continents; et avec la condensation, elle assure les transferts d'eau et d'énergie (chaleur latente) à l'échelle du globe (Koli 2016).

En hydrologie, on utilise le plus souvent le terme d'évaporation totale ou d'évapotranspiration; ce dernier processus prend en compte l'évaporation directe, physique (à partir de l'eau libre) et la transpiration végétale, biologique (des plantes vers l'atmosphère). La figure suivante représente schématiquement les différents éléments intervenant dans les processus d'interception et d'évaporation qui feront l'objet de ce chapitre (Figure I.1).




Figure I.1. Cycle hydrologique globale (<http://www.futura-sciences.com/magazines/environnement/>)

I.2. Notions liées à l'évaporation

L'évaporation est un phénomène clé dans de très nombreux domaines, comme l'hydrologie, la météorologie, le séchage, la régulation thermique du corps humain, ainsi que dans de nombreux dispositifs ou équipement industriels. La définition de l'évaporation varie selon les auteurs si bien qu'il est parfois difficile de distinguer entre évaporation, vaporisation et

ébullition. Il est toutefois assez classique d'admettre que l'évaporation se produit à la surface libre d'un liquide (ce qui la distingue ainsi de l'ébullition de paroi) et qu'elle se produit à une température inférieure à la température de saturation, ce qui peut la distinguer de la simple vaporisation (Aldomany 2017). On peut distinguer les principales notions suivantes:

1. Le taux de l'évaporation est défini comme étant la quantité d'eau, en masse ou en volume, évaporée d'une unité de surface par rapport à une unité de temps. L'unité de temps est normalement le jour. La quantité d'eau évaporée doit être exprimée en millimètre (OMM 2003).
2. Transformation plus ou moins lente d'un liquide en vapeur. L'évaporation de l'eau et de toutes sortes de liquides se fait naturellement, soit par la seule action de l'air, soit par la chaleur du soleil (Vachala 2008).
3. L'évaporation est le transfert des masses d'eau ou autre substance dans le phénomène de l'évaporation que est conditionné par la différence des pressions partielles de vapeur existant au voisinage de la surface et dans l'atmosphère libre (Dalton 1802; Segal et Burstein 2010).
4. L'évaporation se définit comme étant le passage de la phase liquide à la phase vapeur, il s'agit de l'évaporation physique. Les plans d'eau et la couverture végétale sont les principales sources de vapeur d'eau. On parle de sublimation lors du passage direct de l'eau sous forme solide (glace) en vapeur. Le principal facteur régissant l'évaporation est la radiation solaire (Liamas 1993 ; Lambert 1996). Ce processus nécessite de l'énergie afin de casser les liens qui existent entre les molécules d'eau lors du changement d'état. Ce processus se produit à la surface des océans, mers et plans d'eau continentaux ou à la surface des milieux humides (sol, végétal,...) (Beltrando 2011).

I.3. Facteurs météorologiques conditionnant l'évaporation

Par suite des difficultés que présentent les observations directes de l'évaporation sur les lacs et réservoirs, on a généralement tendance à utiliser des méthodes indirectes d'évaluation basées sur le bilan hydrique, le bilan énergétique ou la mécanique des fluides. Les facteurs météorologiques qui entrent dans ce mode d'évaluation sont le rayonnement solaire et le rayonnement de grande longueur d'onde, les températures de l'air et de la surface de l'eau, l'humidité atmosphérique ou la tension de vapeur et le vent. Les facteurs conditionnels de l'évaporation sont assez nombreux (Roche 1963). Nous retiendrons les suivants:

1. Température de l'air;
2. La température de l'eau;
3. L'humidité de l'air;
4. Le rayonnement solaire;
5. La vitesse du vent;
6. La pression atmosphérique.

I.3.1. La Température

Dans l'air, il existe des particules d'eau aux propriétés physiques très différentes; si bien que lorsque deux particules d'eau se rencontrent, il y a interaction (elles ne se mélangent pas) ce qui entraînent des échanges d'énergie très importants qui donnent naissance à la

température. Ces transferts d'énergie peuvent avoir lieu grâce à la conduction : transfert de la chaleur d'un point à un autre sans que les propriétés physiques de la particule d'air soient modifiées. La température se mesure, soit en degré Celsius (astronome et physicien Suédois 1701-1744) noté °C, soit en degré Kelvin (alias William Thomson, physicien britannique 1824-1907) noté K tel que $T(\text{Kelvin}) = T(\text{Celsius}) + 273.15 \text{ K}$.

Les températures maximales et minimales journalières sont les variables les plus fréquemment employées. La température de l'air est disponible sur de très longues séries, parfois sur plus de 50 ans (Koli 2016).

1.3.2. Le vent

Le vent est un paramètre important pour l'estimation de l'évaporation car il permet le renouvellement des masses d'air non saturées à la surface de la retenue, et maintient ainsi un certain pouvoir évaporant de l'air. La mesure du vent est facilement accessible, soit auprès de Météo-Algérie, soit auprès des aérodromes, aéroports ou barrages. Les données sont disponibles en valeurs horaires ou en moyennes journalières ou mensuelles (Roche 1963).

1.3.3. L'humidité de l'air

C'est la quantité de vapeur d'eau qui se trouve dans une particule d'air. L'humidité est présente en permanence dans l'atmosphère et même au niveau du Sahara. La raison est la suivante: les rayons du soleil réchauffent la surface de la Terre et provoquent l'évaporation de l'eau des Océans ou de certaines réserves d'eau dans le Sahara. Il arrive à un moment donné qu'une particule d'air soit saturée en vapeur d'eau mais pas tout le temps; l'humidité relative est donc la quantité d'eau présente dans une particule d'air sur la quantité d'eau que peut contenir la particule d'air (Koli 2016).

1.3.4. Le rayonnement solaire

Le rayonnement solaire est l'élément moteur des conditions météorologiques et climatiques, et par voie de conséquence, du cycle hydrologique. Son action intéresse l'atmosphère, l'hydrosphère et la lithosphère, par émission, convection, absorption, réflexion, transmission, diffraction ou diffusion. L'émission solaire se situe essentiellement dans une bande de longueur d'onde allant de 0.25 à 5 mm (Musy 2005). Le rayonnement solaire fournit la chaleur nécessaire aux surfaces pour créer une évaporation. Il existe plusieurs appareils de mesure du rayonnement (pyranomètre, pyréliomètre, piles thermoélectriques...) (Roche 1963).

1.4. Facteurs physique conditionnant l'évaporation

On distingue (Musy 2005):

1. Évaporation à partir des surfaces d'eau libre (salinité, température, profondeur, étendue).
2. Évaporation à partir d'un sol nu (teneur en eau du sol, capillarité, couleur du sol et albédo).
3. Évaporation de la neige (densité, type, etc.)

I.5. Classification des différentes Méthodes d'estimation de l' E_{pan}

L'évaporation (E_{pan}) est la transformation plus ou moins lente d'un liquide en vapeur. L'évaporation de l'eau et de toutes sortes de liquides se fait naturellement, soit par la seule action de l'air, soit par la chaleur du soleil. On distingue deux méthodes d'estimation de l'évaporation: les méthodes directes et les méthodes indirectes à base de formules empiriques et à base d'intelligence artificielles (IA). L'évaporation peut être directement mesurée par des appareils, normalisés. On recense principalement deux types d'appareils: (i) les atmomètres et les évaporimètres et (ii) les bacs évaporatoires. Les méthodes indirectes d'estimation d' E_{pan} reposent sur l'utilisation des variables climatiques plus ou moins nombreuses et plus ou moins faciles à mesurer (Dalton 1802b; Penman 1948; Morton 1967, 1979, 1983a, 1983b, 1986; Riou 1967, 1970, 1977; Winter et al. 2003; Xu and Singh 1998, 2000, 2001, 2002). L'évaporation est un phénomène complexe et non linéaire parce qu'il dépend de plusieurs facteurs climatiques, tels que la température, l'humidité, la vitesse du vent, la durée d'insolation, etc. (Vachala 2008).

I.5.1. Les méthodes directes

Les mesures directes sont effectuées par des appareils normalisés, soumis aux phénomènes évaporatoires, qui mesurent une variation de quantité d'eau. On recense principalement deux types d'appareils, les atmomètres, évaporimètres et les bacs évaporatoires (Vachala 2008).

I.5.1.1. Les atmomètres et évaporimètres

Les atmomètres et évaporimètres mesurent le pouvoir évaporateur de l'air ou l'évaporation latente, définie comme l'évaporation maximale d'une surface saturée, plane, horizontale, noire et exposée aux conditions météorologiques du milieu étudié (Arnaud and Lavabre 1999). Plusieurs appareils ont été développés à cet effet, l'évaporimètre Piche, l'évaporimètre de Livingstone, l'atmomètre de Bellani, etc. Cependant ces appareils sont peu adaptés à la mesure de l'évaporation des surfaces d'eau libre (Aldomany 2017). En effet, ils sont souvent situés dans des abris météorologiques et ne prennent pas en compte tous les paramètres atmosphériques (comme le vent, le degré d'insolation...), ainsi que l'inertie thermique du volume d'eau. Leur utilisation première est la mesure de l'évapotranspiration et non l'évaporation d'une surface d'eau libre (Aldomany 2017).




Figure I.2. L'atmomètre de Bellain (Aldomany 2017).

1.5.1.2. Les bacs évaporatoires

Les bacs d'évaporation sont les instruments les plus communément utilisés pour mesurer l'évaporation. Actuellement, il y a plus de vingt-cinq modèles différents et la liste va continuer à augmenter (Maidment 1993). En général, les bacs d'évaporation sont des appareils constitués d'un bassin ou d'une cuve d'assez grandes dimensions, dans lequel on mesure l'abaissement du niveau de l'eau sous l'action de l'évaporation. Au contraire des premiers bacs utilisés par Halley, Dobson, Dalton...etc., où les dimensions sont petites (voir très petites), les bacs d'évaporation ont des dimensions plus grandes. Certains sont carrés, d'autres cylindriques; certains sont installés au-dessus du sol, d'autres sont enterrés de façon à ce que l'eau soit sensiblement au même niveau que le sol. Les bacs d'évaporation sont parfois installés sur des plates-formes flottantes ancrées sur des lacs ou d'autres plans d'eau. La raison principale pour fabriquer ces bacs était la difficulté d'accéder à la mesure directe de l'évaporation d'une surface d'eau. Parmi les différents types de bacs évaporatoires nous pouvons citer (Aldomany 2017):

1. **Le bac de classe A:** développé par le Weather Bureau. Bac round de 122cm de diamètre, 25.4cm de profondeur. Il est posé à 18cm au-dessus du sol et l'eau à l'intérieur du bac doit affleurer à 5-8cm du bord (Aldomany 2017).
2. **Le bac Colorado:** est un bac carré de 91.4 cm de côté, et de 46 à 91cm de profondeur. Il est enterré de manière à ce que son rebord soit à 10cm au-dessus de la surface du sol. Il existe des variantes du bac Colorado, notamment la version ORSTOM (Aldomany 2017).
3. **Les bacs Russe, GGI 3000 et le bac de 20m²:** sont aussi très utilisés. Bacs circulaires enterrés, à base conique de 62cm de diamètre et 61cm de profondeur pour le premier, et 5m de diamètre et 2m de profondeur pour le deuxième (Aldomany 2017).
4. Les bacs flottants sont partiellement immergés à la surface de l'eau. Cette mesure est la plus représentative des conditions d'évaporation de la surface d'eau libre mais est très difficile à mettre en œuvre et très coûteuse (Aldomany 2017).




Figure I.3. Le bac classe A barrage Bougous El Taref.



Figure I.4. Le bac GGI-3000 et Bac flottant (Stan et al. 2016).

L'ensemble de ces mesures permet d'obtenir une mesure de l'évaporation plus ou moins fine. Le gros avantage est de pouvoir constituer des séries de données journalières voire horaires. Il faut cependant être très prudent concernant la mesure obtenue. Les résultats sont intimement liés aux caractéristiques des bacs et de leur lieu d'implantation. A cela il faut rajouter les possibles erreurs de mesure, dues souvent, en climat aride, à la présence d'animaux venant s'abreuver. La pose de grillages est peu recommandée car elle perturbe la mesure du vent. La mesure n'est pas universelle et il faut adapter les coefficients de passage selon le climat et les dimensions de la retenue considérée. Très peu d'auteurs ont procédé à la réalisation de bacs flottants (Aldomany 2017).

1.5.2. Les méthodes indirectes ou empiriques

Il existe de nombreuses formules de calcul de l'évaporation. Certaines sont plus ou moins complexes. Une liste plus exhaustive est disponible dans les études d'Arnaud et al. (2000) et Singh et Xu (1997). Les formulations ayant été établies pour la plupart dans la première moitié du XXème. Les formules ci-après sont écrites dans leur version d'origine et les coefficients ne sont pas modifiés. On distingue : (i) les méthodes basées sur le transfert de masse (Dalton 1802b; Fitzgerald 1886; Meyer 1915; Horton 1917; Rohwer 1931; Penman 1948 ; Romanenko 1961), (ii) les méthodes basées sur le rayonnement (Makkink 1957; Turc 1961; Priestley 1972; Linacre 1993) et (iii) la formule algérienne de Boutoutaou (1995). Pour la première catégorie; les méthodes sont très faciles à mettre en œuvre car elles ne nécessitent que la température et le vent comme paramètres d'entrée (la tension de vapeur saturante peut aussi être utile mais n'est pas indispensable car elle peut être approchée par une formule utilisant la température du point de rosée) (Vachala 2008). Les méthodes basées sur le rayonnement sont moins évidents que les méthodes basées sur le transfert de masse car elles utilisent des paramètres plus difficilement mesurables. Pour la formule de Boutoutaou, elle est établie pour les conditions climatiques de l'Algérie. Le modèle de calcul de l'évaporation est le suivant (Boutoutaou 1995):

$$E_{pan} = 0.233 \times n(e_s - e_a)(1 + 0.39V) \quad (I.1)$$

Où: E_{pan} évaporation en mm; e_s correspond à la tension de vapeur d'eau saturante à la température de la surface évaporante en millibar; e_a est tension de vapeur d'eau dans l'atmosphère en millibar; $(e_s - e_a)$ le déficit de saturation dans l'atmosphère, millibar; V est la vitesse du vent (m/s); n le nombre de jours du mois considéré. Cette formule a été appliquée en 2011 sur trois barrages réservoirs en Algérie Ain Zada (Sétif), Ksob (Msila), Fergoug (Mascara). La comparaison a montré que la différence entre les valeurs calculées par la formule et mesurées au niveau des différents barrages ne dépasse pas $\pm 25\%$. L'erreur systématique de calcul n'apparaît pas. Cette différence n'est pas tout à fait homogène (un petit peu élevée en hiver et en automne et faible en printemps et en été) durant l'année (Boutoutaou 2011).

1.5.3. Les méthodes à base d'Intelligence Artificielles (IA)

Il existe plusieurs types de modèles à base d'intelligence artificielles (IA) utilisées pour la quantification et la modélisation de l'évaporation: (i) les réseaux de neurones artificiels (ANN), (ii) les modèles Neuro-flous à base de la logique floue, (iii) les modèles à base de machines à vecteurs de supports (SVM), (iv) les modèles utilisant les séries temporelles ou chronologiques,

(v) les modèles utilisant Les algorithmes évolutionnaires et (vi) les modèles à base de réseaux de neurones combinées avec les réseaux d'ondelettes.

I.5.3.1. Application des modèles à base des ANN pour la modélisation de l' E_{pan}

Han and Felker (1997) furent les premiers à utiliser les réseaux de neurones artificiels pour la modélisation de l' E_{pan} journalière en USA. Ils ont appliqués le modèle des réseaux de neurones à fonctions de base radiales (RBFNN) en utilisant quatre variables climatiques comme entrées du modèle, à savoir: la vitesse du vent (U_2), la température moyenne de l'air (T_{moy}), l'humidité relative moyenne ($H\%$), et la teneur en eau du sol ($H_s\%$). Bruton et al. (2000) ont appliqués un modèle de type perceptron multicouche (MLPNN) pour estimer l' E_{pan} journalière mesuré à partir des bacs d'évaporation. Les données climatiques utilisées comprennent 2044 données mesurées entre 1992 à 1996 à Georgia USA. Les T_{moy} , $H\%$, le rayonnement solaire (SR) et U_2 ont été utilisés comme variables d'entrées. Le modèle MLPNN a été légèrement plus performant que le modèle à base de régression linéaire multiple (MLR). Sudheer et al. (2002) ont étudiés la modélisation de l' E_{pan} mesurer dans les bacs classe A par le modèle MLPNN, en utilisant les températures minimale et maximale (T_{min} , T_{max}), l'humidité relative maximale et minimale (H_{min} , H_{max}), SR et U_2 . Plusieurs combinaisons des variables climatiques ont été utilisées et les résultats obtenus ont été comparés avec celles obtenus par les formules empiriques, et les résultats ont démontrés les capacités des modèles MLPNN dans la modélisation du processus d'évaporation. Özlem and Keski (2005) ont estimé l' E_{pan} mesurée à partir du bac d'évaporation par un modèle MLPNN en utilisant six variables climatique, mesuré à la station Automated Gro Weather près du lac Egirdir à l'ouest de la Turquie, à savoir la T_{moy} , la température de l'eau (T_w), SR , la pression de l'air (Pr), U_2 et $H\%$. Les résultats ont montré que le modèle MLPNN fournit de bonnes estimations avec le moins d'erreur quadratique moyenne (RMSE). Keskin and Özlem (2006) ont proposés un MLPNN comme approche alternative de l'estimation de l'évaporation au niveau du lac Egirdir en Turquie. Ils ont fixés trois objectifs: (1) développer les modèles MLPNN pour estimer l' E_{pan} journalière à partir des données météorologiques, (2) comparer le modèles MLPNN au modèle de Penman, and (3) évaluer numériquement les potentiels des modèles MLPNN. Les variables météorologiques utilisées comprennent les observations journalières, T_{moy} , T_w , la durée d'ensoleillement (SH), SR , Pr , $H\%$ et (U_2). Les résultats ont montrés qu'il y a une meilleure concordance entre les estimations du modèle MLPNN et les mesures de l' E_{pan} journalières à partir du bac d'évaporation, et que le MLPNN fournie de meilleures performances par apport au modèle de Penman. Stephen et al. (2007) ont utilisé le model MLPNN pour la modélisation de l' E_{pan} à pas de temps horaires et journaliers, dans les zones à climat équatorial en Singapore. Les auteurs ont utilisés quatre variables climatiques comme entrées du modèle : T_{moy} , SR , U_2 , et $H\%$. Les résultats obtenus par le modèle MLPNN ont été comparés aux modèles empiriques basées sur le rayonnement, température, et sur les méthodes basées sur le transfert de masse. Ils ont conclu que le MLPNN donne de meilleurs résultats. Deswal and Mahesh Pal (2008) ont utilisé le modèle MLPNN pour étudier l'influence de différentes combinaisons des variables climatique sur l' E_{pan} hebdomadaire en Inde. Plusieurs variables d'entrée ont été utilisés pour prédire l' E_{pan} . La précision de prédiction par la technique MLPNN était également comparée avec les précisions obtenues par la régression linéaire (MLR). La comparaison à démontrer que les performances du MLPNN étaient meilleures. Les résultats de cette étude ont indiqué une corrélation très élevée ($R=0.960$), RMSE plus bas (0.865) en utilisant les T_{moy} , U_2 , SH , et $H\%$.

Kisi (2009) a comparé les MLPNN et RBFNN appliquées pour l'estimation de l' E_{pan} , en utilisant les T_{moy} , SR, U_2 , Pr et H%, à pas de temps mensuels, mesurés au niveau de trois stations en USA. Les deux modèles ont été comparés avec les MLR et les méthodes de Stephens-Stewart (SS) sont également considérées pour la comparaison. Les auteurs ont étudiés aussi la capacité de calcul des modèles MLPNN, RBFNN, MLR et SS pour l'estimation de l' E_{pan} en utilisant des données pour des stations proches. Il a été démontré que les modèles MLPNN et RBFNN pouvaient être utilisées avec succès dans la modélisation de l' E_{pan} mensuel. Shirsath and Singh (2009) ont appliqués le MLPNN, MLR et les modèles empirique à savoir; Penman, Priestley-Taylor et SS, pour l'estimation de l' E_{pan} journalière, en utilisant cinq variables climatiques: T_{min} , T_{max} , SR, U_2 et H%. Les résultats des modèles MLPNN, MLR ainsi que des modèles empiriques ont été comparés statistiquement avec les valeurs de l' E_{pan} du bac. Les résultats obtenus ont montrés que les performances du modèle MLPNN ont été plus meilleures. Moghaddammia et al. (2009) ont estimé l' E_{pan} à pas de temps journalier dans les régions arides et semi-aride de l'Iran, par les modèles MLPNN et ANFIS. Il a été démontré que les modèles MLPNN et ANFIS ont de bien meilleures performances que les formules empiriques. Tabari et al. (2010) ont estimé l' E_{pan} journalières en utilisant le MLPNN et la méthode de régressions non linéaires multiples (MNL) en Iran. La comparaison des modèles à montrer que le modèle MLPNN utilisant un algorithme d'apprentissage Delta-Bar-Delta et une fonction d'activation sigmoïde fournie de meilleures performances. Kim et al. (2012) ont appliqué les modèles de réseaux de neurones pour estimer l' E_{pan} au niveau de différentes zones climatiques tempérées et arides en République de Corée et Iran. Trois types de modèles ont été utilisés: MLPNN, RBFNN et les machines à vecteurs de support (SVM), en utilisant les T_{moy} , U_2 , SR, H% et le rayonnement terrestre (Ra). Les résultats obtenus par les SVM étaient meilleures que le MLPNN et le GRNN pour estimer l' E_{pan} journalière. Kim et al. (2013) ont appliqués trois modèles de réseaux de neurones pour estimer l' E_{pan} journalière en Corée du Sud: MLPNN, GRNN et le système d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS), en utilisant les données climatiques de deux stations sur une période de 6 ans : T_{moy} , U_2 , SH, H%, SR, et l' E_{pan} . Les résultats obtenus ont montré la supériorité du modèle MLPNN.

Malik and Kumar (2015) ont appliqués deux modèles: le MLPNN, et le modèle Coactive ANFIS (CANFIS) pour l'estimation de l' E_{pan} en Inde. Les résultats ont indiqués que les performances du modèle MLPNN étaient supérieures aux modèles CANFIS et MLR. Wang, et al. (2016) ont comparés six modèles dans l'estimation de l' E_{pan} mensuelle: MLPNN, réseaux de neurones à fonction de régression générale (GRNN), génétique floue (FG), machine à vecteurs de support à base des moindres carrés (LSSVM), les modèles à base de régression multivariées par splines adaptative (MARS), le modèle ANFIS avec partition carrée (ANFIS-GP), et deux méthodes de régression: MLR et SS. Les données de huit stations climatiques en chine, à savoir T_{moy} , SR, SH, H% et U_2 , sur une période allant de 1961 à 2000 ont été utilisées pour le développement des modèles. Les résultats ont montrés que les modèles ont des degrés de précision différents selon les stations, et que le modèle MLPNN a été supérieur aux autres modèles dans la plupart des stations, alors que le modèle GRNN a mieux fonctionné dans le Plateau Tibétain. Ghorbani et al. (2017) ont introduit un nouveau modèle hybride appelé MLPNN-FFA basé sur l'optimisation par l'algorithme de Luciole (Firefly: FFA), qui est intégré avec le MLPNN est développé et évalué pour la prédiction de l' E_{pan} . Les résultats ont montrés qu'un modèle MLPNN-FFA surpasse le modèle MLPNN standard. Les résultats obtenus ont démontrés l'importance de l'algorithme de Firefly appliqué pour améliorer les performances du modèle MLPNN, tel que démontré par ses meilleures performances prédictives par rapport au

modèle MLPNN. Malik et al. (2018) ont exploré le potentiel des modèles MLPNN, CANFIS et MLR dans la simulation de l' E_{pan} hebdomadaire à Pantnagar, en Inde. Un outil de modélisation non linéaire, à savoir le gamma test (GT), a été utilisé pour identifier les variables d'entrée les plus significatifs pour les approches MLPNN, CANFIS et MLR. L' E_{pan} simulée à l'aide de ces techniques a été comparée aux modèles empiriques tels que SS et Griffith (GF) basés sur l'erreur quadratique moyenne (RMSE), Nash-Sutcliffe (NSE) et le coefficient de corrélation (R). Les résultats de la comparaison ont révélé que le modèle MLPNN donnait de meilleurs résultats que les modèles CANFIS, MLR, SS et GF dans la modélisation de l' E_{pan} hebdomadaire à l'aide des variables climatiques (T_{min} , T_{max} , H_{max} %, H_{min} %, SH, U_2).

I.5.3.2. Application des SVM pour la modélisation de l' E_{pan}

Eslamian et al. (2008) ont montrés l'efficacité des machines à vecteurs de support (SVM) dans l'estimation de l' E_{pan} . Plusieurs variables climatiques, y compris T_{moy} , SR, U_2 , H% et les précipitations (P), ont été utilisés comme entrées des modèles. Les R^2 des modèles MLPNN et SVM obtenus ont été respectivement 0.940 et 0.936. Shalamu et al. (2011) ont appliqués le modèle de régression à base des moindres carrés partiels (PLSR) dans l'estimation de l' E_{pan} journalière en utilisant: T_{min} , T_{max} , H_{max} %, H_{min} %, SR, et U_2 , mesurées au niveau de deux stations météorologiques situées près du réservoir Elephant Butte, au New-Mexico, USA, et une station météorologique située en Chine. La relation non linéaire entre les variables climatiques et l' E_{pan} journalière a été modélisée avec succès en utilisant l'approche PLSR en résolvant la colinéarité qui existe dans les variables climatiques. Les résultats de la modélisation ont été comparés à des modèles MLPNN avec les mêmes variables d'entrée. Les résultats ont montré que les équations non linéaires développées en utilisant le PLSR ont des performances similaires avec une approche MLPNN. Deo et al. (2016) ont appliquées trois modèles, à savoir, les machine à vecteur de pertinence (RVM), machine a apprentissage extrême (ELM) et le modèle MARS pour la prédiction de l' E_{pan} mensuelle, en utilisant plusieurs variables prédictives : SR, T_{max} , T_{min} , et P. Les performance des modèles en termes de coefficients de corrélation (R) ont été de l'ordre de 0.979 pour RVM, 0.977 pour ELM et 0.974 pour MARS. Malgré les petites différences dans la précision de prédiction globale, le modèle RVM semble être plus précis dans la prédiction de l' E_{pan} . Deo et al. (2017) ont comparés plusieurs modèles: LSSVM, la régression par processus gaussien (GPR), les machines de régression à base de probabilité min/max (MPMR) et les modèles de programmation génétique (GP), pour la modélisation de l' E_{pan} journalière pour la ville de Brisbane Queensland Australie. Les résultats ont démontrés la supériorité du LSSVM par rapport aux modèles GP, GPR et MPMR pour la modélisation de l' E_{pan} journalière. Wang, et al. (2017) ont comparés plusieurs modèles à savoir, la génétique floue FG, LSSVM, MARS, model d'arbre (M5Tree) et le modèle MLR, dans l'estimation de l' E_{pan} journalière. Les résultats globaux indiquent que les modèles ci-dessus peuvent être utilisés avec succès pour estimer l' E_{pan} journalière en utilisant les données d'entrée et de sortie locales alors que les LSSVM et FG fonctionnent généralement mieux que les autres modèles sans entrées et sorties locales.

I.5.3.3. Application des Réseaux d'Ondelettes pour la modélisation de l' E_{pan}

Au lieu d'utiliser des fonctions d'activation sigmoïde dans le réseau MLPNN, la fonction d'ondelette a été appliquée pour construire un réseau de neurones d'ondelettes, appelé WNN

(Abghari et al. 2012). La comparaison du WNN avec le MLPNN a montré que l'ondelette mère type mexicaine pourrait avoir une meilleure précision dans la modélisation de l' E_{pan} journalière. Dans une autre étude, Pammar et Deka (2017) ont modélisé l' E_{pan} journalière en employant un modèle hybride constitué des SVM et de la décomposition en ondelettes (DWT). L'étude a été réalisée sur deux zones climatique contrastées de la station Bajpe et Bangalore, en inde. Les modèles hybrides de DWT-SVR sont été supérieurs aux modèles SVR conventionnels.

I.5.3.4. Application des modèles ANFIS pour la modélisation de l' E_{pan}

Le modèle le plus utilisé et le plus reporté en littérature est sans doute le modèle d'inférence floue à base de réseaux de neurones adaptatifs (Adaptive Neurofuzzy Inference System: ANFIS). Le modèle ANFIS combine à la fois la logique floue et les réseaux de neurones. Kisi (2006) a étudié les capacités du modèle ANFIS pour l'estimation de l' E_{pan} journalière en utilisant plusieurs variables climatiques, à savoir la T_{moy} , SR, U_2 , Pr et H%. Les résultats obtenus par le modèle ANFIS ont été comparés avec celles obtenus avec le modèle MLPNN et la méthode SS. Sur la base des comparaisons, il a été démontré que le modèle ANFIS pourrait être utilisée avec succès dans la modélisation du processus d'évaporation, Le model MLPNN a également fournie de meilleurs résultats que la méthode SS. Terzi et Keskin (2006) ont appliqués le modèle ANFIS pour l'estimation de l' E_{pan} journalière, en utilisant les SR, T_{moy} , T_w , et H%. Le modèle ANFIS a fournie des résultats meilleurs que la formule empirique de Penman. Dogan et al. (2010) ont proposés le modèle ANFIS comme une approche alternative à l'estimation de l' E_{pan} pour le barrage de Yuvacik en Turquie. Diverses combinaisons de données météorologiques journalières, à savoir la T_{moy} , H%, SR et U_2 , sont utilisées comme données d'entrée pour l'ANFIS afin d'évaluer le degré d'effet de chacune de ces variables sur l' E_{pan} journalière. Les résultats du modèle ANFIS sont comparés à celle du modèle MLR. Sur la base des comparaisons, Le model ANFIS a également donné de meilleurs résultats que la méthode MLR. Sanikhani et al. (2012) ont étudié la capacité de deux modèles, incluant ANFIS avec le partitionnement carrée (ANFIS-GP) et ANFIS avec le regroupement soustractif (ANFIS-SC), dans la modélisation de l' E_{pan} journalière. Les résultats obtenus par les deux modèles ANFIS-GP et ANFIS-SC sont comparés avec les modèles de régression non linéaire multiple (MNLr), MLPNN, SS et Penman. Les résultats obtenus indiquent que ANFIS-GP et ANFIS-SC sont supérieurs aux MNLr, MLPNN, SS et Penman dans la modélisation de l' E_{pan} . Kisi and Tombul (2013) Ont étudié la capacité de l'approche génétique floue (FG) dans l'estimation de l' E_{pan} mensuelle, dans la région méditerranéenne de Turquie. Les résultats ont montré que les modèles FG ont donnés de meilleurs résultats que les modèles ANFIS et MLPNN, et que le modèle FG fournissait l'estimation la plus proche de l' E_{pan} . Wang et al (2017) ont étudié les capacités de trois méthodes d'estimation de l' E_{pan} mensuelle en utilisant la T_{moy} , SR, Pr et U_2 , mesurés durant la période allant de 1961 à 2000. Les résultats obtenus ont démontrés que le modèle FG peut être utilisé avec succès pour estimer l' E_{pan} .

I.5.3.5. Application des Algorithmes Evolutionnaires pour la modélisation de l' E_{pan}

Sivapragasam et al (2017), furent les premiers à proposer un algorithme évolutionnaire (AE) pour la modélisation de l' E_{pan} . Ils ont appliqués une approche basée sur la programmation génétique (GP). Les résultats du modèle GP ont été comparés avec celle de Penman. Guven et Kisi (2011) Ont étudié la capacité de la programmation génétique linéaire (LGP), qui est une extension de la GP, dans la modélisation de l' E_{pan} journalière, en utilisant la T_{moy} , SR, U_2 , Pr, et

H%, mesurés au niveau de trois stations météorologiques, Fresno, Los Angeles et San Diego en Californie, USA. Les estimations par le modèle LGP sont comparées à celles de la programmation génétique d'expression GEP, qui est une autre branche de GP, des MLPNN, RBFNN, GRNN et de SS. Basé sur la comparaison, il a été démontré que la technique LGP pourrait être utilisée avec succès dans la modélisation du processus d'évaporation à partir des données climatiques disponibles, et elle dépasse les autres techniques en termes de performances. Kisi (2013) a proposé l'application des réseaux neuronaux évolutionnaire (ENN) pour la modélisation de l' E_{pan} mensuelles, dans la région méditerranéenne de Turquie. Il a été conclu que l' E_{pan} mensuelles peut être estimées avec succès par la méthode ENN. Kisi et Tombol (2013) ont utilisés la GEP et le modèle ANFIS comme approches alternative pour estimer l' E_{pan} journalière du lac Egirdir dans la partie sud-ouest de la Turquie, et il a constaté que le modèle GEP était plus meilleure que le modèle ANFIS.

I.6. Conclusion

Dans ce chapitre, nous avons présenté d'une manière générale quelques définitions relatives à l'évaporation avec les différentes méthodes de mesure, soit les méthodes directes ou les méthodes indirectes pour la mesure de l'évaporation. En effet nous avons donné un bilan détaillé sur les méthodes de modélisation de l'évaporation. Dans ce contexte nous avons exposé les techniques de modélisation de l'évaporation les plus couramment utilisées dans littératures. La sélection de l'un de ces approches est basée essentiellement sur les variables climatiques. Dans notre présent travail, nous nous intéresserons aux techniques de de modélisation de l'évaporation utilisant les méthodes l'intelligence artificielles pour la quantification de l'évaporation dans les barrages réservoirs.

*Chapitre II : Présentation Des Modèles à base D'intelligence
Artificielle*

II.1. L'Intelligence Artificielle

II.1.1. Historique

L'Intelligence Artificielle, branche de l'Informatique fondamentale s'est développée avec objectif la simulation des comportements du cerveau humain. Les premières tentatives de modélisation du cerveau sont anciennes et précèdent même l'ère informatique. C'est en 1943 que [Mc-Culloch et Pitts](#) ont proposé les premières notions de neurone formel ([Dreyfus, 1998](#)) Ce concept fut ensuite mis en réseau avec une couche d'entrée et une sortie par [Rosenblatt en \(1959\)](#) pour simuler le fonctionnement rétinien et tacher de reconnaître des formes: le perceptron ([Tschirhart 2010](#)). Au début des années 80 plusieurs travaux ont permis de relancer l'approche connexionniste. Celle-ci a connu au début des années 90 un développement considérable si l'on considère le nombre de publications et de congrès qui lui ont été consacrés mais aussi les domaines d'applications très divers où elle apparaît ([Tschirhart 2010](#)).

II.1.2. Définition

Terme créé par [John McCarthy \(1956\)](#): construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant accomplies de façon plus satisfaisantes par des êtres humains car elles demandent des processus mentaux de haut niveau tels que l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique ([Minsky, 1969](#)).

II.2. Les Réseaux de Neurones Artificiels

II.2.1. Introduction

Les réseaux de neurones artificiels (ANN) connaissent depuis quelques années un succès croissant dans divers domaines des sciences de l'ingénieur, celui des sciences hydrologiques et ressources en eau n'échappe pas à cette règle. Dans ce chapitre, nous rappellerons les définitions et notations de base relatives aux réseaux de neurones artificiels (ANN). Nous poursuivrons en exposant les types et la méthodologie d'apprentissage. Nous présenterons aussi, d'une manière générale, les étapes de conception d'un réseau de neurones: le choix des entrées et sorties, la structure du réseau, etc.....

II.2.2. Historique des Réseaux de Neurones Artificiels

Les recherches menées dans le domaine du connexionnisme ont démarré avec la présentation en 1943 par [Mc-Culloch et Pitts](#) d'un modèle simplifié de neurone biologique communément appelé neurone formel. Ils montrèrent théoriquement que des ANN formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes ([Mc-Culloch et Pitts 1943](#)). En 1949, [Hebb](#) initie, dans son ouvrage "*The Organization of Behavior*", la notion d'apprentissage: On parle de loi de Hebb. En 1958, [Rosenblatt](#) développe le modèle du Perceptron. Il possède deux couches de neurones : une couche de perception (sert à recueillir les entrées) et une couche de décision ([Rosenblatt 1958](#)). S'inspirant du perceptron, [Widrow and Hoff \(1960\)](#), développent, dans la même période, le modèle de l'Adaline (*Adaptive Linear Element*). En 1982, [Hopfield](#) développe un modèle qui utilise des

réseaux totalement connectés basés sur la règle de Hebb pour définir les notions d'attracteurs et de mémoire associative (Hopfield 1982). Une révolution survient dans le domaine des réseaux de neurones artificiels: le perceptron multicouche (MLPNN) ne possède pas les défauts mis en évidence par M. Minsky (Minsky et Papert 1988). Le Perceptron Multicouche a été introduit par Rumelhart (1986), ces systèmes reposent sur la Rétro-Propagation du gradient de l'erreur dans des systèmes à plusieurs couches. De nos jours, l'utilisation des ANN dans divers domaines ne cesse de croître (Ammar 2007).

II.2.3. Neurones biologique

Un neurone biologique (Figure II.1) est une cellule qui se caractérise par:

- Synapses : points de connexion avec les autres neurones.
- Dendrites: signaux d'entrée.
- Axone: signal de sortie.
- Noyau qui active la sortie en fonction des stimuli en entrée (Touzet 1992)




Figure II.1. Le Neurone biologique (Touzet 1992)

II.2.4. Le Neurone Artificiel

Par analogie, un neurone artificiel est conçu comme un automate doté d'une fonction de transfert qui transforme ses entrées en sortie selon des règles précises. Chaque neurone artificiel est un processeur élémentaire (Mc-Culloch et al. 1943; Minsky et al. 1969). Il reçoit un nombre de variables d'entrées en provenance de neurones en amont. A chacune de ses entrées est associé un poids représentatif de la force de la connexion (Touzet 1992). Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre de neurones en aval. A chaque connexion est associé un poids (Touzet 1992). Il est commode de représenter graphiquement un neurone comme indiqué sur la (Figure II.2).

Le neurone réalise alors trois opérations sur ses entrées:

- Pondération: multiplication de chaque entrée par un paramètre appelé poids.
- Sommation: une sommation des entrées pondérées est effectuée.
- Activation: passage de cette somme dans une fonction, appelée fonction d'activation.

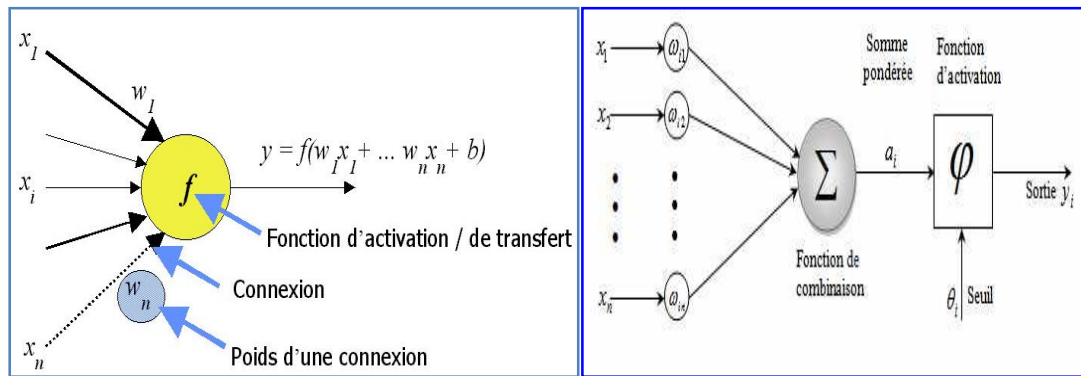


Figure II.2. Modèle non-linéaire d'un neurone formel (Touzet 1992)

La valeur calculée est transmise aux neurones suivants. Les fonctions d'activation d'un neurone formel sont toujours comparée au seuil θ de modélisation, cette comparaison est donnée par:

$$A = \sum_{i=1}^n w_{ij} x_i \quad (II.1)$$

$$f(x) = \begin{cases} 0, & \text{si } x < \theta \\ 1, & \text{si } x \geq \theta \end{cases} \quad (II.2)$$

Tableau II.1. Fonctions d'activation comparées au seuil θ .

Seuil	Seuil symétrique	Linéaire	Sigmoïde	Tangente Hyperbolique
$f(x) = \begin{cases} 0, & \text{si } x < \theta \\ 1, & \text{si } x \geq \theta \end{cases}$	$f(x) = \begin{cases} -1, & \text{si } x < \theta \\ 1, & \text{si } x \geq \theta \end{cases}$	$f(x) = x$	$f(x) = \frac{1}{1 + e^{-x}}$	$f(x) = \frac{e - e^{-x}}{e + e^{-x}}$

La fonction f peut être paramétrée de manière quelconque. Deux types de paramétrages sont fréquemment utilisés (Yonaba 2009):

- Les paramètres sont attachés aux entrées du neurone: la sortie du neurone est une fonction non linéaire d'une combinaison des entrées $\{x_i\}$ pondérées par les paramètre $\{w_i\}$, qui sont alors souvent désignés sous le nom de poids (Blayo et Verleysen 1996).

$$Y = th \left[w_0 + \sum_{i=1}^n w_i x_i \right] \quad (II.3)$$

- Les paramètres sont attachés à la non-linéarité du neurone; ils interviennent directement dans la fonction f (Blayo et Verleysen 1996).

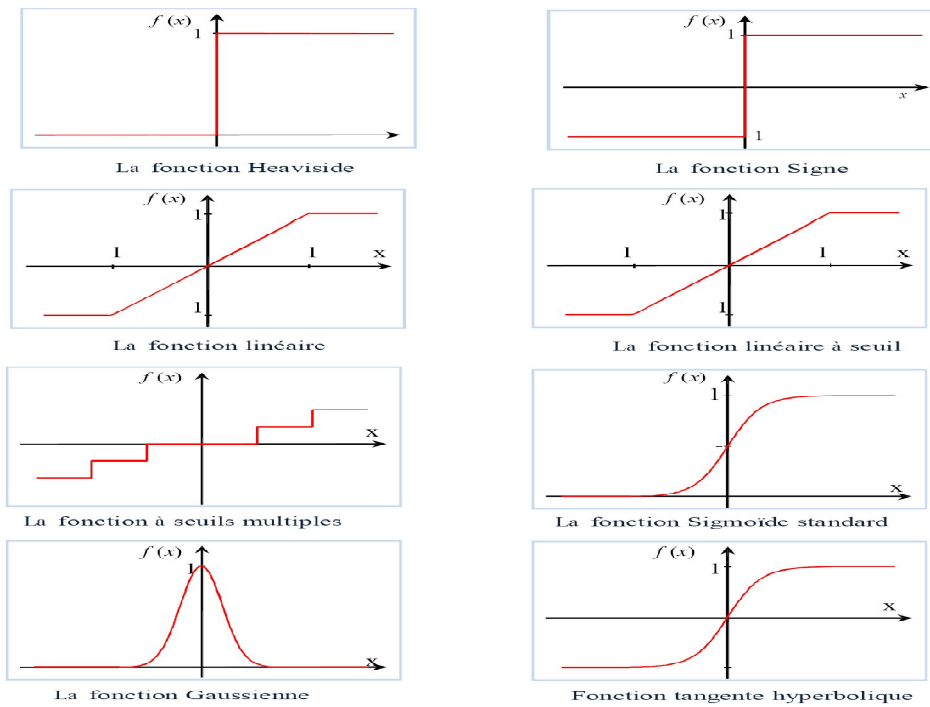


Figure II.3. Quelques types des fonctions d'activations (Touzet 1992).

II.2.4.1. Définitions

Un réseau de neurones artificiel peut être considéré comme un modèle mathématique de traitement de donnée, composé de plusieurs éléments de calcul non linéaire (neurones), opérant en parallèle et connectés entre eux par des poids (Blayo et Verleysen 1996). Les neurones artificiels sont souvent utilisés sous forme de réseaux qui diffèrent selon le type de connections entre les neurones. Les neurones de deux couches adjacentes sont interconnectés par des poids. L'information dans le réseau se propage d'une couche à l'autre, on dit qu'ils sont de type « Feedforward ». Nous distinguons trois types de couches (Blayo et Verleysen 1996; Touzet 1992):

- Couche d'entrée: les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés (Blayo et Verleysen 1996; Touzet 1992).
- Couches cachées: chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation qui est en général une fonction sigmoïde (Blayo et Verleysen 1996; Touzet 1992).
- Couche de sortie: elle joue le même rôle que les couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone (Blayo et Verleysen 1996; Touzet 1992).

II.2.5. Architecture des Réseaux de Neurones

On distingue deux structures de réseau (Benzineb 2017):

- Les réseaux de neurones non bouclés (statiques).
- Les réseaux de neurones bouclés (ou récurrents, ou dynamiques).

II.2.5.1. Les Réseaux de Neurones non Bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonction algébrique de ses entrées par composition des fonctions réalisées par chacun de ses neurones. Dans un tel réseau (Figure II.4), le flux d'information circule des entrées vers les sorties sans retour en arrière (Benzineb 2017).




Figure II.4. Réseau de neurones non bouclés (Chiang et al. 2004).

II.2.5.2. Les Réseaux de Neurones Bouclés

Lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (Figure II.5), un tel chemin est désigné sous le terme de « cycle » (Benzineb 2017).




Figure II.5. Réseau de neurone bouclé (Chiang et al. 2004).

II.2.6. Apprentissage des Réseaux de Neurones

Le point crucial du développement d'un réseau de neurones est son apprentissage. Il s'agit d'une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information (Hebb 1949; Grossberg 1988; Rumelhart et al. 1986). L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience (Press et al.1992). Les poids sont initialisés avec des valeurs

aléatoires, puis des exemples expérimentaux représentatifs du fonctionnement du procédé dans un domaine donné, sont présentés au réseau de neurones. Ces exemples sont constitués de couples expérimentaux de vecteurs d'entrée et de sortie (Blayo et Verleysen 1996). Une méthode d'optimisation modifie les poids au fur et à mesure des itérations pendant lesquelles on présente la totalité des exemples, afin de minimiser l'écart entre les sorties calculées et les sorties expérimentales (Blayo et Verleysen 1996). Il existe de nombreux types de règles d'apprentissage qui peuvent être regroupées en trois catégories: l'apprentissage supervisé, non supervisé, et renforcé.

II.2.6.1. Apprentissage Supervisé

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif. Ce genre d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties (les entrées du réseau et les sorties désirées ou encore les solutions souhaitées pour l'ensemble des sorties du réseau (Benkaci 2006; Benzineb 2017).

II.2.6.2. Apprentissage non Supervisé

L'apprentissage non supervisé consiste à ajuster les poids à partir d'un seul ensemble d'apprentissage formé uniquement de données. Aucun résultat désiré n'est fourni au réseau. L'apprentissage consiste à détecter les similarités et les différences dans l'ensemble d'apprentissage (Benkaci 2006; Benzineb 2017).

II.2.6.3. Apprentissage Renforcé

L'apprentissage renforcé est une technique similaire à l'apprentissage supervisé à la différence qu'au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade (ou score) qui est une mesure du degré de performance du réseau après quelques itérations (Benkaci 2006; Benzineb 2017).

II.2.7. Algorithme de Rétro-Propagation

La Rétro-Propagation «Backpropagation» est l'algorithme d'apprentissage supervisé le plus utilisé. La technique de Rétro-Propagation (BP) du gradient est une méthode qui permet de calculer le gradient de l'erreur pour chaque neurone du réseau, de la dernière couche vers la première. La BP a été découvert par différents auteurs mais sous différentes appellations (Grossberg 1988; Benzineb 2017). La règle est inventée par Rumelhart et al. (1986), est utilisée pour ajuster les poids de la couche d'entrée à la couche de sortie. Cette règle peut aussi être considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire (Benzineb 2017). Les poids sont au préalable initialisés avec des valeurs aléatoires. On considère ensuite un ensemble de données qui vont servir à l'apprentissage (Hafaifa et al. 2016). L'algorithme s'applique en deux étapes. La première est le forwad propagation, durant laquelle l'excitation X_p est appliquée à la couche d'entrée et se propage, en avant, dans le réseau pour calculer la sortie O_p , et l'erreur $(d_p - O_p)$ par rapport à la sortie désirée d_p . Durant la deuxième phase (Backward propagation), cette erreur se propage

en arrière pour calculer l'erreur pour chaque neurone, et effectuer des changements appropriés des poids du réseau (Djaidir et al. 2017).

II.3. Conception d'un Réseau de Neurones Artificiels

Les réseaux de neurones réalisent des fonctions non linéaires paramétrées. Leurs mises en œuvre nécessitent (Figure II.6) (Ammar 2007; Benzineb 2017):

- La détermination des entrées et des sorties pertinentes.
- La collecte des données nécessaires à l'apprentissage.
- La détermination du nombre de neurones cachés nécessaires.
- La réalisation de l'apprentissage et l'évaluation des performances du modèle.

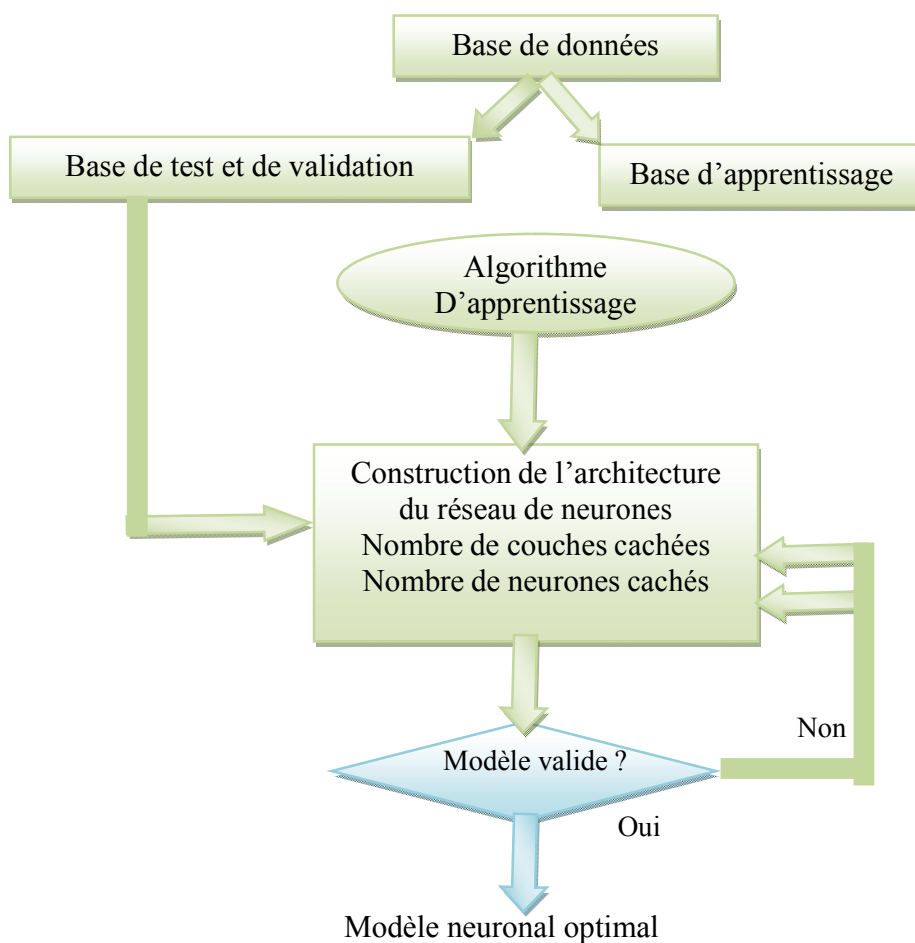


Figure II.6. Organigramme de conception d'un réseau de Neurones.

II.4. Les perceptrons Multicouches MLPNN

Le perceptron multicouche (MLPNN) se compose de trois types de couches successives (Haykin 1999) (Figure II.7). Il englobe successivement une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie (Figure II.7). Ces couches sont interconnectées par les

ponds de leurs neurones. Les neurones de la même couche ne sont pas connectés (Ammar 2007). La couche d'entrée contient les variables d'entrées (x_i), les transforme avec la fonction d'activation f et les envoie aux neurones de la première couche cachée. La couche cachée se compose des neurones qui reçoivent les sommes pondérées S (Eq.II.8) issues de la couche d'entrée, puis effectuent leurs transformations et finalement les transfèrent à la couche de sortie (Riad 2003).

$$S_{ij} = \sum_{i=1}^n w_{ij} x_i + w_0 \quad (\text{II.4})$$

Avec : n est le nombre de variables d'entrée; x_i représentent les variables d'entrées, S_{ij} est la valeur de la sortie du neurone; w_{ij} est la valeur du poids entre le neurone i et le neurone j ; w_0 est le biais.

Les MLPNN fonctionnent le plus souvent avec une seule couche cachée qui offre déjà un degré de liberté suffisant et se rapproche d'une fonction de type non-linéaire (Funahashi 1989; Hornik 1989). La réponse des neurones est une fonction d'activation non linéaire de type sigmoïde qui est défini par la formule suivante (Riad 2003):

$$f(S_{ij}) = \frac{1}{1 + e^{-S_{ij}}} \quad (\text{II.5})$$

$f(S_{ij})$ est pratiquement linéaire entre 0 et 1.

Cette fonction peut être une fonction d'identité, sigmoïdes, logistique, etc. La fonction sigmoïde étant dérivable, est généralement utilisée afin de permettre l'application de l'algorithme de Rétro-Propagation, qui est une technique souvent utilisée et reposant sur le calcul du gradient appliqué à toute fonction dérivable (Tebbi 2014):

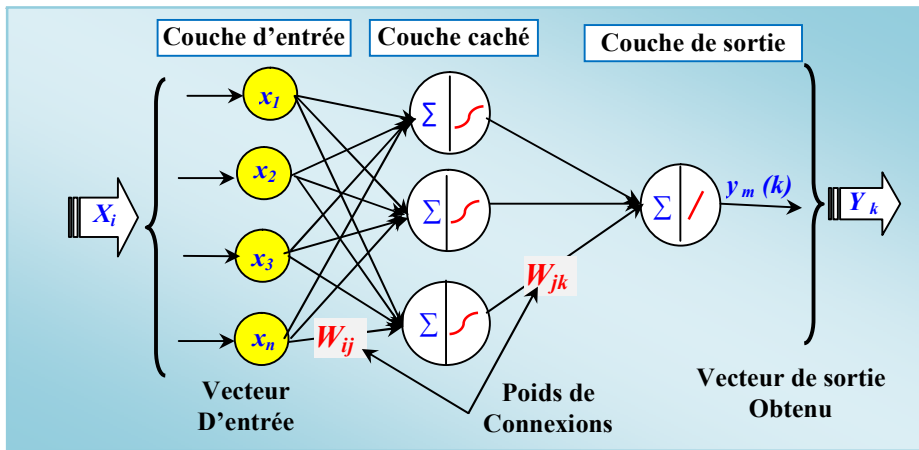


Figure II.7. Structure du perceptron Multicouches (MLPNN)

II.5. Les Réseaux de Neurones à Fonctions de base Radiales (RBFNN)

II.5.1. Présentation des RBFNN

L'idée générale des réseaux RBFNN dérive de la théorie d'approximation des fonctions, et ayant une architecture feedforward puissante (Parizeau 2004). Ce type de réseaux a été introduit pour la première fois par Hardy, et la théorie correspondante a été développée par Powell, ensuite, ces réseaux ont pris le terme de réseaux de neurones grâce à Broomhead and Lowe (Parizeau 2004). D'autre part, la raison de son application vient du fait que le réseau utilise des fonctions gaussiennes standard qui sont à symétrie radiale (Moody and Darken 1989 ; Pooggio and Girosi (1990). Le réseau RBFNN est un réseau de neurones composé d'une couche d'entrée, une seule couche cachée, et une de sortie (Parizeau 2004).

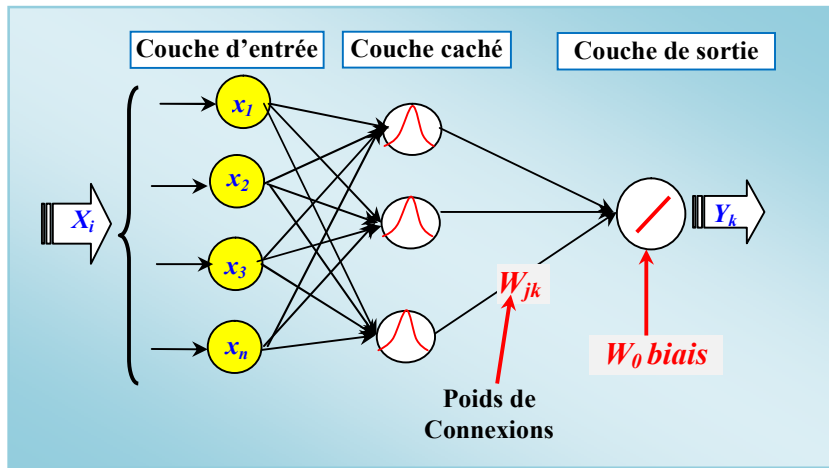


Figure II.8. Architecture détaillé d'un Réseaux de neurones RBFNN

Divers types de fonctions peuvent être utilisées comme noyau ou fonction de base, la fonction gaussienne reste cependant la plus utilisée (Seghouane and Fleury 2003). La fonction gaussienne ne répond qu'à une petite région de l'espace d'entrée, région sur laquelle elle est centrée. Sa forme générale est donnée par:

$$O_i = f(x, \mu_i, \sigma_i) = \exp\left(\frac{-\|x - \mu_i\|^2}{2\sigma_i^2}\right) \quad (\text{II.6})$$

Avec μ est le centre de la fonction gaussienne et σ_i est le rayon de cette fonction et x est la variable d'entrée. Les sorties y du réseau à fonction radiale RBFNN sont calculées comme suite:

$$y_i = f(O_i) = w_i O_i + w_0 \quad (\text{II.7})$$

Où w_i est le poids de la connexion entre l'unité cachée Φ et la sortie y_j , les poids de connexion sont des paramètres à adapter (en plus des paramètres des y_j) lors de la phase d'apprentissage, afin que les sorties du réseau soient proches des sorties désirées, σ est l'écart type de la gaussienne et μ est le vecteur des coordonnées de son centre. Enfin, la configuration d'un réseau de neurones RBFNN optimal est difficile. Lors du processus d'apprentissage du réseau, deux stratégies sont possibles, la première consiste à modifier simultanément, par descente de gradient, tous les paramètres du réseau (les coordonnées des centres des fonctions radiales, leur écart-type et les poids). Cependant les dynamiques de

convergence des fonctions radiales et des poids sont différentes et les poids convergent plus rapidement que les autres paramètres (Viennet 2006).

II.6. Réseaux de neurones à fonction de régression générale (GRNN)

Le modèle de réseaux de neurones à régression généralisée (GRNN) est une forme modifiée du modèle de réseaux de neurones à fonction de base radiale (RBFNN) (Kim 2012). Le modèle GRNN est composé de quatre couches, à savoir la couche d'entrée, la couche cachée, la couche de sommation et la couche de sortie (Figure II.9). La couche d'entrée, la couche cachée et les nœuds de la couche de sommation sont complètement connectés, tandis que le nœud de la couche de sortie n'est connecté qu'à certains des nœuds de la couche de sommation (Wasserman 1993; Kim et Kim 2008).

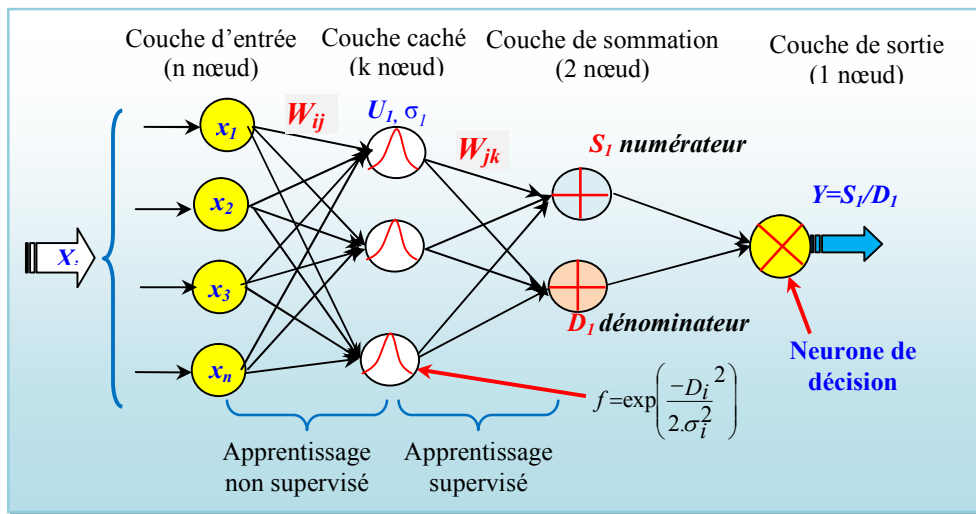


Figure II.9. Architecture détaillé d'un réseau de neurones GRNN

La fonction de connexion entre la couche d'entrée et la couche cachées de GRNN est représentée comme la somme du carré de la valeur de soustraction du centre, u_{ji} , à partir du nœud d'entrée, x_i , (Eq. II.8):

$$R_{ij} = \sqrt{\sum_{i=1}^m (x_i - u_{ji})^2} \quad (II.8)$$

Où i, j représentent la couche d'entrée et la couches cachées, respectivement; et R_j est la distance euclidienne entre les nœuds d'entrée et les centres. Les nœuds d'entrée peuvent être écrits sous la forme suivante (Eq. II.9):

$$X = [x_1, x_2, \dots, x_m]^T \quad (II.9)$$

Où le centre de rayon, $U^{(j)}$, peut être écrit comme suit (Eq. II.10):

$$U^{(j)} = [u_{j1}, u_{j2}, \dots, u_{jm}]^T \quad (II.10)$$

Finalement on a :

$$R_j = (\|X - U^{(j)}\|) \quad (\text{II.11})$$

Où $\|\cdot\|$ = la longueur euclidienne. R_j peut être appliqué à la fonction de transfert de la couche cachée, $\Phi_1(\cdot)$, et les résultats calculés à partir de R_j et la fonction de transfert de la couche cachée peuvent être écrits comme suit (Eq. II.12):

$$S_j = \Phi_1(R_j) = \Phi_1(\|X - U^{(j)}\|) \quad (\text{II.12})$$

Où S_j sont les résultats calculés à partir des R_j et la fonction de transfert de la couche cachée. La fonction RBF est largement utilisée comme fonction de transfert de la couche cachée.

La couche de sommation peut recevoir les résultats calculés à partir des S_j et les poids de connexion entre la couche cachée et la couche de sommation. Elle peut s'écrire comme suit (Eq. II.13):

$$T_k = \sum_{j=1}^5 W_{kj} \times S_j = \sum_{j=1}^5 W_{kj} \times \Phi_1(\|X - U^{(j)}\|) \quad (\text{II.13})$$

Où k représente la couche de sommation; T_k : les résultats calculés à partir de S_j et les poids de connexion entre la couche cachée et la couche de sommation ; W_{kj} = les poids de connexion entre la couche cachée et la couche de sommation; et le nœud de sommation et le nœud de division dans la couche de sommation peuvent être écrits comme les équations suivantes:

$$S_1 = \Phi_2 \left\langle \sum_{j=1}^5 W_{1j} \cdot \Phi_1(\|X - U^{(j)}\|) \right\rangle \quad (\text{II.14})$$

$$D_1 = \left\langle \sum_{j=1}^5 W_{2j} \cdot \Phi_1(\|X - U^{(j)}\|) \right\rangle \quad (\text{II.15})$$

Où $\Phi_2(\cdot)$ = la fonction de transfert de la couche de somme; S_1 = le résultat calculé à partir du nœud de sommation; et D_1 = le résultat calculé à partir du nœud de division. Enfin, la fonction du nœud de la couche de sortie consiste à diviser le résultat calculé à partir du nœud de sommation par le résultat calculé à partir du nœud de division. Il peut s'écrire comme suit:

$$Y = \frac{S_1}{D_1} \quad (\text{II.16})$$

Où Y = l'évaporation journalière (mm / jour).

II.7. Les modèles ANFIS

Jang (1993) a présenté une procédure d'apprentissage pour le système d'inférence floue (FIS). L'auteur a proposé l'utilisation d'un algorithme d'apprentissage des réseaux de neurones pour construire un ensemble de règles flou [If-Then] avec des fonctions d'appartenance (*MFs*) appropriées à partir de paires d'entrée-sortie spécifiées (Sanikhani et al. 2012), et ainsi le modèle d'inférence floue à base de réseaux de neurones adaptatifs (Adaptive Neurofuzzy Inference System), dite couramment ANFIS a été proposé. La Figure II.10 montre une structure de base

d'ANFIS. ANFIS est composée d'un certain nombre de nœuds connectés via des liaisons directionnelles. Chaque nœud est caractérisé par une fonction de nœud comprenant des paramètres fixes ou ajustables (Sanikhani et al. 2012). La règle d'apprentissage de base est la méthode bien connue de Rétro-Propagation (Drake 2000). En fonction des types d'opérations d'inférence sur les «règles If-Then», la plupart des FIS peuvent être classés en deux types: le système de Mamdani (Mamdani and Assilian 1975) et le système de Sugeno (Takagi and Sugeno 1985). Pour créer un système flou, tout d'abord, les variables linguistiques auraient dû être fournies en plus des variables numériques. Ensuite, le système a besoin de règles floues If/Then pour qualifier les relations simples entre les variables floues. Un ensemble de règles typique avec deux règles If/Then floues dans le système de premier ordre de Sugeno peut être présenté comme suit (Sanikhani et al. 2012):

$$\text{Rule 1} = \text{If } (x \text{ is } A_1) \text{ and } (y \text{ is } B_1) \text{ Then } (f_1 = p_1x + q_1y + r_1) \quad (\text{II.17})$$

$$\text{Rule 2} = \text{If } (x \text{ is } A_2) \text{ and } (y \text{ is } B_2) \text{ Then } (f_2 = p_2x + q_2y + r_2) \quad (\text{II.18})$$

Où x et y font référence aux entrées et f représente la variable de sortie, respectivement. Les termes A et B désignent les termes linguistiques. La partie " S_i " de la règle " x est A " est appelée la prémisse, alors que la partie "Alors" de la règle est appelée la conséquence. Les p , q , r indiquent les paramètres linéaires de sortie (Sayed et al. 2003). Selon la Figure II.10, ANFIS est composé des cinq couches suivantes (Sanikhani 2012):

Couche 1 : Chaque nœud i de cette couche est un nœud adaptatif, y compris les MF , généralement décrit par des fonctions de cloche généralisées :

$$f_{1,i} = \mu_{A_i}(x) = \frac{1}{1 + \left[\frac{(x - c_i)}{a_i} \right]^{2b_i}} \quad (\text{II.19})$$

Où x est une variable d'entrée dans le nœud et a_i , b_i et c_i sont des variables adaptables appelées paramètres non linéaire des fonctions d'appartenance. Les valeurs d'appartenance de la partie de base constituent les sorties de cette couche.

Couche 2 : Chaque nœud i de cette couche est un nœud circulaire appelé Π qui engendre en sortie le produit de ses entrées. Ce produit représente le degré d'activation d'une règle :

$$f_{2,1} = O_i^2 = w_i = \mu_{A_i} \times \mu_{B_i}, \quad i=1, 2, \quad (\text{II.20})$$

Couche 3 : Chaque nœud de cette couche est un nœud appelé N . La sortie du nœud i est le degré d'activation normalisé de la règle i :

$$f_{3,1} = O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1, 2, \quad (\text{II.21})$$

Couche 4 : Chaque nœud de cette couche est un nœud carré avec une fonction réalisant:

$$f_{4,i} = O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i x + r_i) \quad i=1, 2, \quad (II.22)$$

Couche 5 : Le seul nœud de cette couche est un nœud circulaire qui effectue la somme des signaux provenant de la couche 4, c'est à dire :

$$f_{5,1} = O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (II.23)$$

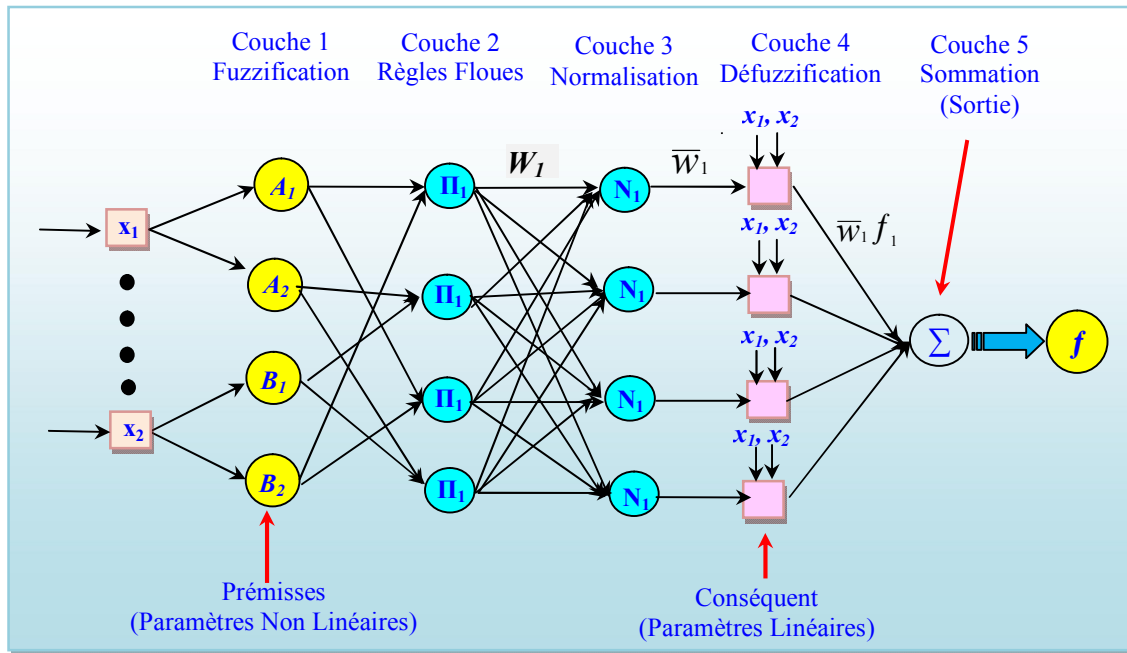


Figure II.10. Architecture détaillé d'un modèle ANFIS

II.8. Les Machines A Vecteurs De Support (SVM)

II.8.1. Introduction

Parmi les méthodes à noyaux, inspirées de la théorie statistique de l'apprentissage de [Vladimir Vapnik](#), les Machines à vecteurs de support (SVM) constituent la forme la plus connue ([Bouaziz 2017](#)). SVM est une méthode de classification binaire par apprentissage supervisé, elle fut introduite par [Vapnik en \(1998, 1999a, 1999b\)](#). Elle est basée sur l'utilisation de fonctions dites noyau (Kernel) qui permettent une séparation optimale des données. Dans la présentation des principes de fonctionnements, nous schématiserons les données par des « points » dans un plan ([Bouaziz 2017](#)). L'algorithme sous sa forme initiale revient à chercher une frontière de décision linéaire entre deux classes, mais ce modèle peut considérablement être enrichi en se projetant dans un autre espace permettant d'augmenter la séparabilité des données ([Bouaziz 2017](#)). On peut alors appliquer le même algorithme dans ce nouvel espace, ce qui se traduit par une frontière de décision non linéaire dans l'espace initial ([Mahé 2003](#)). Les SVM cherchent à séparer deux groupes d'instances (ou projections d'instances) par un hyperplan de marge maximale. Un tel hyperplan est considéré comme un séparateur optimal qui aura une meilleure

capacité à généraliser et à classifier les nouveaux exemples inconnus (Bouaziz 2017).

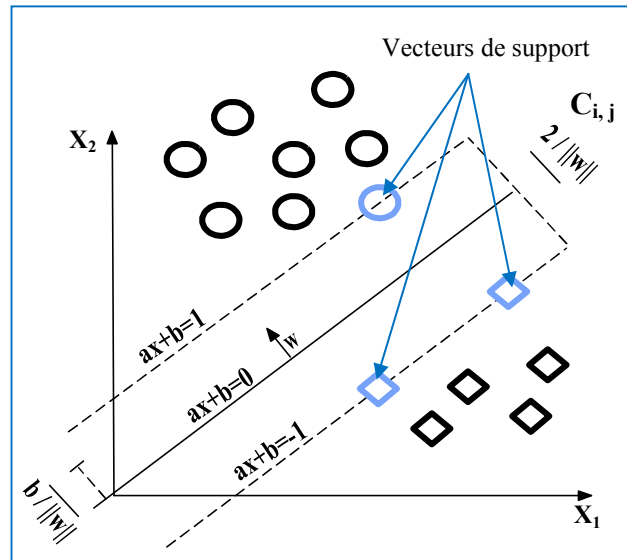


Figure II.11: Un exemple de classification par SVM

Les SVM linéaires sont la forme la plus simple de cet algorithme. Ils sont applicables dans le cas où les données sont linéairement séparables. Ils essaient de trouver un hyperplan d'équation (Bouaziz 2017):

$$w^T \cdot x + b = 0 \quad (\text{II.24})$$

Qui sépare deux classes entre elles en satisfaisant aux contraintes suivantes:

$$w^T x_i + b \geq 1, \forall_i \text{ tel que } Y_i = 1 \quad (\text{II.25})$$

$$w^T x_i + b \leq -1, \forall_i \text{ tel que } Y_i = -1 \quad (\text{II.26})$$

La distance entre les deux hyperplans d'équation $w^T \cdot x + b = 1$ et $w^T \cdot x + b = -1$ est $M = 2/\|w\|^2$ représente la marge du classifieur. L'hyperplan optimal peut être trouvé en maximisant la marge, c'est-à-dire, en minimisant la norme de l'hyperplan séparateur. Le problème est donc exprimé comme suit (Bouaziz 2017):

$$\text{Min}_{w,b} \frac{1}{2} \|w\|^2 \quad (\text{II.27})$$

Sous la contrainte : $Y_i (w^T x_i + b) \geq 1, \forall_i \leq n$. La fonction de décision est exprimée par:

$$f(x) = w^T \cdot x + b \quad (\text{II.28})$$

Qui attribue la classe 1 à x si $h(x) \geq 0$ et la classe -1 sinon (Bouaziz 2017).

Si les données d'apprentissage ne sont pas linéairement séparables, mais pourront être séparées par le moyen d'une fonction non linéaire, le processus de détermination de la fonction de classification se compose dans ce cas de deux étapes. Premièrement, les vecteurs d'entrée sont projetés dans un espace de plus grande dimension afin de pouvoir être linéairement séparables (Bouaziz 2017). Ensuite, l'algorithme SVM est utilisé pour trouver l'hyperplan optimal qui sépare les nouveaux vecteurs de données. Une fonction noyau $K(x_i, x_j)$ fournit un résultat égal au produit $\Phi(x_i) \cdot \Phi(x_j)$. Parmi les noyaux les plus utilisés, nous pouvons citer les noyaux polynomiaux et les noyaux RBF formulés respectivement comme suit (Bouaziz 2017):

$$K(x, y) = (x^T \cdot x + c)^d \quad (\text{II.29})$$

$$K(x, x') = \exp\left(\frac{-\|x - x'\|^2}{2 \cdot \sigma^2}\right) \quad (\text{II.30})$$

Malgré les avantages des fonctions noyau, leur interprétation est difficile et l'utilisateur ne peut pas tirer de connaissances à partir du comportement des classifieurs concernés (Bouaziz 2017).

II.8.2. Les SVM pour la Régression (SVR)

Dans leur origine, les SVMs ont été développées pour des problèmes de classification (Lauer and Bloch. 2006). Cependant, leur nature leur permet de résoudre également des problèmes de régression. L'utilisation des séparateurs à vastes marges étendue au cas de la régression constitue une alternative prometteuse pour la modélisation de ces systèmes. Soit l'ensemble D de N paires de données, ayant un vecteur de données x_i comme entrée et l'étiquette z_i de ce vecteur comme sortie, qui peut maintenant prendre n'importe quelle valeur réelle (Djefal 2012):

$$D = \{(x_1, z_1), \dots, (x_i, z_i), \dots, (x_n, z_n)\}, \text{ pour } i=1 \dots N, \text{ avec } x_i \in \mathbb{R}, z_i \in \mathbb{R} \quad (\text{II.31})$$

Dans une régression le but est trouver une fonction pouvant mettre en relation les entrées x_i et les sorties z_i : $z_i = f(x_i)$. Les étapes nécessaires pour réaliser une régression classique sont:

- le choix d'un modèle qui représente au mieux ces données, par exemple une droite:

$$f(x_i) = a x_i + b \quad (\text{II.32})$$

- Optimiser un critère pour trouver les paramètres a et b de ce modèle, par exemple moindres carrés (Djefal 2012) :

$$\min \sum_{i=1}^N (z_i - f(x_i)) \quad (\text{II.33})$$

Où z_i est la sortie réelle. Avec une fonction de coût de type quadratique (moyenne des erreurs quadratique RMSE), on obtient la solution de maximum de vraisemblance quand le bruit est gaussien. L'idée qui permet de généraliser l'utilisation des SVMs de la classification à la régression est l'adoption d'une nouvelle fonction de (coût) qui inclut la notion de distance, ce type de fonction à l'avantage de diminuer ainsi le sur-apprentissage (Djefal 2012).

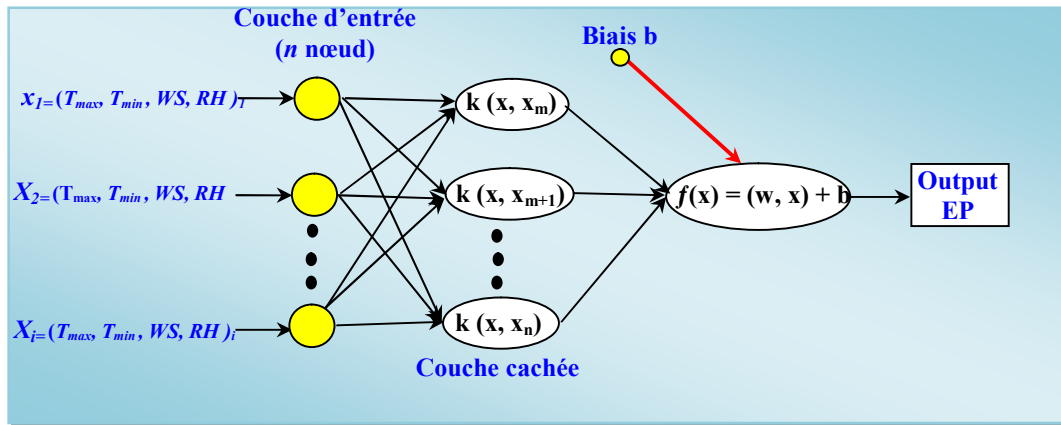


Figure II.12. Architecture des SVR

II.9. Conclusion

Dans ce chapitre nous avons essayé de donner en bref une description sur l'intelligence artificielle principalement sur les réseaux de neurones artificiels, les différents types d'architectures et de modèles qui existent. Nous avons aussi présenté une définition de l'apprentissage des réseaux de neurones, puis une description générale de l'algorithme de Rétro-Propagation. Ensuite, nous avons mis l'accent en détails sur les modèles de calcul de base, leurs applications, leurs classes et leurs caractéristiques... à savoir : les MLPNN, les RBFNN, les GRNN, le système d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS), les Machines à Vecteurs de Support (SVM).

***Chapitre III : Présentation de la Zone D'étude
& Traitement Des Données***

III.1. Présentation de la Région d'Etude

III.1.1. Situation Géographique

Le Nord-Est Algérien est une zone géographique très vaste, elle couvre plus de 150109 km² comprenant plusieurs plaines fertiles et étendues (Mebarki 2005). Une première partie de cette étude a pris en considération une partie la superficie mentionnée (Figure III.1). Notre étude s'est focalisé uniquement sur une superficie d'environ 109 000 km² s'étalant entre les longitudes 8°40'10"E et 3°15'6"E et les latitudes 37°5'00"N et 34°32'30"N. La zone d'étude est limitée au nord par la mer Méditerranéenne, cette région côtière reçoit le maximum de précipitation de tout le pays où le climat est humide à subhumide, vers l'intérieur des terres, on observe une diminution des précipitations (Mebarki 2005, 2010) jusqu'à ce qu'elle atteigne le minimum, particulièrement dans les plaines de sud caractérisées par un climat aride. La région est en effet connue par une diversité climatique très marquée, de ce fait pour mieux analyser le phénomène d'évaporation (Mebarki 2005).

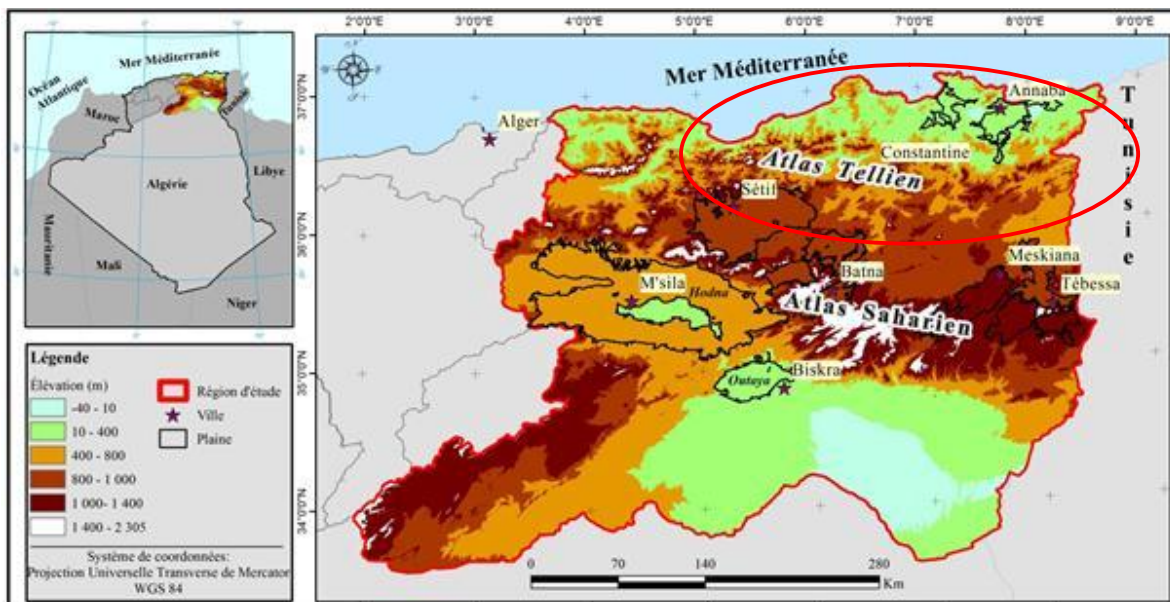


Figure III.1. Localisation de la région d'étude (Mebarki 2005)

III.1.2. Les Aspects Topographiques

L'Est-Algérien est loin de l'espace uniforme cristallin. Vu son hétérogénéité structurale très poussée, il ne correspond pas à une seule entité naturelle. Il s'agit d'un relief diversifié qui se présente sous forme d'un dispositif caractérisé par une alternance de zones élevées (rides) et de zones basses (bassins ou plaines) (Ghennai 2014). L'allure générale du relief se présente comme un ensemble de hautes terres où les basses plaines sont très étroites et encaissées (Cherrad 1993). La physionomie générale du relief apparaît comme un agencement de lignes orthogonales ordonnées faisant front au littoral se caractérisant plus par des contraintes que de potentialités (Raham 2001). L'Est-Algérien apparaît schématiquement sous forme de cinq grandes unités physiques comprenant eux-mêmes des nuances. Ces unités sont disposées du Nord au Sud (Figure III.2).

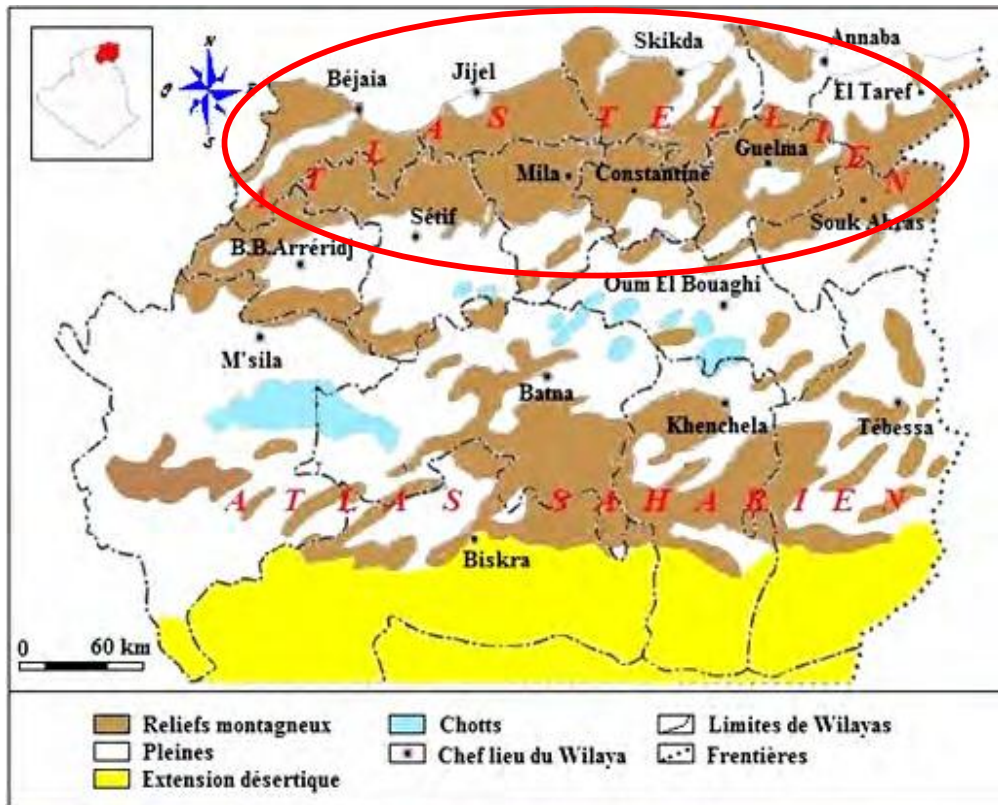


Figure III.2. Les grandes unités physiques de l'Est-Algérien (Raham 2001)

III.1.3. Le Réseau Hydrographique et Climat

L'Algérie orientale, vaste région aux contextes physiques variés, est marquée par un fort contraste climatique, Méditerranéen au Nord et continental subdésertique au Sud (Cote 1998a). L'inégale répartition des ressources en eau de surface et leur irrégularité s'inscrit dans ces contextes: cours d'eau relativement fournis, tributaires de la mer Méditerranée et oueds à débit modeste, reliés à des dépressions fermées où l'évaporation est intense (Mebarki 2010). Le réseau hydrologique est très encaissé et relativement court. Le débit des cours d'eau, l'abondance et la modération de l'écoulement varie selon les saisons: abondant et modéré pendant la saison humide et très faible pendant la saison sèche (Cote 1998a). Le Nord, des bassins à écoulement exoréique (les oueds se jettent dans la mer) à régime quasiment pérenne: Oued Rhumel-El Kebir, Beni Haroun, Oued Saf-Saf et Oued Seybous, et plus à l'Ouest l'Oued Djendjen et l'Oued Soummam (Tabet 2008).

III.1.4. Le Climat

L'Est-Algérien est la région la plus variée du pays sur le plan climatique. Il est caractérisé par une longue période de sécheresse estivale variant de 3 à 4 mois sur le littoral, de 5 à 6 mois au niveau des Hautes Plaines et supérieure à 6 mois au niveau de l'Atlas Saharien (Nedjraoui 2001).

III.1.4.1. La pluviosité

Les précipitations accusent une grande variabilité mensuelle et surtout annuelle. Cette variabilité est due à l'existence de gradients (Djellouli 1990). Les moyennes pluviométriques annuelles varient atteints plus de 1500 mm dans certaines localités du nord (Jijel) (Ghennai 2014). Le littoral est caractérisé par des fortes précipitations (supérieures à 900 mm) dans la zone montagneuse Nord-Ouest, allant de Bejaia à Collo, ainsi que dans les tranches d'altitude les plus élevées des monts de la Medjerda et du massif de l'Edough dans le Nord-Est (D.G.F. 2004).

III.1.4.2. Les Températures

La moyenne des températures minimales du mois le plus froid (T_{\min}) est comprise entre 0°C et 9°C dans les régions littorales et entre -2°C et +4°C dans les régions semi-arides et arides. La moyenne des températures maximales du mois le plus chaud (T_{\max}) varie avec la continentalité, de 28°C à 31°C sur le littoral, de 33°C à 38°C dans les Hautes Plaines steppiques et supérieure à 40°C dans les régions sahariennes (Nedjraoui 2001).

III.2. Présentation et Description de la base de Données Utilisée

III.2.1. Introduction

Cette étude repose sur l'utilisation des modèles à base d'intelligence artificielles pour la modélisation de l'évaporation (E_{pan}) au niveau des barrages réservoirs dans la région Est de l'Algérie, à pas de temps journalière et mensuelle. Il est très important de sélectionner des données pertinentes et fiables pour le développement des modèles, puisque les performances des modèles seront directement liées à la qualité des données choisies. Dans ce chapitre nous présenterons les bases de données utilisées et correspondent aux différents barrages sélectionnés, selon la disponibilité et l'accessibilité à la base de données.

III.2.2. Situation Géographique des Barrages et Stations Climatiques

Le phénomène de l'évaporation des lacs de barrages en Algérie est considérable. Une perte de volume très élevée est enregistrée annuellement. Chaque barrage est équipé d'un bac Colorado, et une station climatique gérée par l'Agence Nationale des Ressources Hydrauliques (ANRH) installée à proximité de la retenue, qui permet aux techniciens de prendre des mesures journalières de l'évaporation. Nous avons utilisé les données de l'évaporation de 07 barrages (Tableau III.1) sur les barrages que compte l'Algérie au Nord-Est (Figure III.3). Les données climatiques sont mesurées au niveau des stations de chaque barrage. Pour ce qui est de la taille de la base de données, elle varie d'une station à une autre. Pour la station de Beni Zid nous avons pu récupérer uniquement 06 ans (Tableau III.2). Quant aux données climatiques, les séries les plus complètes comprennent quatre variables (Tableau III.3): les températures minimale et maximale (T_{\max} , T_{\min}), la vitesse du vent (U_2), et l'humidité relative (H%).

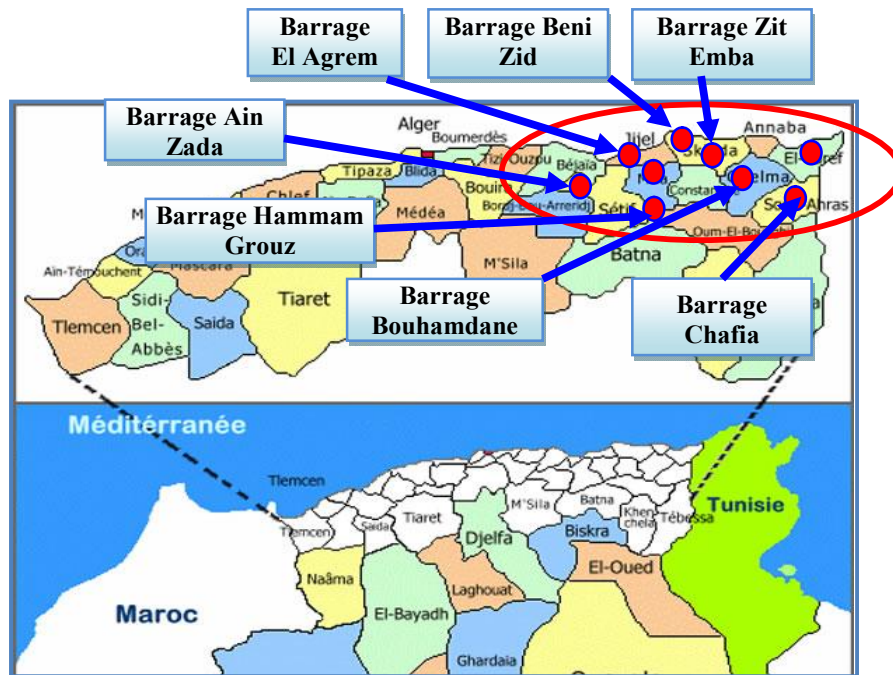


Figure III.3. Situation géographique des barrages retenus

Tableau III.1. Présentation des Barrages Réservoirs

Barrages	Wilaya	Code	Latitude	Longitude	Périodes
Chafia	EL taref	CHF	36°36' 33''	8°02'32''	01/04/2003-31/08/2016
Beni Zid	Skikda	BEZ	36°54'29''	6°30'06''	01/01/2003-31/12/2008
Zit Emba	Skikda	ZEM	36°41'41''	7°18'07''	01/01/2005-31/12/2016
El Agram	Jijel	ELG	36°43'36''	5°49'37''	01/01/2003-31/12/2015
Hammam Grouz	Constantine	HMG	36°14'79''	6°16'58''	01/01/1999-29/02/2016
Bouhamdane	Guelma	BHM	36°27'42''	7°14'16''	01/01/2004-31/12/2016
Ain Zada	Sétif	AIZ	36°10'27''	5°08'58''	01/01/2000-30/06/2016

Tableau III.2. Taille de la base de données utilisée

N°	Barrages	Code	Durée (ans)	Journalier	Mensuel
01	Chafia	CHF	14	6179	203
02	Beni Zid	BEZ	06	2192	72
03	Zit Emba	ZEM	12	4383	144
04	El Agram	ELG	13	4474	147
05	Hammam Grouz	HMG	18	5963	196
06	Bouhamdane	BHM	13	3566	117
07	Ain Zada	AIZ	17	5237	170

Tableau III.3. Variables climatiques utilisées

N°	Barrages	Code	T _{min}	T _{max}	U ₂	H%
01	Chafia	CHF	✓	✓	✓	✓
02	Beni Zid	BEZ	✓	✓	✓	✓
03	Zit Emba	ZEM	✓	✓	✓	✓
04	El Agram	ELG	✓	✓	✓	✓
05	Hammam Grouz	HMG	✓	✓	✓	✓
06	Bouhamdane	BHM	✓	✓	✓	✓
07	Ain Zada	AIZ	✓	✓	✓	✓

III.3. Analyse Statistique des données

III.3.1. Statistiques Descriptives

Dans le présent travail, nous avons calculé les paramètres statistiques pour les différentes variables climatiques à pas de temps journalière (Tableau III.4) et mensuelle (Tableau III.5).

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

Tableau III.4. Paramètres statistiques de la base de données utilisée (journalières)

Barrages	Variables	Unité	X _{moy}	X _{max}	X _{min}	S _x	C _v	R
Beni Zid	T _{max}	°C	23.722	44.00	2.500	6.952	0.299	0.805
	T _{min}	°C	16.518	36.50	0.500	7.132	0.432	0.819
	H%	%	71.143	100	15.00	13.862	0.195	-0.645
	U ₂	m/s	0.135	1.950	0.000	0.166	1.230	0.082
	E _{pan}	mm	3.569	11.20	0.000	2.560	0.717	1.000
Zit Emba	T _{max}	°C	22.744	45.900	2.000	5.917	0.260	0.723
	T _{min}	°C	15.514	35.500	0.600	5.534	0.357	0.754
	H%	%	70.384	98.000	2.000	9.808	0.139	-0.078
	U ₂	m/s	3.411	16.000	0.000	1.164	0.341	-0.233
	E _{pan}	mm	4.902	17.700	0.000	3.301	0.673	1.000
Ain Zada	T _{max}	°C	21.162	42.000	-1.000	9.485	0.448	0.862
	T _{min}	°C	8.066	26.400	-9.600	7.111	0.882	0.846
	H%	%	61.443	97.000	14.000	18.811	0.306	-0.806
	U ₂	m/s	3.614	12.000	0.000	1.393	0.382	0.012
	E _{pan}	mm	4.542	20.300	20.300	3.536	0.778	1.000
Bouhamdane	T _{max}	°C	25.637	46.700	5.200	8.492	0.331	0.883
	T _{min}	°C	11.441	32.700	0.000	6.198	0.542	0.767
	H%	%	62.689	96.000	17.000	15.108	0.241	-0.639
	U ₂	m/s	1.991	12.667	0.000	1.528	0.767	-0.044
	E _{pan}	mm	3.710	12.000	0.000	2.689	0.725	1.000
El Agram	T _{max}	°C	23.524	43.000	6.000	6.308	0.268	0.779
	T _{min}	°C	13.582	29.200	0.100	5.604	0.413	0.690
	H%	%	72.982	95.700	20.500	10.200	0.140	-0.409
	U ₂	m/s	2.535	14.100	0.000	1.726	0.681	-0.062
	E _{pan}	mm	4.046	18.300	0.070	2.752	0.680	1.000
Hammam Grous	T _{max}	°C	22.965	44.000	1.000	9.297	0.405	0.854
	T _{min}	°C	9.621	28.000	-10.000	6.576	0.683	0.802
	H%	%	64.579	99.000	18.000	16.645	0.258	-0.780
	U ₂	m/s	2.612	11.306	0.000	1.630	0.624	-0.020
	E _{pan}	mm	4.710	19.450	0.000	3.502	0.743	1.000
Chafia	T _{max}	°C	23.731	45.700	5.100	6.495	0.274	0.786
	T _{min}	°C	12.656	27.00	0.000	5.381	0.425	0.765
	H%	%	75.756	96.100	25.000	9.522	0.126	-0.377
	U ₂	m/s	3.7000	11.000	0.000	1.208	0.327	0.004
	E _{pan}	mm	2.748	33.80	0.000	1.877	0.681	1.000

Tableau III.5. Paramètres statistiques de la base de données utilisée (mensuels)

Barrages	Data set	Unit	X_{moy}	X_{max}	X_{min}	S_x	C_v	R
Beni Zid	T_{max}	°C	23.733	35.226	12.750	6.104	0.255	0.921
	T_{min}	°C	16.473	28.468	5.823	6.592	0.397	0.936
	H%	%	71.192	87.467	50.629	9.161	0.128	-0.910
	U_2	m/s	0.135	0.398	0.030	0.074	0.546	-0.020
	E_{pan}	mm	108.668	250.800	21.800	70.878	0.648	1.000
Zit Emba	T_{max}	°C	15.480	24.781	5.906	5.003	0.322	0.881
	T_{min}	°C	22.710	30.813	8.877	5.000	0.219	0.875
	H%	%	70.381	85.742	56.587	4.324	0.061	-0.047
	U_2	m/s	3.413	4.710	0.000	0.528	0.154	-0.489
	E_{pan}	mm	149.196	354.600	17.600	89.817	0.600	1.000
Ain Zada	T_{max}	°C	21.175	37.065	6.786	8.576	0.404	0.953
	T_{min}	°C	8.108	20.765	-3.216	6.474	0.796	0.940
	H%	%	61.376	85.516	30.484	14.936	0.243	-0.955
	U_2	m/s	3.660	5.429	2.125	0.618	0.168	-0.117
	E_{pan}	mm	139.277	364.400	19.600	97.127	0.695	1.000
Bouhamdane	T_{max}	°C	25.441	39.516	12.818	7.356	0.288	0.917
	T_{min}	°C	11.569	37.055	2.879	5.941	0.511	0.858
	H%	%	62.725	80.733	36.032	10.519	0.167	-0.836
	U_2	m/s	1.993	3.222	0.811	0.494	0.247	0.106
	E_{pan}	mm	113.074	305.700	23.400	76.870	0.677	1.000
El Agram	T_{max}	°C	23.488	33.823	13.103	5.555	0.236	0.910
	T_{min}	°C	13.549	22.300	4.103	5.108	0.376	0.872
	H%	%	72.984	82.167	58.150	4.687	0.064	-0.576
	U_2	m/s	2.539	4.565	0.658	0.713	0.280	-0.135
	E_{pan}	mm	123.112	286.800	29.100	67.318	0.545	1.000
Hammam Grous	T_{max}	°C	22.907	37.848	8.910	8.321	0.362	0.956
	T_{min}	°C	9.581	21.735	-0.579	5.982	0.623	0.918
	H%	%	64.641	85.129	33.129	12.397	0.191	-0.933
	U_2	m/s	2.616	4.535	0.896	0.631	0.240	-0.172
	E_{pan}	mm	143.382	357.650	25.880	94.221	0.655	1.000
Chafia	T_{max}	°C	23.693	35.426	13.059	5.580	0.235	0.916
	T_{min}	°C	12.625	21.374	4.500	4.855	0.384	0.895
	H%	%	75.768	86.129	64.145	4.803	0.063	-0.621
	U_2	m/s	3.701	5.693	2.537	0.436	0.118	-0.016
	E_{pan}	mm	83.794	212.600	24.600	49.812	0.593	1.000

III.3.2. La technique Gamma Test (GT)

III.3.2.1. Introduction

Le Gamma Test dite couramment GT est une technique importante du développement de modèles d'apprentissage automatique non linéaires. Son principe de base est le suivant: on cherche à déterminer les prédicteurs utiles à partir d'une base de données composée de plusieurs variables d'entrée potentielles susceptibles d'améliorer la fonction de sortie du modèle. Afin d'évaluer l'utilité de différentes combinaisons de variables d'entrée et leur effet sur la sortie du modèle souhaitée, une approche efficace consiste à utiliser une technique récente appelée

Gamma Test (GT) (Koncar 1997; Agalbjörn et al. 1997). La technique GT consiste à estimer l'erreur quadratique moyenne (RMSE) qui peut être modélisée par le modèle le plus lisse possible. Gamma Test donne une indication de la variance inexplicable qui existe entre un jeu de données entrée-sortie. Il s'agit d'une statistique très utile à utiliser lors de la comparaison de plusieurs jeux de données de variables d'entrée avec une sortie souhaitée. La méthode GT a été utilisée dans d'autres études hydrologiques pour évaluer l'utilité de divers ensembles de données entrée-sortie pour le problème de sélection de variable d'entrée (Noori et al. 2011; Wan Jaafar, L 2011). En particulier Moghaddamnia et al. (2009) ont utilisé le GT comme méthode pour identifier les ensembles de prédicteurs les plus utiles pour l'estimation de l'évaporation en utilisant les approches ANN et ANFIS (Goyal et al. 2014). La technique GT est une technique multi-objective et impartiale permettant d'identifier le potentiel important de chaque paramètre d'entrée par l'estimation de l'erreur standard minimum pour chaque jeu de données d'entrée-sortie avec des modèles non linéaires continus. Stefansson et al. (1997) ont tout d'abord introduit le concept de GT qui est utilisé plus tard par d'autres chercheurs (Tsui et al. 2002; Remesan et al. 2008; Moghaddamnia et al. 2009; Noori et al. 2011).

III.3.2.2.L'implémentation de la technique Gamma Test

La technique Gamma Test (GT) est une technique d'analyse et de modélisation non linéaire, utilisée pour la sélection de la meilleure combinaison d'un certain nombre de variables explicatives (Input) pour exprimer une variable à expliquer (Output). Pour notre cas d'étude, la GT doit déterminer parmi les quatre variables climatiques (T_{min} , T_{max} , U_2 , $H\%$), la meilleure combinaison des variables prises simultanément et qui permettent d'estimer l' E_{pan} avec les meilleures performances. Cette méthode est basée sur l'estimation de la meilleure erreur quadratique moyenne (EQM) qui peut être assurée par un modèle correspondant à une certaine sélection des variables d'entrée (Jones 2001). Par un examen d'EQM estimée pour plusieurs sélections des différents inputs, on peut décider et choisir la meilleure combinaison des variables d'entrées qui correspond à la valeur de la variable expliquée. Dans notre étude nous avons utilisé le software *Win Gamma* pour l'application de la méthode GT (Remesan et Mathew 2015).

III.3.2.3. Formulation mathématique de la Technique Gamma Test

Le GT estime l'EQM minimale qui peut être obtenue lors de la modélisation à base de données à l'aide des modèles non linéaires. Le GT a été rapporté pour la première fois par Koncar N (1997), et Agalbjörn et al. (1997), et plus tard amélioré et discuté en détail par de nombreux chercheurs (Oliveira (1999; Durrant 2001; Jones et al. 2002). L'idée de base est tout à fait distincte des tentatives précédentes avec l'analyse non linéaire. Supposons que nous avons un ensemble de données Entrée-Sortie (Input-Output) (Salehnia et al. 2013):

$$\{x_1(i), \dots, x_m(i), y_i\} = \{(x_i, y_i) \mid 1 \leq i \leq M\} \quad (III.1)$$

Où : x_1 à x_m les entrées du modèle (Input) ou les variables explicatives et Y la sortie du modèle ou la variables à expliquer (output). La relation entre la variable à expliquer Y et les variables explicatives X_i est de type :

$$Y = f(X_i) + \varepsilon \quad (III.2)$$

Où : f une fonction quelconque et ε est l'erreur probable ou bruit (noise en anglais).

En générale la question la plus posée dans ce genre de cas est: à quel niveau de signification la variable Y est représentée par les variables explicatives x_i ? Et quelle sont les variables qui ont le plus d'influence sur le modèle ? Dans notre travail nous avons utilisé la technique GT (Stefánsson et al. 1997; Evans et al. 2002), que nous présentons dans ce qui suit. On peut supposer que la moyenne des ε est égale à zéro (0) et la variance du bruit (ε) est $\text{Var}(\varepsilon)$. Le domaine possible du modèle est maintenant limité aux fonctions qui ont des dérivés partiels liées. Le terme Gamma statistique (Γ) est une estimation de la variance de la réponse du modèle (output).

Le GT est basé sur $N [i, k]; k$ qui sont $k^{\text{ème}}$ ($1 \leq k \leq P$) les plus proches voisins $X_{N[i, k]}$ ($1 \leq k \leq P$) pour chaque vecteur x_i ($1 \leq k \leq P$). Plus précisément, le gamma test est dérivé de la fonction delta des vecteurs d'entrée:

$$\delta_M(k) = \frac{1}{M} \left| X_{N[i, k]} - X_i \right|^2 \quad (1 \leq k \leq p) \quad (\text{III.3})$$

Où $|\dots|$ est la distance euclidienne et par conséquent la fonction Gamma correspondante à la valeur de la sortie (output) ou (la variable à expliquer):

$$\gamma_M(k) = \frac{1}{2M} \left| Y_{N[i, k]} - Y_i \right|^2 \quad (1 \leq k \leq p) \quad (\text{III.4})$$

Où $y_{N[i, k]}$ est la valeur correspondante pour chaque ($1 \leq k \leq P$) pour chaque $k^{\text{ème}}$ plus proche voisins de vecteur x_i ($1 \leq k \leq P$). Pour calculer (Γ) une droite de régression des moindres carrés est construite pour les points $P (\delta_M(k), \gamma_M(k))$:

$$\gamma = A \delta + \Gamma \quad (\text{III.5})$$

Pour les valeurs de ($\delta=0$) on aura $\gamma=\Gamma$. On peut facilement démontrer que $\gamma_M(k) \rightarrow \text{Var}(k)$ dans la probabilité est $\delta_M(k) \rightarrow 0$. En pratique on peut réaliser la technique GT en utilisant le logiciel Win Gamma (Durrant 2001; Evans and Jones 2002). Les résultats peuvent être standardisés en considérant le terme dit V_{ratio} qui est défini comme suit:

$$V_{\text{ratio}} = \frac{\Gamma}{\sigma^2(y)} \quad (\text{III.6})$$

$\sigma^2(y)$ est la variance de Y (la réponse du modèle ou la variable à expliquer) qui nous fournit la capacité de jugement formé indépendamment de l'intervalle de variation de Y. Une valeur de V_{ratio} proche de zéro ($V_{\text{ratio}}=0$) indique un très grand degré de prédiction pour la valeur à expliquer Y. En fait :

$$1 - |V_{\text{ratio}}| = 1 - \frac{|\Gamma|}{\text{Var}(y)} \quad (\text{III.7})$$

Est pratiquement analogue a conventionnel R^2 (coefficient de détermination) qui exprime la capacité des données (X_i, Y_i) à construire un modèle linéaire. Par contre le V_{ratio} ici exprime la capacité des données à construire un modèle non linéaire.

III.3.2.4. Analyse des données à l'aide de la Technique GT

Le GT décrit les jeux de fonctionnalités (sous-ensembles) des données d'entrée disponibles sous forme de masques (MASK). Comme exemple de la façon dont GT pourrait être utilisé comme meilleure sélection de fonctionnalités, supposons un ensemble de séries de données d'entrée (x_1 , x_2 et x_3) et trois jeux de masques [0, 1, 1], [1, 0, 1] et [1, 1, 0]. Le sous-ensemble de masques [0, 1, 1] correspond aux ensembles de données sans x_1 et les deux autres masques sont des ensembles de données sans x_2 et x_3 , respectivement. Nous utilisons 0 et 1 représentation dans le contexte de la sélection des entités pour décrire les séries de données qui sont utilisées [1] et qui ne sont pas utilisées [0]. L'analyse GT sur les sous-ensembles de données masqués fournirait des informations telles que le statistique gamma (mesure du meilleur (EQM) réalisable), V_{ratio} sont proches à zéro, cela indique qu'il existe un degré élevé de prévisibilité de la sortie, et gradient (la complexité du modèle). Si les valeurs du statistique gamma et de V_{ratio} sont proches à zéro, cela indique qu'il existe un degré élevé de prévisibilité de la sortie donnée à l'aide de l'entité sélectionnée. En même temps, la valeur plus élevée du dégradé montre la complexité de l'entité sélectionnée pour créer un modèle. Cela permet au chercheur d'atteindre une conclusion fiable sur la sélection des données de modèle (Oliveira 1999; Corcoran et al. 2003).

III.3.2.5. Application de la Technique GT avec quatre (04) variables

Dans cette étude différentes combinaisons de données d'entrée ont été explorées pour évaluer leur influence sur la modélisation de l'évaporation. Il y avait (2^n-1) combinaisons significatives d'entrées (dans ce cas, $n=4$, les entrées totales disponibles étant des enregistrements journalières la température de l'air (T_{max} et T_{min}), la vitesse du vent (U_2), et l'humidité relative (H%). Sur les (2^n-1) combinaisons, le meilleur peut être déterminé en observant la valeur Gamma, qui indique une mesure du meilleur EQM pouvant être atteint à l'aide de n'importe quelle méthode de modélisation pour les données d'entrée invisibles. Les résultats de l'analyse sont présentés dans ce qui suit. Le Tableau III.6 présente l'ordre de présentation des données. Par exemple, pour le masque [1011], on a un modèle pour lequel la température T_{min} est exclue et n'est prise en compte.

Tableau III.6. Ordre de présentation des différentes variables climatiques

Variable	T_{max}	T_{min}	H%	U_2
Ordre	1	2	3	4

Nous avons quatre (04) entrées (T_{min} , T_{max} , U_2 , H%), nous avons donc quatre types de modèles : modèle à une, à deux, à trois, à quatre entrées ; et pour chaque modèle nous avons plusieurs scénarios, et on doit sélectionner le meilleur scénario. Nous présentons dans le Tableau III.7 Le nombre de scénarios possible pour chaque type de modèle. Donc pour chaque barrage, la technique GT teste tous les (15) scénarios possibles et elle nous fournit le meilleur scénario sous forme de MASK, contenant les variables à inclure et celles à exclure.

Tableau.III.7. Nombre de scénarios testés pour chaque type de modèle

Modèle	Une entrée	Deux entrées	Trois entrées	Quatre entrées
Scénarios	04	06	04	01

III.3.2.6. Résultats obtenues par la Technique GT

III.3.2.6.1. Résultats obtenues au pas de temps journalier

Nous présentons dans ce qui suit les résultats obtenus par la technique GT. Nous présentons deux types de résultats: les statistiques détaillées et les tableaux de sélection des meilleurs Mask.

Tableau III.8.Meilleurs Mask obtenus par la technique GT au pas de temps journalier

Barrages	Mask (04)	Mask (03)	Mask (02)	Mask (01)
Ain Zada	1111	0111	0110	1000
Bouhamdane	1111	1101	1100	1000
Chafia	1111	1110	1100	1000
Hammam Grouz	1111	1110	1001	1000
Zit Emba	1111	1110	1100	0100
Beni Zid	1111	1101	1100	1000
El Agram	1111	1011	1100	1000

Tableau III.9 Résultats correspondant au meilleur Mask au pas de temps journalier.

Barrages	Gamma (I)	Gradient (A)	SE	V _{ratio}	PPV	N	Mask
Ain Zada	0.0426	0.0497	0.000914	0.170	10	5237	1111
Bouhamdane	0.0512	0.0505	0.000950	0.205	10	3566	1111
Chafia	0.0667	0.0979	0.001103	0.267	10	6179	1111
Hammam Grouz	0.0535	0.0082	0.001139	0.214	10	5963	1111
Zit Emba	0.0872	0.0672	0.001648	0.349	10	4383	1110
Beni Zid	0.0523	0.1373	0.001811	0.209	10	2192	1101
El Agram	0.0881	0.2110	0.001104	0.352	10	4474	1011

Les résultats obtenus au pas de temps journalier par la technique GT varie d'un barrage à un autre (Tableau III.8), nous remarquons que, pour le modèle utilisant une seule variable, l'analyse a fait ressortir uniquement deux types de modèle : six barrages (06) utilisant uniquement la température max (T_{max}) et un barrage (01) utilisant uniquement la température minimale (T_{min}). Pour le modèle à deux entrées la technique GT à fait aussi ressortir trois types de modèles: un seul barrage (01) utilisant uniquement la température maximale (T_{max}) et le vent (U_2), cinq barrages (05) utilisant uniquement la température maximale (T_{max}) la température minimale (T_{min}), et un barrage (01) utilisant uniquement la température minimale (T_{min}) et l'humidité relative ($H\%$). Pour les modèles à trois entrées, deux barrages (02) utilisant uniquement la température maximale (T_{max}), la température minimale (T_{min}) et le vent (U_2), trois barrages (03) utilisant uniquement la température maximale (T_{max}), la température minimale (T_{min}) et le l'humidité relative ($H\%$), et un barrage (01) utilisant uniquement la température maximale (T_{max}), l'humidité relative ($H\%$), et le vent (U_2), et un barrage (01) utilisant uniquement la température minimale (T_{min}), l'humidité relative ($H\%$) et le vent (U_2). Pour le modèle à quatre entrées nous avons le modèle contenant toutes les variables climatiques. Suite aux résultats obtenus (Tableau III.8), parmi les 15 modèles testés pour chaque barrage, le meilleure modèle est celui qui a la plus faible valeur de Gamma (I).

III.3.2.6.2. Résultats Trouvées au pas de Temps Mensuelle

Les résultats obtenus par la technique GT au pas de temps mensuel sont reportés dans le (Tableau III.10)

Tableau III.10. Meilleurs Mask obtenus par la technique GT au pas de temps mensuel

Barrages	Mask (04)	Mask (03)	Mask (02)	Mask (01)
Ain Zada	1111	1011	1010	1000
Hammam Grouz	1111	1110	1100	1000
Zit Emba	1111	1101	0101	0100
El Agram	1111	1011	1100	1000
Beni Zid	1111	1101	0110	0100
Chafia	1111	1110	1010	1000
Bouhamdane	1111	1110	1100	1000

Tableau III.11. Résultats correspondant meilleur Mask au pas de temps mensuel.

Barrages	Gamma (Γ)	Gradient (A)	SE	V _{ratio}	PPV	N	Mask
Ain Zada	0.0067	0.0695	0.001422	0.027	10	170	1111
Hammam Grouz	0.0113	0.2225	0.001014	0.045	10	196	1110
Zit Emba	0.0334	0.2947	0.004365	0.134	10	144	0101
El Agram	0.0288	1.1312	0.003177	0.115	10	147	1100
Beni Zid	0.0114	0.1652	0.003355	0.046	10	72	1101
Chafia	0.0215	0.3381	0.004678	0.086	10	203	1010
Bouhamdane	0.0116	0.1132	0.003000	0.046	10	117	1111

Les résultats trouvés au pas de temps mensuel par la technique GT varie d'un barrage à un autre (Tableau III.10), nous remarquons que, pour le modèle utilisant une seule variable, l'analyse a fait ressortir uniquement deux types de modèle: cinq barrages (05) utilisant uniquement la température max (T_{max}) et deux barrages (02) utilisant uniquement la température minimale (T_{min}). Pour le modèle à deux entrées la technique GT à fait aussi ressortir cinq types de modèles modèle : trois barrages (03) utilisant uniquement les deux températures (T_{min} et T_{max}), un barrage (01) utilisant uniquement la température maximale (T_{max}) et l'humidité relative (H%), un barrage (01) utilisant la température minimale (T_{min}) et l'humidité relative (H%), un barrage (01) utilisant la température minimale (T_{min}) et le vent (U_2). Pour les modèles à trois entrées, trois types de modèles ont été obtenus ; trois barrages (03) utilisant (T_{max} , T_{min} et H%), deux barrages (02) utilisant (T_{max} , T_{min} et U_2) et deux barrages (02) utilisant (T_{max} , H% et U_2). Pour le modèle à quatre entrées nous avons choisi le modèle contenant toutes les variables climatiques: T_{min} , T_{max} , H%, U_2 . Chaque meilleur modèle pour chaque barrage a été sélectionné sur la base des résultats reportés dans le (Tableau III.11) et en particulier le facteur Gamma, parmi les 15 modèles testés pour chaque barrage, le meilleure modèle est celui qui a la plus faible valeur de Gamma (Γ).

III.3.2.7. Structures des Modèles Sélectionnés

A la lumière des résultats obtenus à différents pas de temps, nous avons opté pour la structure des modèles ci-dessous (Tableau III.12). Il est important de signaler que nous avons inclus la périodicité représenté par le jour (J: de 1 à 31) et le mois (M: de 1 à 12) comme input, pour étudier l'importance et l'impact de l'inclusion de la périodicité sur les performances des modèles. En total nous avons six différentes combinaisons des variables d'entrées.

Tableau III.12. Structure des modèles utilisés.

Modèles	Journalier	Mensuelle	Output
	Inputs	Inputs	
Modèle 1	$T_{max}, T_{min}, U_2, H\%, J, M$	$T_{max}, T_{min}, U_2, H\%, M$	E_{pan}
Modèle 2	$T_{max}, T_{min}, U_2, H\%$	$T_{max}, T_{min}, U_2, H\%$	E_{pan}
Modèle 3	T_{max}, T_{min}, U_2	T_{max}, T_{min}, U_2	E_{pan}
Modèle 4	$T_{max}, T_{min}, H\%$	$T_{max}, T_{min}, H\%$	E_{pan}
Modèle 5	$T_{max}, H\%$	$T_{max}, H\%$	E_{pan}
Modèle 6	T_{max}, T_{min}	T_{max}, T_{min}	E_{pan}

III.4. Conclusion

En raison du succès de la technique GT dans la sélection des ensembles de variables requis pour la modélisation, Nous avons démontré avec succès la capacité informative du Gamma test dans la sélection de variables pertinentes dans la construction de modèles non linéaires d'estimation de l'évaporation. Six modèles retenu et choisis qui vont être appliqués et comparés en utilisant les techniques à base d'intelligences artificielles à savoir les réseaux de neurones, les systèmes Neuro-flous et les machine à supports de vecteurs.

*Chapitre IV :
Modélisation de l'évaporation E_{pan} au pas de temps journalier par les
techniques à base d'intelligence artificielle*

IV.1. Introduction

Dans ce chapitre nous présentons les résultats obtenues par les différents modèles à base d'intelligences artificielle (IA) déjà définis au chapitre précédent sous les abréviations (MLPNN, RBFNN, GRNN, ANFIS, SVM). Nous discuterons les résultats obtenues au pas de temps journalier au niveau des sept barrages réservoirs objet de la présente étude. Pour le développement de ces modèles, le logiciel Matlab 2011b a été utilisé comme outil de programmation, ce dernier permet de développer et d'exécuter des applications utilisant la technique de l'intelligence artificielle. Pour les différentes techniques, nous avons testés plusieurs modèles et plusieurs variantes en se basant sur les résultats obtenus à l'aide de la technique Gamma Test (GT), pour notre cas d'étude, nous avons élaboré six (6) combinaisons des variables climatiques (Tableau III.12).

La base de données a été divisée en trois parties: une première partie dite d'apprentissage pour le développement et le calage des modèles, une deuxième partie dite de validation, et une troisième partie dite de test. L'apprentissage est la propriété la plus intéressante des modèles à base d'intelligence artificielle. C'est la phase de développement, durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. Une fois le modèle développé, il sera validé avec des données non utilisées durant la phase d'apprentissage, en utilisant les données de validation. Finalement, une dernière étape consiste à tester le modèle avec une partie de donnée, non utilisée durant les deux phases d'apprentissage et de validation : si la phase de test. Dans notre étude, nous avons opté pour la répartition suivante: 60% des données pour l'apprentissage, 20% pour la validation et 20% pour le test (Tableau IV.1). Le caractère aléatoire de la division de la base de données permet une représentation acceptable des différents événements tout au long des trois phases, apprentissage, validation et test.

Tableau IV.1. Répartition de la base de données utilisée au pas de temps journalier.

Station	Durée (ans)	Jours	Apprentissage	Validation	Test
Chafia	17	6179	3707	1236	1236
Beni Zid	06	2192	1315	438	438
Zit Emba	12	4383	2630	877	877
El Agram	13	4474	2684	895	895
Hammam Grouz	18	5963	3578	1193	1193
Bouhamdane	13	3566	2140	713	713
Ain Zada	17	5237	3142	1047	1047

IV.2. Critères de validation et de performances des modèles

L'évaluation d'un modèle consiste à comparer les valeurs calculées aux valeurs observées. Des indices statistiques sont utilisés pour caractériser globalement la qualité de la simulation sur l'ensemble des données, à savoir l'apprentissage, la validation et le test. Dans notre travail, nous avons utilisé quatre critères de performances numériques: la racine carrée de l'erreur quadratique moyenne (RMSE: Root Mean Squared Error), le coefficient de corrélation (Pearson Correlation Coefficient: R), l'erreur absolue moyenne (MAE : Mean Absolute Error) et l'Indice de conformité de Willmott (d: Index of agreement). En plus des performances numériques, des représentations graphiques des résultats obtenus en termes des

courbes Scatterplot et des courbes de comparaison entre les valeurs mesurées et calculées ont été élaborés.

La racine carrée de l'erreur quadratique moyenne RMSE (Eq. IV.1) est l'un des critères d'évaluation les plus utilisés dans les travaux de recherche de modélisation (Lallahem et Mania, 2003; Sudheer et al, 2002). Elle donne une indication quantitative sur l'erreur des calculs obtenue par le modèle de prévision. Il détermine la déviation de la prévision et de la simulation par rapport à la valeur observée.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (IV.1)$$

La RMSE est égale à 0 si les valeurs calculées et les valeurs observées sont égales.

Le coefficient de corrélation de Pearson (R) est habituellement le plus utilisé pour évaluer les performances des modèles hydrologiques (Legates et McCabe, 1999). Il est obtenu en calculant la régression linéaire entre les valeurs (évaporation) calculées et les valeurs (évaporation) observées ou mesurées. Sa formulation est donnée par l'équation (Eq. IV.2) Le coefficient de corrélation est compris toujours entre -1 et 1.

$$R = \left[\frac{\frac{1}{N} \sum (O_i - O_m)(P_i - P_m)}{\sqrt{\frac{1}{N} \sum (O_i - O_m)^2} \sqrt{\frac{1}{N} \sum (P_i - P_m)^2}} \right] \quad (IV.2)$$

Plus R est proche à 1 plus nous aurons un bon ajustement entre les valeurs calculées et les valeurs observées (Legates et McCabe 1999).

L'Indice de conformité de Willmott (d) (Eq. IV.3) se veut une mesure descriptive, relative et circonscrite à l'intérieur des bornes (0-1) qui permet de l'utiliser de façon générale à des fins de comparaison. Tous comme le coefficient de corrélation R, une valeur de 1 indique une relation parfaite entre l'observé et le prédit (Willmott 1981).

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (|P_i - O_m| + |O_i - O_m|)^2} \quad 0 \leq d \leq 1 \quad (IV.3)$$

L'Erreur moyenne absolue MAE définit la valeur moyenne de la différence absolue entre les valeurs calculées et mesurées. Un MAE bas signifie une bonne performance de modèle. Une parfaite concordance entre les valeurs observées et celles simulées produit un MAE=0. Le MAE est calculée par (Eq. IV.4):

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (IV.4)$$

Où :

- O_i : Valeur de l'évaporation mesurée ou dite parfois observée E_{pan} ;
 P_i : Valeur de l'évaporation E_{pan} calculée (prédites) par le modèle ;
 N : Nombre total des mesures en jours ou en mois (nombre d'individus);
 O_m : Moyenne des valeurs observées de l' E_{pan} ;
 P_m : Moyenne de valeurs calculées (prédites) de l' E_{pan} .

Avant d'introduire les données aux différents modèles, elles sont normalisées (centrées et réduits) en utilisant la formule suivante:

$$x_{ni,k} = \frac{x_{i,k} - m_k}{S_{dK}} \quad (IV.5)$$

Avec :

- $x_{n,i,k}$: Valeur normalisée de la variable k pour l'individu i ;
 m_k : Moyenne de la variable k ;
 σ_k : Ecart type de la variable k .

IV.3. La mise en œuvre des différents modèles

Les différents modèles utilisés possèdent différent type de paramètres à optimiser durant la phase d'apprentissage. Pour le modèle MLPNN, nous avons utilisées un modèle à trois couches: couche d'entrée, couche cachée et couche de sortie. Pour les fonctions d'activation, nous avons choisi la fonction sigmoïde pour les neurones de la couche cachée et la fonction linéaire pour le neurone de sortie. L'apprentissage du réseau s'est fait en utilisant l'algorithme de Rétro-Propagation du gradient. Le nombre de neurones dans la couche d'entrée est égale au nombre de variables climatique selon l'architecture choisie (de 2 à 6). Nous avons varié le nombre de neurones de la couche cachée de 1 à 20, et le nombre optimal varie d'un barrage à l'autre et d'un modèle à l'autre. Les réseaux RBFNN comportent une seule couche cachée dont la fonction d'activation est appelée fonction-noyau ou Gaussienne et une couche de sortie avec une fonction d'activation linéaire. Durant la phase d'apprentissage on fait varier un seul paramètre qui est le « *Spread* » de la fonction Gaussienne, généralement entre 0.01 et 1. Dans la majorité des cas, nous avons pu constater que le « *Spread* » varie entre 0.1 et 0.35. Une remarque très importante concernant les modèles RBFNN: le nombre de neurones dans la couche cachée est déterminé automatiquement durant la phase d'apprentissage et peut être égale au nombre de données d'entrée. Pour les modèles GRNN, se sont des modèles sans apprentissage et dite « *modèles à un seul passage* ». Malgré qu'il se compose de quatre couches, l'utilisateur n'intervient pas dans la détermination du nombre de neurones dans les différentes couches, mais à l'image des modèles RBFNN on fait varier un seul paramètre qui est le « *Spread* » de la fonction Gaussienne, au niveau de la deuxième couche. Généralement le paramètre « *Spread* » varie entre 0.1 et 1. Comme sur la couche cachée, il y a autant de neurones que d'observations, le réseau GRNN assigne un neurone à chaque observation (individu). Ce neurone possède une zone d'influence, dont le rayon est fonction du paramètre « *Spread* », autour de l'observation correspondante. Plus le paramètre « *Spread* » est faible, plus le neurone mémorise bien l'observation qui lui a été assignée. Le réseau GRNN donne alors une excellente précision lorsque l'observation à l'entrée est une des observations apprises (bonne capacité à mémoriser).

Pour les modèles SVM, nous avons utilisés une version modifiée qui porte le nom de Least Squares-SVM et est dénommé par l'acronyme LSSVM. Les LSSVM peuvent également être mis en œuvre en situation de régression pour prédire l'évaporation, c'est-à-dire pour l'approximation de fonctions d' E_{pan} en fonction des variables climatiques. Dans le cas non linéaire, le principe consiste à rechercher une estimation de la fonction par sa décomposition sur une base fonctionnelle. La forme générale des fonctions calculées par les LSSVM se met sous la forme :

$$\Phi(x, y) = \sum_{i=1}^{\infty} w_i v_i(x) \quad (IV.6)$$

Le problème se pose toujours comme la minimisation d'une fonction coût, mais plutôt que d'être basée sur un critère d'erreur quadratique (moindres carrés). On note $|\cdot|_{\epsilon}$ la fonction qui est paire, continue, identiquement nulle sur l'intervalle $[0, \epsilon]$ et qui croit linéairement sur $[\epsilon, +\infty]$, la fonction coût est alors définie par:

$$E(w, \gamma) = \frac{1}{n} \sum_{i=1}^n |y_i - \Phi(x, \gamma)|_{\epsilon} + \gamma \|w\|^2 \quad (IV.7)$$

Où γ est un paramètre de régularisation assurant le compromis entre généralisation et ajustement. De même que précédemment, on peut écrire les solutions du Problème d'optimisation. Les points de la base d'apprentissage associés à un coefficient non nul sont là encore nommés vecteurs support. Dans cette situation, les noyaux k utilisés sont ceux naturellement associés à la définition de bases de fonctions.

Pour les modèles d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS), nous avons testés trois types de modèles de type Sugeno, avec trois différentes méthodes de partitionnement. Le problème du modèle ANFIS se réside au niveau de l'optimisation du nombre de règles floues, pour cela plusieurs méthodes ont été proposé et dite couramment méthodes de partitionnement. Ces méthodes cherchent la meilleure méthode de partitionnement de l'espace d'entrée (des variables d'entrée) pour construire la base de règles floues. Trois méthodes ont été proposées et largement utilisé dans la littérature: (i) la méthode en grille dite «*Grid Partition*» et le modèle correspondant est appelée «ANFIS_GP», (ii) la méthode du Groupage soustractif dite «*Subtractive Clustering* » et le modèle correspondant est appelée «ANFIS_SC» et (iii) la méthode c -moyennes floues dite «*Fuzzy c-mean Clustering*» et le modèle correspondant est appelée «ANFIS_FC». Ces méthodes de partage de l'espace des entrées sont utilisées pour la détermination des règles floues sur la base des fonctions d'appartenance. Les trois modèles sont développés sous Matlab avec trois différentes fonctions: Genfis1 pour le modèle ANFIS_GP, Genfis2 pour le modèle ANFIS_SC et Genfis3 pour le modèle ANFIS_FC. Pour le modèle ANFIS_GP on peut utiliser plusieurs fonctions d'appartenance, par contre pour les deux autres; ANFIS_SC et ANFIS_FC on utilise des fonctions de type gaussien. La méthode de partitionnement en grille partage ou divise l'espace des entrées en sous-espace rectangulaire utilisant un nombre prédéfini des sous-ensembles floues (MFs). En augmentant le nombre des variables d'entrée, le nombre des règles floues croit exponentiellement. Dans le cas de n variables d'entrées, et m MFs pour chaque variable d'entrée, le nombre total des règles floues est égale à n^m . Le nombre des MFs testées varie de 2

à 5 MFs. La méthode du Groupage soustractif est une méthode qui utilise le concept de la classification pour la détermination des règles floues. Chiu (1994) a proposé un algorithme soustractif inspiré de la méthode de Yager (Yager et Filev, 1994). Contrairement à la première méthode, la construction de la base de règles, se fait elle-même d'une façon automatique: le nombre de règles floues est égale au nombre de sous-ensembles floues, et on fixe uniquement le centre du groupage soustractif, généralement entre 0.15 et 0.85. Une fois le centre choisi, la répartition des variables d'entrée en fonction d'appartenance se fait d'une façon automatique et sans aucun choix préalable: l'algorithme procède à la répartition des variables d'entrée en différents sous-ensembles appelés classe ou *Cluster*, et chaque cluster correspond à une règle floue. Pour la troisième méthode dite *c-moyennes floues* ou «Fuzzy c-mean Clustering», est une méthode de classification, mais contrairement à la méthode du Groupage soustractif, on fixe le nombre de cluster ou classe, et chaque cluster correspond à une règle floue.

IV.4. Résultats de la modélisation et analyse comparative

Comme déjà reporté dans les chapitres précédents, l'objectif principal de notre étude est le développement des modèles mathématique à base d'intelligence artificielle pour l'estimation de l'évaporation au niveau des barrages réservoirs (E_{pan}). Pour avoir des conclusions solide sur la qualité de la modélisation, et pour pouvoir comparer la robustesse des modèles, nous avons testé six scénarios (ou combinaison), ayant chacun différents variables climatique comme entrée (inputs). Les six scénarios sont : (i) les modèles qui utilisent les T_{max} , T_{min} , U_2 , H%, J, et M, (ii) les modèles qui utilisent les T_{max} , T_{min} , U_2 et H%, (iii) les modèles qui utilisent les T_{max} , T_{min} et la U_2 , (iv) les modèles qui utilisent les T_{max} , T_{min} , et H%, (v) les modèles qui utilisent les T_{max} , et H%, et (vi) les modèles qui utilisent les T_{max} et T_{min} . Il est important de rappeler que les J et M représentent respectivement le numéro du jour (de 1 à 31) et le numéro du mois (de 1 à 12), qui sont deux composantes du calendrier Grégorien. Pour chaque scénario, les sept modèles (MLPNN, RBFNN, GRNN, LSSVM, ANFIS_SC, ANFIS_FC, ANFIS_GP) utilisent les mêmes entrées. Par la suite les modèles qui utilisent le premier scénario seront désignés par le numéro 1: MLPNN1, RBFNN1, GRNN1, ..., etc. Les modèles utilisent le deuxième scénario seront désignés par le numéro 2 : MLPNN2, RBFNN2, GRNN2, ..., etc., (Tableau IV.2-8). Les performances des modèles sont évaluées en utilisant quatre critères de mesure de l'erreur numérique: RMSE, MAE, R , et le critère d . Les résultats obtenus seront discutés ci-après au niveau de chaque barrage séparément.

IV.4.1. Résultats de la modélisation pour le Barrage Chafia

Les résultats numériques obtenus au niveau du barrage Chafia sont reportés au niveau du Tableau IV.2, agrémenté par les Figure IV.1-2, durant les trois phases d'apprentissage, de validation et de test. Nous analysons ci-après les résultats obtenus par une comparaison des performances des différents modèles. En phase d'apprentissage, les performances varient d'un modèle à l'autre et varient significativement selon le nombre de variables d'entrée utilisé. Pour le MLPNN, en utilisant les quatre variables climatiques (MLPNN2) comme entrées (T_{max} , T_{min} , U_2 , H %) nous obtenons les meilleures performances par rapport aux autres modèles avec les meilleures indices statistiques ($R=0.854$, $d=0.916$, $RMSE= 0.932mm$, $MAE=0.697mm$). Lorsque les deux composantes du calendrier Grégorien (J et M) sont incluses avec les quatre variables climatiques (MLPNN1), on enregistre une amélioration significative au niveau des performances

du modèle MLPNN1. En accord avec les résultats reportés dans le **Tableau IV.2**, en incluant les J et M , les R et d passent de 0.854 à 0.906, et de 0.916 à 0.949, entre le modèle MLPNN2 et MLPNN1, avec des améliorations de l'ordre de 5.2% et 3.3%, respectivement. En plus, les RMSE et MAE se dégradent significativement avec des pourcentages de l'ordre de 18.24% et 19.65%, respectivement, entre les deux modèles MLPNN2 et MLPNN1. Donc, une des premières conclusions de notre travail est la contribution significative des composantes du calendrier Grégorien (J et M) dans l'amélioration des performances du MLPNN qui sera confirmé par la suite en phase de validation et de test.

En utilisant uniquement trois variables climatiques (MLPNN3 et MLPNN4), on remarque que les performances du modèle MLPNN3 ayant comme variables d'entrée les (T_{max} , T_{min} , U_2) sont meilleure que les performances du modèle MLPNN4, et que les deux modèles (MLPNN3, MLPNN4) sont moins performant que les modèles MLPNN1 et MLPNN2. Par comparaison, le MLPNN3 dépasse le MLPNN4 avec des pourcentages de l'ordre de 2.2% et 1.6% en tenant compte des valeurs des R et d , et que le MLPNN3 permet une réduction des RMSE et MAE du modèle MLPNN4 avec des pourcentages de l'ordre de 5.7% et 6.06%. Par rapport au meilleure modèle (le MLPNN1), on remarque que le MLPNN1 est largement supérieur au modèle MLPNN3 avec des pourcentages de l'ordre de 6.1% et 3.8% en tenant compte des R et d , et des pourcentages de l'ordre de 20.45% et 21.34%, en tenant compte des valeurs des RMSE et MAE, respectivement. Donc on peut conclure que lorsqu'on utilise uniquement trois variables climatiques, mieux d'utiliser le vent que l'H%. Lorsqu'on utilise uniquement deux variables (MLPNN5, MLPNN6), les meilleurs résultats sont obtenus avec le modèle MLPNN6 qui utilise les deux températures (T_{max} , T_{min}) comme entrées, meilleure que les deux modèles MLPNN5 et MLPNN4, et légèrement inférieure au modèle MLPNN3. Avec le MLPNN6, on obtient des R et d de l'ordre de 0.843 et 0.908, et des RMSE et MAE de l'ordre de 0.964mm et 0.721mm, respectivement.

Les résultats obtenus en phase de validation et de test (**Tableau IV.2**) confirment celles obtenus en phase d'apprentissage. En phase de validation, les meilleures performances sont obtenues avec le MLPNN1, largement supérieure aux autres modèles, ce qui confirme l'utilité et l'importance des composantes du calendrier Grégorien (J et M) dans l'estimation de l' E_{pan} . En tenant compte des R et d , le MLPNN1 dépasse le modèle MLPNN2 avec des pourcentages de 5.1% et 3.1%, respectivement. La différence entre les deux modèles MLPNN2 et MLPNN3 est relativement négligeable, alors que le MLPNN6 qui utilise les deux températures (T_{min} et T_{max}) possède relativement les mêmes performances que le modèle MLPNN2. Durant la phase de test, on enregistre des résultats similaire aux résultats obtenus durant la phase de validation avec des différences non significatives en tenant compte de tous les indices de performances. Les meilleurs résultats sont obtenus avec le modèle MLPNN1 avec des valeurs R et d de l'ordre de 0.894 et 0.943, respectivement. On remarque aussi que les trois modèles MLPNN2, MLPNN3 et MLPNN6 possèdent les mêmes performances avec des différences non significatives. Finalement, les plus faibles résultats sont obtenus avec les modèles MLPNN4 et MLPNN5, avec les plus faibles R et d .

Les résultats obtenus avec les modèles RBFNN (**Tableau IV.2**) montrent une différence significative entre le modèle RBFNN1 et les autres modèles, et la différence est plus remarquable en phase d'apprentissage, et aussi on remarque que les résultats en phase de test sont plus meilleure qu'on phase de validation. En phase d'apprentissage, l'estimation de l' E_{pan} est excellente avec des valeurs des RMSE rangés entre 0.537mm et 1.013mm, des MAE rangés

entre 0.399mm et 0.755mm. Le modèle RBFNN1 est meilleure que le modèle RBFNN2, et il améliore les valeurs des R et d avec des pourcentages de l'ordre de 10% et 5.9%, et il assure une amélioration des RMSE et MAE avec des pourcentages de l'ordre de 42.32% et 42.50%. Ces résultats confirment l'importance et l'utilité de l'utilisation des composantes du calendrier Grégorien (J et M) dans l'estimation de l' E_{pan} , comme déjà démontré précédemment avec les MLPNN. On remarque que les trois modèles RBFNN2, RBFNN3 et RBFNN4 possèdent les mêmes performances, cela peut être interprété par le fait que la contribution des températures (T_{max} , T_{min}) est prédominante par rapport à la contribution des $H\%$ et U_2 . Finalement, toujours en phase d'apprentissage, les plus faibles performances sont obtenues avec le modèle RBFNN5 ($R=0.824$ et $d=0.897$) pour lequel nous avons exclu la T_{min} des variables d'entrée.

En phase de validation, les modèles RBFNN sont moins performants qu'en phase d'apprentissage et les meilleures performances sont toujours obtenues avec le modèle RBFNN1 ($R=0.855$ et $d=0.920$), suivie par le RBFNN3 ($R=0.843$ et $d=0.911$), alors que les faibles performances sont obtenues par le modèle RBFNN5 (RMSE=1.046mm, MAE=0.774mm). Durant la phase de test, on enregistre une légère amélioration des performances par rapport à la phase de validation. Pour le RBFNN1 les R et d passent de (0.855 et 0.920) à (0.867 et 0.929) avec des améliorations de l'ordre de 1.2% et 0.9%. Il est important de signaler que les plus faibles performances durant la phase de test sont obtenues par le modèle RBFNN5, avec les plus grandes valeurs des RMSE (1.049mm) et MAE (0.789mm). En accord avec les résultats obtenus avec les modèles RBFNN, nous pouvons conclure que ces derniers possèdent plus de capacité durant la phase de calage (apprentissage) par rapport aux modèles MLPNN, mais sont relativement faibles en phases de généralisations (validation et test).

Avec les modèles GRNN, on remarque que les meilleures performances sont obtenues avec le modèle GRNN1 et cela à l'image des résultats obtenus avec les modèles (RBFNN et MLPNN), largement supérieure aux modèles (GRNN2 au GRNN6) en phase d'apprentissage, et légèrement en phases de validation et de test. En phase d'apprentissage, le modèle GRNN1 dépasse largement le modèle GRNN2 avec des améliorations significatives en termes des R (4.4%) et d (2.5%). Le modèle GRNN2 occupe la deuxième place en termes de performances, le modèle GRNN5 fournit les plus faibles performances ($R=0.805$ et $d=0.889$), alors que le modèle GRNN6 qui utilise uniquement les T_{max} et T_{min} comme entrée occupe la troisième place ($R=0.865$ et $d=0.922$), largement meilleure que les modèles utilisant trois entrées (GRNN3 et GRNN4). Durant les phases de validation et de test, on remarque que les performances des modèles se dégradent et que le modèle GRNN1 est toujours le meilleur par rapport aux autres avec les plus grandes valeurs des R et d et les plus faibles valeurs des RMSE et MAE. Il est important de signaler aussi que le modèle GRNN6 est meilleur que les modèles utilisant trois entrées et que le modèle GRNN5 a fourni les plus faibles performances. Une des plus importantes conclusions tirées des résultats obtenus avec le modèle GRNN est sa capacité d'estimation des E_{pan} en utilisant uniquement les températures maximale et minimale, plus meilleure que les deux modèles précédents (MLPNN6 et RBNN6).

Avec les modèles LSSVM (Tableau IV.2) qui sont une version améliorée des modèles SVM standard, bien que les résultats soient acceptables durant les trois phases d'apprentissage, de validation et de test; on remarque que le LSSVM1 a fourni les meilleures performances légèrement inférieures aux modèles RBFNN1 et GRNN1, et meilleure que le modèle MLPNN1 en phase d'apprentissage. En utilisant les quatre variables climatiques en plus des composantes du calendrier Grégorien (J et M), le LSSVM1 estime l' E_{pan} avec des R et d de l'ordre de 0.934 et

0.964, meilleure que les valeurs fournies par le LSSVM2 ($R=0.865$ et $d=0.922$), alors que les modèles LSSVM3, LSSVM4 et LSSVM6 sont relativement égaux avec des différences non significatives. En phase de validation, les plus faibles résultats en termes des quatre indices statistiques sont obtenus par le modèle LSSVM5 ($RMSE=1.047mm$, $MAE=0.783mm$).


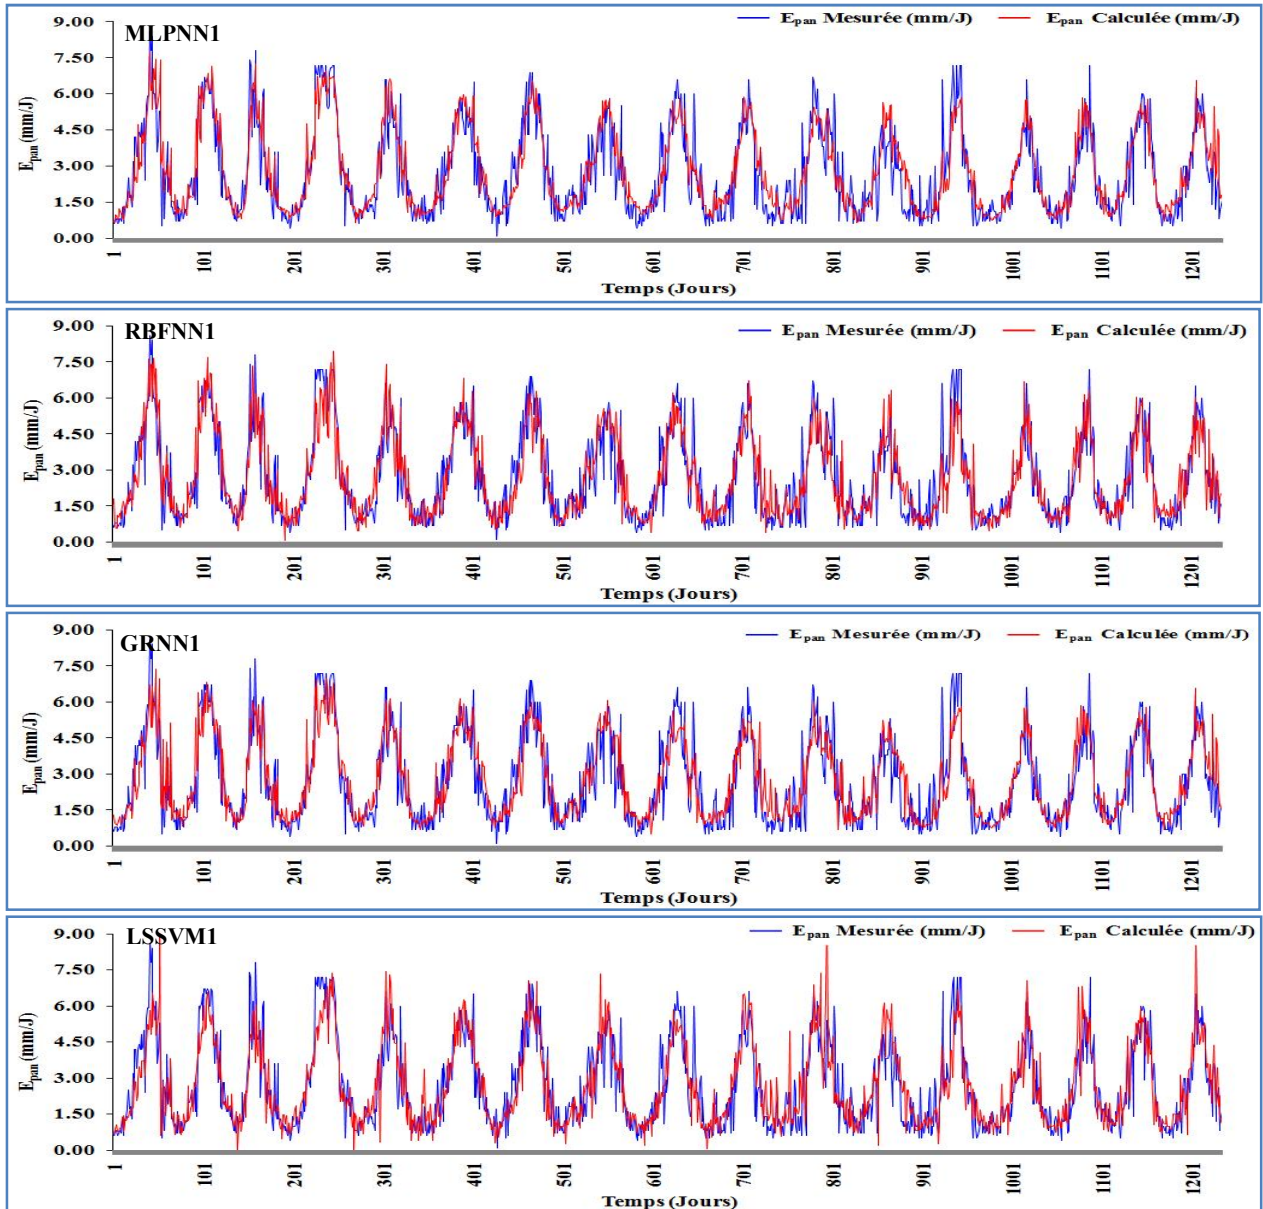


Figure IV.1. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Chafia, phase de test.

Finalement, en phase de test, on peut facilement remarquer que le modèle LSSVM6 qui utilise uniquement les deux températures (T_{min} et T_{max}) occupe la deuxième place légèrement inférieure au meilleur modèle (LSSVM6) avec des différences de l'ordre de 0.9% et 1% en termes de R et d , respectivement, qui sont négligeables. Étant donné que la phase de test est la phase la plus importante et sur la base de laquelle on juge définitivement les performances des modèles, on peut conclure qu'en utilisant les LSSVM comme modèles d'estimation de l' E_{pan} , l'utilisation des températures T_{min} et T_{max} permet largement d'obtenir d'excellentes performances sans la nécessité d'inclure les U_2 et $H\%$. Cette conclusion est en accord avec les résultats obtenus

avec les deux modèles RBFNN et GRNN. On peut ajouter aussi que l'apport d'information supplémentaire assuré par les deux variables climatiques (U_2 et $H\%$) peut être capturé uniquement par le modèle MLPNN. Toutes ces conclusions doivent être vérifiées par l'utilisation d'un autre type de modèles complètement différent des modèles déjà discuté, il s'agit des modèles d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS) qui feront l'objet des prochaines discussions.



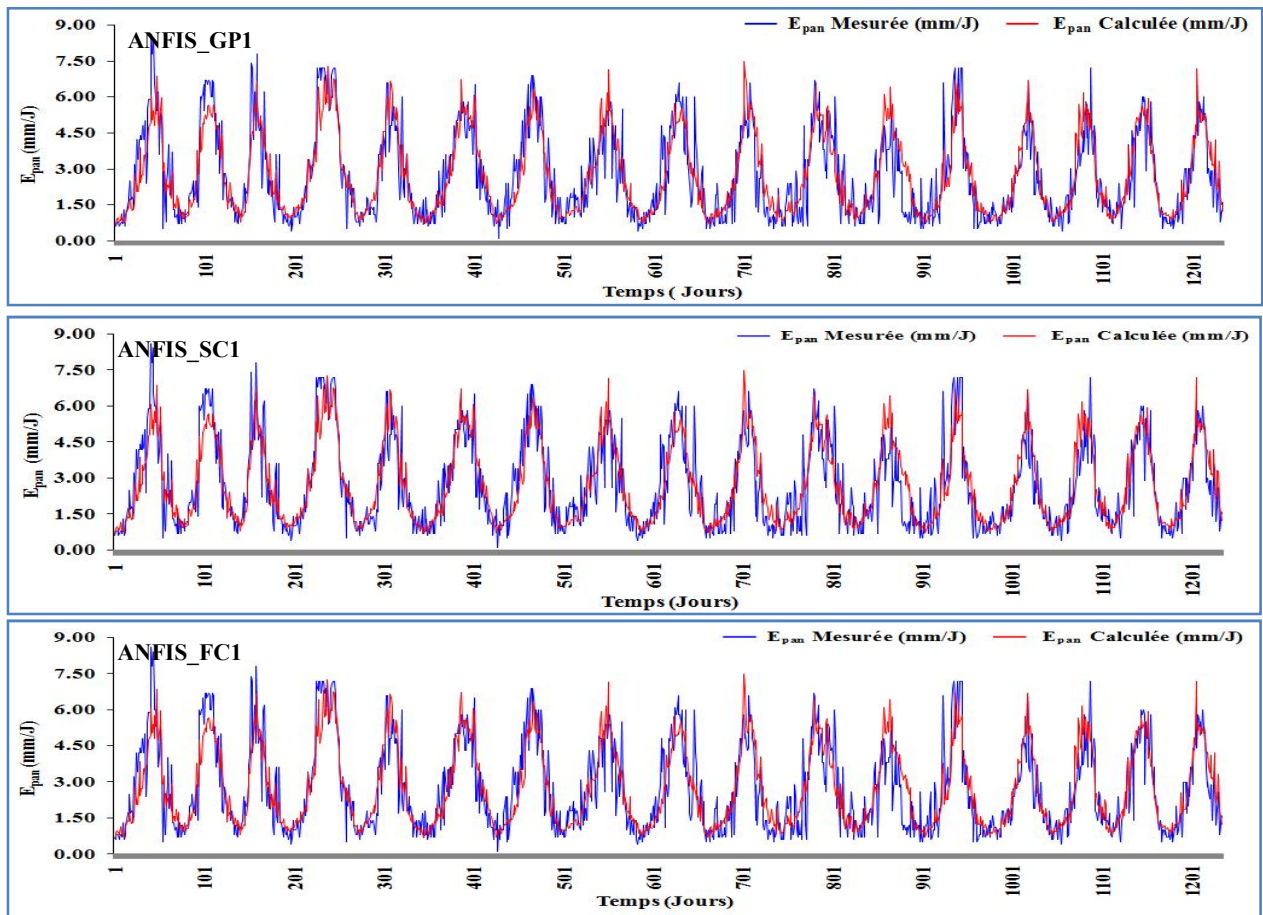


Figure IV.2. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Chafia, phase de test.

Pour les modèles d'inférence floue à base de réseaux de neurones adaptatifs (ANFIS), nous avons appliqué trois types de modèles (ANFIS_GP, ANFIS_SC et ANFIS_FC). Pour les modèles ANFIS_GP, le paramètre important qui influe le plus sur les performances est le nombre des sous-ensembles flous à utiliser pour chaque variable (les MFs): plus le nombre des MFs augmente plus la complexité du modèle augmente, et ce type de modèle ne peut pas être utilisé au-delà de six variables (Jang 1993; Sanikhani 2012). Dans le cadre de notre étude, nous avons varié le nombre des MFs selon la structure du modèle: deux MFs pour les modèles ANFIS_GP1 et ANFIS_GP2, et trois MFs pour les quatre autres modèles. Les résultats obtenus avec les modèles ANFIS_GP montrent une supériorité du modèle ANFIS_GP1 durant la phase d'apprentissage ($\bar{R}=0.905$, $d=0.948$), largement supérieure au modèle ANFIS_GP2 ($R=0.857$, $d=0.919$). En plus, le modèle ANFIS_GP1 améliore les RMSE et MAE du modèle ANFIS_GP2 par des pourcentages de l'ordre de 17.55% et 19.65%, respectivement. Ces résultats confirment l'importance des composantes du calendrier Grégorien (J et M) déjà démontré par les modèles précédent. Toujours en phase d'apprentissage, les plus faibles performances sont obtenues par le modèle ANFIS_GP5 pour lequel nous avons exclu la T_{min} . Pour les autres trois modèles on enregistre des performances relativement similaires avec des R et d qui varient entre (0.842 et 0.851), (0.908 et 0.915), respectivement.

Tableau IV.2 Performances des modèles journaliers au niveau du Barrage Chafia

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.906	0.949	0.762	0.560	0.894	0.942	0.799	0.597	0.894	0.943	0.817	0.604
MLPNN2	0.854	0.916	0.932	0.697	0.843	0.911	0.958	0.702	0.847	0.912	0.963	0.722
MLPNN3	0.845	0.911	0.958	0.712	0.840	0.909	0.967	0.709	0.845	0.911	0.967	0.724
MLPNN4	0.823	0.895	1.016	0.758	0.814	0.890	1.034	0.765	0.816	0.891	1.044	0.786
MLPNN5	0.823	0.895	1.016	0.758	0.814	0.890	1.034	0.765	0.816	0.892	1.044	0.786
MLPNN6	0.843	0.908	0.964	0.721	0.842	0.908	0.964	0.710	0.845	0.909	0.968	0.727
RBFNN1	0.954	0.976	0.537	0.399	0.855	0.920	0.933	0.684	0.867	0.929	0.908	0.668
RBFNN2	0.854	0.917	0.931	0.694	0.839	0.909	0.970	0.708	0.840	0.910	0.980	0.734
RBFNN3	0.854	0.917	0.930	0.696	0.843	0.911	0.958	0.707	0.843	0.910	0.972	0.725
RBFNN4	0.854	0.917	0.930	0.692	0.830	0.904	0.994	0.732	0.837	0.908	0.987	0.741
RBFNN5	0.824	0.897	1.013	0.755	0.805	0.889	1.046	0.774	0.814	0.891	1.049	0.789
RBFNN6	0.846	0.911	0.956	0.715	0.839	0.908	0.969	0.715	0.845	0.912	0.966	0.725
GRNN1	0.944	0.969	0.594	0.410	0.876	0.931	0.860	0.628	0.881	0.934	0.858	0.640
GRNN2	0.900	0.944	0.781	0.563	0.849	0.916	0.941	0.691	0.848	0.915	0.957	0.714
GRNN3	0.843	0.911	0.958	0.707	0.853	0.915	0.927	0.686	0.850	0.913	0.951	0.713
GRNN4	0.830	0.904	0.994	0.732	0.849	0.911	0.940	0.693	0.848	0.911	0.956	0.717
GRNN5	0.805	0.889	1.046	0.774	0.827	0.894	1.002	0.746	0.830	0.896	1.009	0.759
GRNN6	0.865	0.922	0.899	0.667	0.854	0.917	0.926	0.683	0.854	0.916	0.941	0.704
LSSVM1	0.934	0.964	0.641	0.456	0.851	0.920	0.948	0.682	0.854	0.922	0.954	0.700
LSSVM2	0.864	0.923	0.902	0.666	0.843	0.912	0.960	0.701	0.837	0.909	0.992	0.744
LSSVM3	0.855	0.917	0.927	0.693	0.844	0.911	0.954	0.705	0.841	0.911	0.977	0.730
LSSVM4	0.850	0.914	0.943	0.700	0.836	0.906	0.977	0.717	0.843	0.912	0.972	0.734
LSSVM5	0.822	0.896	1.019	0.760	0.810	0.890	1.043	0.772	0.815	0.894	1.047	0.783
LSSVM6	0.842	0.909	0.965	0.721	0.839	0.908	0.969	0.714	0.845	0.912	0.969	0.730
ANFIS_GP1	0.905	0.948	0.761	0.552	0.853	0.922	0.955	0.684	0.853	0.921	0.957	0.689
ANFIS_GP2	0.857	0.919	0.923	0.687	0.844	0.913	0.958	0.701	0.843	0.912	0.973	0.723
ANFIS_GP3	0.852	0.915	0.937	0.700	0.844	0.912	0.955	0.704	0.843	0.911	0.972	0.725
ANFIS_GP4	0.847	0.912	0.949	0.706	0.839	0.908	0.970	0.711	0.843	0.911	0.970	0.728
ANFIS_GP5	0.821	0.895	1.022	0.761	0.812	0.891	1.038	0.767	0.816	0.892	1.043	0.780
ANFIS_GP6	0.841	0.908	0.969	0.726	0.841	0.909	0.963	0.711	0.845	0.911	0.966	0.731
ANFIS_SC1	0.889	0.938	0.822	0.597	0.882	0.934	0.839	0.605	0.877	0.933	0.870	0.642
ANFIS_SC2	0.857	0.919	0.923	0.687	0.844	0.913	0.958	0.701	0.843	0.912	0.973	0.723
ANFIS_SC3	0.846	0.912	0.953	0.714	0.840	0.909	0.964	0.709	0.841	0.910	0.975	0.731
ANFIS_SC4	0.848	0.913	0.947	0.707	0.840	0.909	0.965	0.706	0.843	0.911	0.969	0.726
ANFIS_SC5	0.848	0.913	0.947	0.707	0.840	0.909	0.965	0.706	0.843	0.911	0.969	0.726
ANFIS_SC6	0.841	0.908	0.969	0.726	0.841	0.909	0.963	0.711	0.845	0.911	0.966	0.731
ANFIS_FC1	0.885	0.936	0.833	0.606	0.871	0.928	0.876	0.633	0.869	0.928	0.895	0.662
ANFIS_FC2	0.855	0.917	0.930	0.691	0.841	0.910	0.964	0.707	0.840	0.910	0.980	0.730
ANFIS_FC3	0.854	0.916	0.931	0.696	0.842	0.911	0.959	0.712	0.842	0.910	0.972	0.723
ANFIS_FC4	0.851	0.914	0.940	0.699	0.833	0.909	0.985	0.721	0.839	0.908	0.983	0.738
ANFIS_FC5	0.824	0.897	1.012	0.753	0.810	0.890	1.044	0.779	0.814	0.892	1.049	0.784
ANFIS_FC6	0.844	0.910	0.961	0.718	0.840	0.909	0.967	0.713	0.844	0.910	0.970	0.728

Durant la phase de validation, on enregistre une dégradation significative au niveau des performances des modèles, en particulier pour le modèle ANFIS_GP1, pour lequel le coefficient R passe de 0.905 (apprentissage) à 0.853 (validation), avec une perte de l'ordre de 5.2%, et le coefficient d passe de 0.948 (apprentissage) à 0.922 (validation), avec une perte de l'ordre de

2.6%. Pour les autres modèles, ils possèdent pratiquement les mêmes performances avec des RMSE et MAE rangés entre 0.955mm et 0.970mm, et 0.701mm et 0.711mm, respectivement. Finalement, le modèle ANFIS_GP5 a fourni les plus faibles performances. En phase de test, cinq modèles ont fournies des performances relativement égales avec une légère supériorité au profit du modèle ANFIS_GP1 ($R=0.823$, $d=0.921$), alors que le modèle ANFIS_GP5 était le moins performant ($R=0.816$, $d=0.892$). Les résultats obtenus avec les modèles ANFIS_SC sont différent de tous les modèles précédents, pour lequel on enregistre une supériorité du modèle ANFIS_SC1 durant les trois phases, apprentissage ($R=0.889$, $d=0.938$), avec relativement les mêmes performances durant la phase de validation ($R=0.882$, $d=0.934$), et légèrement inférieure en phase de test ($R=0.877$, $d=0.933$). Pour les autres 5 modèles on enregistre une égalité durant les trois phases avec des différences négligeable. Ces résultats nous conduit à conclure qu'on utilisant le modèle ANFIS_SC, l'effet des deux variables (U_2 et $H\%$) est négligeable et que l'effet des deux températures T_{min} et T_{max} est prédominant. Finalement, pour les résultats obtenus avec les modèles ANFIS_FC; ANFIS_FC1 était meilleure durant les trois phases, d'apprentissage (RMSE=0.833mm, MAE=0.606mm), validation (RMSE=0.876mm, MAE=0.633mm) et de test (RMSE=0.895mm, MAE=0.662mm), respectivement. Pour les autres modèles, on enregistre une égalité avec des différences négligeable entre les quatre modèles (ANFIS_FC2, 3, 4 et 6), et que le modèle ANFIS_FC5 est le moins performant avec les plus faible R et d ($R=0.810$, $d=0.890$) en phase de validation, et ($R=0.814$, $d=0.892$).

IV.4.1.1. Résultats récapitulatif des différents modèles pour barrage Chafia

Dans la section précédente nous avons comparés les différents modèles proposés dans la présente étude pour l'estimation de l' E_{pan} , et nous avons analysé les résultats selon les différentes combinaisons des variables climatiques utilisés. A la lumière des résultats obtenus, et sur la base des performances des modèles en phase de test, différentes conclusions peuvent être tirées:

1. Les meilleures performances (Tableau IV.3) sont toujours obtenues avec les modèles utilisant les quatre variables climatiques et les deux composantes (J et M) du calendrier Grégorien (combinaison N°1).
2. Par comparaison, le MLPNN1 était meilleure que tous les autres modèles, avec les R et d les plus élevées ($R=0.894$, $d=0.943$) et les RMSE et MAE les plus faibles (RMSE =0.817mm, MAE =0.604mm), suivie par le modèle GRNN1, alors que le modèle LSSVM1 a fourni les plus faibles résultats.
3. Bien que le modèle RBFNN1 fût meilleure en phase d'apprentissage, il a occupé la cinquième place en phase de test, donc il possède moins de capacité de généralisation que les autres modèles, et meilleure que les deux modèles LSSVM1 et ANFIS_GP1.
4. Lorsque les deux composantes du calendrier Grégorien (J et M) sont exclues des inputs, on remarque que les meilleures performances sont obtenues avec les deux modèles MLPNN2 et GRNN2 qui possèdent les mêmes performances, légèrement supérieure aux autres modèles.
5. En utilisant uniquement deux variables climatiques comme entrées, les modèles utilisant les deux températures T_{max} et T_{min} (combinaison N°6) ont été meilleures par rapport aux modèles utilisant la T_{max} et $H\%$ (combinaison N°5). Les meilleures performances sont assurées par le modèle GRNN6 ($R=0.854$, $d=0.916$) et (RMSE=0.854mm, MAE=0.916mm), légèrement supérieures aux six autres modèles qui ont fourni les mêmes performances avec égalité de tous les quatre indices statistiques.
6. Pour les modèles utilisant trois variables climatiques (combinaison 3 et 4), les résultats ont montrés que, les meilleures performances sont obtenues avec les modèles MLPNN3,

RBFNN3, GRNN3, et le modèle ANFIS_FC3, utilisant les T_{max} , T_{min} et U_2 comme entrées. Pour les autres trois modèles, les meilleures performances sont obtenues avec la combinaison 4 (LSSVM4, ANFIS_SC4 et ANFIS_GP4), utilisant les T_{max} , T_{min} et $H\%$.

Tableau IV.3 Résultats récapitulatif des meilleures modèles pour barrage Chafia

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.894	0.943	0.817	0.604	01
RBFNN1	0.867	0.929	0.908	0.668	05
GRNN1	0.881	0.934	0.858	0.640	02
LSSVM1	0.854	0.922	0.954	0.700	07
ANFIS_GP1	0.853	0.921	0.957	0.689	06
ANFIS_SC1	0.877	0.933	0.870	0.642	03
ANFIS_FC1	0.869	0.928	0.895	0.662	04

IV.4.2. Résultats de la modélisation pour le Barrage Beni Zid

Les résultats de simulations obtenus au niveau du barrage Beni Zid sont reportés dans le **Tableau IV.4**, argumenté par les **Figures IV.3-4**. En phase d'apprentissage, les performances varient d'un modèle à un autre et varient significativement selon le nombre de variables d'entrée utilisé. Pour les modèles RBFNN, l'utilisation de quatre variables climatiques (RBFNN1) comme entrées (T_{max} , T_{min} , U_2 , $H\%$) avec l'ajout de deux composantes du calendrier Grégorien (J et M) nous obtenons les meilleures performances par rapport aux autres modèles, avec les indices statistiques les plus élevées ($R=0.964$, $d=0.982$, $RMSE=0.678mm$; $MAE=0.515mm$), suivi par le modèle RBFNN2 ($R=0.911$, $d=0.952$, $RMSE=1.071mm$; $MAE=0.808mm$) respectivement. Une des premières conclusions est que le RBFNN1 dépasse le RBFNN2 avec des pourcentages de l'ordre de 5.3% et 3% en tenant compte des valeurs des R et d , ce qui confirme l'importance des composantes du calendrier Grégorien dans l'amélioration des performances du RBFNN.

Pour les modèles développés avec trois variables climatiques (RBFNN3 et RBFNN4), on remarque que le modèle RBFNN4 ayant comme variables d'entrée les (T_{max} , T_{min} , $H\%$) est plus performant que le modèle RBFNN3 ayant comme variables d'entrée les (T_{max} , T_{min} , U_2), et que les deux modèles (RBFNN3, RBFNN4) sont moins performant que les modèles RBFNN1 et RBFNN2. Par comparaison, le RBFNN4 dépasse le RBFNN3 avec des pourcentages de l'ordre de 2.8% et 1.7% en tenant compte des valeurs des R et d , et que le RBFNN4 permet une réduction des RMSE et MAE du modèle RBFNN3 avec des pourcentages de l'ordre de 9.8% et 15.9%. Donc on peut conclure que lorsqu'on utilise uniquement trois variables climatiques, mieux d'utiliser l'humidité $H\%$ que l' U_2 , avec les deux températures T_{max} , T_{min} . On constate que lorsqu'on utilise uniquement deux variables (RBFNN5, RBFNN6), les résultats obtenus avec le modèle RBFNN6 qui utilise les deux températures (T_{max} , T_{min}) comme entrées ($R=0.866$, $d=0.925$, $RMSE=1.300mm$, $MAE=1.025mm$), sont meilleurs par rapport à ceux obtenus par le modèle RBFNN5 qui utilise (T_{max} , $H\%$) comme entrées ($R=0.842$, $d=0.909$, $RMSE=1.399mm$, $MAE=1.111mm$). En conclusion la comparaison entre les différents modèles montre que le modèle RBFNN1 est largement supérieur aux autres modèles.

En phases de validation et de test les résultats consignés dans le **Tableau IV.4** sont jugés satisfaisants et confirment ceux obtenus en phase d'apprentissage. Durant la phase de validation,

le modèle RBFNN1 est le plus performant, ce qui confirme aussi l'importance de l'ajout des composantes du calendrier Grégorien et leurs influences vis-à-vis de ce modèle dans l'estimation de l' E_{pan} . En tenant compte des R et d , le RBFNN1 dépasse le modèle RBFNN2 avec des pourcentages de 1.1% et 0.4%, respectivement. La différence entre les deux modèles RBFNN2 et RBFNN4 est relativement négligeable, alors que le RBFNN6 qui utilise les deux températures (T_{min} et T_{max}) possède relativement les mêmes performances que le modèle RBFNN3. Durant la phase de test, on enregistre des résultats similaires aux résultats obtenus durant la phase de validation avec des différences non significatives en tenant compte de tous les indices de performances. Les meilleurs résultats sont obtenus avec le modèle RBFNN1 avec des valeurs R et d de l'ordre de 0.890 et 0.939, respectivement. On remarque aussi que les trois modèles RBFNN2, RBFNN3 et RBFNN6 possèdent les mêmes performances avec des différences non significatives. Finalement, les plus faibles résultats sont obtenus avec le modèle RBFNN5, avec les plus faibles R et d . 0.839 et 0.906, respectivement.

L'analyse des résultats obtenus avec les modèles MLPNN [Tableau IV.4](#) montre que dans l'ensemble, tous les modèles sont généralement proches les uns aux autres et très satisfaisants, mais la comparaison entre les six modèles montre que le modèle MLPNN1 ayant comme variables d'entrée (T_{max} , T_{min} , U_2 , $H\%$, J et M) donne des bons résultats par rapport aux autres modèles, en apprentissage, et que les résultats en phase de test sont plus meilleurs qu'en phase de validation. En phase d'apprentissage le modèle MLPNN1 est meilleur que le modèle MLPNN2, et il améliore les valeurs des R et d avec des pourcentages de l'ordre de 4% et 2.4%, et il assure une réduction des RMSE et MAE avec des pourcentages de l'ordre de 23.80% et 20.20%. Ces résultats confirment l'importance et l'utilité de l'ajout des composantes du calendrier Grégorien dans l'estimation de l' E_{pan} , comme démontré précédemment avec les RBFNN. On remarque que les trois modèles MLPNN2, MLPNN3, et MLPNN4 possèdent les mêmes performances, et légèrement supérieurs au modèle MLPNN6. Finalement, toujours en phase d'apprentissage, les plus faibles performances sont obtenues avec le modèle MLPNN5 ($R=0.840$ et $d=0.908$) pour lequel nous avons exclu la T_{min} des variables d'entrée. Pour les phases de validation et test, les modèles MLPNN sont généralement moins performants qu'en phase d'apprentissage et les meilleures performances sont toujours obtenues avec le modèle MLPNN1 ($R=0.928$, $d=0.961$), suivi par le MLPNN2 ($R=0.890$, $d=0.940$), alors que les faibles performances sont obtenues par le modèle MLPNN5 ($R=0.845$, $d=0.910$). Durant la phase de test, on enregistre les mêmes performances avec des différences non significatives par rapport à la phase de validation. Nous pouvons conclure que les modèles MLPNN possèdent moins de capacité durant la phase de calage (apprentissage) par rapport aux modèles RBFNN, mais sont meilleurs en phases de validation et test.

Les résultats obtenus avec les différents modèles GRNN sont généralement très satisfaisants en phases d'apprentissage, validation et test avec des critères supérieurs à 89% pour l'indice de conformité d et de 0.83 à 0.95 % pour les coefficients de corrélation de Pearson. On constate que les meilleures performances sont obtenues avec le modèle GRNN1 et cela à l'image des résultats obtenues avec les modèles (RBFNN et MLPNN), largement supérieure aux modèles (GRNN2 jusqu'au GRNN6) en phase d'apprentissage, validation et de test. En phase d'apprentissage, le modèle GRNN1 dépasse le modèle GRNN2 avec des améliorations significatives en termes des R (2.3%) et d (1.2%). Le modèle GRNN2 occupe la deuxième place en termes de performances, le modèle GRNN5 fournit les plus faibles performances ($R=0.835$ et $d=0.893$), alors que le modèle GRNN4 qui utilise les T_{max} , T_{min} et $H\%$ occupe la troisième place ($R=0.880$ et $d=0.926$), largement meilleure que les modèles

utilisant deux entrées (GRNN5 et GRNN6). Durant les phases de validation et de test, on constate une certaine détérioration de performance des modèles, le modèle GRNN1 est toujours le plus performant par rapport aux autres, suivi par le modèle GRNN2. Il est important de signaler aussi que le modèle GRNN4 est meilleure que les modèles utilisant deux entrées et que le modèle GRNN5 a toujours fournie les plus faibles performances. Une des plus importantes conclusions tirées des résultats obtenues avec le modèle GRNN est sa capacité d'estimation des E_{pan} en utilisant les températures maximale, minimale et l'humidité, sont identiques avec les deux modèles précédents (RBFNN4 et MLPNN4).




Figure IV.3. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Beni Zid, phase de test.

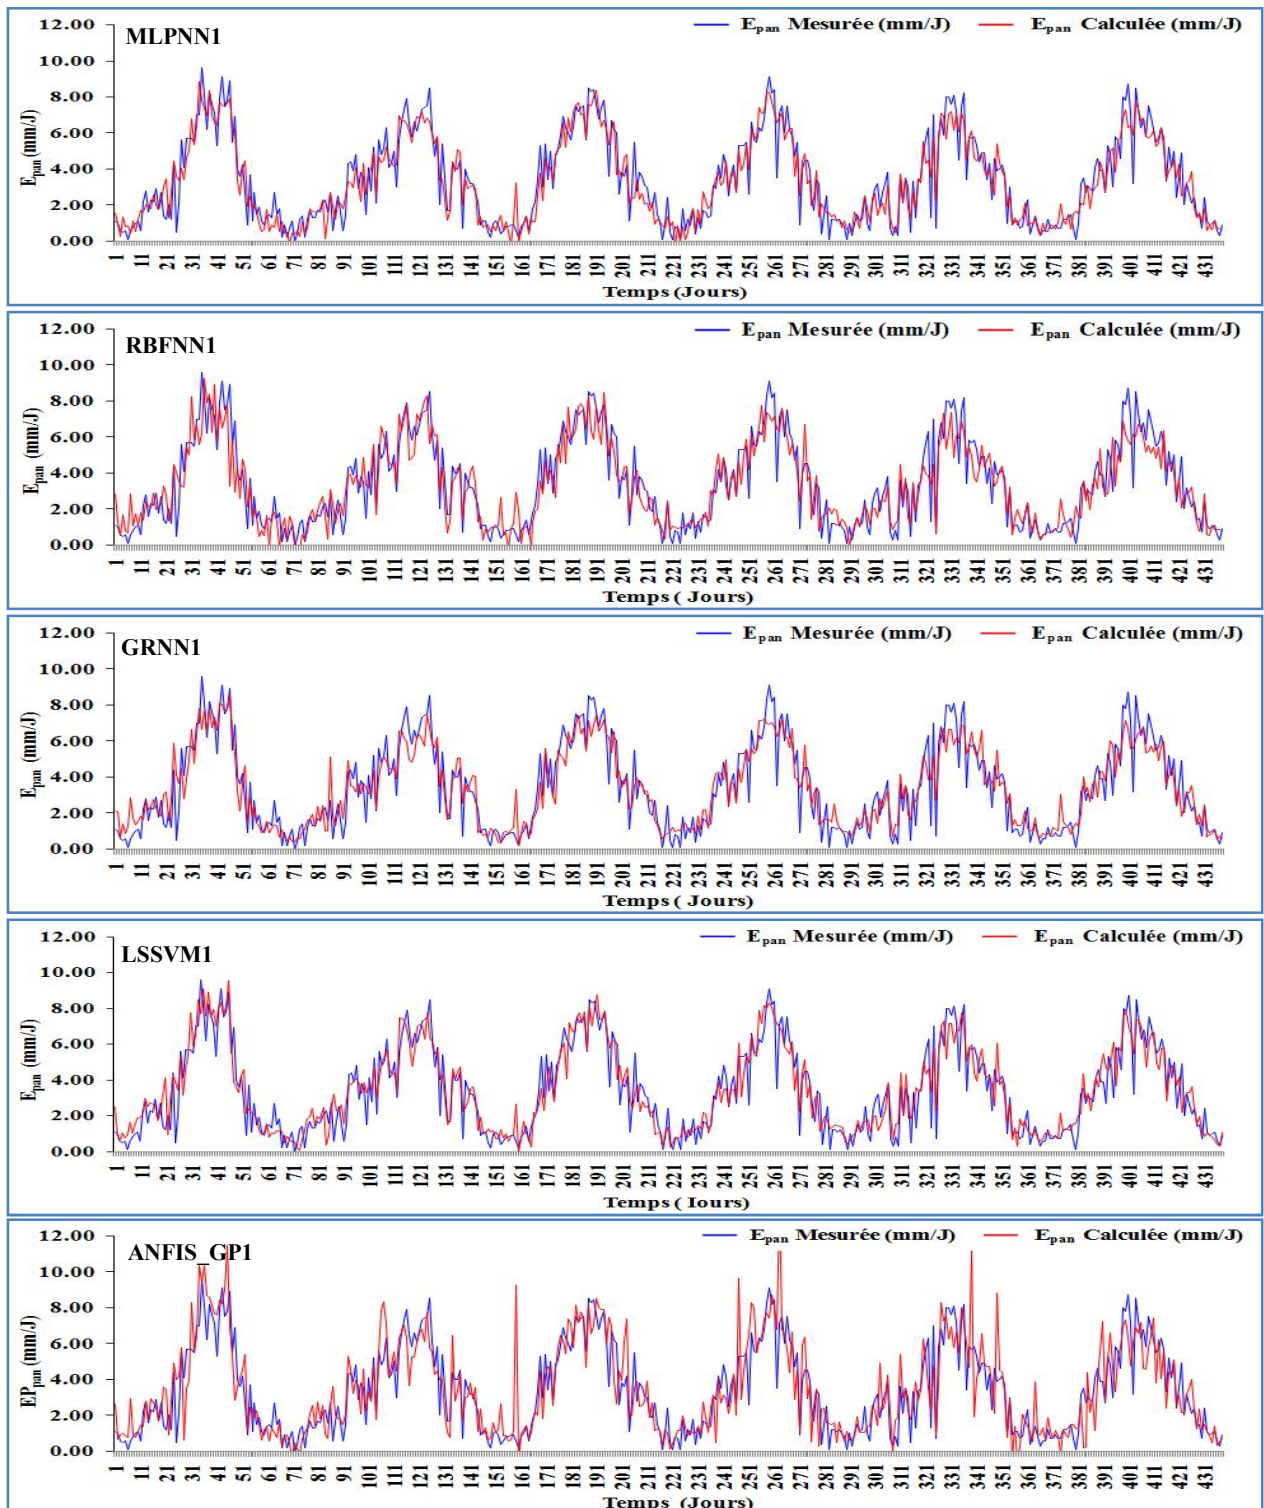
Pour les modèles LSSVM, en phase d'apprentissage, on remarque que le LSSVM1 a toujours fourni les meilleures performances légèrement inférieures aux modèles RBFNN1 et GRNN1, et meilleure que le modèle MLPNN1. LSSVM1 estime l' E_{pan} avec des R et d de l'ordre de 0.952 et 0.975, est le plus performant suivi par LSSVM2 (R=0.900 et d=0.945),

alors que les modèles LSSVM3, LSSVM4 et LSSVM6 sont proches avec une légère différence, le modèle LSSVM5 a toujours fourni les plus faibles performances. En phase de validation, les plus faibles résultats en termes des quatre indices statistiques sont obtenus par le modèle LSSVM5 ($R=0.845$, $d=0.909$, $RMSE=1.367\text{mm}$, $MAE=1.081\text{mm}$). Finalement, en phase de test, on constate aussi que le modèle LSSVM4 qui utilise uniquement les trois entrées (T_{min} , T_{max} et $H\%$) est plus performant par rapport aux modèles LSSVM3 et LSSVM6 et occupe la troisième place légèrement inférieure au meilleur modèle LSSVM1 avec des différences de l'ordre de 2.5% et 1.6% en termes des R et d , respectivement. En accord avec les résultats obtenus avec les trois modèles RBFNN, MLPNN et GRNN.

Selon les résultats reportés dans le **Tableau IV.4**; pour les modèles ANFIS_GP, les indices numériques montrent une supériorité du modèle ANFIS_GP1 en phase d'apprentissage ($R=0.961$, $d=0.980$), largement supérieure au modèle ANFIS_GP2 ($R=0.899$, $d=0.945$). En plus, le modèle ANFIS_GP1 améliore les RMSE et MAE du modèle ANFIS_GP2 par des pourcentages de 6.2% et 3.5%, respectivement. Ces résultats confirment l'importance de l'ajout des composantes du calendrier Grégorien (J et M) déjà démontré par les modèles précédents. Toujours les plus faibles performances sont obtenues par le modèle ANFIS_GP5 pour lequel nous avons exclu la T_{min} . On constate aussi que le modèle ANFIS_GP4 qui utilise uniquement les trois entrées (T_{min} , T_{max} et $H\%$) est plus performant par rapport aux modèles ANFIS_GP3 et ANFIS_GP6 et occupe la troisième place légèrement inférieure au modèle (ANFIS_GP2) avec des différences de l'ordre de 1.6% et 1.0% en termes des R et d , respectivement. En phase de validation, on constate une détérioration significative des performances du modèle ANFIS_GP1, pour lequel le coefficient R passe de 0.961 (apprentissage) à 0.767 (validation), avec une perte de l'ordre de 19.4%, et le coefficient d passe de 0.980 (apprentissage) à 0.873 (validation), avec une perte de l'ordre de 10.70%. Pour les autres modèles, en générale ils apportent des résultats relativement acceptables avec des RMSE et MAE rangés entre 1.826mm et 1.223mm, et 1.124mm et 0.902 mm, respectivement, le modèle ANFIS_GP5 a toujours fourni les plus faibles performances. Finalement en phase de test, les résultats trouvés montrent que une grande détérioration des performances du modèle ANFIS_GP1 ($R=0.499$, $d=0.591$) et les autres modèles ont fournies des performances relativement proches avec une légère détérioration du modèle ANFIS_GP5 avec ($R=0.842$, $d=0.908$). Les modèles ANFIS_SC ont généralement donné de bons résultats, avec une supériorité du modèle ANFIS_SC1 durant la phase d'apprentissage ($R=0.967$, $d=0.983$), en phase de validation et de test les résultats sont relativement égaux ($R=0.845$, $d=0.918$), ($R=0.838$, $d=0.913$), respectivement. Pour les autres cinq modèles, ils ont les mêmes ordres de grandeur durant les trois phases avec des différences négligeable. Ces résultats nous conduit à conclure qu'on utilisant le modèle ANFIS_SC, l'effet des T_{min} , T_{max} et $H\%$ est prédominant, Finalement, les résultats obtenus avec les modèles ANFIS_FC confirment la supériorité du modèle ANFIS_FC1 durant les trois phases, d'apprentissage ($RMSE=1.004\text{mm}$, $MAE=0.747\text{mm}$), validation ($RMSE=1.052\text{mm}$, $MAE=0.780\text{mm}$) et de test ($RMSE=1.039\text{mm}$, $MAE=0.772\text{mm}$), respectivement. Le modèle ANFIS_FC5 est le moins performant avec les plus faible R et d ($R=0.842$, $d=0.910$) en phase de validation, et ($R=0.839$, $d=0.907$) en phase de test. On peut conclure aussi que le ANFIS_FC4 est plus performant que ANFIS_FC3 et ANFIS_FC6, et légèrement inférieure au modèle ANFIS_FC2 avec des différences de l'ordre de 1.2 % et 3.6 % en termes des R et d , respectivement.

Tableau IV.4 Performances des modèles journaliers au niveau du Barrage Beni Zid

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.934	0.965	0.928	0.691	0.928	0.961	0.955	0.699	0.932	0.963	0.890	0.672
MLPNN2	0.894	0.941	1.166	0.893	0.890	0.940	1.176	0.903	0.896	0.941	1.094	0.850
MLPNN3	0.879	0.933	1.235	0.953	0.886	0.936	1.186	0.897	0.892	0.938	1.106	0.856
MLPNN4	0.871	0.917	1.296	1.042	0.877	0.921	1.252	0.993	0.882	0.921	1.181	0.952
MLPNN5	0.840	0.908	1.407	1.116	0.845	0.910	1.364	1.076	0.841	0.907	1.315	1.041
MLPNN6	0.864	0.924	1.308	1.036	0.870	0.927	1.261	0.984	0.870	0.925	1.205	0.959
RBFNN1	0.964	0.982	0.687	0.515	0.885	0.936	1.194	0.876	0.890	0.939	1.117	0.831
RBFNN2	0.911	0.952	1.071	0.808	0.874	0.932	1.253	0.938	0.864	0.923	1.235	0.933
RBFNN3	0.866	0.925	1.295	1.036	0.869	0.924	1.263	0.984	0.869	0.923	1.208	0.954
RBFNN4	0.894	0.942	1.161	0.877	0.872	0.930	1.252	0.912	0.859	0.920	1.255	0.935
RBFNN5	0.842	0.909	1.399	1.111	0.831	0.903	1.419	1.092	0.839	0.906	1.325	1.048
RBFNN6	0.866	0.925	1.300	1.025	0.868	0.926	1.269	0.979	0.861	0.921	1.239	0.972
GRNN1	0.954	0.974	0.793	0.571	0.911	0.949	1.059	0.786	0.913	0.949	1.002	0.759
GRNN2	0.931	0.962	0.951	0.687	0.879	0.934	1.222	0.910	0.876	0.929	1.177	0.896
GRNN3	0.869	0.922	1.288	1.033	0.874	0.924	1.248	0.988	0.879	0.924	1.178	0.940
GRNN4	0.880	0.926	1.248	0.979	0.884	0.929	1.204	0.937	0.882	0.926	1.163	0.918
GRNN5	0.835	0.893	1.443	1.176	0.839	0.894	1.411	1.157	0.837	0.893	1.350	1.092
GRNN6	0.864	0.922	1.308	1.038	0.870	0.926	1.260	0.982	0.874	0.925	1.191	0.949
LSSVM1	0.952	0.975	0.796	0.572	0.921	0.958	0.998	0.729	0.917	0.956	0.977	0.728
LSSVM2	0.900	0.945	1.132	0.858	0.890	0.939	1.170	0.877	0.901	0.945	1.059	0.817
LSSVM3	0.874	0.929	1.262	0.994	0.878	0.930	1.224	0.944	0.882	0.934	1.147	0.909
LSSVM4	0.887	0.937	1.195	0.912	0.886	0.937	1.181	0.889	0.892	0.940	1.099	0.849
LSSVM5	0.839	0.907	1.411	1.120	0.845	0.909	1.367	1.081	0.841	0.909	1.323	1.051
LSSVM6	0.862	0.922	1.319	1.046	0.870	0.926	1.262	0.988	0.872	0.929	1.194	0.947
ANFIS_GP1	0.961	0.980	0.715	0.528	0.767	0.873	1.826	1.124	0.499	0.591	4.111	1.300
ANFIS_GP2	0.899	0.945	1.140	0.863	0.871	0.931	1.272	0.920	0.886	0.937	1.135	0.848
ANFIS_GP3	0.874	0.929	1.261	0.992	0.878	0.931	1.223	0.937	0.880	0.931	1.158	0.921
ANFIS_GP4	0.883	0.935	1.216	0.926	0.878	0.933	1.223	0.902	0.891	0.939	1.107	0.849
ANFIS_GP5	0.838	0.907	1.414	1.123	0.845	0.910	1.363	1.075	0.842	0.908	1.314	1.039
ANFIS_GP6	0.861	0.922	1.321	1.047	0.870	0.926	1.262	0.988	0.871	0.925	1.199	0.955
ANFIS_SC1	0.967	0.983	0.665	0.493	0.845	0.918	1.430	1.043	0.838	0.913	1.430	0.988
ANFIS_SC2	0.890	0.940	1.183	0.907	0.888	0.938	1.177	0.892	0.889	0.938	1.117	0.853
ANFIS_SC3	0.876	0.931	1.250	0.987	0.874	0.930	1.240	0.947	0.877	0.930	1.170	0.930
ANFIS_SC4	0.886	0.937	1.203	0.919	0.884	0.937	1.196	0.899	0.886	0.937	1.133	0.879
ANFIS_SC5	0.839	0.907	1.413	1.124	0.843	0.908	1.374	1.079	0.841	0.907	1.318	1.042
ANFIS_SC6	0.864	0.923	1.310	1.035	0.870	0.927	1.259	0.973	0.868	0.923	1.214	0.968
ANFIS_FC1	0.922	0.958	1.004	0.747	0.912	0.953	1.052	0.780	0.905	0.949	1.039	0.772
ANFIS_FC2	0.902	0.947	1.120	0.852	0.879	0.935	1.227	0.935	0.881	0.935	1.159	0.884
ANFIS_FC3	0.881	0.934	1.226	0.963	0.861	0.924	1.300	0.985	0.860	0.921	1.242	0.977
ANFIS_FC4	0.890	0.939	1.182	0.897	0.881	0.936	1.212	0.907	0.880	0.935	1.162	0.899
ANFIS_FC5	0.845	0.911	1.388	1.094	0.842	0.910	1.372	1.076	0.839	0.907	1.325	1.049
ANFIS_FC6	0.867	0.925	1.297	1.021	0.856	0.921	1.322	0.994	0.862	0.922	1.237	0.973



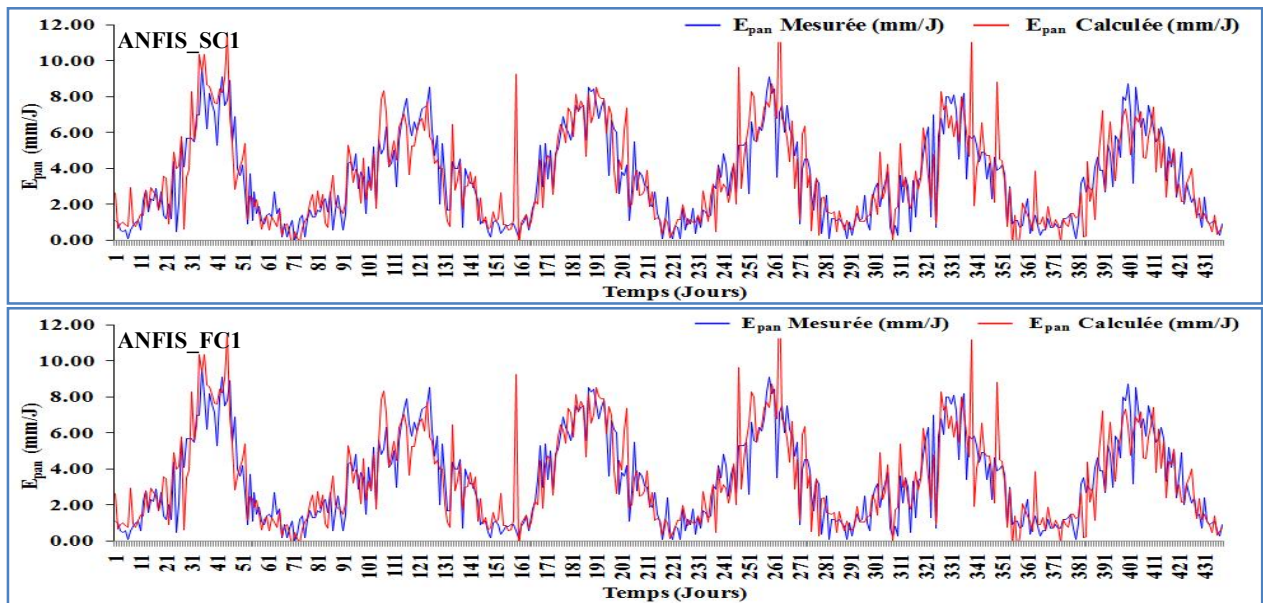


Figure IV.4. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Beni Zid, phase de test.

IV.4.2.1. Résultats récapitulatif des différents modèles pour barrage Beni Zid

En comparant les différents modèles au niveau du barrage Beni Zid on peut conclure ce qui suit:

1. Les modèles (Tableau IV.4) qui utilisent quatre variables climatiques et les deux composantes (J et M) du calendrier Grégorien (combinaison N°1) sont toujours les modèles les plus performants par rapport aux autres modèles.
2. Le modèle MLPNN1 a effectivement donné de résultats relativement meilleurs par rapport autres modèles, avec les R et d les plus élevées ($R=0.932$, $d=0.0.963$) et les RMSE et MAE les plus faibles ($R=0.890\text{mm}$, $d=0.672\text{mm}$), suivi par les modèle LSSVM1, GRNN1, ANFIS_FC1 et RBFNN1, respectivement, alors que le modèle ANFIS_GP1 a fourni les plus faibles résultats.
3. On constate aussi que le modèle ANFIS_SC1 fût meilleure performances en phase d'apprentissage, il a occupé la sixième place en phase de test, donc il possède moins de capacité de généralisation que les autres modèles, et meilleure par apport au modèle ANFIS_GP1.
4. Les modèles utilisant quatre variables climatiques comme entrées, on remarque que les meilleures performances sont obtenues par le modèle LSSVM2 avec un $R=0.901$, les autres modèles (combinaison 2) sont moins performants avec un R entre 0.881 et 0.896.
5. Aussi les résultats fournis par les modèles utilisant trois variables climatiques (combinaison 3 et 4), sont supérieurs à ceux trouvés par les modèles utilisant deux variables climatiques comme entrées (combinaison 5 et 6).
6. Pour les modèles utilisent uniquement deux variables climatiques comme entrées, les modèles utilisant les deux températures T_{max} et T_{min} sont plus performants par rapport aux modèles utilisant la T_{max} et $H\%$.
7. Les résultats révèlent que les plus faibles performances sont obtenues avec les modèles utilisant la T_{max} et $H\%$ durant les trois phases.

Tableau IV.5 Résultats récapitulatif des meilleures modèles pour barrage Beni Zid

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.932	0.963	0.890	0.672	01
RBFNN1	0.890	0.939	1.117	0.831	05
GRNN1	0.913	0.949	1.002	0.759	03
LSSVM1	0.917	0.956	0.977	0.728	02
ANFIS_GP1	0.499	0.591	4.111	1.300	07
ANFIS_SC1	0.838	0.913	1.430	0.988	06
ANFIS_FC1	0.905	0.949	1.039	0.772	04

IV.4.3. Résultats de la modélisation pour le Barrage Zit Emba

Les résultats trouvés au niveau du barrage Zit Emba sont présentés sous forme de **Tableau IV.6**, et **Figure IV.5-6**. Le tableau permet d'apprécier les valeurs des différents critères de performance (R, d, RMSE, MAE). Par comparaison on peut s'apercevoir que ces résultats changent d'un modèle à un autre et varient selon le nombre de variables d'entrée utilisées durant les trois phases à savoir, l'apprentissage, la validation et le test. Pour les modèles GRNN, nous notons que les meilleures performances ont été observées avec le modèle GRNN1 (T_{max} , T_{min} , U_2 , H%, J et M), avec les (R et d) les plus élevées, (RMSE et MAE) les plus faibles. En phase d'apprentissage, le modèle GRNN1 a fourni des résultats très performants avec (R=0.936, d=0.961, RMSE=1.195 mm), supérieur au modèle GRNN2 avec des pourcentages de l'ordre de 11.10% et 7.10% en terme des R et d, ce qui confirme l'ampleur et l'impact de l'ajout des composantes du calendrier Grégorien (J et M) dans l'amélioration des résultats. On note également que Les modèles développés avec trois variables climatiques (GRNN3 et GRNN4) sont moins performant que les modèles GRNN1 et GRNN2 et que le modèle GRNN3 possède les mêmes performances que le modèle GRNN4, en terme de critères R et d, avec une déférence négligeable, (R=0.808, d=0.880, RMSE=1.943 mm), (R=0.801, d=0.874, RMSE=1.977mm), respectivement. On constate lorsqu'on utilise uniquement deux variables (GRNN5, GRNN6), les résultats obtenus avec le modèle GRNN6 qui utilise les deux températures (T_{max} , T_{min}) comme entrées, sont légèrement supérieurs à ceux obtenus par le modèle GRNN5 qui utilise (T_{max} , H%), mais la comparaison entre les différents modèles montre que le modèle GRNN1 est largement supérieur aux autres modèles, et que les résultats s'améliorent en augmentant le nombres d'entrées.

Durant la phase de validation, on note aussi que le modèle GRNN1 est le plus performant selon les valeurs de tous les critères de performance, ce qui confirme l'importance de l'ajout des composantes du calendrier Grégorien et leurs influences dans l'estimation de l' E_{pan} . En tenant compte des R et d, (R=0.862, d=0.918), le GRNN1 dépasse le modèle GRNN2 avec des pourcentages de 5.2% et 3.5%, respectivement. Les résultats obtenus par modèles GRNN2 et GRNN3, GRNN4, GRNN6 sont proches avec une déférence relativement négligeable, avec R varie entre 0.805 et 0.820, et d varie entre 0.876 et 0.887, les résultats obtenus avec le modèle GRNN6 sont supérieurs à ceux obtenus par le modèle GRNN5 (R=0.817, d=0.887, RMSE=1.944mm, MAE=1.541mm), (R=0.797, d=0.857, RMSE=2.036 mm, MAE=1.679 mm), respectivement. En phase de test, on note que les résultats obtenus sont légèrement moins performants par rapport aux résultats obtenus durant la phase de validation avec des différences non significatives. Les meilleurs résultats sont obtenus toujours avec le modèle

GRNN1 avec ($R=0.797$, $d=0.857$, $RMSE=2.036$ mm, $MAE=1.679$ mm), et que les plus faibles résultats sont obtenus avec le modèle GRNN5 avec ($R=0.797$, $d=0.857$, $RMSE=2.036$ mm, $MAE=1.679$ mm).

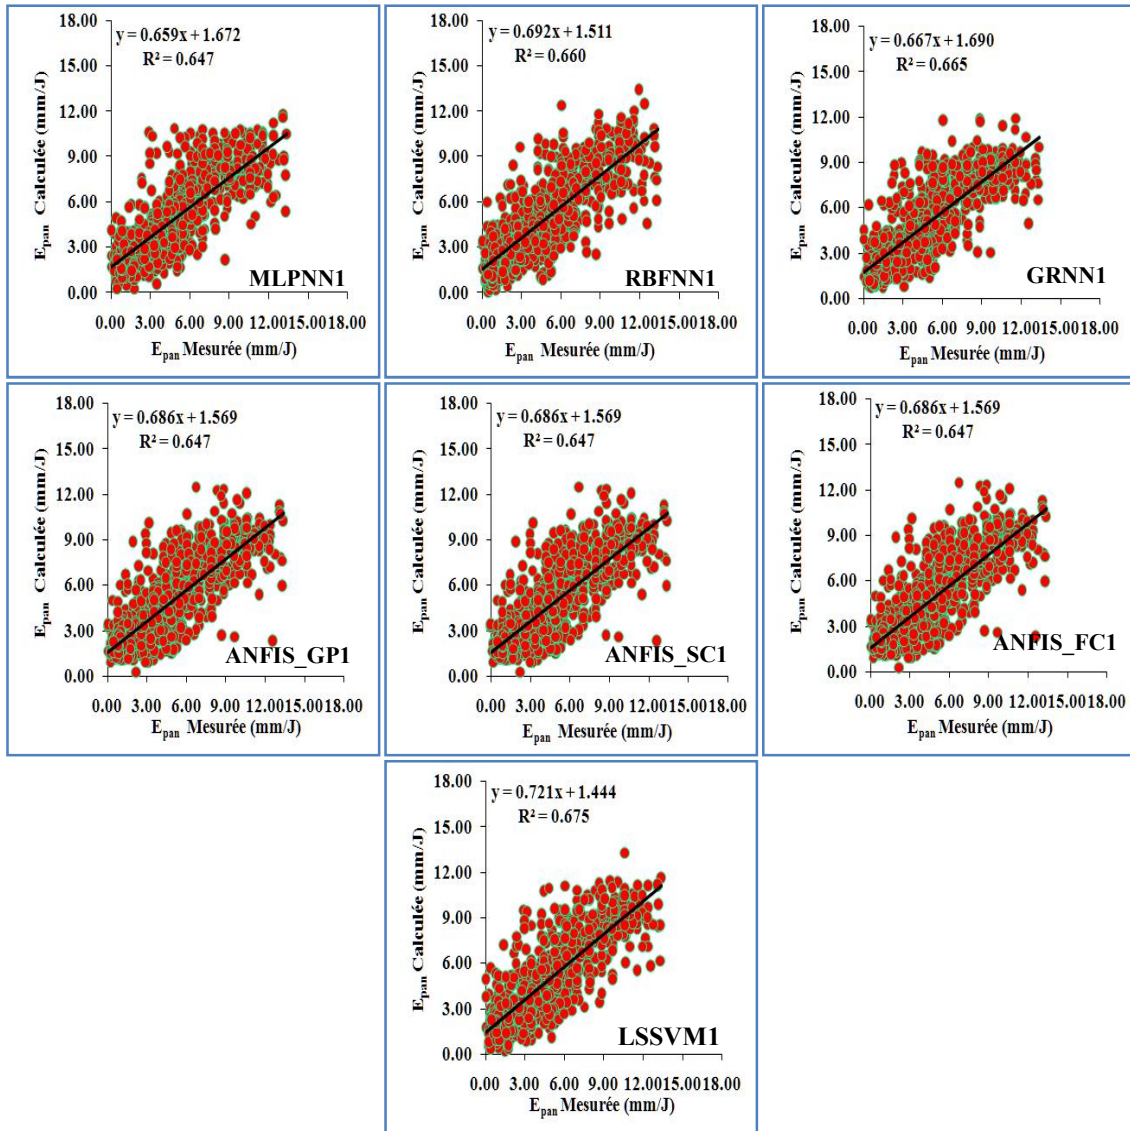
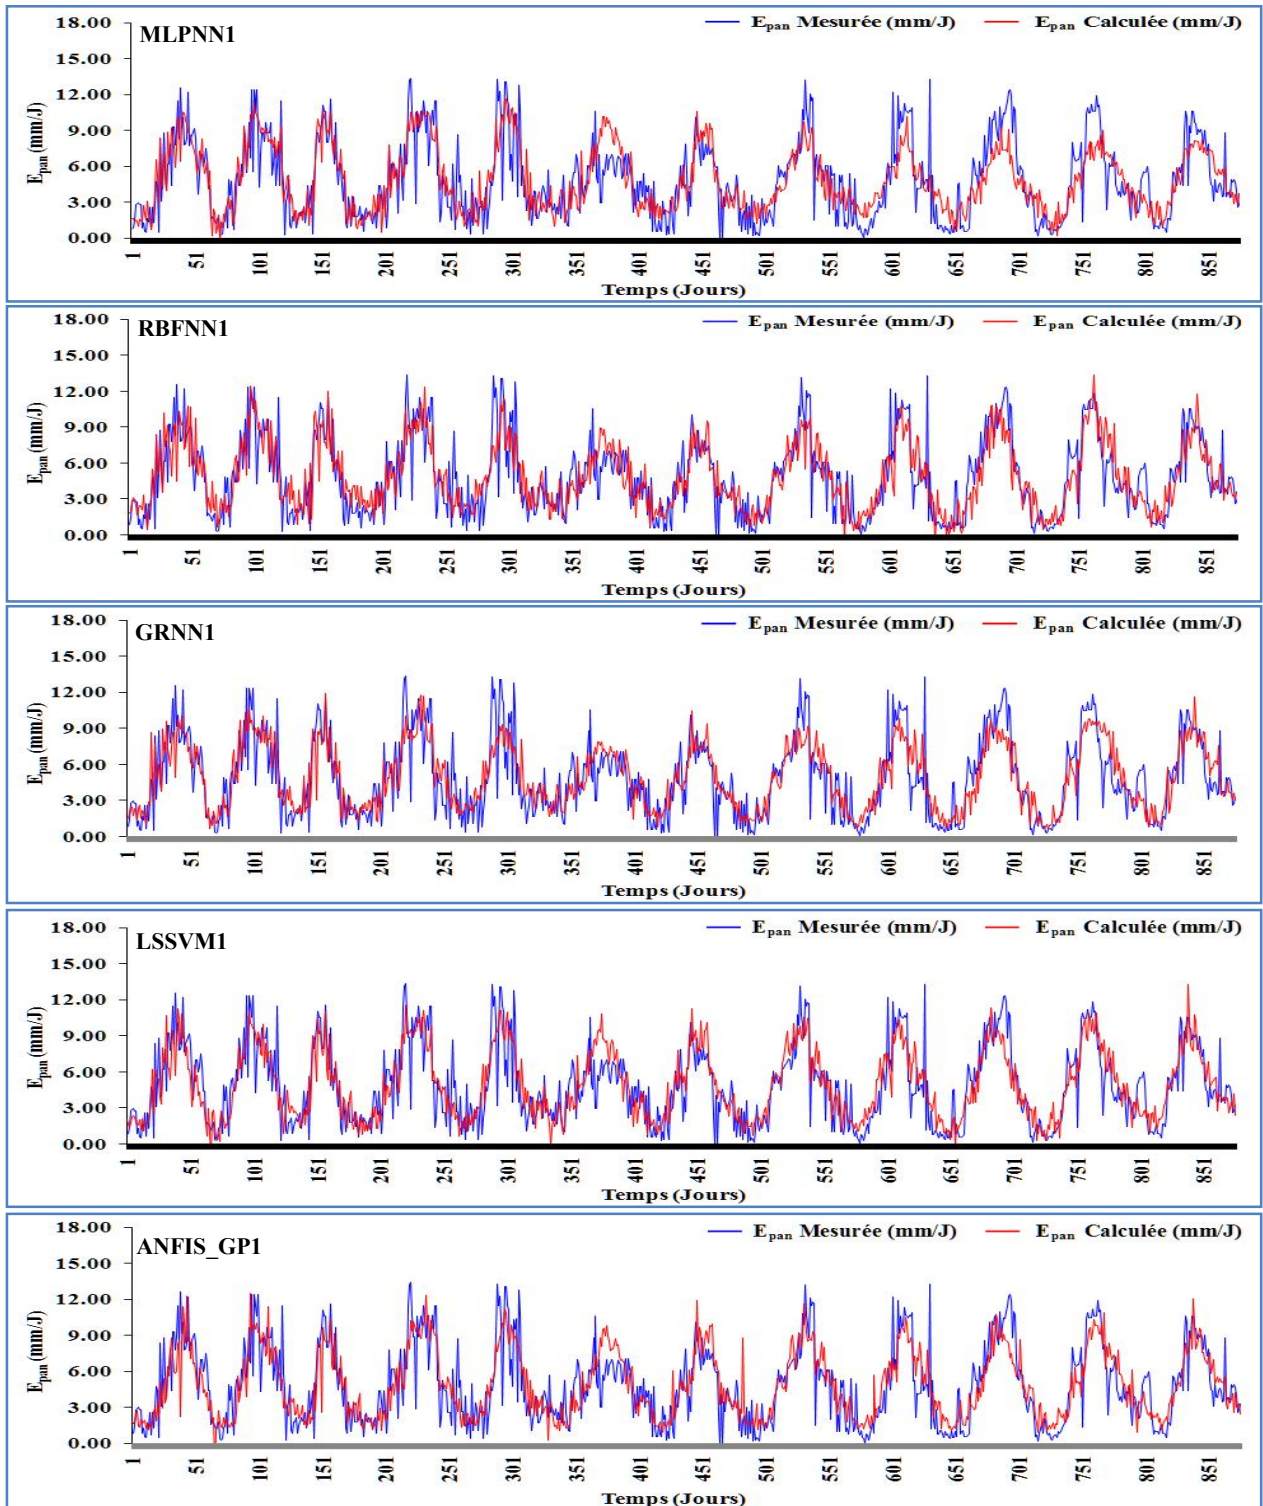


Figure IV.5. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.

La comparaison montre que les résultats obtenus avec les modèles RBFNN (Tableau IV.5) sont proches à ceux obtenus avec les modèles GRNN durant les trois phases avec une légère supériorité des modèles GRNN. En phase d'apprentissage, on remarque que le modèle RBFNN1 a fourni des résultats très satisfaisants par rapport aux autres modèles, ($R=0.922$, $d=0.958$, $RMSE=1.276$ mm, $MAE=0.976$ mm), dans lequel toutes les variables sont prises en compte (T_{max} , T_{min} , U_2 , $H\%$, J , M), ce qui confirme les résultats obtenus par les modèles GRNN. On note également que le modèle RBFNN1 est supérieur au modèle RBFNN2 avec une différence significative, en tenant compte des RMSE et MAE avec des pourcentages de l'ordre de 52.9% et 43.4%. On remarque que les trois modèles RBFNN3, RBFNN4 et

RBFNN6 possèdent les mêmes performances, et sont légèrement supérieurs au modèle RBFNN5, avec R varie entre 0.799 et 0.806. Les plus faibles performances toujours sont obtenues avec le modèle MLPNN5 ($R=0.787$ et $d=0.872$) ce qui montre l'importance d'utiliser la T_{min} comme variable d'entrée. Pour les phases de validation, les modèles RBFNN sont moins performants qu'en phases d'apprentissage et légèrement supérieurs à ceux obtenus en phase de test. Le modèle RBFNN1 a donné les plus élevés R (0.847) et d (0.914), suivi par le RBFNN3 ($R=0.820$ et $d=0.893$), alors que les faibles performances sont obtenues par le modèle RBFNN5 ($R=0.744$ et $d=0.868$). Durant la phase de test, on note une légère détérioration des performances avec des différences non significatives par rapport à ceux obtenus en phase de validation. Le **Tableau IV.5** montre clairement que les modèles MLPNN possèdent des performances satisfaisantes durant les trois phases, en particulier le MLPNN1 avec R et d supérieurs à 86% et 92%, respectivement. En phase d'apprentissage on note également que le modèle MLPNN1 a toujours fourni de meilleures performances par rapport aux autres modèles ($R=0.863$, $d=0.922$), suivie par le modèle MLPNN3 ($R=0.796$, $d=0.878$), respectivement, soit un dépassement de (6.7%) et d (4.4%) en tenant compte des R et d. Alors qu'en validation et en test on constate une certaine supériorité de performance des modèles à ceux obtenus en apprentissage. Durant les phases de validation et de test, par comparaison, le modèle MLPNN1 est toujours le plus performant par rapport aux autres avec les plus grandes valeurs des R et d et les plus faibles valeurs des RMSE et MAE, suivi par le modèle MLPNN3. Il est également noté que les modèles utilisant trois variables comme entrées MLPNN3 et MLPNN4 sont meilleurs que les modèles utilisant deux entrées MLPNN5 et MLPNN6 et que le modèle MLPNN 5 a toujours fourni les plus faibles performances.

Pour les modèles LSSVM, en phase d'apprentissage on constate que le meilleur résultat est enregistré avec le modèle LSSVM1 avec des R et d de l'ordre de (0.879 et 0.932), suivi de près par le LSSVM2 ($R=0.817$ et $d=0.892$), on constate également que les modèles utilisant trois variables comme entrées MLPNN3 et MLPNN4 sont meilleurs que les modèles utilisant deux entrées, et que le modèle LSSVM5 a toujours fourni les plus faibles performances ($R=0.781$, $d=0.867$), ce qui confirme les résultats obtenus par les modèles précédents (GRNN, RBFNN et MLPNN). En phase de validation, on constate que le modèle LSSVM1 a toujours fourni les meilleurs résultats, avec ($R=0.836$ et $d=0.908$), suivi directement par le modèle LSSVM3 avec ($R=0.823$ et $d=0.908$). On constate aussi que les résultats obtenus avec les modèles LSSVM2, LSSVM3, LSSVM4 et LSSVM6 sont proches les uns des autres, avec R varie entre (0.807 et 0.823), le modèle LSSVM5 a toujours fourni les plus faibles performances ($R=0.798$, $d=0.873$, $RMSE=2.028mm$, $MAE=1.633mm$). En phase de test, on remarque que les résultats obtenus sont moins performants à ceux obtenus en phase d'apprentissage et validation. Les meilleures performances sont obtenus avec LSSVM1 avec ($R=0.822$, $d=0.900$, $RMSE=1.865mm$, $MAE=1.430mm$), et le modèle LSSVM5 a donné les plus faibles performances ($R=0.758$, $d=0.857$, $RMSE=2.139mm$, $MAE=1.717mm$). Finalement on peut conclure que les performances des modèles LSSVM sont très similaires à ceux obtenus avec les modèles MLPNN durant les trois phases.



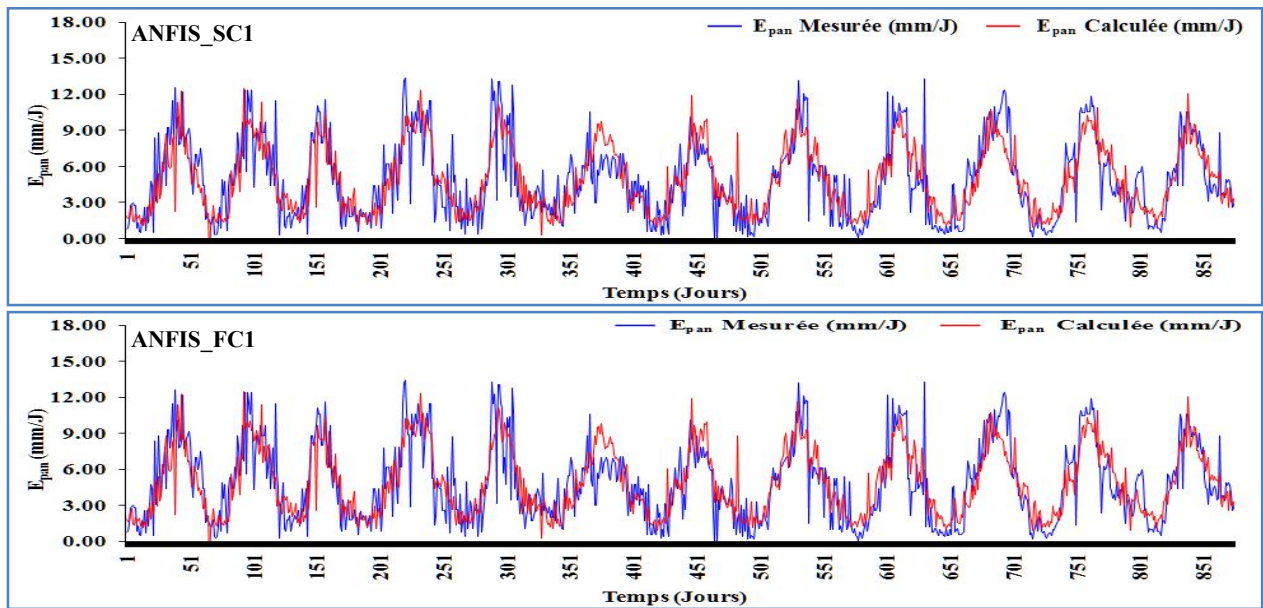


Figure IV.6. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.

Le modèle Neuroflou ANFIS_GP a donné des résultats moins performants ([Tableau IV.5](#)). En effet, en période d'apprentissage, Le coefficient de corrélation pour les différents modèles varie entre 0.77 et 0.88, les meilleurs résultats toujours fournis par ANFIS_GP1 qui utilise les six variables comme entrées ($R=0.880$, $d=0.933$), suivie directement par le ANFIS_GP2. Les plus faibles performances sont obtenus par le modèle ANFIS_GP5 ($R=0.777$ et $d=0.865$). En phase de validation, il est à signaler une dégradation de la simulation de 13.5 % pour le modèle ANFIS_GP1 avec ($R=0.745$ et $d=0.858$), les meilleures performances sont obtenus par ANFIS_GP3 qui utilise avec ($R=0.821$ et $d=0.892$), et les plus faibles performances sont obtenus par le modèle ANFIS_GP5 ($R=0.799$ et $d=0.878$). En phase de test les résultats obtenus avec les modèles ANFIS_GP1 et ANFIS_GP2 sont moins qu'en phase d'apprentissage et validation avec un R inférieur à 61%, alors que les meilleures performances sont obtenus ANFIS_GP3 avec ($R=0.780$ et $d=0.868$). Finalement on peut conclure que les modèles ANFIS_GP sont relativement moins performants par rapport à ceux obtenus par les modèles RBFNN, GRNN, MLPNN et LSSVM. Le [Tableau IV.5](#) montre clairement que les modèles ANFIS_SC ont les mêmes performances que les modèles ANFIS_GP durant l'apprentissage et la validation, alors qu'en phase de test on constate une certaine supériorité des modèles ANFIS_SC. En apprentissage, les résultats obtenus montrent que le modèle ANFIS_SC1 donne des résultats satisfaisants et plus supérieurs aux autres modèles avec ($R=0.891$ et $d=0.940$), suivie par ANFIS_SC2 avec un écart de 8.1% et 3.82% au moyens de R et d respectivement, les modèles ANFIS_SC3, ANFIS_SC4, ANFIS_SC6, effectuent des résultats très proches avec R varie entre 0.794 et 0.799, alors que le modèle ANFIS_SC5 se situe en dernière place au classement des performances en termes de ($RMSE=2.067mm$, $MAE=1.641mm$). En phase de validation, les meilleures performances sont obtenues avec ANFIS_SC2 avec ($R=0.821$ et $d=0.894$), les autres modèles ANFIS_SC3, ANFIS_SC4, ANFIS_S6 ont fonctionné de manière plus ou moins similaire avec R entre 0.804 et 0.820, et d entre 0.883 et 0.892, et que le modèle ANFIS_SC5 toujours se situe en dernière place en moyens de R et d ($R=0.798$ et $d=0.878$). En phase de test, on constate que tous les modèles ANFIS_SC ont les mêmes performances obtenus au cours de phase de validation.

Tableau IV.6. Performances des modèles journaliers au niveau du Barrage Zit Emba

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.863	0.922	1.609	1.214	0.829	0.901	1.879	1.427	0.805	0.885	1.934	1.498
MLPNN2	0.789	0.872	1.956	1.521	0.817	0.888	1.942	1.541	0.781	0.864	2.035	1.630
MLPNN3	0.796	0.878	1.924	1.504	0.824	0.895	1.905	1.525	0.782	0.867	2.031	1.634
MLPNN4	0.782	0.866	1.980	1.552	0.821	0.888	1.926	1.542	0.785	0.865	2.018	1.628
MLPNN5	0.748	0.851	2.114	1.652	0.797	0.880	2.029	1.621	0.757	0.855	2.132	1.716
MLPNN6	0.779	0.869	1.993	1.555	0.817	0.891	1.938	1.535	0.784	0.868	2.022	1.621
RBFNN1	0.922	0.958	1.276	0.976	0.847	0.914	1.790	1.363	0.813	0.893	1.901	1.427
RBFNN2	0.837	0.906	1.805	1.410	0.785	0.877	2.094	1.642	0.752	0.852	2.151	1.688
RBFNN3	0.806	0.884	1.949	1.541	0.820	0.893	1.920	1.517	0.783	0.867	2.024	1.617
RBFNN4	0.800	0.880	1.976	1.571	0.801	0.881	2.010	1.589	0.765	0.856	2.095	1.681
RBFNN5	0.787	0.872	2.031	1.604	0.744	0.868	2.130	1.668	0.750	0.849	2.154	1.741
RBFNN6	0.799	0.880	1.983	1.564	0.818	0.890	1.936	1.524	0.781	0.867	2.031	1.629
GRNN1	0.936	0.961	1.195	0.864	0.862	0.918	1.709	1.280	0.816	0.892	1.884	1.423
GRNN2	0.825	0.890	1.871	1.481	0.810	0.883	1.974	1.564	0.767	0.854	2.089	1.671
GRNN3	0.808	0.880	1.943	1.545	0.820	0.887	1.931	1.543	0.778	0.861	2.044	1.643
GRNN4	0.801	0.874	1.977	1.583	0.805	0.876	1.999	1.592	0.764	0.851	2.098	1.688
GRNN5	0.779	0.847	2.089	1.686	0.797	0.857	2.063	1.679	0.761	0.836	2.124	1.737
GRNN6	0.801	0.879	1.976	1.565	0.817	0.887	1.944	1.541	0.773	0.862	2.066	1.653
LSSVM1	0.879	0.932	1.570	1.213	0.836	0.908	1.846	1.409	0.822	0.900	1.865	1.430
LSSVM2	0.817	0.892	1.898	1.495	0.814	0.889	1.954	1.540	0.771	0.867	2.095	1.659
LSSVM3	0.804	0.883	1.957	1.547	0.823	0.892	1.910	1.518	0.781	0.873	2.048	1.627
LSSVM4	0.803	0.882	1.962	1.553	0.807	0.882	1.984	1.579	0.775	0.868	2.072	1.654
LSSVM5	0.781	0.867	2.056	1.631	0.798	0.873	2.028	1.633	0.758	0.857	2.139	1.717
LSSVM6	0.793	0.876	2.006	1.588	0.813	0.884	1.961	1.562	0.783	0.873	2.034	1.624
ANFIS_GP1	0.880	0.933	1.563	1.197	0.745	0.858	2.416	1.638	0.612	0.776	3.000	1.754
ANFIS_GP2	0.811	0.888	1.928	1.526	0.800	0.885	2.025	1.567	0.607	0.761	3.039	1.741
ANFIS_GP3	0.800	0.880	1.976	1.562	0.821	0.892	1.919	1.526	0.780	0.868	2.035	1.633
ANFIS_GP4	0.799	0.880	1.977	1.571	0.807	0.884	1.985	1.577	0.773	0.864	2.063	1.658
ANFIS_GP5	0.777	0.865	2.070	1.643	0.799	0.878	2.019	1.620	0.758	0.853	2.121	1.722
ANFIS_GP6	0.791	0.875	2.016	1.600	0.810	0.885	1.973	1.575	0.779	0.866	2.041	1.646
ANFIS_SC1	0.891	0.940	1.497	1.150	0.796	0.889	2.096	1.504	0.781	0.879	2.075	1.548
ANFIS_SC2	0.810	0.888	1.933	1.520	0.821	0.894	1.921	1.507	0.781	0.868	2.033	1.616
ANFIS_SC3	0.799	0.880	1.977	1.559	0.820	0.892	1.924	1.528	0.779	0.867	2.041	1.628
ANFIS_SC4	0.799	0.880	1.978	1.569	0.804	0.883	1.996	1.576	0.774	0.864	2.058	1.647
ANFIS_SC5	0.778	0.865	2.067	1.641	0.798	0.878	2.021	1.624	0.762	0.856	2.107	1.705
ANFIS_SC6	0.794	0.876	2.004	1.579	0.815	0.888	1.949	1.545	0.784	0.867	2.022	1.624
ANFIS_FC1	0.863	0.923	1.662	1.286	0.832	0.905	1.868	1.432	0.805	0.889	1.939	1.482
ANFIS_FC2	0.817	0.893	1.898	1.495	0.803	0.887	2.006	1.559	0.763	0.859	2.108	1.673
ANFIS_FC3	0.812	0.888	1.923	1.516	0.816	0.892	1.943	1.531	0.778	0.866	2.042	1.620
ANFIS_FC4	0.809	0.887	1.936	1.527	0.804	0.884	1.996	1.574	0.749	0.851	2.158	1.686
ANFIS_FC5	0.785	0.870	2.040	1.614	0.788	0.873	2.068	1.650	0.751	0.849	2.151	1.733
ANFIS_FC6	0.801	0.881	1.973	1.555	0.815	0.888	1.950	1.531	0.779	0.866	2.042	1.635

D'après les résultats obtenus avec les modèles ANFIS_FC, on constate que le modèle ANFIS_FC1 durant les trois phases, d'apprentissage, validation et test a donné de bons résultats. Les modèles ANFIS_FC3, ANFIS_FC4, ANFIS_FC6 ont fourni les mêmes résultats avec une différence négligeable, et que les faibles performances sont toujours fournies par le

modèle ANFIS_FC5 qui utilise seulement (T_{max} , H%) comme entrées de modèle avec R: 0.785, 0.788 et 0.751, respectivement, finalement on peut conclure que le modèle Neuroflou ANFIS_FC a fourni des performances légèrement supérieur aux modèles Neuroflou ANFIS_GP, ANFIS_SC, et moins performant aux RBFNN,GRNN.

IV.4.3.1. Résultats récapitulatif des différents modèles pour barrage Zit Emba

Les résultats obtenus avec les différents modèles au niveau du barrage Zit Emba nous permettent de conclure ce qui suit:

1. Les modèles ayant les quatre variables climatiques et les deux composantes (J et M) du calendrier Grégorien ont fourni les meilleures performances par rapport aux autres modèles à l'exception les deux modèles Neuroflou ANFIS_GP et ANFIS_SC qui sont moins performants.
2. Le modèle LSSVM1 est le plus performant par rapport aux autres modèles, avec les R et d les plus élevées ($R=0.822$, $d=0.900$) et les RMSE et MAE les plus faibles (RMSE =1.865mm, MAE=1.430mm), suivi par le modèle, GRNN1, RBFNN1, ANFIS_FC1 et MLPNN1 respectivement alors que les modèles ANFIS_GP1 et ANFIS_SC1 ont fourni les plus faibles résultats.
3. On note également que le modèle LSSVM1 a montré un bon accord avec R: 0.879, 0.836 et 0.822, respectivement, donc il possède une bonne capacité de généralisation que les autres modèles.
4. Les résultats montrent que les plus faibles performances sont obtenues avec les modèles utilisant la T_{max} et H% durant les trois phases.

Tableau IV.7 Résultats récapitulatif des meilleures modèles pour barrage Zit Emba

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.805	0.885	1.934	1.498	05
RBFNN1	0.813	0.893	1.901	1.427	03
GRNN1	0.816	0.892	1.884	1.423	02
LSSVM1	0.822	0.900	1.865	1.430	01
ANFIS_GP1	0.612	0.776	3.000	1.754	07
ANFIS_SC1	0.781	0.879	2.075	1.548	06
ANFIS_FC1	0.805	0.889	1.939	1.482	04

IV.4.4. Résultats de la modélisation pour le Barrage El Agram

Les résultats obtenus par les différents modèles au niveau du barrage *El Agram* sont récapitulés dans le **Tableau IV.8** et les **Figures IV.7-8**, durant les trois phases, d'apprentissage, validation et test. Les performances des modèles varient selon le nombre de variables d'entrée utilisés. En phase d'apprentissage Le plus faible (RMSE=1.332mm, MAE=0.928mm) et le plus élevés ($R=0.875$ et $d=0.928$) ont été obtenus avec le modèle (LSSVM1) dans lequel toutes les variables sont prises en compte, (T_{max} , T_{min} , U_2 , H%, J et M). Les valeurs de ($R=0.808$ et $d=0.886$) du modèle LSSVM2 sont légèrement inférieurs aux valeurs obtenus par le modèle LSSVM1. On note aussi que les modèles avec trois variables climatiques (LSSVM3 et

LSSVM4) ont les mêmes performances en tenant compte des valeurs des R et d ($R=0.800$ et $d=0.881$), ($R=0.802$ et $d=0.882$), respectivement, et sont légèrement supérieurs aux modèles ayant deux variables climatique (LSSVM5 et LSSVM6). Les plus faibles performances sont obtenus avec le modèle à deux variables climatique (T_{max} , $H\%$) avec ($R=0.793$ et $d=0.876$), ce qui confirme l'importance de la T_{min} . En phases de validation les résultats consignés dans le **Tableau IV.7** sont jugés satisfaisants et confirment ceux obtenus en phase d'apprentissage en particulier le modèle à six entrées (LSSVM1). Les autres modèles LSSVM2 à LSSVM6 sont moins performants à ceux obtenus en phase d'apprentissage. En tenant compte des R et d , ($R=0.818$ et $d=0.896$), LSSVM1 est supérieur au modèle LSSVM2 avec des pourcentages de 2.6% et 1.8%, respectivement. La différence entre les modèles LSSVM2, LSSVM3, LSSVM4, LSSVM5 et LSSVM6 est relativement négligeable, avec R varie entre 0.781 et 0.792. Durant la phase de test, on enregistre des résultats similaires aux résultats obtenus durant la phase d'apprentissage avec des différences non significatives en tenant compte des tous les indices de performances. Les meilleurs résultats sont obtenus avec le modèle LSSVM1 avec des valeurs R et d de l'ordre de 0.827 et 0.903, respectivement. Légèrement supérieurs aux autres modèles, LSSVM2, LSSVM3, LSSVM4, LSSVM5 et LSSVM6, ont fourni un coefficient de corrélation R varie entre 0.805 et 0.809. Finalement on peut conclure que le modèle LSSVM1 possède une bonne capacité de généralisation que les autres modèles.

Les résultats obtenus par les modèles Neuroflou ANFIS_GP sont relativement acceptables et du même ordre de grandeur, avec celles simulées par les modèles LSSVM. En phase d'apprentissage, les résultats montrent que dans l'ensemble, les performances des modèles ANFIS_GP1 à ANFIS_GP6 sont généralement proches les uns des autres et satisfaisantes. Cela montre qu'il y a une supériorité du modèle ANFIS_GP1 par rapport aux autres modèles avec ($R=0.869$ et $d=0.926$), pour les modèles ANFIS_GP2, ANFIS_GP3, ANFIS_GP4, et ANFIS_GP6 les résultats obtenus sont très proches avec R varie entre 0.793 et 0.806, et les plus faibles performances toujours obtenus avec ANFIS_GP5 avec ($R=0.791$ et $d=0.874$). En période de validation, nous avons enregistré une détérioration significative de la qualité de simulation avec le modèle ANFIS_GP1 par rapport aux résultats obtenus en apprentissage, de l'ordre de 9.2% et 5%, pour les R et d , respectivement. On note également que les autres modèles ANFIS_GP2, ANFIS_GP3, ANFIS_GP4, et ANFIS_GP6 les résultats obtenus sont très proches avec R varie entre 0.786 et 0.788, avec des différences négligeables, et les plus faibles performances toujours obtenus avec ANFIS_GP5 avec ($R=0.778$ et $d=0.870$). En phase de test, les meilleurs résultats sont obtenus avec le modèle appliqué à trois variables climatique ANFIS_GP3 (T_{max} , T_{min} , U_2) avec ($R=0.807$ et $d=0.886$), on note également que les résultats obtenus avec les modèles ANFIS_GP2 à ANFIS_GP6 sont très proches avec R varie entre 0.801 et 0.807 et supérieurs à ceux obtenus en phase d'apprentissage et validation, et les faibles performances sont obtenus avec ANFIS_GP1 avec ($R=0.791$ et $d=0.874$).

Les résultats obtenus avec les modèles ANFIS_SC sont généralement acceptables durant les trois phases, et légèrement supérieures ANFIS_GP. En phase de d'apprentissage le modèle ANFIS_SC1 a fourni les meilleures performances dans lequel toutes les variables sont prises en compte avec ($R=0.871$, $d=0.927$, $RMSE=1.353\text{mm}$, $MAE=1.018\text{mm}$). Suivi de près par le modèle ANFIS_SC2 avec ($R=0.805$, $d=0.884$). Les résultats obtenus par les modèles à trois et quatre variables sont très similaires et moins performants par rapport à ceux obtenus par les modèles ANFIS_SC1 et ANFIS_SC2 avec R entre 0.794 et 0.799, alors qu'en validation on remarque une certaine détérioration des performances, mais en générale ils apportent des résultats relativement acceptables : Tous les modèles ont fourni des résultats très proches avec

R varie entre 0.779 et 0.799. En phase de test, le meilleur résultat est obtenu avec ANFIS_SC1, alors que les résultats obtenus avec les modèles ANFIS_SC2 à ANFIS_SC6 sont légèrement supérieurs en période de test qu'en période de calage et validation avec R compris entre 0.803 et 0.809. Finalement, les modèles à six variables ANFIS_FC1 sont les plus performants par rapport aux autres modèles durant les trois phases d'apprentissage ($R=0.841$, $d=0.908$), validation ($R=0.815$, $d=0.893$) et de test ($R=0.833$, $d=0.907$), respectivement.

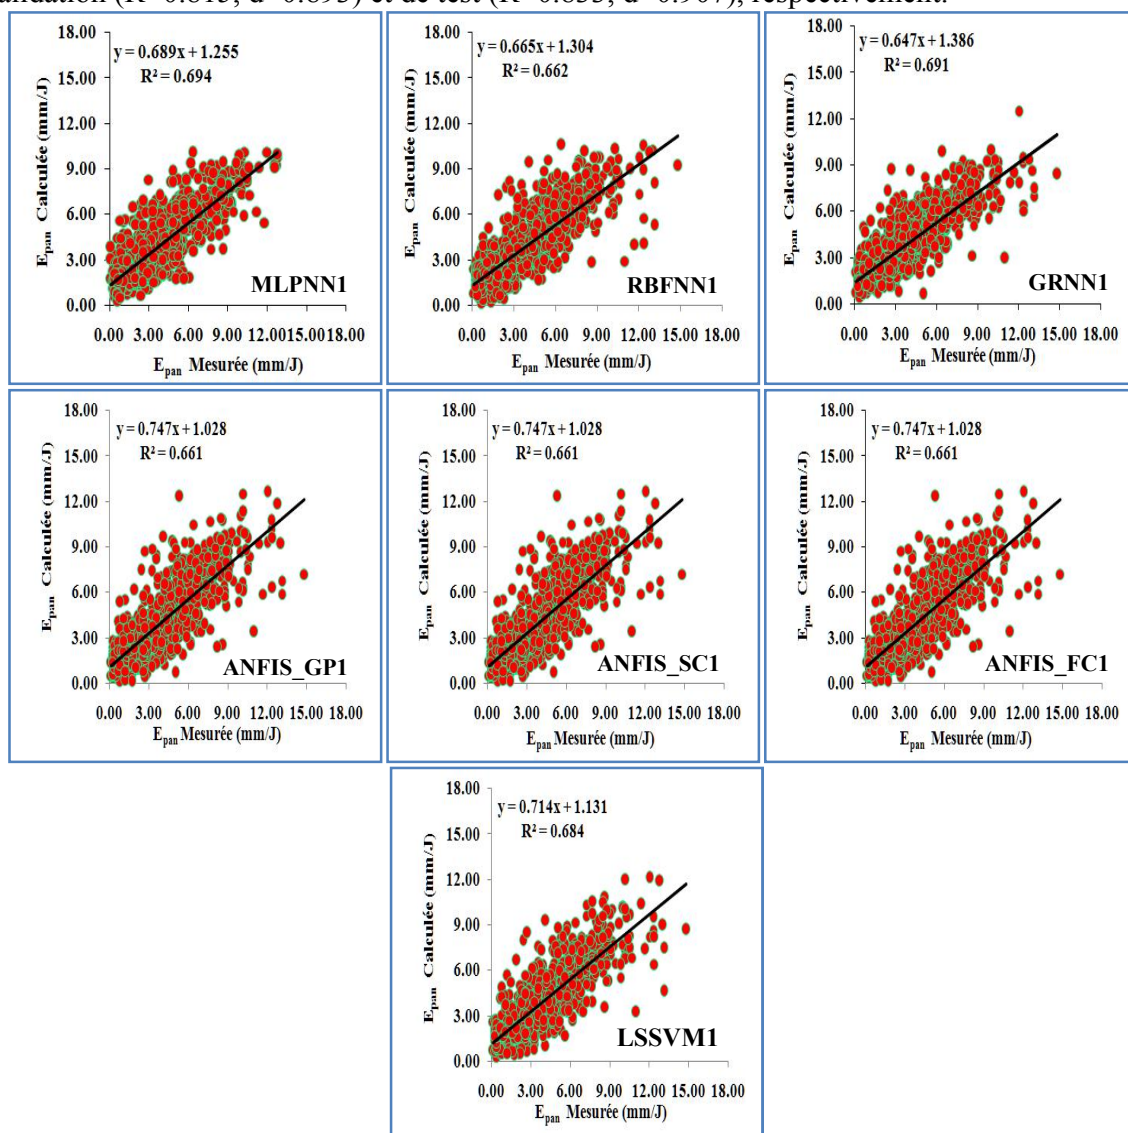


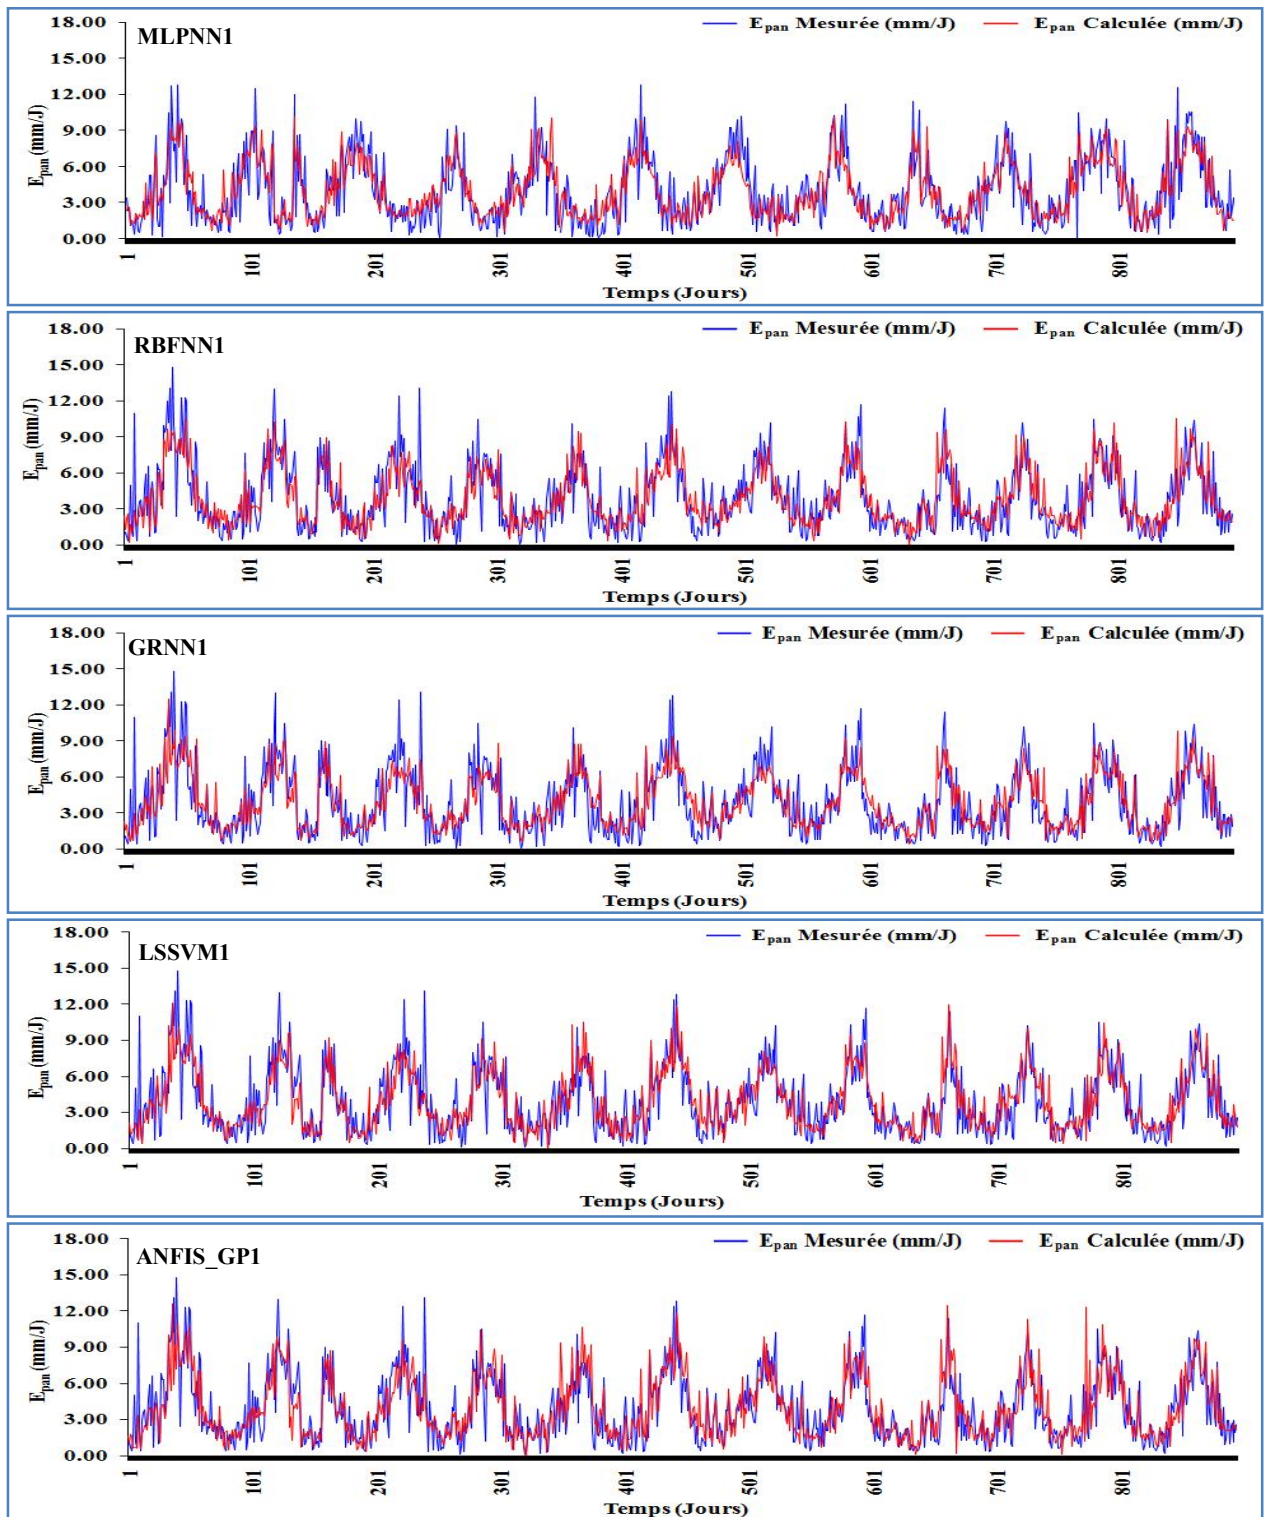
Figure IV.7. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage El Agram, phase de test.

Les modèles MLPNN ont fournies à peu près les mêmes résultats que les modèles ANFIS_FC et LSSVM durant les trois phases. En phase d'apprentissage, le modèle MLPNN1 apporte les meilleures performances avec ($R=0.843$, $d=0.908$), suivi par le modèle MLPNN2 avec une détérioration des valeurs de R et d de l'ordre de 3.9% et 2.5%. Ceci est principalement dû à l'exclu des deux composantes du calendrier Grégorien (J et M). Les performances des modèles MLPNN3- MLPNN6 ont des performances moyennes très proches, et sensiblement inférieures à celles des MLPNN1-MLPNN2 avec R entre 0.793 et 0.801. Les

modèles MLPNN5 et MLPNN6 ont donnés les plus faibles performances par apport aux autre modèles, avec (R=0.793, R=0.797), respectivement.

Tableau IV.8 Performances des modèles journaliers au niveau du Barrage *El Agram*

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.843	0.908	1.473	1.113	0.829	0.897	1.594	1.155	0.833	0.904	1.491	1.140
MLPNN2	0.804	0.883	1.626	1.254	0.795	0.877	1.727	1.261	0.833	0.904	1.491	1.140
MLPNN3	0.801	0.882	1.638	1.253	0.796	0.878	1.721	1.262	0.799	0.882	1.622	1.238
MLPNN4	0.799	0.879	1.646	1.275	0.793	0.873	1.736	1.262	0.791	0.874	1.651	1.284
MLPNN5	0.793	0.874	1.665	1.291	0.793	0.873	1.736	1.278	0.794	0.875	1.641	1.274
MLPNN6	0.797	0.878	1.654	1.276	0.793	0.875	1.732	1.261	0.792	0.876	1.648	1.277
RBFNN1	0.866	0.925	1.375	1.049	0.813	0.889	1.604	1.251	0.814	0.891	1.595	1.191
RBFNN2	0.837	0.906	1.507	1.137	0.756	0.857	1.811	1.376	0.785	0.878	1.708	1.289
RBFNN3	0.809	0.887	1.615	1.230	0.779	0.869	1.724	1.318	0.794	0.881	1.669	1.260
RBFNN4	0.806	0.885	1.627	1.224	0.786	0.871	1.698	1.310	0.800	0.883	1.646	1.240
RBFNN5	0.796	0.878	1.662	1.268	0.780	0.866	1.721	1.327	0.803	0.882	1.637	1.248
RBFNN6	0.803	0.883	1.639	1.248	0.774	0.865	1.742	1.333	0.792	0.879	1.678	1.265
GRNN1	0.900	0.936	1.231	0.894	0.821	0.887	1.579	1.223	0.832	0.896	1.533	1.153
GRNN2	0.825	0.892	1.559	1.178	0.788	0.867	1.696	1.307	0.804	0.881	1.635	1.250
GRNN3	0.791	0.864	1.691	1.306	0.781	0.857	1.723	1.346	0.798	0.868	1.668	1.283
GRNN4	0.786	0.857	1.714	1.324	0.783	0.854	1.724	1.352	0.792	0.863	1.691	1.297
GRNN5	0.787	0.852	1.719	1.333	0.770	0.841	1.770	1.383	0.803	0.860	1.674	1.290
GRNN6	0.799	0.877	1.656	1.269	0.785	0.867	1.705	1.322	0.802	0.879	1.645	1.253
LSSVM1	0.875	0.928	1.332	0.986	0.818	0.896	1.585	1.207	0.827	0.903	1.547	1.160
LSSVM2	0.808	0.886	1.621	1.221	0.792	0.878	1.681	1.285	0.809	0.889	1.617	1.220
LSSVM3	0.800	0.881	1.647	1.255	0.789	0.876	1.691	1.290	0.806	0.886	1.623	1.230
LSSVM4	0.802	0.882	1.641	1.235	0.792	0.877	1.680	1.290	0.804	0.885	1.632	1.225
LSSVM5	0.793	0.876	1.673	1.276	0.781	0.869	1.721	1.319	0.805	0.884	1.628	1.233
LSSVM6	0.795	0.877	1.669	1.269	0.787	0.874	1.700	1.304	0.805	0.885	1.630	1.233
ANFIS_GP1	0.869	0.926	1.363	1.012	0.777	0.876	1.779	1.311	0.745	0.860	1.955	1.304
ANFIS_GP2	0.806	0.885	1.627	1.228	0.787	0.873	1.697	1.302	0.801	0.885	1.645	1.226
ANFIS_GP3	0.798	0.880	1.655	1.260	0.788	0.872	1.691	1.298	0.807	0.886	1.621	1.227
ANFIS_GP4	0.799	0.880	1.651	1.245	0.786	0.871	1.699	1.309	0.800	0.882	1.648	1.233
ANFIS_GP5	0.791	0.874	1.682	1.284	0.778	0.865	1.727	1.335	0.804	0.883	1.631	1.240
ANFIS_GP6	0.793	0.876	1.674	1.272	0.786	0.870	1.701	1.313	0.804	0.884	1.633	1.236
ANFIS_SC1	0.871	0.927	1.353	1.018	0.799	0.887	1.668	1.264	0.813	0.898	1.625	1.190
ANFIS_SC2	0.805	0.884	1.633	1.234	0.790	0.874	1.686	1.300	0.809	0.887	1.615	1.219
ANFIS_SC3	0.798	0.879	1.655	1.258	0.789	0.872	1.690	1.298	0.808	0.885	1.617	1.228
ANFIS_SC4	0.799	0.880	1.652	1.246	0.790	0.873	1.684	1.300	0.806	0.886	1.625	1.227
ANFIS_SC5	0.794	0.876	1.671	1.275	0.779	0.867	1.722	1.328	0.803	0.881	1.638	1.244
ANFIS_SC6	0.795	0.878	1.668	1.268	0.787	0.871	1.696	1.309	0.805	0.884	1.630	1.233
ANFIS_FC1	0.841	0.908	1.490	1.113	0.815	0.893	1.599	1.230	0.833	0.907	1.524	1.122
ANFIS_FC2	0.807	0.886	1.624	1.224	0.787	0.872	1.700	1.304	0.808	0.888	1.618	1.221
ANFIS_FC3	0.801	0.881	1.644	1.251	0.785	0.870	1.704	1.304	0.801	0.883	1.641	1.248
ANFIS_FC4	0.800	0.881	1.648	1.245	0.789	0.873	1.687	1.300	0.807	0.887	1.620	1.219
ANFIS_FC5	0.797	0.878	1.661	1.270	0.776	0.864	1.734	1.334	0.805	0.883	1.627	1.241
ANFIS_FC6	0.798	0.879	1.658	1.259	0.783	0.869	1.713	1.317	0.806	0.885	1.628	1.234



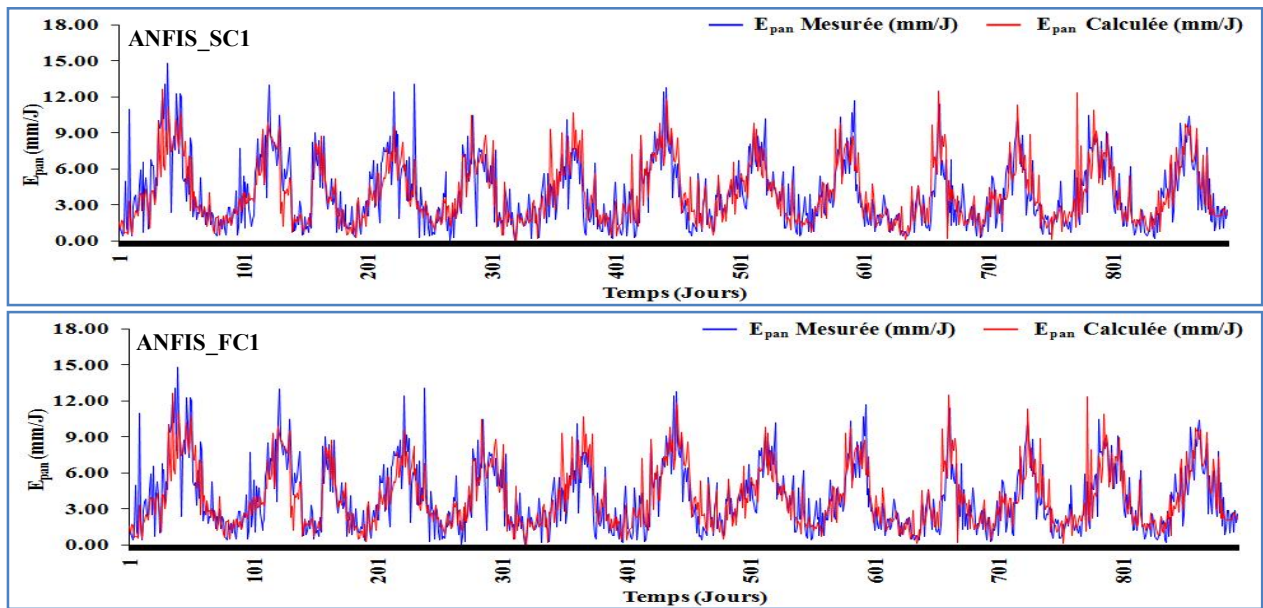


Figure IV.8. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage *El Agram*, phase de test.

Au cours de la phase de validation, on observe que le modèle MLPNN1 est le seul modèle qui apporte des résultats acceptables avec ($R=0.829$, $d=0.897$), alors que les autres modèles, MLPNN2-MLPNN6 ont fournis des résultats de moins importance que le modèle MLPNN1 avec R compris entre 0.793 et 0.796. Finalement en phase test, on note que les performances des modèles MLPNN sont légèrement supérieures à celles obtenus en phase de validation en particulier MLPNN1 et MLPNN2, avec ($R=0.833$, $d=0.904$), ($R=0.833$, $d=0.904$), respectivement. Pour les modèles MLPNN3-MLPNN6 sont égales aux performances initialement obtenues en phase d'apprentissage et validation avec R compris entre 0.791 et 0.799. Finalement, on peut conclure que le modèle MLPNN1 est le seul qui a fourni des performances acceptables par rapport aux autres modèles MLPNN au cours de trois phases.

Les résultats obtenus par les modèles RBFNN sont satisfaisants durant les trois phases en particulier le RBFNN1: R entre (0.813 et 0.866) et RMSE compris entre (0.889mm et 0.925mm). En phase d'apprentissage, les résultats révèlent que la meilleure performance est celui de RBFNN1 avec ($R=0.866$ et $RMSE=1.375mm$), suivi directement par le RBFNN2 avec une baisse des performances, en terme des R et d de l'ordre de 2.9% et 1.9%. Quant aux modèles RBFNN3, RBFNN4 et RBFNN6, ils ont à peu près les mêmes performances avec R entre 0.803 et 0.809. Nous notons également toujours que le modèle RBFNN5 est le moins performant par rapport aux autres modèles avec ($R=0.796$ et $RMSE=1.662mm$), cela est dû à l'utilisation de l'humidité $H\%$ au lieu d'utiliser T_{min} comme entrée du modèle. Au cours de la phase de validation, les modèles RBFNN sont moins performants qu'en phase d'apprentissage, nous remarquons également que le modèle RBFNN1 est le seul modèle qui donne des performances satisfaisantes avec R supérieure à 80%, alors que les autres modèles ont fourni des faibles performances avec R entre 0.756 et 0.786. Les résultats obtenus en phase de test sont à peu près du même ordre à ceux obtenus en validation. Les résultats obtenus avec les modèles GRNN, ils sont égales ou légèrement supérieurs à ceux obtenus par les modèles ANFIS, MLPNN, RBFNN, durant les trois phases, en apprentissage. On note que le modèle

qui possède de bonne performance est le GRNN1, avec ($R=0.900$ et $RMSE= 1.231mm$), le modèle GRNN2 occupe la deuxième place avec une légère baisse des valeurs des indices de performances, ($R=0.825$ et $RMSE= 1.559mm$), les modèles GRNN3 au GRNN6 fournirent des résultats relativement acceptables et très proche avec R entre 0.786 et 0.799 .

IV.4.4.1. Résultats récapitulatif des différents modèles pour barrage *El Agram*

D'après les résultats obtenus par les différents modèles au niveau du barrage El Agram nous a permis de tiré les conclusions suivantes:

1. Les résultats révèlent que les meilleures performances sont observées quand on inclut tous les variables climatiques et les deux composantes (J et M) du calendrier Grégorien.
2. Les modèle ANFIS_FC1 et MLPNN1 présentent un avantage pour la simulation de l' E_{pan} par rapport autres modèles, avec les R et d les plus élevées ($R=0.833$, $d=0.0.907$) et les RMSE et MAE les plus faibles ($RMSE=1.524mm$, $MAE=1.122mm$), suivi par le modèle, GRNN1, LSSVM1 RBFNN1 et ANFIS_FC1, respectivement, alors que le modèle ANFIS_GP1 a fourni les plus faibles résultats.
3. On note également que le modèle GRNN1 a donné de bons résultats en phase d'apprentissage avec $R=0.900$, il a occupé la troisième place en phase de test.
4. Les modèles avec quatre variables climatiques, occupent la deuxième place, et apportent des performances acceptables avec R dépasse les 80%, à l'exception de modèle ANFIS_GP.
5. Les résultats obtenus avec Les modèles à trois variables sont très proches, avec des déréférences négligeables.
6. Les résultats montrent que les plus faibles performances sont obtenues avec les modèle ANFIS_GP1 avec $R=0.745$ et $RMSE=1.955mm$.

Tableau IV.9 Résultats récapitulatif des meilleures modèles pour barrage *El Agram*

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.833	0.904	1.491	1.140	02
RBFNN1	0.814	0.891	1.595	1.191	05
GRNN1	0.832	0.896	1.533	1.153	03
LSSVM1	0.827	0.903	1.547	1.160	04
ANFIS_GP1	0.745	0.860	1.955	1.304	07
ANFIS_SC1	0.813	0.898	1.625	1.190	06
ANFIS_FC1	0.833	0.907	1.524	1.122	01

IV.4.5. Résultats de la modélisation pour le Barrage Hammam Grouz

Les résultats obtenus au niveau du barrage Hammam Grouz sont reportés au niveau du **Tableau IV.10** et les **Figure IV.9-10**. Les différents modèles possèdent de très bonnes performances en apprentissage, de validation et test, et que les différents modèles ont les mêmes ordres de grandeur de performance dans la simulation de l' E_{pan} . Pour les modèles ANFIS_GP, Les meilleure performances sont obtenus avec le modèle ANFIS_GP1, avec un $RMSE=1.307mm$ et $R=0.927$, suivi directement par le modèle ANFIS_GP2, avec une légère dégradation, de l'ordre de 3.7% et 2.2% en terme de R et d , cette dégradation reste marginale et

reflète une bonne qualité de prédiction. Quant aux autres modèles, les modèles ANFIS_GP3 et ANFIS_GP4, sont légèrement moins performants que le modèle ANFIS_GP2 et légèrement supérieurs aux modèles qui utilisent deux variables climatiques ANFIS_GP5 et ANFIS_GP6 avec R varie de 0.874 à 0.884. En phase de validation, les résultats obtenus sont bons, on note que les meilleures performances sont toujours obtenues par le modèle ANFIS_GP1 avec une légère détérioration par rapport à ceux obtenus en phase d'apprentissage avec ($R=0.871$ et $RMSE=1.753mm$), les résultats obtenus par les modèles ANFIS_GP2-ANFIS_GP6 sont très proches avec R compris entre 0.878 et 0.888. Finalement, durant la phase de test, on remarque que les meilleurs résultats sont obtenus avec le modèle ANFIS_GP6, qui utilise les deux variables climatiques T_{max} , T_{min} avec ($R=0.895$ et $RMSE=1.567mm$), alors que les résultats et les performances des autres modèles sont identiques à ceux obtenus en phases de validation et d'apprentissage. Pour les modèles ANFIS_SC et ANFIS_FC, on note une nette amélioration des résultats avec six variables (T_{max} , T_{min} , \bar{U}_2 , $H\%$, J , M), ANFIS_SC1 et ANFIS_FC1 étaient meilleures en particulier en phase de validation par rapport au modèle ANFIS_GP avec ($R=0.902$ et $RMSE=1.525 mm$) et ($R=0.902$ et $RMSE=1.525 mm$), respectivement, alors que les résultats obtenus par les modèles ANFIS_SC et ANFIS_FC sont très proches à ceux obtenus par le modèle ANFIS_GP durant les trois phases, avec des différences négligeables.

Les résultats de la modélisation de l' E_{pan} par les modèles GRNN indiquent une bonne corrélation entre les valeurs mesurées et calculées. Il en découle que le modèle de GRNN possède un meilleur pouvoir de prédiction de l' E_{pan} en comparaison avec les modèles ANFIS en particulier les modèles GRNN1, en phase d'apprentissage et validation. Les deux critères de performances sont supérieurs à 95% pour l'indice de conformité de Willmott (d) et de 91 % pour le coefficient de corrélation (R). En phase d'apprentissage, il apparaît nettement que le modèle GRNN1 a donné de bons résultats, le R est relativement élevé (94%), dépassant le modèle GRNN2 avec des améliorations relativement significatives en termes des R (3.1%) et d (1.8%). Le modèle GRNN2 occupe la deuxième place en termes de performances, les modèles GRNN3 au GRNN6 ont des performances moyennes très proches, avec R compris entre 0.869 et 0.882, tandis que les performances du GRNN3 sont légèrement supérieures avec $R=0.882$. Durant la phase de validation, on constate que le modèle GRNN1 possède de bons critères de performance et toujours occupe la première place avec ($R=0.910$ et $RMSE=1.467mm$), quant aux modèles GRNN2 au GRNN6, nous avons obtenus des performances très proches avec R compris entre 0.873 et 0.887, et sont légèrement inférieure à celle du GRNN1. En phase de test on note que les modèles GRNN possèdent des résultats assez bons, et la majorité des modèles de GRNN1 à GRNN6 ont les mêmes performances avec des différences négligeables, avec R oscillant entre 0.858 et 0.897, bien que les meilleures performances sont obtenues avec le GRNN6 ($R=0.897$). On peut conclure que le modèle GRNN1 est doté d'une bonne robustesse dans la simulation de l' E_{pan} au cours de trois phases.

Le **Tableau IV.9** indique que les résultats obtenus avec les modèles RBFNN sont à peu près les mêmes obtenus avec les modèles GRNN. En phase d'apprentissage on obtient d'excellents critères de performances, en particulier avec le modèle RBFNN1 ($R=0.949$ et $RMSE=1.105mm$), les modèles RBFNN2, RBFNN3, RBFNN4, ont les mêmes performances avec R 0.894, les modèles RBFNN 5, RBFNN6 occupent les dernières places avec $R=0.880$ et 0.878, respectivement. En phase de validation, on note une légère baisse des critères de performances, on constate également que les meilleures performances toujours fournies par le modèle RBFNN1 avec ($R=0.891$ et $RMSE=1.606 mm$), alors que les résultats obtenus avec les modèles (RBFNN2 à RBFNN6) sont très proches, avec des différences négligeables, où les

valeurs de R varient entre 0.856 et 0.883. Finalement, en phase de test, nous remarquons que les meilleurs résultats sont obtenus avec le modèle RBFNN6 ayant les (T_{max}, T_{min}) comme entrées avec $(R=0.899$ et $RMSE=1.536mm)$. Quant aux modèles RBFNN1 au RBFNN5, ils ont donné des résultats très proches, où les valeurs de R varient entre 0.841 et 0.867.

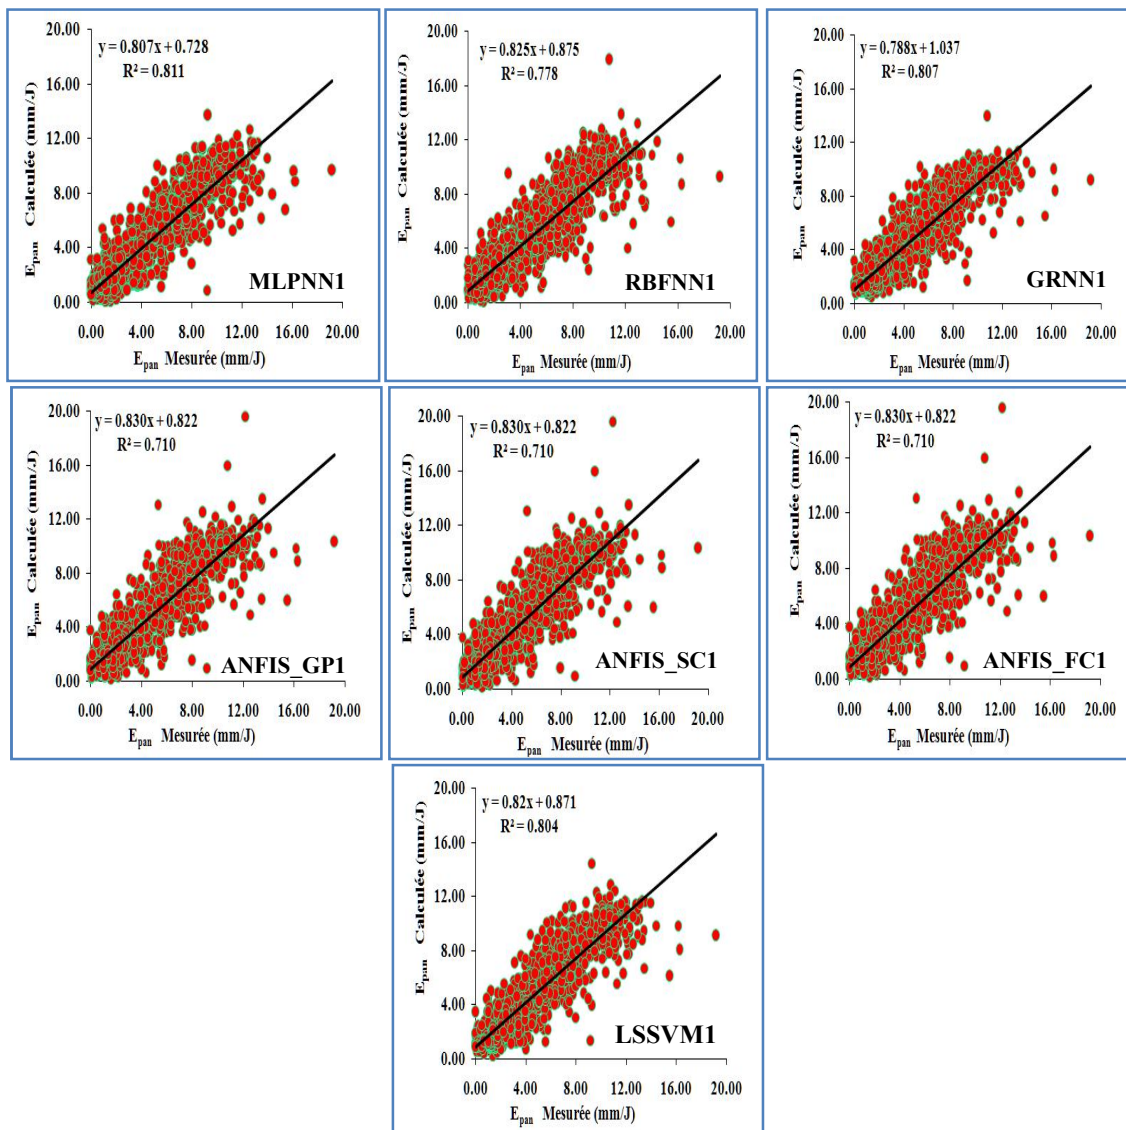
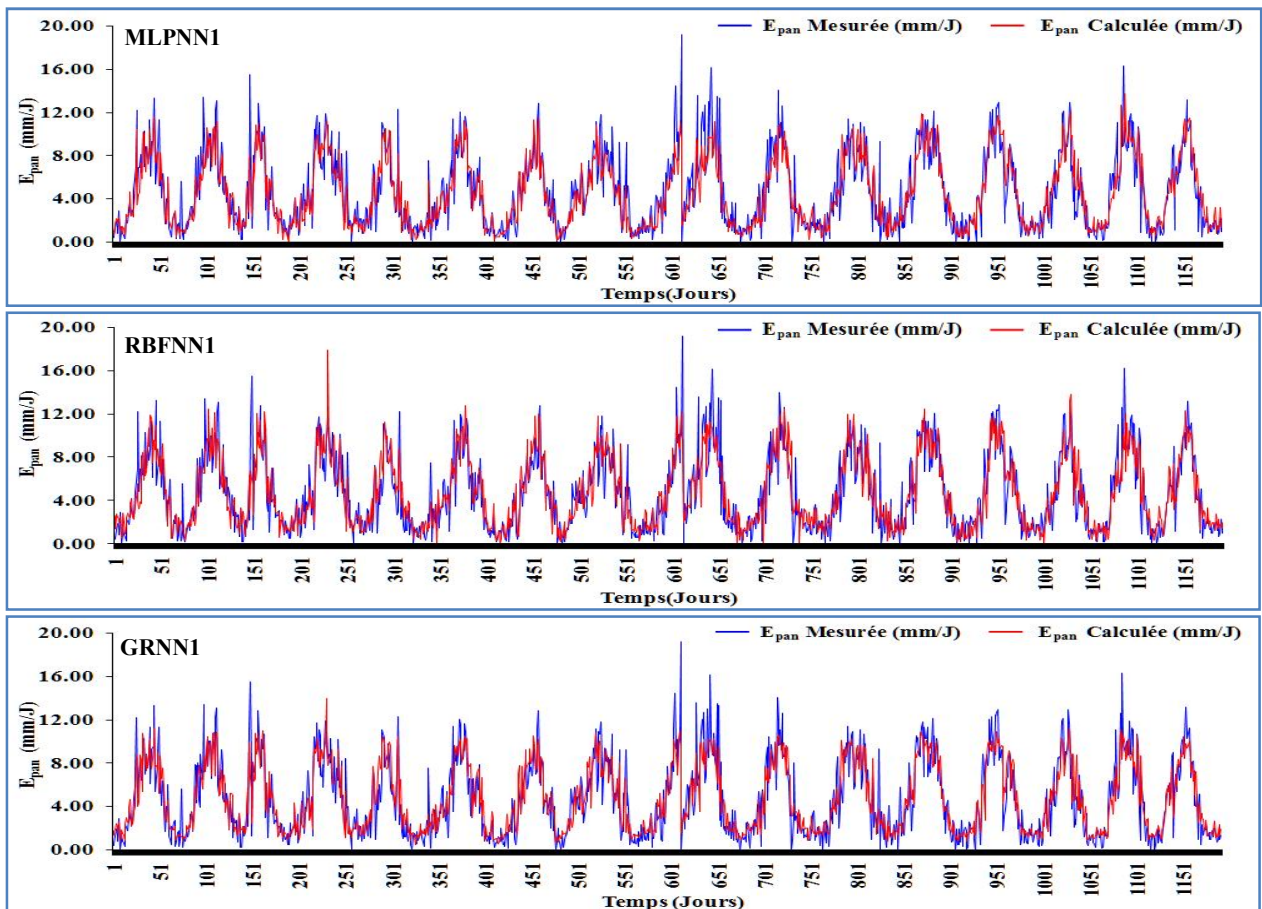


Figure IV.9. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Hammam Grouz, phase de test.

Il apparaît nettement que les modèle MLPNN ont donné de bons résultats, en effet, en phase d'apprentissage, pour le modèle MLPNN1, le critère R est relativement élevé (91%) et RMSE très faible (1.475mm), suivi par le modèle MLPNN2 avec une légère dégradation $(R=0.888$ et $RMSE=1.654mm)$, alors les valeurs de critères de performances obtenus par les modèles MLPNN3 au MLPNN6 sont identiques avec R compris entre 0.875 et 0.886. En phase de validation, on trouve toujours les meilleures performances avec le modèle MLPNN1 avec $(R=0.910$ et $RMSE=1.477mm)$. Ceci exprime le bon fonctionnement du modèle et le choix judicieux des entrées du modèle ; dépassant le modèle MLPNN2 avec 1.7% et 11.5% en

termes des R et RMSE, respectivement. Pour les modèles MLPNN3 au MLPNN6, ils ont des performances très proches avec R compris entre 0.882 et 0.891, et on obtient les meilleures valeurs de critères de performances avec le modèle ayant (T_{max} , T_{min}) comme entrées de modèles, avec (R=0.882 et RMSE= 1.657 mm). Les modèles MLPNN1 au MLPNN5 ont des performances très proches avec RMSE compris entre 1.786mm et 1.692mm. Finalement, on peut conclure que les résultats obtenus les modèles MLPNN, ont les mêmes ordres de grandeur à ceux obtenus avec les modèles précédents ANFIS et GRNN, RBFNN durant les trois phases.

Les résultats obtenus par les modèles LSSVM confirment ceux obtenus par les modèles précédents, ANFIS, GRNN, RBFNN et MLPNN durant les trois phases. En phase d'apprentissage la meilleure qualité de prédiction est obtenus par le modèle à six entrées (LSSVM1), avec (R=0.931 et RMSE=1.275 mm), alors que lorsque les deux composantes (J et M) du calendrier Grégorien sont exclus, les valeurs de critères de performances du modèle se dégradent (LSSVM2) avec 3.7% et 29% en termes des R et RMSE, respectivement. On note également que les valeurs des critères de performances obtenus par les modèles LSSVM3 au LSSVM6 sont très proches, avec R compris entre 0.875 et 0.886. Durant la phase de validation et test, nous remarquons que les meilleurs valeurs de critères de performances sont obtenus par modèles LSSVM1 avec (R=0.874, RMSE=1.701mm) et (R=0.904, RMSE=1.507mm), respectivement.



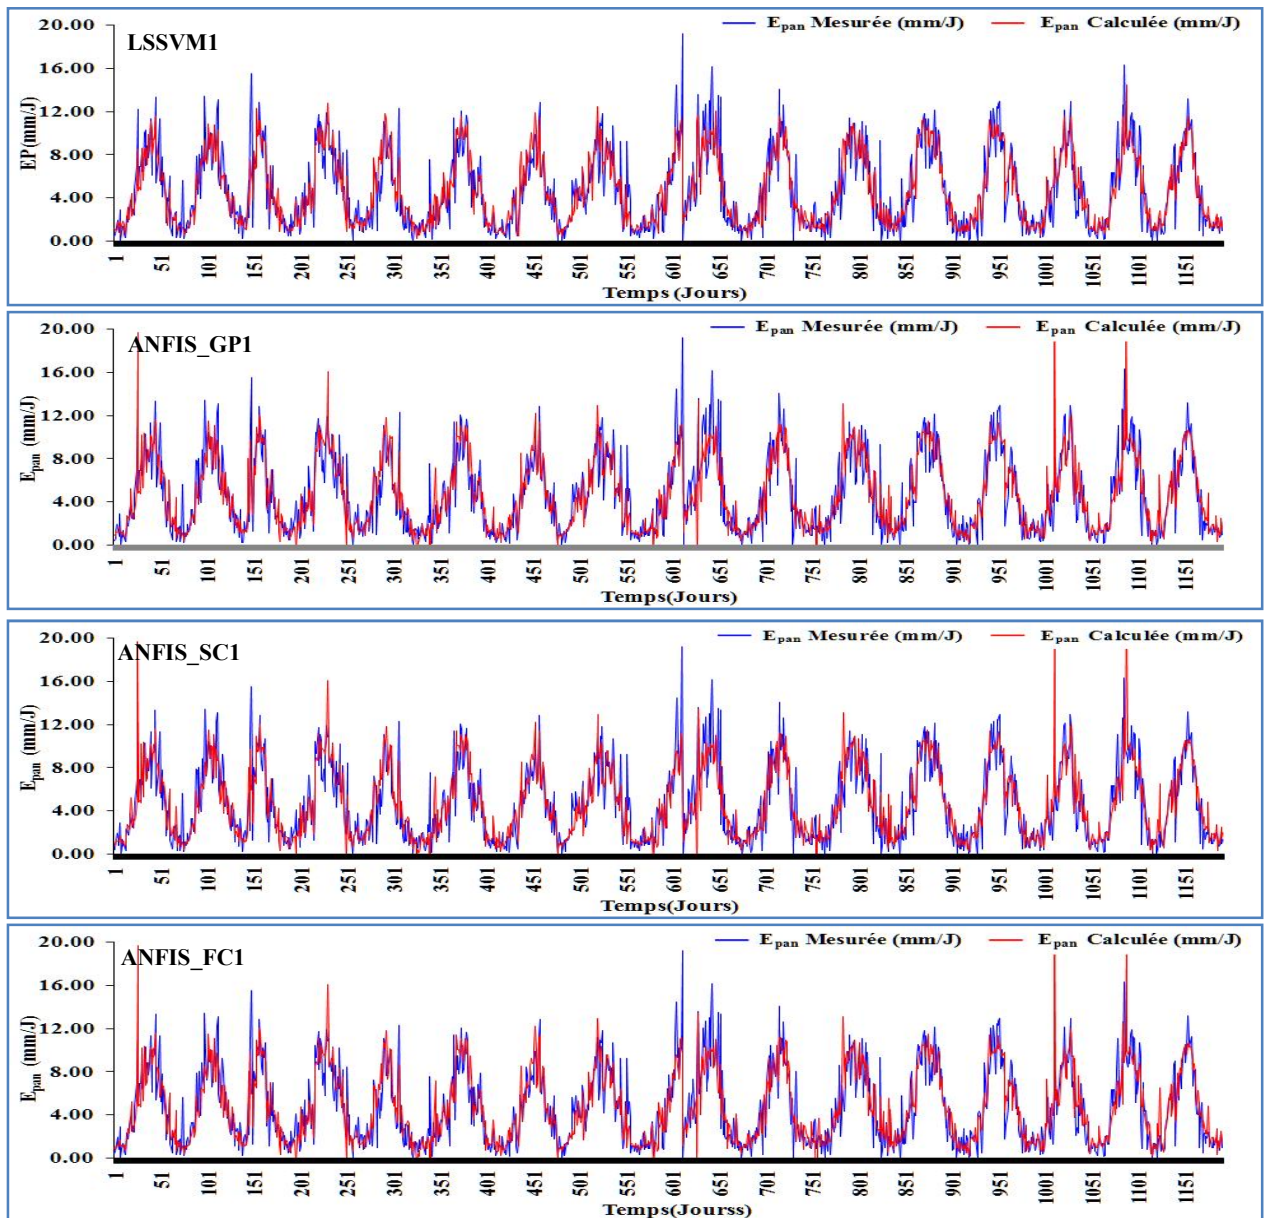


Figure IV.10. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Hammam Grouz, phase de test.

Tableau IV.10 Performances des modèles journaliers au niveau du Barrage Hammam Grouz.

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.913	0.951	1.475	1.032	0.910	0.948	1.477	1.030	0.876	0.928	1.692	1.248
MLPNN2	0.888	0.935	1.654	1.221	0.893	0.938	1.592	1.187	0.871	0.928	1.719	1.254
MLPNN3	0.885	0.936	1.671	1.230	0.886	0.937	1.631	1.210	0.874	0.930	1.704	1.243
MLPNN4	0.886	0.937	1.659	1.211	0.891	0.940	1.601	1.175	0.869	0.926	1.729	1.262
MLPNN5	0.878	0.932	1.715	1.254	0.882	0.935	1.659	1.213	0.860	0.921	1.786	1.304
MLPNN6	0.875	0.930	1.733	1.289	0.882	0.934	1.660	1.234	0.882	0.937	1.657	1.208
RBFNN1	0.949	0.973	1.105	0.829	0.891	0.940	1.606	1.136	0.867	0.926	1.746	1.267
RBFNN2	0.894	0.942	1.563	1.161	0.883	0.936	1.653	1.210	0.853	0.918	1.831	1.305
RBFNN3	0.894	0.941	1.563	1.157	0.863	0.926	1.797	1.243	0.841	0.913	1.898	1.335
RBFNN4	0.894	0.941	1.563	1.165	0.872	0.930	1.727	1.262	0.850	0.917	1.844	1.299
RBFNN5	0.880	0.933	1.658	1.237	0.856	0.922	1.839	1.249	0.861	0.922	1.779	1.303
RBFNN6	0.878	0.931	1.676	1.253	0.870	0.928	1.737	1.265	0.899	0.943	1.536	1.111
GRNN1	0.941	0.967	1.193	0.847	0.910	0.949	1.467	1.050	0.872	0.928	1.713	1.242
GRNN2	0.909	0.949	1.463	1.072	0.886	0.937	1.632	1.193	0.874	0.925	1.705	1.250
GRNN3	0.882	0.931	1.648	1.225	0.887	0.934	1.631	1.208	0.858	0.914	1.802	1.334
GRNN4	0.875	0.923	1.704	1.286	0.873	0.922	1.734	1.305	0.868	0.919	1.751	1.287
GRNN5	0.869	0.920	1.739	1.298	0.879	0.926	1.692	1.251	0.859	0.918	1.792	1.319
GRNN6	0.875	0.928	1.697	1.272	0.876	0.929	1.704	1.270	0.897	0.944	1.550	1.108
LSSVM1	0.931	0.963	1.275	0.913	0.904	0.948	1.507	1.050	0.874	0.931	1.701	1.238
LSSVM2	0.894	0.942	1.565	1.153	0.890	0.940	1.607	1.175	0.870	0.928	1.721	1.264
LSSVM3	0.886	0.936	1.618	1.193	0.888	0.939	1.615	1.187	0.871	0.928	1.721	1.260
LSSVM4	0.883	0.935	1.637	1.215	0.883	0.935	1.648	1.214	0.867	0.925	1.740	1.277
LSSVM5	0.875	0.930	1.691	1.259	0.881	0.934	1.663	1.223	0.861	0.922	1.781	1.310
LSSVM6	0.876	0.930	1.689	1.262	0.878	0.932	1.689	1.253	0.843	0.916	1.948	1.211
ANFIS_GP1	0.927	0.961	1.307	0.950	0.871	0.931	1.753	1.139	0.867	0.927	1.749	1.255
ANFIS_GP2	0.890	0.939	1.592	1.177	0.888	0.938	1.624	1.189	0.869	0.927	1.730	1.262
ANFIS_GP3	0.884	0.936	1.628	1.203	0.888	0.938	1.616	1.190	0.870	0.927	1.724	1.256
ANFIS_GP4	0.880	0.933	1.657	1.230	0.882	0.935	1.656	1.218	0.867	0.925	1.738	1.266
ANFIS_GP5	0.874	0.929	1.696	1.262	0.880	0.933	1.668	1.224	0.861	0.922	1.779	1.304
ANFIS_GP6	0.875	0.930	1.692	1.264	0.878	0.932	1.691	1.251	0.895	0.943	1.567	1.119
ANFIS_SC1	0.923	0.958	1.349	0.973	0.902	0.947	1.525	1.067	0.873	0.929	1.709	1.243
ANFIS_SC2	0.889	0.939	1.598	1.177	0.890	0.940	1.605	1.178	0.871	0.928	1.716	1.251
ANFIS_SC3	0.884	0.935	1.630	1.204	0.889	0.939	1.610	1.183	0.868	0.926	1.734	1.268
ANFIS_SC4	0.881	0.934	1.650	1.223	0.882	0.934	1.661	1.221	0.867	0.925	1.742	1.272
ANFIS_SC5	0.875	0.930	1.690	1.258	0.881	0.934	1.664	1.219	0.861	0.922	1.780	1.304
ANFIS_SC6	0.875	0.930	1.692	1.264	0.878	0.932	1.687	1.250	0.890	0.941	1.599	1.147
ANFIS_FC1	0.912	0.952	1.433	1.035	0.902	0.947	1.522	1.076	0.872	0.929	1.715	1.243
ANFIS_FC2	0.893	0.941	1.575	1.160	0.887	0.938	1.627	1.191	0.871	0.928	1.715	1.262
ANFIS_FC3	0.888	0.938	1.606	1.183	0.887	0.937	1.624	1.190	0.865	0.925	1.757	1.275
ANFIS_FC4	0.885	0.936	1.624	1.207	0.882	0.935	1.661	1.225	0.867	0.925	1.743	1.272
ANFIS_FC5	0.877	0.931	1.677	1.250	0.878	0.932	1.685	1.229	0.861	0.921	1.782	1.306
ANFIS_FC6	0.877	0.931	1.682	1.257	0.878	0.932	1.690	1.251	0.876	0.928	1.692	1.248

V.4.5.1. Résultats récapitulatif des différents modèles pour barrage Hammam Grouz

En comparant les résultats obtenus par les différents modèles au niveau du barrage Hammam Grouz, nous pouvons conclure ce qui suit (Table IV.10):

1. Les modèles à six entrées, (combinaison N°1), ont fourni des bonnes valeurs de critères de performances, avec R dépassant les 86%.
2. La majorité des modèles apportent des performances très proches, avec R compris entre 0.867 et 0.876.
3. les modèles à deux entrées (T_{max} et T_{min}), sont plus performants par rapport aux autres modèles, avec R dépassant 88%, à l'exception du LSSVM6 qui a donné les plus faibles performances avec $R=0.843$, durant la phase de test.
4. Le modèle MLPNN1 a effectivement donné de résultats relativement meilleurs par rapport autres modèles, avec les R et d les plus élevées ($R=0.932$, $d=0.963$) et les RMSE et MAE les plus faibles, suivi par le modèle LSSVM1, GRNN1, ANFIS_FC1 et RBFNN1 respectivement, alors que le modèle ANFIS_GP1 a fourni les plus faibles résultats.
5. Les plus faibles performances sont obtenues par les modèles qui utilisent les deux variables climatiques (T_{max} et H %).

Tableau IV.11. Résultats récapitulatif des meilleures modèles pour barrage Hammam Grouz

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.876	0.928	1.692	1.248	01
RBFNN1	0.867	0.926	1.746	1.267	07
GRNN1	0.872	0.928	1.713	1.242	05
LSSVM1	0.874	0.931	1.701	1.238	02
ANFIS_GP1	0.867	0.927	1.749	1.255	06
ANFIS_SC1	0.873	0.929	1.709	1.243	03
ANFIS_FC1	0.872	0.929	1.715	1.243	04

IV.4.6. Résultats de la modélisation pour le Barrage Bouhamdane

Les résultats obtenus au niveau du barrage Bouhamdane sont reportés dans le **Tableau IV.12** et **Figure IV.11-12**. On remarque que les modèles MLPNN sont performants en produisant des valeurs de l' E_{pan} proches des valeurs mesurées avec de faibles erreurs, en particulier le modèle à six entrées (MLPNN1) durant les trois phases. En apprentissage, on note que le modèle MLPNN1 apporte de très bonne performance avec ($R=0.936$, $MAE=0.699$ mm), suivi de près par le modèle MLPNN2, dans lequel seules les quatre variables climatiques ont été utilisées, avec une légère différence de l'ordre de 3.6% et 17.4% en terme des R et MAE. Cette dégradation reste minimale et le modèle MLPNN2 garde une très bonne qualité de prédiction. Les modèles à trois variables climatique MLPNN3&MLPNN4 ont fourni les même performances avec $R=0.89$, et sont légèrement supérieurs aux modèles à deux entrées MLPNN4 et MLPNN5, les plus faibles performances sont obtenus avec le modèle MLPNN5 ($R=0.882$, $MAE=0.962$ mm). En phases de validation et de test les résultats représentés dans le **Tableau IV.11** sont jugés très satisfaisants et confirment ceux obtenus en phase d'apprentissage. Durant la phase de validation, on enregistre que le modèle à six entrées MLPNN1 assure les meilleures

performances ($R=0.904$, $MAE=0.827\text{mm}$), suivi par le modèle MLPNN2 ($R=0.880$, $MAE=0.933\text{mm}$), alors que les modèles à trois variables climatique sont légèrement supérieurs aux modèles à deux entrées MLPNN4&MLPNN5 ($R=0.875$, $MAE=0.953\text{mm}$), le modèle MLPNN5 occupe la 6^{ème} place avec ($R=0.869$, $MAE=0.975\text{mm}$). Pour la phase de test, nous remarquons que les résultats obtenus sont légèrement supérieurs qu'en phase de validation, le modèle MLPNN1 occupe toujours la première place ($R=0.925$, $MAE=0.759\text{mm}$), supérieur au MLPNN2 avec 2.1% et 11.8% en terme de R et MAE, le modèle MLPNN5 toujours occupe la 6^{ème} place avec ($R=0.886$, $MAE=0.946\text{mm}$).




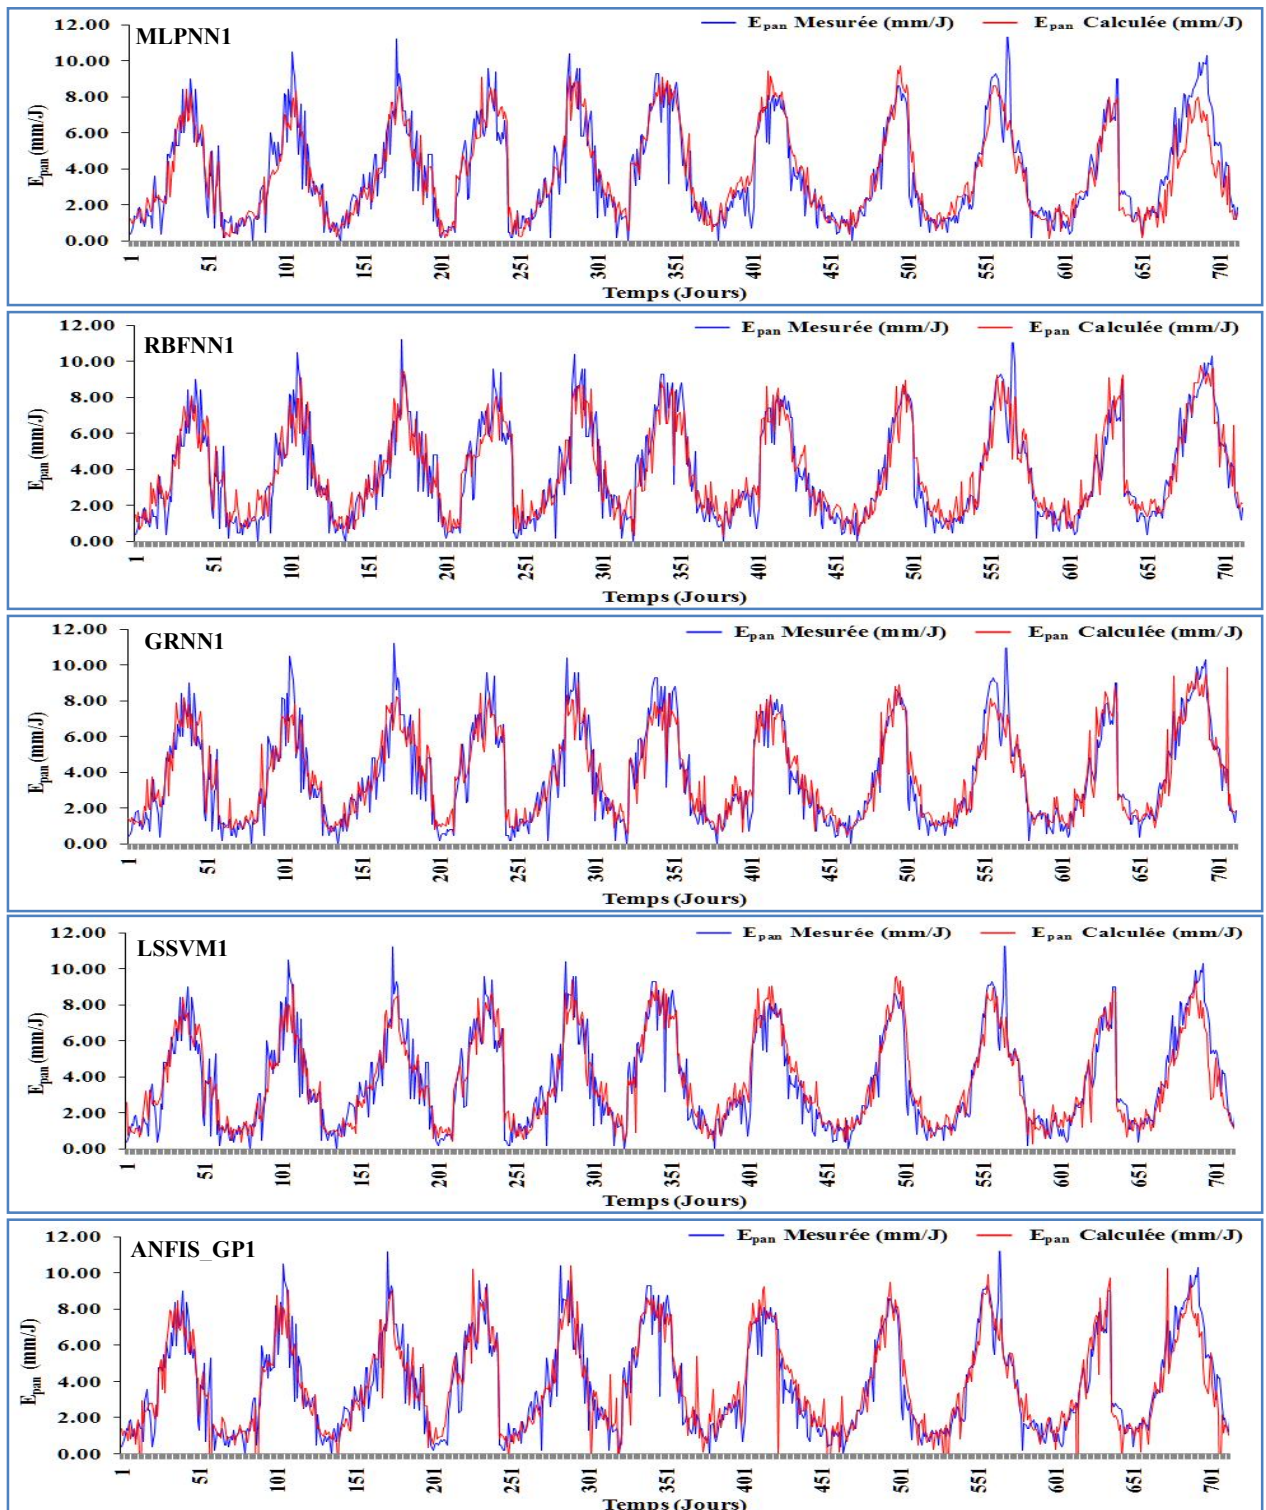
Figure IV.11. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Bouhamdane, phase de test.

Les résultats obtenus avec les modèles LSSVM représentés dans le [Tableau IV.11](#) sont légèrement supérieurs à ceux obtenus par les modèles MLPNN, et que ces derniers possèdent de très bonnes valeurs des critères de performances durant les trois phases. En phase

d'apprentissage, les meilleures performances sont obtenus avec LSSVM1 avec ($R=0.954$, $MAE=0.591mm$), les modèles LSSVM2 et LSSVM4 occupent la deuxième place avec les mêmes performances ($R=0.901$, $MAE=0.864mm$), le modèle LSSVM5 toujours occupe la 6^{ème} place avec les plus faibles performances ($R=0.859$, $MAE=0.967mm$). Les résultats de la validation et de test sont très acceptables, et les différents modèles LSSVM gardent les mêmes ordres de classement qu'en phase d'apprentissage. En effet, le coefficient de corrélation R (83.8%) est largement supérieur à 80% la valeur à partir de laquelle un modèle peut être considéré comme performant et stable.

Pour les modèles RBFNN nous avons un bon niveau de performance avec un coefficient de corrélation supérieur à 81.8% au cours de trois phases. En phase d'apprentissage, nous constatons que les meilleurs résultats sont obtenus par le modèle RBFNN1 avec ($R=0.970$, $MAE=0.497mm$), cela dû à l'influence positif de l'ajout des deux composantes du calendrier Grégorien (J et M) sur les résultats. Les modèles RBFNN2, RBFNN3, RBFNN4 et RBFNN6, donnent des résultats sensiblement proches, avec R compris entre 0.88 et 0.89, supérieurs au modèle RBFNN5, l'erreur moyenne absolue la plus élevée est obtenue par le modèle RBFNN5 avec ($MAE=1.00mm$). En phase de validation, les résultats obtenus sont moins performants qu'en phase d'apprentissage, mais ils apportent de bons performances, le modèle à six entrées RBFNN1 toujours estime mieux l' E_{pan} par rapport aux autres modèles ($R=0.954$, $MAE=0.591mm$), les valeurs de critères de performances obtenus par les modèles RBFNN2, RBFNN3, RBFNN4 et RBFNN6, sont égaux avec R supérieur à 86% et MAE inférieure à 0.99 mm, les plus faibles performances sont toujours obtenu par modèle RBFNN5 ($R=0.818$, $MAE=1.110mm$). En phase de test, on observe toujours que le modèle le plus performant est le RBFNN1 ($R=0.917$, $MAE=0.804mm$), le modèle RBFNN2, RBFNN3 et RBFNN4, occupent la deuxième place avec les mêmes performances avec un R supérieurs à 86 % et MAE inférieures à 0.99mm. Le modèle RBFNN5 à deux entrées (T_{max} , T_{min}) toujours occupe la 6^{ème} place avec les plus faibles performances ($R=0.809$, $MAE=1.008mm$). En conclusion, pour les résultats obtenus par les différents modèles RBFNN, on observe une légère dégradation par rapport à ceux obtenus par les modèles MLPNN et LSSVM, mais les résultats obtenus sont généralement satisfaisants.

Les modèles GRNN ont donnés de bonnes performances avec un R supérieur à 82.8% pour la phase d'apprentissage, la phase de validation et la phase de test. Durant la phase d'apprentissage, on note que Le modèle le plus performant est le GRNN1, avec le minimum d'erreur ($MAE=0.445mm$), le modèle GRNN2 occupe la deuxième place ($R=0.923$, $MAE=0.754mm$), les performances des modèles GRNN3 au RBFNN6 sont identiques avec R supérieur à 87.8% et MAE inférieure à 0.968mm. Les plus faibles performances correspond au modèle GRNN5 ($R=0.850$, $MAE=1.078mm$), en validation, on observe une certaine diminution des performances, le modèle GRNN1 toujours occupe la première place ($R=0.903$, $MAE=0.813mm$), les modèles GRNN2, GRNN3, GRNN4 et GRNN6, ont relativement les mêmes valeurs des critères de performances avec R supérieur à 86.5% et MAE inférieure à 1.000 mm, alors que les plus faibles performances sont toujours obtenu par le modèle GRNN5 ($R=0.826$, $MAE=1.130mm$). En phase de test, les performances des différents modèles GRNN sont légèrement supérieurs qu'en phase de validation avec R supérieur à 87.4%, le modèle GRNN1 toujours présente de meilleure performances par rapport aux autres modèles ($R=0.928$, $MAE=0.740mm$), les modèles GRNN2, GRNN3, GRNN4, et GRNN6, ont donnés des résultats très proches avec R supérieur à 87.4% et MAE inférieure à 1.027mm.






Figure IV.12. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Bouhamdane, phase de test.

Pour les modèles ANFIS_GP, en phase d'apprentissage nous remarquons que le modèle à ANFIS_GP1 produise de très bons résultats comparativement aux autres modèles ($R=0.944$, $MAE=0.657\text{mm}$), dépasse le modèle ANFIS_GP2 avec des améliorations considérables des performances en termes de R (9.9%) et MAE (23.6%). Les modèles à trois entrées ANFIS_GP3 et ANFIS_GP4 ont les mêmes performances avec $R=0.88$, et sont légèrement supérieurs aux modèles à deux entrées ANFIS_GP5 et ANFIS_GP6, le moins performant est ANFIS_GP5 ($R=0.857$, $MAE=1.033\text{mm}$). Au niveau de la phase de validation, on constate que les modèles ANFIS_GP sont moins performants comparativement à ceux qu'en phase d'apprentissage, les résultats trouvés par ces derniers sont très proches, avec des différences non significatives avec R entre 83.9% et 86.8%. Pour la phase de test on constate également que les modèles ANFIS_GP sont performants comparativement à ceux qu'en phase de validation, les résultats obtenus sont similaires, avec des différences négligeables, le R compris entre 87.6% et 89.8%. Finalement on conclut que les modèles ANFIS_GP sont moins performants à ceux obtenus par les modèles précédents MLPN, GRNN, LSSVM, RBFNN mais les résultats généralement sont acceptables.

Pour les modèles ANFIS_SC, on remarque qu'ils sont meilleurs que les modèles ANFIS_GP. En phase d'apprentissage, le modèle ANFIS_SC1 occupe la première place ($R=0.935$, $MAE=0.703\text{mm}$), les modèles ANFIS_SC2 au ANFIS_SC4 ont les mêmes performances avec un R supérieurs à 88%, et sont légèrement supérieurs aux modèles à deux entrées ANFIS_SC5 ($R=0.858$, $MAE=1.029\text{mm}$) et ANFIS_SC6 ($R=0.875$, $MAE=0.974\text{mm}$), en phase de validation on observe le même ordre de classement qu'en phase d'apprentissage, avec R compris entre 0.839 et 0.902. En phase de test, nous avons les mêmes résultats obtenus en phase d'apprentissage avec le même ordre de classement avec R varie entre 0.878 et 0.931. Pour les modèles ANFIS_FC, on remarque une certaine dégradation des performances des en phase validation par rapport aux modèles ANFIS_SC. Les meilleurs résultats sont obtenus toujours avec les modèles à six entrées durant les trois phases avec $R=0.925$, 0.881 et 0.912,

respectivement. Les résultats obtenus avec les modèles ANFIS_FC2 à ANFIS_FC6 sont très proches à ceux obtenus par les modèles ANFIS_GP au cours de trois phases

Tableau IV.12. Performances des modèles journaliers au niveau du Barrage Bouhamdane

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.936	0.966	0.938	0.699	0.904	0.947	1.144	0.827	0.925	0.959	1.032	0.759
MLPNN2	0.900	0.945	1.161	0.873	0.880	0.934	1.266	0.933	0.904	0.947	1.159	0.877
MLPNN3	0.891	0.940	1.207	0.911	0.875	0.931	1.293	0.953	0.896	0.943	1.199	0.908
MLPNN4	0.893	0.941	1.198	0.912	0.875	0.930	1.292	0.970	0.895	0.942	1.206	0.919
MLPNN5	0.865	0.924	1.339	1.013	0.843	0.911	1.437	1.065	0.878	0.931	1.295	0.983
MLPNN6	0.882	0.934	1.256	0.962	0.869	0.926	1.321	0.975	0.886	0.936	1.252	0.946
RBFNN1	0.970	0.984	0.659	0.497	0.911	0.951	1.101	0.816	0.917	0.954	1.083	0.804
RBFNN2	0.895	0.942	1.202	0.897	0.869	0.927	1.319	0.965	0.898	0.943	1.190	0.903
RBFNN3	0.883	0.935	1.261	0.950	0.865	0.924	1.336	0.992	0.890	0.938	1.232	0.938
RBFNN4	0.894	0.941	1.203	0.896	0.863	0.925	1.347	0.978	0.890	0.939	1.231	0.930
RBFNN5	0.866	0.924	1.344	1.001	0.818	0.898	1.540	1.110	0.859	0.920	1.383	1.029
RBFNN6	0.880	0.933	1.276	0.956	0.864	0.924	1.344	0.999	0.809	0.896	1.670	1.008
GRNN1	0.972	0.985	0.641	0.445	0.903	0.947	1.144	0.813	0.928	0.960	1.015	0.740
GRNN2	0.923	0.958	1.035	0.754	0.869	0.927	1.319	0.967	0.895	0.942	1.209	0.911
GRNN3	0.883	0.932	1.265	0.954	0.865	0.921	1.339	1.000	0.893	0.937	1.226	0.941
GRNN4	0.887	0.933	1.247	0.938	0.869	0.923	1.319	0.973	0.894	0.937	1.220	0.932
GRNN5	0.850	0.907	1.424	1.078	0.826	0.893	1.503	1.130	0.874	0.920	1.335	1.027
GRNN6	0.878	0.930	1.291	0.968	0.867	0.924	1.327	0.986	0.886	0.934	1.258	0.957
LSSVM1	0.954	0.976	0.810	0.591	0.901	0.946	1.155	0.848	0.923	0.959	1.041	0.770
LSSVM2	0.901	0.946	1.165	0.864	0.873	0.928	1.301	0.950	0.900	0.945	1.177	0.891
LSSVM3	0.888	0.938	1.232	0.923	0.869	0.925	1.316	0.982	0.896	0.942	1.199	0.913
LSSVM4	0.901	0.945	1.165	0.864	0.872	0.927	1.300	0.950	0.900	0.945	1.176	0.890
LSSVM5	0.859	0.920	1.372	1.025	0.838	0.906	1.453	1.087	0.878	0.930	1.292	0.986
LSSVM6	0.877	0.931	1.294	0.967	0.868	0.924	1.327	0.988	0.886	0.937	1.253	0.950
ANFIS_GP1	0.944	0.970	0.891	0.657	0.841	0.915	1.486	0.950	0.886	0.940	1.278	0.855
ANFIS_GP2	0.895	0.942	1.200	0.893	0.854	0.920	1.396	0.977	0.898	0.944	1.190	0.902
ANFIS_GP3	0.885	0.936	1.248	0.937	0.864	0.924	1.340	0.989	0.895	0.940	1.207	0.921
ANFIS_GP4	0.887	0.937	1.240	0.924	0.869	0.927	1.315	0.957	0.894	0.941	1.210	0.911
ANFIS_GP5	0.857	0.918	1.383	1.033	0.839	0.908	1.448	0.908	0.876	0.928	1.302	0.988
ANFIS_GP6	0.876	0.930	1.299	0.971	0.868	0.926	1.326	0.981	0.886	0.935	1.255	0.953
ANFIS_SC1	0.935	0.965	0.955	0.703	0.902	0.947	1.155	0.832	0.931	0.963	0.989	0.722
ANFIS_SC2	0.889	0.939	1.231	0.916	0.871	0.929	1.309	0.951	0.899	0.944	1.184	0.894
ANFIS_SC3	0.883	0.935	1.261	0.944	0.868	0.925	1.323	0.979	0.892	0.939	1.221	0.927
ANFIS_SC4	0.883	0.935	1.258	0.937	0.870	0.927	1.313	0.959	0.894	0.941	1.209	0.919
ANFIS_SC5	0.858	0.919	1.377	1.029	0.839	0.908	1.448	1.078	0.878	0.929	1.296	0.989
ANFIS_SC6	0.875	0.930	1.302	0.974	0.867	0.925	1.328	0.981	0.885	0.935	1.259	0.952
ANFIS_FC1	0.925	0.960	1.022	0.754	0.881	0.936	1.270	0.916	0.912	0.953	1.110	0.813
ANFIS_FC2	0.901	0.946	1.166	0.866	0.865	0.925	1.342	0.978	0.893	0.941	1.217	0.918
ANFIS_FC3	0.893	0.941	1.205	0.907	0.856	0.920	1.381	1.012	0.885	0.936	1.255	0.940
ANFIS_FC4	0.895	0.942	1.194	0.891	0.863	0.925	1.348	0.981	0.890	0.939	1.232	0.932
ANFIS_FC5	0.866	0.924	1.345	1.007	0.830	0.904	1.489	1.096	0.870	0.925	1.332	1.014
ANFIS_FC6	0.882	0.934	1.268	0.949	0.864	0.924	1.342	1.002	0.882	0.934	1.276	0.958

IV.4.6.1. Résultats récapitulatif des différents modèles pour barrage Bouhamdane

A partir des résultats obtenus par les différents modèles au niveau du barrage Bouhamdane, on peut conclure ce qui suit:

1. Les modèles de la combinaison N°1 donnent les meilleurs résultats par rapport aux autres.
2. La valeur de l'indice R pour la majorité des modèles à six entrées dépasse 91.2% à l'exception de modèle ANFIS_GP1 qui montre une légère détérioration de ses performances lors de la validation et test (R=0.886).
3. Le modèle ANFIS_SC1 a donné de résultats légèrement supérieurs aux autres, avec les R le plus élevées (R=0.932) et MAE la plus faible (MAE=0.722), suivi par le modèle GRNN1, MLPNN1, LSSVM1, RBFNN1 et ANFIS_FC1, respectivement. Alors que le modèle ANFIS_GP1 occupe la dernière place.
4. On note également que les modèles GRNN1 et RBFNN1 fût meilleures performances en phase d'apprentissage ($R > 0.97$), occupant la 2^{ème} et la 3^{ème} places en phase de test.
5. Pour les modèles de la combinaison 2, on note que les meilleures performances sont obtenues par le modèle MLPNN2 avec un R=0.904.
6. Pour les modèles de la combinaison 4, on observe que les meilleurs résultats sont obtenues par le modèle LSSVM4 avec (R=0.900, MAE=0.890mm).
7. Les résultats obtenus par les modèles à deux variables climatiques, les modèles utilisant les deux températures T_{max} et T_{min} sont légèrement supérieurs à ceux obtenus par les modèles utilisant la T_{max} et H% (combinaison N°5).
8. Les résultats montrent que les plus faibles performances sont obtenues avec les modèles utilisant la T_{max} et H% (combinaison N°5) durant les trois phases.

Tableau IV.13. Résultats récapitulatif des meilleurs modèles pour barrage Bouhamdane

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.925	0.959	1.032	0.759	03
RBFNN1	0.917	0.954	1.083	0.804	05
GRNN1	0.928	0.960	1.015	0.740	02
LSSVM1	0.923	0.959	1.041	0.770	04
ANFIS_GP1	0.886	0.940	1.278	0.855	07
ANFIS_SC1	0.931	0.963	0.989	0.722	01
ANFIS_FC1	0.912	0.953	1.110	0.813	06

IV.4.7. Résultats de la modélisation pour le Barrage Ain Zada

Le **Tableau IV.14** et les **figures IV.13-14** illustrent les résultats obtenus au niveau du barrage Ain Zada. Pour les modèles GRNN, les résultats obtenus montrent que le modèle GRNN1 présente la plus faible erreur (MAE=0.771mm), et plus meilleure que le modèle GRNN2 qui occupe la deuxième place, avec des différences de l'ordre de 2.6% et 17.7% en termes des R et MAE, respectivement. On note que Le modèle GRNN3 simule mieux l' E_{pan} (R=0.903, MAE=1.147mm) par rapport au GRNN4 (R=0.898, MAE=1.198mm), le modèle GRNN6 a fourni les mêmes performances que le modèle GRNN4 (R=0.875, MAE=0.974mm), alors que le modèle GRNN5 occupe la sixième place avec les plus faibles performances

($R=0.886$, $MAE=1.251mm$). En phase de validation on observe que les modèles GRNN gardent le même ordre de classement qu'en phase d'apprentissage avec une dégradation non significative des valeurs des indices de performances. La valeur de R pour les différents modèles est comprise entre 0.872 et 0.913. En phase de test les résultats obtenus sont légèrement supérieurs à ceux obtenus en phase de validation et les différents modèles GRNN toujours gardent leur ordre de classement qu'en phase d'apprentissage et validation en termes de performance, où les valeurs de R et MAE varient de (0.886 à 0.924) et (1.234 à 0.983), respectivement.


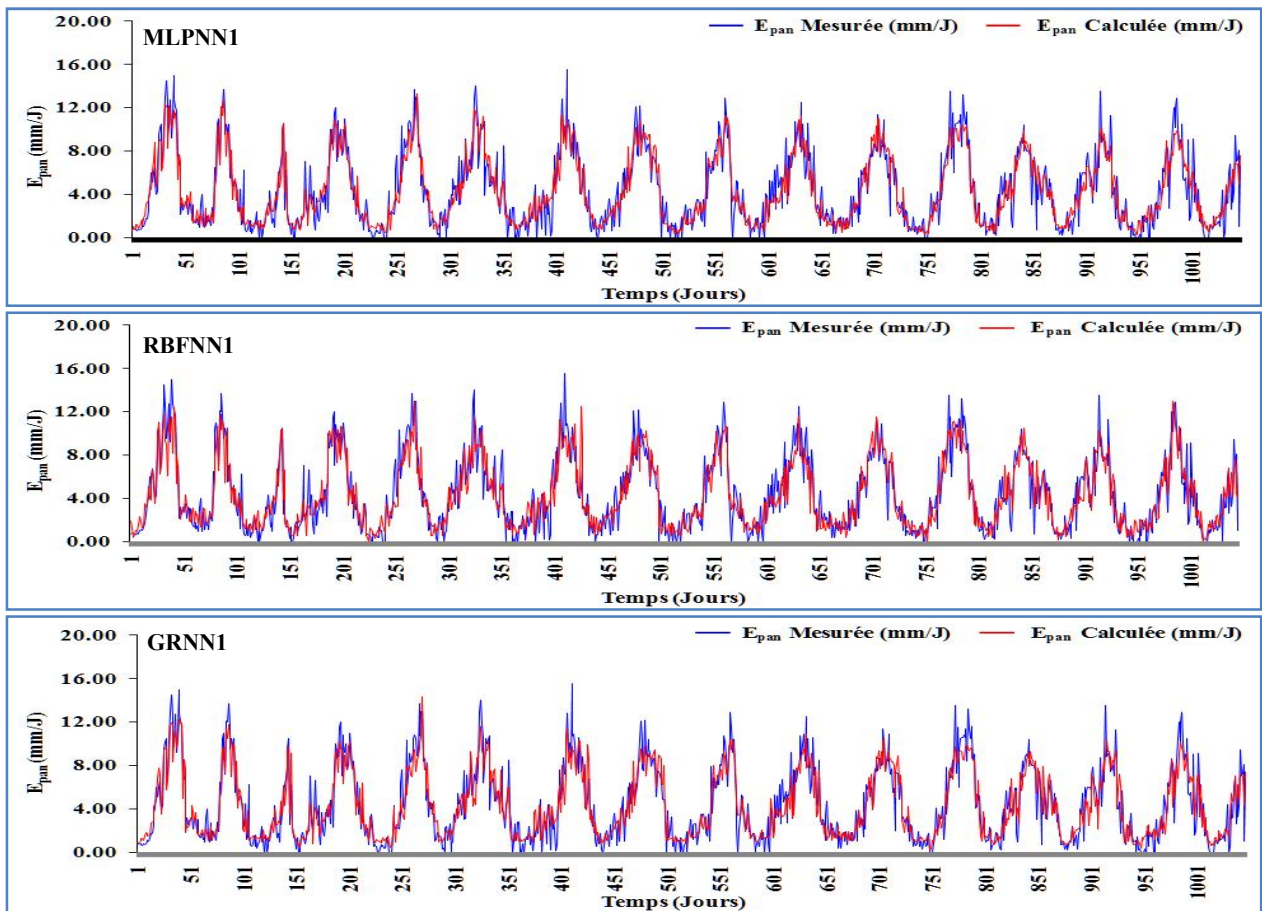


Figure IV.13. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Ain Zada, phase de test.

La majorité des modèles RBFNN donnent de très bonnes performances durant les trois phases ($R > 87.5\%$). On note que le résultat le plus satisfaisant a été obtenu avec le modèle RBFNN1, les valeurs de R sont très élevés, supérieurs à 0.906. Les performances en calage, en

validation et test sont du même ordre de grandeur, mais celles en apprentissage semblent être légèrement supérieures à celles obtenues en validation et en test. Quant aux modèles RBFNN2 et RBFNN3, ils occupent la deuxième place avec les mêmes performances au cours de chaque phase ($R=0.911$, $MAE=1.100mm$), ($R=0.897$, $MAE=1.135mm$), ($R=0.904$, $MAE=1.115mm$), respectivement, légèrement supérieurs aux modèles RBFNN4, RBFNN5 et RBFNN6. On note que les plus faibles performances sont obtenues avec les modèles à deux entrées RBFNN5. Les résultats obtenus par les modèles MLPNN sont très acceptables, en effet, les valeurs du R sont supérieures à 87.9% durant les trois phases. Le modèle MLPNN1 occupe la première place avec les meilleures performances ($R=0.931$, $MAE=0.931mm$), ($R=0.923$, $MAE=0.955mm$), ($R=0.933$, $MAE=0.926mm$), suivi par le modèle MLPNN2 avec ($R=0.913$, $MAE=1.078mm$), ($R=0.901$, $MAE=1.112mm$), ($R=0.908$, $MAE=1.088mm$), respectivement, on observe que le MLPNN4 simule mieux l' E_{pan} par rapport au modèle MLPNN3. Les modèles à deux entrées MLPNN5 et MLPNN6 occupent la dernière place avec les mêmes performances. Pour les modèles LSSVM, les résultats montrent que ces modèles sont performants en produisant des estimations proches des valeurs mesurées, avec de faibles erreurs au cours de trois périodes. On note que le modèle LSSVM1 est le plus performant par rapport aux autres modèles avec une valeur du critère R élevée ($>91.6\%$) durant les trois phases, le modèle LSSVM2 se classe deuxième. On note également que le modèle GRNN3 est meilleure que le GRNN4. Les modèles à deux entrées LSSVM5 et LSSVM6 occupent les dernières places avec des performances sensiblement proches durant chaque phase avec R qui varie de 0.879 à 0.896.



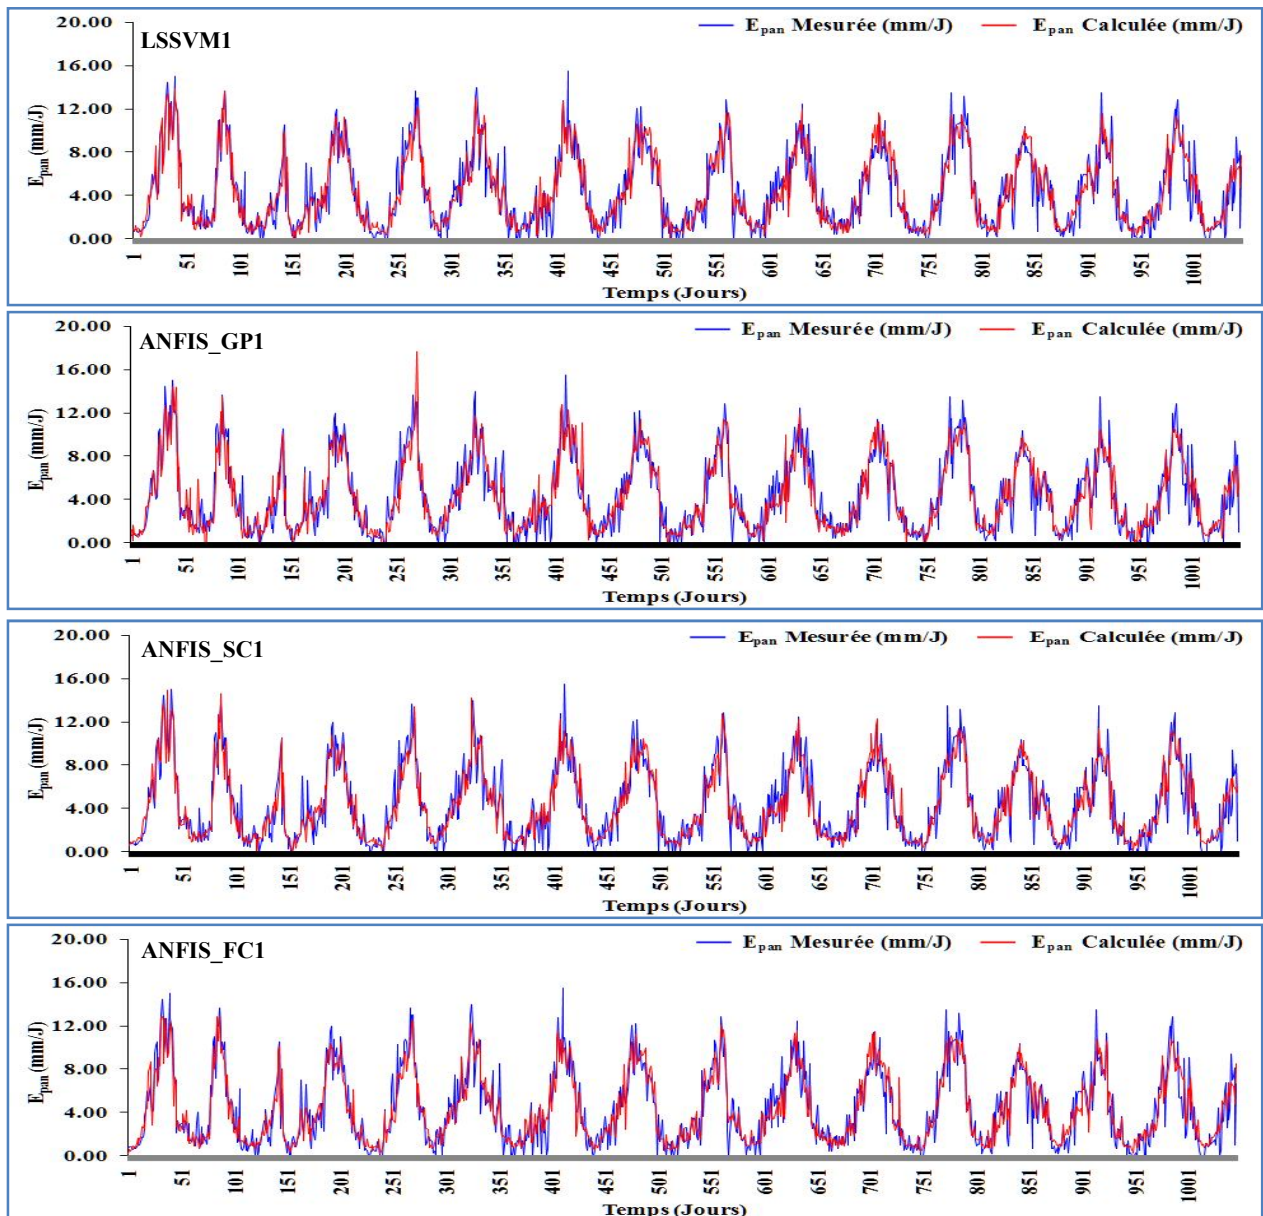


Figure IV.14. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Ain Zada, phase de test.

Les modèles ANFIS_GP produisent de très bons résultats avec une valeur du critère R supérieure à ($>87.8\%$) durant les trois phases, De ce fait le modèle le plus approprié est le modèle ANFIS_GP1, suivi de près par le modèle ANFIS_GP2. On remarque aussi que le modèle ANFIS_GP3 occupe la troisième place, légèrement supérieurs au modèle ANFIS_GP4. Le modèle ANFIS_GP6 occupe la cinquième place avec des résultats légèrement supérieurs à celle qui utilise seulement la T_{max} et $H\%$ (ANFIS_GP5. Quant aux modèles ANFIS_SC et ANFIS_FC, la comparaison montre que les résultats obtenus par ces deux derniers sont sensiblement similaires, avec des différences négligeables, légèrement supérieurs à ceux obtenus par les modèles ANFIS_GP, tout en gardant le même ordre de classement des différents modèles durant les trois phases.

Tableau IV.14. Performances des modèles journaliers au niveau du Barrage Ain Zada

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.931	0.963	1.314	0.931	0.923	0.959	1.319	0.955	0.933	0.964	1.237	0.926
MLPNN2	0.913	0.953	1.470	1.078	0.901	0.947	1.489	1.112	0.908	0.950	1.434	1.088
MLPNN3	0.904	0.948	1.536	1.137	0.894	0.942	1.538	1.158	0.896	0.944	1.523	1.155
MLPNN4	0.944	0.948	1.526	1.127	0.895	0.943	1.531	1.149	0.903	0.947	1.473	1.126
MLPNN5	0.893	0.941	1.624	1.214	0.879	0.933	1.637	1.243	0.893	0.941	1.543	1.187
MLPNN6	0.896	0.943	1.597	1.186	0.885	0.936	1.598	1.208	0.892	0.941	1.547	1.176
RBFNN1	0.954	0.976	1.081	0.808	0.906	0.949	1.452	1.074	0.912	0.951	1.411	1.056
RBFNN2	0.911	0.952	1.485	1.100	0.897	0.944	1.517	1.135	0.904	0.947	1.464	1.115
RBFNN3	0.911	0.951	1.485	1.097	0.890	0.940	1.560	1.165	0.900	0.946	1.490	1.137
RBFNN4	0.905	0.948	1.527	1.128	0.893	0.941	1.542	1.161	0.893	0.942	1.537	1.163
RBFNN5	0.894	0.941	1.611	1.197	0.875	0.931	1.660	1.252	0.890	0.940	1.561	1.192
RBFNN6	0.897	0.944	1.591	1.180	0.885	0.936	1.602	1.210	0.891	0.941	1.555	1.182
GRNN1	0.955	0.975	1.085	0.771	0.913	0.952	1.399	1.017	0.924	0.957	1.319	0.983
GRNN2	0.929	0.961	1.336	0.984	0.901	0.945	1.490	1.108	0.902	0.946	1.481	1.115
GRNN3	0.903	0.944	1.552	1.147	0.892	0.938	1.551	1.167	0.902	0.944	1.483	1.142
GRNN4	0.898	0.938	1.602	1.198	0.888	0.932	1.591	1.213	0.888	0.933	1.586	1.208
GRNN5	0.886	0.931	1.679	1.251	0.872	0.923	1.690	1.274	0.886	0.931	1.600	1.234
GRNN6	0.896	0.941	1.600	1.188	0.885	0.935	1.599	1.209	0.890	0.939	1.563	1.190
LSSVM1	0.946	0.972	1.165	0.828	0.916	0.956	1.383	1.000	0.927	0.962	1.287	0.964
LSSVM2	0.915	0.954	1.451	1.067	0.904	0.949	1.473	1.098	0.909	0.952	1.439	1.085
LSSVM3	0.906	0.949	1.518	1.116	0.895	0.943	1.528	1.141	0.906	0.950	1.453	1.109
LSSVM4	0.904	0.948	1.534	1.136	0.895	0.943	1.532	1.150	0.897	0.945	1.522	1.148
LSSVM5	0.892	0.940	1.625	1.206	0.879	0.934	1.639	1.231	0.893	0.943	1.546	1.180
LSSVM6	0.896	0.943	1.597	1.186	0.885	0.937	1.599	1.207	0.892	0.943	1.558	1.183
ANFIS_GP1	0.944	0.971	1.184	0.847	0.898	0.946	1.525	1.056	0.919	0.957	1.356	0.998
ANFIS_GP2	0.915	0.954	1.455	1.072	0.903	0.948	1.479	1.105	0.904	0.949	1.467	1.110
ANFIS_GP3	0.907	0.949	1.516	1.116	0.895	0.943	1.529	1.146	0.905	0.948	1.455	1.116
ANFIS_GP4	0.903	0.947	1.545	1.145	0.895	0.942	1.531	1.154	0.895	0.943	1.529	1.154
ANFIS_GP5	0.892	0.940	1.626	1.208	0.878	0.933	1.638	1.235	0.893	0.941	1.539	1.177
ANFIS_GP6	0.896	0.943	1.600	1.189	0.885	0.937	1.597	1.209	0.892	0.941	1.553	1.182
ANFIS_SC1	0.943	0.970	1.196	0.863	0.915	0.955	1.387	1.006	0.926	0.961	1.295	0.972
ANFIS_SC2	0.912	0.952	1.477	1.088	0.904	0.948	1.472	1.107	0.909	0.951	1.428	1.084
ANFIS_SC3	0.907	0.949	1.515	1.117	0.894	0.942	1.539	1.150	0.905	0.948	1.458	1.120
ANFIS_SC4	0.903	0.947	1.545	1.144	0.893	0.942	1.539	1.159	0.895	0.943	1.525	1.151
ANFIS_SC5	0.893	0.941	1.619	1.201	0.878	0.933	1.643	1.241	0.892	0.941	1.545	1.182
ANFIS_SC6	0.897	0.943	1.593	1.181	0.885	0.937	1.600	1.209	0.891	0.941	1.556	1.181
ANFIS_FC1	0.933	0.964	1.301	0.930	0.916	0.955	1.381	0.985	0.929	0.962	1.266	0.953
ANFIS_FC2	0.913	0.953	1.471	1.081	0.900	0.946	1.498	1.117	0.909	0.951	1.432	1.098
ANFIS_FC3	0.908	0.950	1.504	1.108	0.892	0.941	1.547	1.154	0.903	0.948	1.469	1.127
ANFIS_FC4	0.901	0.946	1.555	1.146	0.892	0.941	1.547	1.164	0.895	0.943	1.527	1.163
ANFIS_FC5	0.894	0.942	1.609	1.198	0.876	0.932	1.652	1.250	0.891	0.940	1.556	1.185
ANFIS_FC6	0.898	0.944	1.588	1.180	0.884	0.936	1.604	1.212	0.891	0.941	1.558	1.185

IV.4.7.1. Résultats récapitulatif des différents modèles pour barrage Ain Zada

Au regard des résultats obtenus par les différents modèles au niveau du barrage Ain Zada on peut conclure ce qui suit:

1. Les modèles avec six entrées (combinaison N°1) ont donné les meilleurs résultats avec un coefficient de corrélation très élevé ($R > 91.2\%$).
2. Le modèle MLPNN1 s'est avéré être le plus performant par rapport aux autres modèles avec ($R=0.933$, $d=0.0.964$, $RMSE=1.237$, $MAE=0.926$).
3. On note que les performances de différents modèles à six entrées sont très proches en phase de test avec R compris entre 0.912 et 0.933
4. Les modèles à quatre variables climatiques en entrées (combinaison 2), occupent la deuxième place durant les trois périodes avec R oscille entre 0.898 et 0.929, les meilleures performances sont obtenues par le modèle LSSVM2 avec un $R=0.901$, les autres modèles (combinaison 2) sont moins performants avec un coefficient de corrélation R varie 0.881 et 0.896.
5. Pour les modèles à trois variables climatiques (combinaison 3 et 4), sont supérieurs à ceux trouvés par les modèles utilisant deux variables climatiques comme entrées (combinaison 5 et 6).
6. Les performances des modèles à deux entrées sont relativement similaires, avec des différences négligeables.

Tableau IV.15. Résultats récapitulatif des meilleures modèles pour barrage Ain Zada

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.933	0.964	1.237	0.926	01
RBFNN1	0.912	0.951	1.411	1.056	07
GRNN1	0.924	0.957	1.319	0.983	05
LSSVM1	0.927	0.962	1.287	0.964	03
ANFIS_GP1	0.919	0.957	1.356	0.998	06
ANFIS_SC1	0.926	0.961	1.295	0.972	04
ANFIS_FC1	0.929	0.962	1.266	0.953	02

IV.5. Conclusion

L'originalité de notre travail de modélisation réside dans l'utilisation des différentes techniques d'intelligence artificielle pour la prédiction de l'évaporation au niveau des barrages réservoirs situés au Nord-est d'Algérie. L'intérêt de ces modèles réside dans leur capacité d'apprendre des relations complexes à partir de données numériques. La capacité des techniques MLPNN, GRNN, RBFNN, LSSVM, ANFIS_GP, ANFIS_FC, ANFIS_SC, pour estimer l' E_{pan} journalière en utilisant les données climatiques disponibles a été étudiée et discutée. L'étude a démontré que l'estimation de l' E_{pan} journalière est possible grâce à l'utilisation de ces modèles pour différentes zones climatiques.

1. Les modèles MLPNN1, GRNN1, RBFNN1, LSSVM1, ANFIS_FC1, ANFIS_SC1, dont les variables d'entrée comprennent les deux températures maximale et minimale de l'air (T_{max} et

T_{min}), la vitesse moyenne du vent (U_2), l'humidité relative moyenne (H%) et les deux composantes du calendrier Grégorien (J et M) ont assurés les meilleures performances au niveau de six stations météorologiques. Cela indique que toutes les données climatiques disponibles sont nécessaires pour estimer l' E_{pan} journalière pour différentes barrages réservoirs étudiés. Notons aussi que l'ajout des deux composantes du calendrier Grégorien (J et M) comme variables explicative à l'entrée des modèles paraît nécessaire pour améliorer les performances de ces dentiers.

2. Les performances du MLPNN1 utilisant les six entrées (T_{max} , T_{min} , U_2 , H%, J et M) étaient meilleures par rapport aux autres modèles au niveau des barrages Chafia, Beni Zid, El Agram, Hammam Grouz, Ain Zada. Pour le barrage Zit Emba les meilleurs résultats ont été obtenus par le modèle GRNN1, quant au barrage Bouhamdane les meilleurs résultats ont été enregistrés par le modèle RBFNN1.
3. Les modèles peuvent être intégrés en tant que module dans les modèles généraux d'analyse hydrologique.

*Chapitre V :
Modélisation de l'évaporation E_{pan} au pas de temps mensuel par les
techniques à base d'intelligence artificielle*

V.1. Introduction

Dans ce chapitre nous présentons les résultats obtenues par les différents modèles à base d'intelligences artificielle (IA) au pas de temps mensuel au niveau des sept barrages réservoirs objet de la présente étude. A l'image des résultats obtenus au pas de temps journalier, nous discuterons les performances des différents modèles en phases d'apprentissage, validation et test. Nous avons optés pour la même répartition: 60% des données pour l'apprentissage, 20% pour la validation et 20% pour le test (**Tableau V.1**).

Tableau V.1. Répartition de la base de données utilisée au pas de temps mensuels.

Station	Durée (ans)	Mois	Apprentissage	Validation	Test
Chafia	17	203	124	41	41
Beni Zid	06	72	45	15	15
Zit Emba	12	144	89	29	29
El Agram	13	147	90	30	30
Hammam Grouz	18	196	119	41	41
Bouhamdane	13	117	72	24	24
Ain Zada	17	170	103	35	35

V.2. Résultats de l'application des modèles et analyse comparative

V.2.1. Résultats de la modélisation pour le Barrage Chafia

Les résultats obtenus au niveau du barrage Chafia sont reportés dans le **Tableau V.2**, et les **Figure V.3-4**. Nous remarquons que ces modèles assurent d'excellents critères de performance en apprentissage, validation, et en test. Pour les modèles MLPNN, les résultats obtenus sont très satisfaisants. En période de calage, le R souvent supérieur à 94.9% et un RMSE ne dépassant pas 12.795mm, avec une supériorité pour le modèle MLPNN1 à cinq entrées (R=0.976 et RMSE=11.061mm), et cela dû à l'ajout de la composante du calendrier Grégorien (M) aux quatre variables climatiques. Le MLPNN1 est suivi de près par le modèle MLPNN2 (R=0.967 et RMSE=9.941mm), les plus faibles performances sont obtenus par le modèle MLPNN3 (R=0.952 et RMSE=11.816mm). En période de validation, les résultats obtenus sont généralement proches les uns des autres, le R est supérieur à 92.2%, le modèle le plus performant est le MLPNN1 (R=0.948 et RMSE= 12.939mm), le modèle MLPNN4 occupe la deuxième place avec des critères de performance élevées (R=0.940 et RMSE=13.723mm), alors que le modèle MLPNN6 occupe la dernière place (R=0.922 et RMSE=14.578mm). En période de test, le critère R dépasse 92.3% et RMSE inférieure à 12.621mm. Finalement on peut dire que les différents modèles MLPNN possèdent une bonne capacité de généralisation en particuliers le modèle MLPNN1 et le modèle MLPNN2, ce qui indique le bon fonctionnement des modèles dans l'estimation de l' E_{pan} mensuelle. A partir du **Tableau V.2**, on s'aperçoit que les performances du modèle RBFNN sont plutôt satisfaisantes avec des MAE allant de 0.841 jusqu'à 20.665mm durant les trois périodes. En apprentissage les performances de la majorité des modèles sont très élevées avec R dépasse les 97.4%. Au cours de la période de validation, on enregistre une dégradation considérable des performances des différents modèles, mais les résultats obtenus restent acceptables avec un R qui oscille entre 0.817 à 0.938, et un MAE allant de 17.167 à 20.665mm. En phase de test on note que les résultats obtenus sont meilleures à

celles obtenus en validation avec R varie entre 0.830 et 0.950, le modèle le plus performant est le modèle MLPNN4 à trois entrées (T_{max} , T_{min} , $H\%$) avec ($R=0.950$ et $MAE=11.932mm$). la comparaison entre les performances des modèles MLPNN et le modèle RBFNN montre que le modèle RBFNN est plus performant que le modèle MLPNN tant en calage, et il est moins performant en validation et en test, ce qui indique que les modèles RBFNN possèdent moins de capacité de généralisation par rapport aux modèles MLPNN.

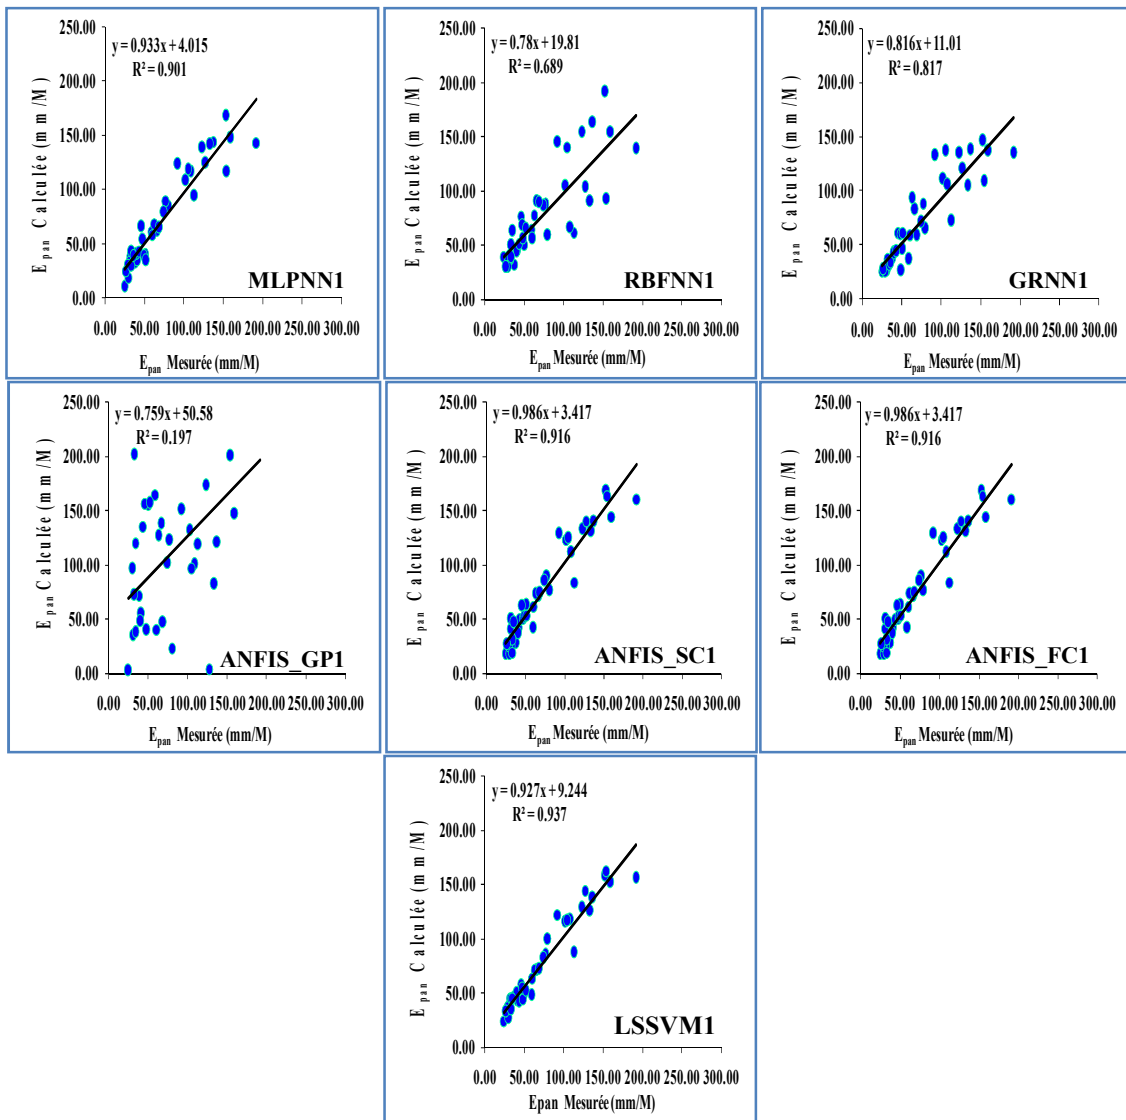


Figure V.1. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Chafia, phase de test.

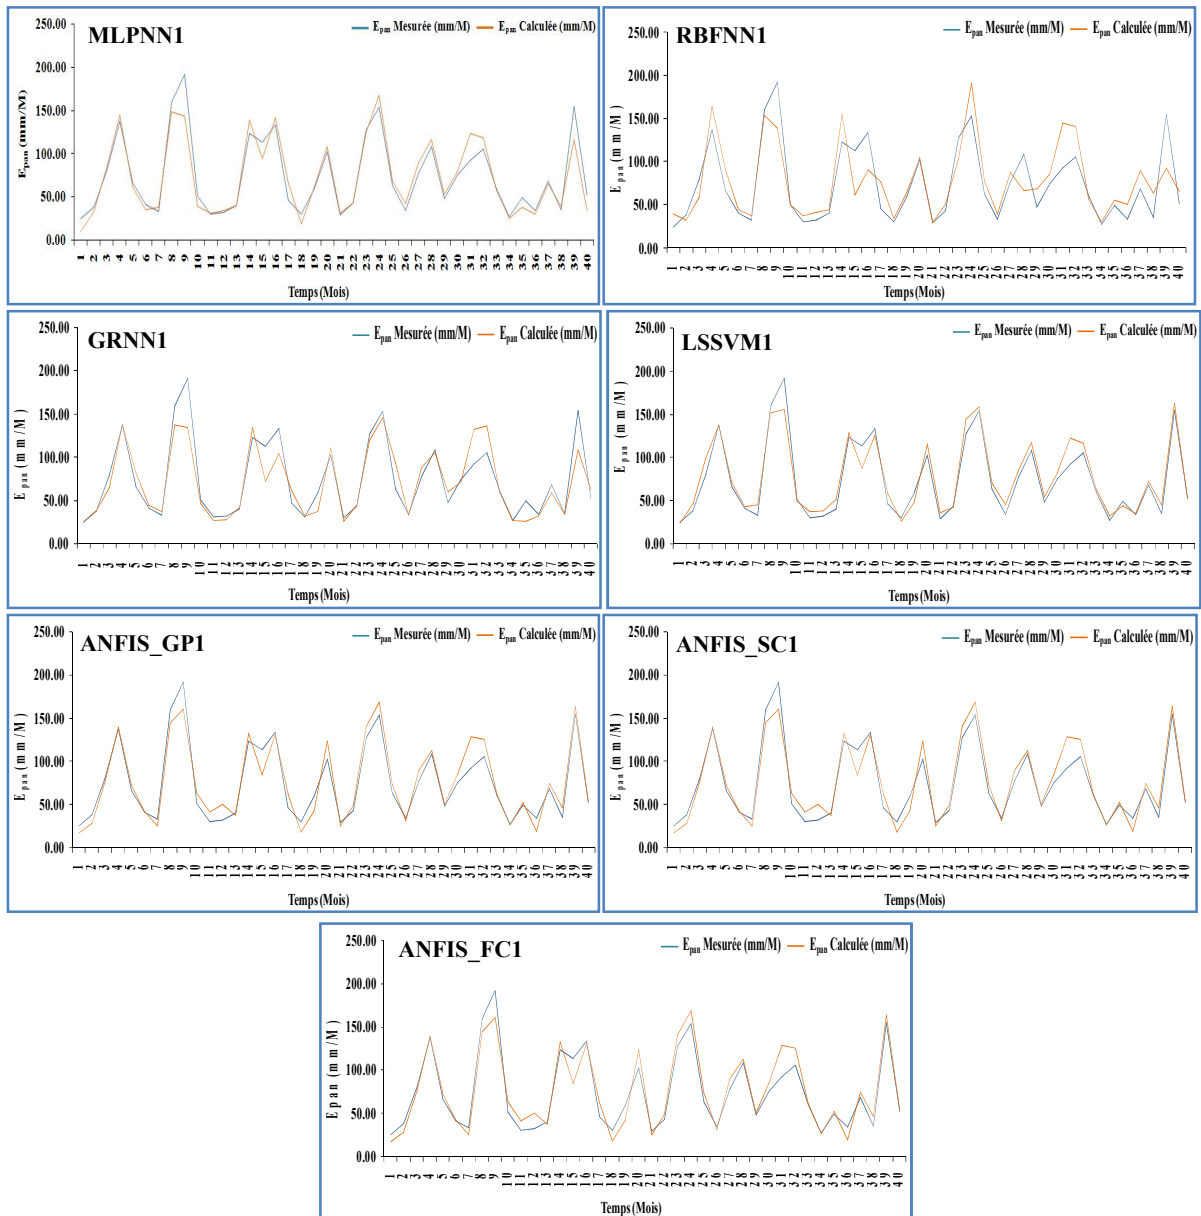


Figure V.2. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel : barrage Chafia, phase de test.

Notons que le modèle GRNN, a donné des très bons résultats comparés à ceux obtenus par les modèles RBFNN cités précédemment. En effet, la valeur du critère R est comprise entre 90% et 97.5%, soit une moyenne de 93.75%. L'erreur MAE est comprise entre 6.730mm et 15.695mm, soit une moyenne de 11.212mm au cours des trois phases. En apprentissage, le modèle à six entrées GRNN1 enregistre ainsi les meilleures performances de simulation avec un R supérieur à 97.5%, légèrement supérieur aux autres modèles. En validation, notons aussi que les résultats obtenus avec les différentes combinaisons sont généralement très proches les uns aux autres, avec des R allant de 0.912 jusqu'à 0.928, avec des différences non significatives. En phase de test, on observe que les résultats obtenus sont similaires à ceux

obtenus en phase de validation en termes de valeurs des critères de performances et ordre de classement.

Tableau V.2. Performances des modèles mensuels au niveau du Barrage Chafia

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.976	0.987	11.061	8.156	0.948	0.968	17.234	12.939	0.949	0.976	14.041	9.801
MLPNN2	0.967	0.983	12.735	9.941	0.927	0.961	19.710	15.137	0.933	0.968	16.363	12.542
MLPNN3	0.952	0.974	15.602	11.816	0.938	0.967	18.367	12.969	0.937	0.968	16.082	12.554
MLPNN4	0.949	0.972	17.334	12.795	0.940	0.969	18.421	13.723	0.956	0.977	14.332	10.548
MLPNN5	0.965	0.981	13.346	9.777	0.928	0.962	19.339	14.273	0.952	0.978	13.300	10.463
MLPNN6	0.954	0.975	15.101	11.307	0.922	0.960	20.242	14.578	0.923	0.963	17.357	12.621
RBFNN1	0.999	0.999	1.296	0.841	0.859	0.909	26.747	19.883	0.830	0.913	25.377	19.099
RBFNN2	0.975	0.987	11.106	8.254	0.893	0.938	23.239	18.197	0.925	0.963	17.135	12.159
RBFNN3	0.974	0.987	11.246	8.110	0.875	0.932	26.551	17.167	0.913	0.955	20.253	14.377
RBFNN4	0.974	0.987	11.262	8.599	0.839	0.905	29.067	18.489	0.950	0.974	15.154	11.932
RBFNN5	0.974	0.987	11.260	8.343	0.856	0.920	27.244	18.482	0.925	0.960	18.923	13.600
RBFNN6	0.975	0.987	11.106	8.571	0.817	0.901	32.211	20.665	0.847	0.911	29.145	18.196
GRNN1	0.975	0.989	10.225	6.730	0.914	0.952	21.034	15.020	0.904	0.952	19.112	12.75
GRNN2	0.959	0.976	14.655	10.414	0.923	0.956	20.135	14.842	0.929	0.962	16.805	11.436
GRNN3	0.938	0.964	17.692	12.866	0.916	0.951	21.006	15.019	0.900	0.948	19.450	13.418
GRNN4	0.942	0.965	17.233	12.645	0.928	0.959	19.550	14.274	0.939	0.965	15.896	10.738
GRNN5	0.931	0.955	19.151	13.891	0.909	0.946	21.964	16.383	0.943	0.961	16.403	11.158
GRNN6	0.921	0.953	19.863	14.125	0.912	0.948	21.559	15.695	0.907	0.951	18.813	12.887
LSSVM1	0.963	0.981	13.496	9.462	0.963	0.980	14.109	10.233	0.968	0.983	11.702	8.893
LSSVM2	0.954	0.976	15.043	10.831	0.944	0.971	17.114	12.324	0.945	0.969	15.363	11.525
LSSVM3	0.949	0.973	15.871	11.389	0.941	0.968	17.589	12.470	0.936	0.966	15.997	12.028
LSSVM4	0.945	0.971	16.438	12.182	0.947	0.972	16.632	12.156	0.957	0.974	13.965	10.827
LSSVM5	0.945	0.971	16.438	12.182	0.947	0.972	16.632	12.156	0.957	0.974	13.965	10.827
LSSVM6	0.938	0.967	17.398	12.541	0.941	0.968	17.486	13.208	0.938	0.967	15.751	11.563
ANFIS_GP1	0.997	0.998	3.572	2.118	0.435	0.521	115.27	74.988	0.444	0.599	75.971	57.227
ANFIS_GP2	0.983	0.991	9.095	6.401	0.690	0.821	43.783	31.460	0.707	0.790	51.746	32.726
ANFIS_GP3	0.962	0.980	13.705	9.879	0.906	0.948	23.724	17.583	0.934	0.968	16.901	12.719
ANFIS_GP4	0.967	0.983	12.650	9.500	0.981	0.942	25.031	18.781	0.927	0.963	18.063	12.625
ANFIS_GP5	0.967	0.983	12.650	9.500	0.891	0.942	25.031	18.781	0.927	0.963	18.063	12.625
ANFIS_GP6	0.945	0.971	16.306	11.908	0.939	0.968	18.654	14.582	0.939	0.971	15.546	10.886
ANFIS_SC1	0.973	0.986	11.514	8.380	0.918	0.954	21.506	16.645	0.899	0.944	20.443	16.509
ANFIS_SC2	0.953	0.975	15.127	11.233	0.950	0.975	16.371	11.721	0.952	0.977	13.437	10.067
ANFIS_SC3	0.950	0.974	15.587	11.418	0.943	0.971	17.505	12.274	0.947	0.975	14.170	10.854
ANFIS_SC4	0.952	0.974	15.391	11.735	0.950	0.975	16.208	11.262	0.944	0.973	14.619	11.216
ANFIS_SC5	0.952	0.974	15.391	11.735	0.950	0.975	16.208	11.262	0.944	0.973	14.619	11.216
ANFIS_SC6	0.944	0.970	16.506	12.056	0.941	0.969	18.385	14.049	0.946	0.974	14.716	10.459
ANFIS_FC1	0.967	0.983	12.720	9.034	0.958	0.979	15.068	11.209	0.957	0.978	13.427	10.538
ANFIS_FC2	0.961	0.980	13.772	9.694	0.942	0.970	18.271	13.253	0.930	0.967	16.632	11.376
ANFIS_FC3	0.958	0.978	14.398	10.647	0.934	0.966	19.314	14.072	0.927	0.965	16.918	12.709
ANFIS_FC4	0.959	0.979	14.131	10.577	0.939	0.968	18.880	13.874	0.926	0.965	17.005	11.752
ANFIS_FC5	0.959	0.979	14.131	10.577	0.939	0.968	18.880	13.874	0.926	0.965	17.005	11.752
ANFIS_FC6	0.951	0.974	15.485	11.591	0.907	0.951	23.271	16.743	0.918	0.960	18.235	13.267

Les modèles LSSVM ont donnés d'excellents résultats comparés à celles obtenus par les MLPNN, RBFNN et GRNN, avec des R souvent supérieure à 93.8% pendant les trois périodes. En phase de calage, on note que le modèle LSSVM1 toujours occupe la première place avec ($R=0.963$, $MAE=9.462\text{mm}$), les performances fournis par les modèles LSSVM2& LSSVM6 sont sensiblement proches avec R compris entre 0.938 et 0.954. En phase de validation, on note que les meilleurs résultats sont toujours enregistrés avec le modèle à six entrées ($R=0.963$, $MAE=10.223\text{mm}$), les autres modèles ont les mêmes performances avec $R=0.94$. Les valeurs des critères de performances en période de test sont similaires à celles obtenus en phase de calage et validation. Finalement on peut conclure que le modèle LSSVM est robuste et performant, et permet d'estimer l' E_{pan} avec une bonne précision.

Les modèle ANFIS_GP donnent de résultats qui diffèrent selon le nombre d'entrées. En phase d'apprentissage, les valeurs de critères de performances sont très élevées avec ($R > 94.5\%$) et ($d > 97.1\%$). le modèle ANFIS_GP1 est le plus performants par rapport aux autres modèles avec ($R=0.997$, $MAE=2.118\text{mm}$). En validation, les résultats obtenus avec les modèles à quatre entrées et cinq entrées ANFIS_GP1 et ANFIS_GP2 sont médiocres avec un R inférieur à 0.435 et 0.690 respectivement. Les meilleures résultats sont obtenus avec le modèle à deux entrées ANFIS_GP6 utilisant les (T_{max} , T_{min}), avec ($R=0.939$). Les résultats obtenus en phase de test confirment ceux obtenus en validation, on note que les performances des modèles ANFIS_GP1 et ANFIS_GP2 sont médiocres avec un R ne dépassant pas les 44.4% et 70.7% respectivement. Les autres modèles donnent des performances moyennes très proches avec R compris entre 0.927 et 0.939. On peut donc conclure que les modèles ANFIS_GP1 et ANFIS_GP2 au pas de temps mensuel sont à écarter.

Pour les différents modèles ANFIS_SC, nous obtenant des résultats très acceptables par rapport à celle obtenus par les modèles ANFIS_GP durant les trois phases. En effet, en phase d'apprentissage le critère R souvent supérieur à 94.4% et l'erreur MAE est inférieur à 12.056mm. En phase de validation et de test les résultats obtenus avec les différents modèles ANFIS_SC sont similaire à ceux obtenus en apprentissage avec R qui varie entre 0.941 et 0.952, sauf pour le modèle ANFIS_SC1 pour lequel on note une légère dégradation des performances en phase de validation et test. Notons aussi que les modèles ANFIS_FC ont donnés de très bons résultats. En effet, la valeur R dépasse les 90.7% durant les trois phases. Le modèle ANFIS_FC1 assure les meilleures performances pour les trois phases, en période d'apprentissage, de validation et test, légèrement supérieur au modèle ANFIS_FC2. Les plus faibles performances ont été obtenues avec le modèle ANFIS_FC2, respectivement.

V.2.1.1. Résultats récapitulatif des différents modèles pour barrage Chafia

Au vu des résultats obtenus par les différents modèles au niveau du barrage Chafia on peut conclure ce qui suit:

9. La majorité des modèles avec les différentes combinaisons donnent d'excellent résultats durant les trois phases avec R varient entre 81.7% et 99.9%, sauf les deux modèles ANFIS_GP1 et ANFIS_GP2 qui ont donné de mauvais résultats en validation et test, avec R inférieur à 70%.

10. Le modèle à cinq entrées LSSVM1 a donné les meilleurs résultats par rapport autres modèles, suivi par ANFIS_FC1, MLPNN1, GRNN1, ANFIS_SC1 et RBFNN1 respectivement alors que le modèle ANFIS_GP1 a fourni les plus faibles résultats.
11. On constate aussi que les valeurs de critères de performances sont proches pour les différents modèles durant chaque phase.

Tableau V.3. Résultats récapitulatif des meilleures modèles pour barrage Chafia

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.949	0.976	14.041	9.801	03
RBFNN1	0.830	0.913	25.377	19.099	06
GRNN1	0.904	0.952	19.112	12.75	04
LSSVM1	0.968	0.983	11.702	8.893	01
ANFIS_GP1	0.444	0.599	75.971	57.227	07
ANFIS_SC1	0.899	0.944	20.443	16.509	05
ANFIS_FC1	0.957	0.978	13.427	10.538	02

V.2.2. Résultats de la modélisation pour le Barrage Beni Zid

Les résultats en phases d'apprentissage, de validation et de test au niveau du barrage Beni Zid sont présentés dans le **Tableau V.4**, et illustrés sur les **Figure V.3-4**. Notons que les différents modèles expriment d'excellentes critères de performance, en particuliers les modèles LSSVM et ANFIS_FC appliqués avec cinq entrées. Pour les modèles GRNN, l'analyse des résultats indique une qualité élevée d'estimation de l' E_{pan} mensuelle. En apprentissage, le R souvent dépasse 95.2% et un MAE inférieur à 20.811mm, avec une amélioration remarquable pour le modèle à cinq entrées GRNN1 avec (R=0.995 et MAE=5.296mm), ce qui confirme l'importance de l'ajout de la composante du calendrier Grégorien (M) aux quatre variables climatiques (T_{max} , T_{min} , U_2 , $H\%$), suivi par le modèle GRNN2 avec une légère baisse de performance de 0.7% et 0.5% en termes de R et d, alors que pour les modèles à deux et trois entrées la valeur de R est comprise entre 95.2% et 97.6%. En phase de validation, on note une légère dégradation des valeurs des critères de performances, le modèle GRNN1 toujours occupe la première place avec (R=0.941 et MAE=17.087mm), suivi par le modèle GRNN2 avec (R=0.934 et MAE= 18.233mm), les plus faibles performances ont été fourni par le modèle GRNN6 avec (R=0.883 et MAE=25.665mm). En phase de test, on note également que les différents modèles possèdent des performances relativement supérieures à ceux obtenus en phase de validation. En effet les valeurs de R oscillent entre 92% et 96.4%. Donc on peut conclure que toutes les architectures donnent de meilleurs critères de performances conformément généralement supérieurs à 80% pour le coefficient de corrélation.

Notons que les critères de performance des modèles MLPNN pour l'ensemble d'apprentissage, de validation et de test sont relativement très acceptables et du même ordre de grandeur. En effet, les valeurs de R sont comprises entre 88.1% et 98.3%. L'erreur MAE est comprise entre 10.672mm et 26.485mm. En apprentissage, on note que les meilleures performances ont été enregistrées avec le modèle à quatre entrées avec R=0.983. Pour les autres modèles la valeur de R est comprise entre 0.909 et 0.983. En validation, notons aussi que les résultats obtenus avec les différentes architectures sont généralement similaires, avec

des R allant de 0.902 jusqu'à 0.955, avec des différences non significatives. Les performances en phase de test sont égales ou légèrement supérieures aux performances initialement obtenues en validation, avec R varie de 0.881 jusqu'à 0.945. Finalement on peut dire que le modèle MLPNN à travers les différentes combinaisons apporte une bonne qualité de performance vis-à-vis la modélisation de l' E_{pan} mensuelle.

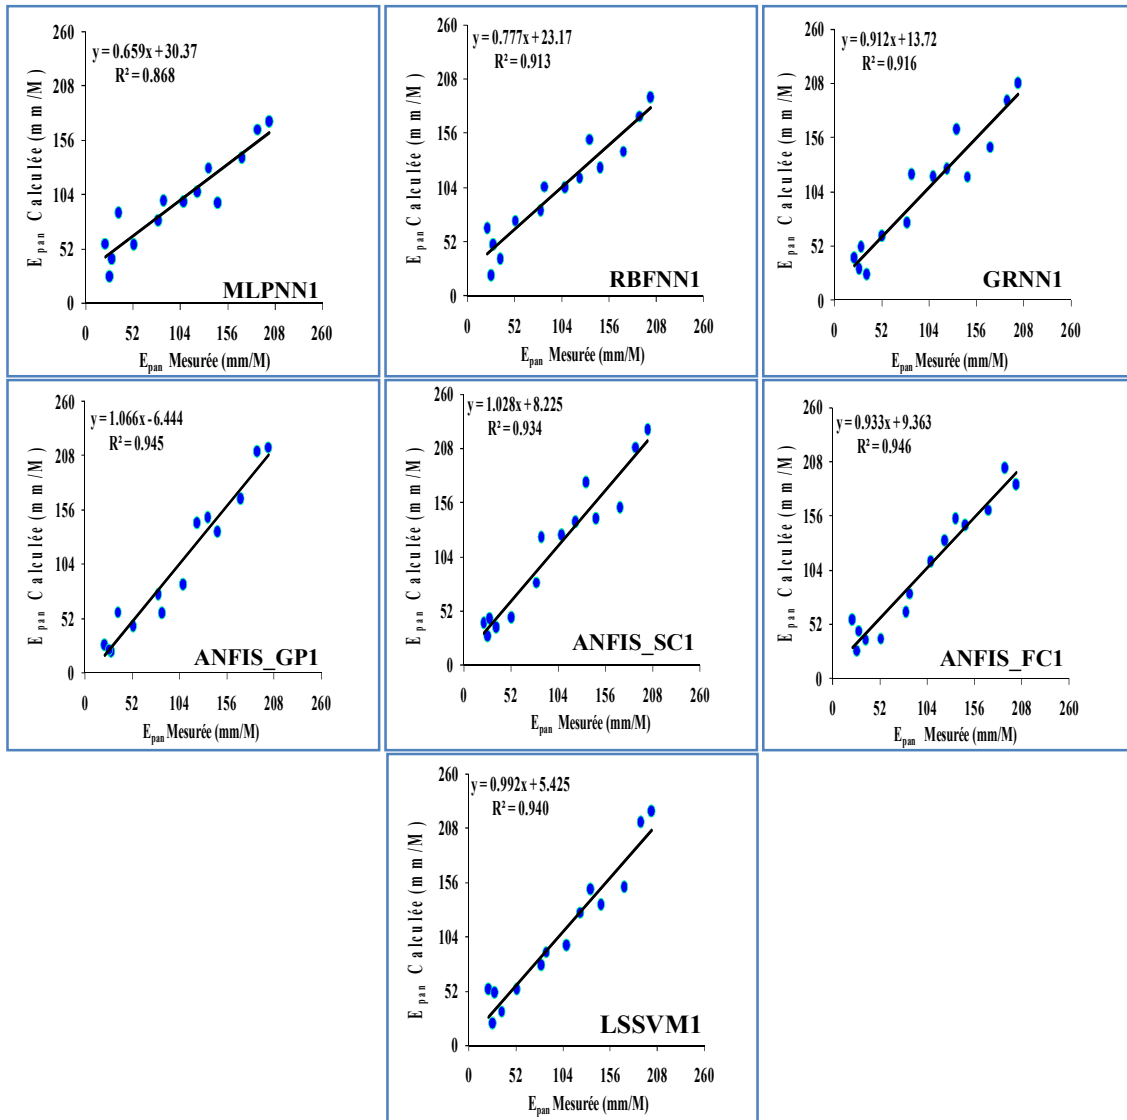


Figure V.3. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Beni Zid, phase de test.

Au vu des valeurs des critères de performance consignées dans le [Tableau V.3](#), nous remarquons que les performances des différents modèles RBFNN varient d'une phase à une autre et varient significativement selon le nombre de variables d'entrée utilisé. En phase d'apprentissage, on note que la valeur du coefficient de corrélation est supérieure à 98.9% pour la majorité des modèles RBFNN, alors qu'en phase de validation on note aussi une dégradation significative des performances de ces modèles avec un R qui oscille entre 0.786 à 0.866, et

un MAE allant de 21.983mm à 33.274mm, le meilleur résultat est celui de RBFNN1 avec ($R=0.886$ et $MAE=24.224mm$), et les plus faibles performances ont été obtenus avec le modèle RBFNN3 avec ($R=0.786$ et $MAE=40.158mm$). Les résultats obtenus en phase de test relèvent une amélioration des performances des différents modèles par rapport à ceux obtenus en phase de validation avec un R entre 0.859 à 955, et un MAE varie de 16.188 à 26.256mm, et les meilleures performances toujours enregistré avec le modèle RBFNN1 avec ($R=0.955$ et $MAE=16.188mm$). Finalement on peut conclure que le modèle RBFNN est moins performant par rapport aux modèles GRNN et MLPNN, et que la majorité des modèles RBFNN possède une faible capacité de généralisation.

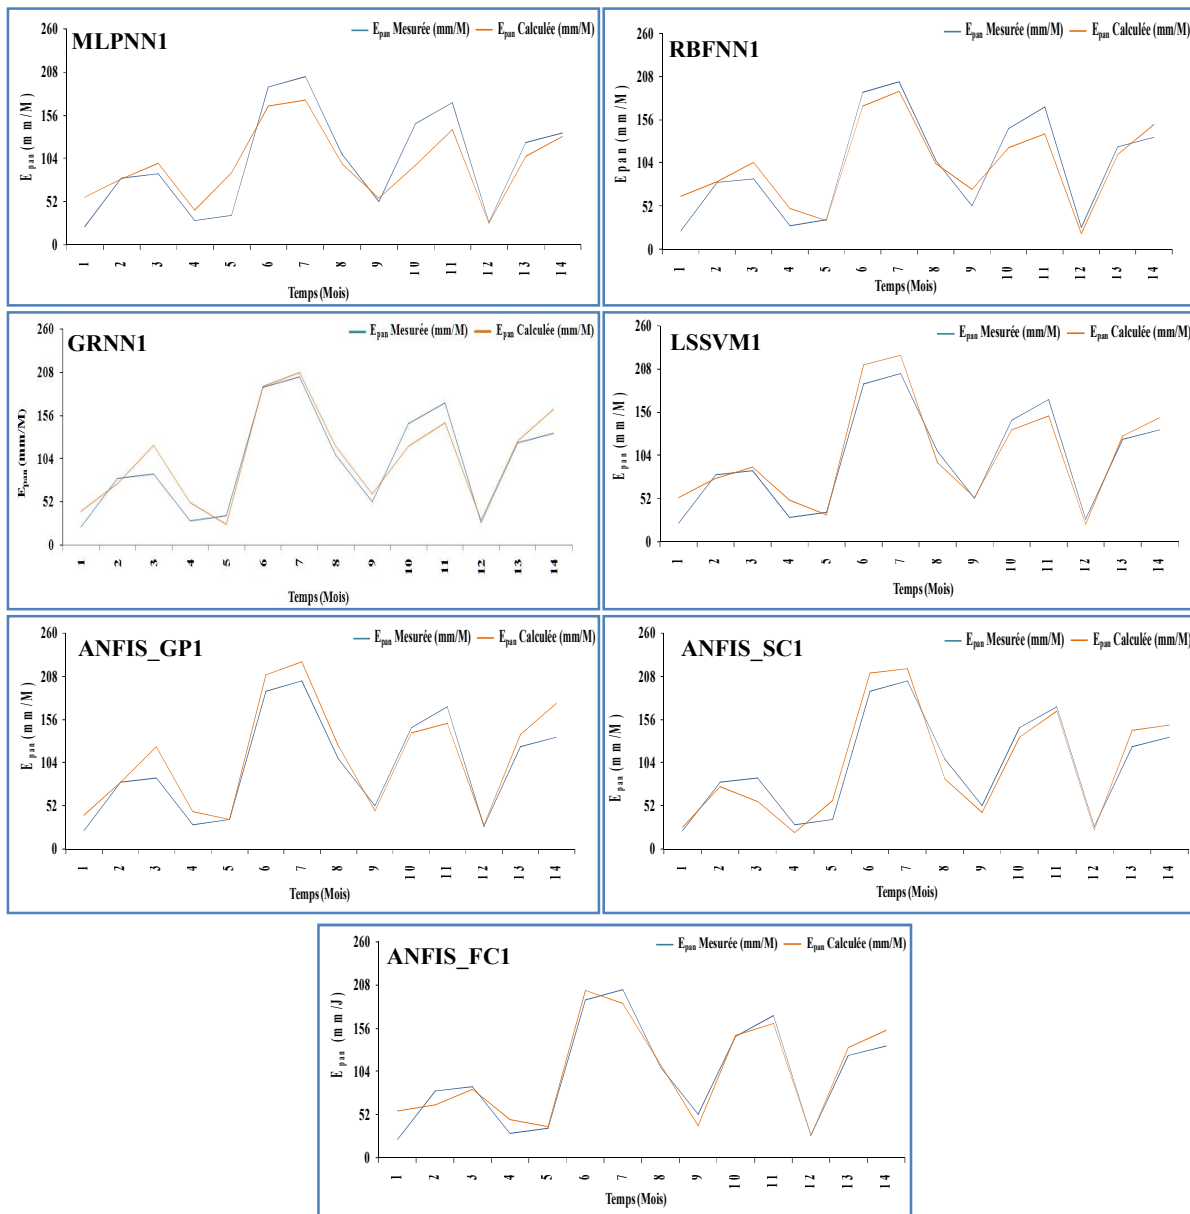


Figure V.4. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Beni Zid, phase de test.

Tableau V.4. Performances des modèles mensuels au niveau du Barrage Beni Zid

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.955	0.965	25.164	20.362	0.931	0.957	26.133	20.762	0.932	0.941	26.013	20.277
MLPNN2	0.983	0.991	13.951	10.672	0.902	0.940	28.925	21.261	0.927	0.965	23.033	17.430
MLPNN3	0.973	0.985	17.920	14.125	0.943	0.972	22.087	20.183	0.911	0.953	25.002	19.668
MLPNN4	0.983	0.989	16.237	13.226	0.926	0.958	29.236	24.415	0.945	0.964	24.343	20.136
MLPNN5	0.982	0.988	15.762	12.751	0.925	0.961	24.696	19.011	0.948	0.971	19.989	16.620
MLPNN6	0.909	0.947	34.733	26.485	0.955	0.977	19.279	14.252	0.881	0.940	30.405	22.364
RBFNN1	0.995	0.997	7.260	5.260	0.866	0.893	35.643	24.224	0.955	0.968	19.741	16.188
RBFNN2	0.994	0.997	7.569	5.149	0.823	0.907	36.625	21.983	0.927	0.960	22.840	17.360
RBFNN3	0.989	0.994	10.731	8.341	0.786	0.888	40.158	25.402	0.925	0.962	23.197	18.060
RBFNN4	0.990	0.995	10.544	7.057	0.882	0.937	34.489	29.978	0.916	0.959	24.841	19.176
RBFNN5	0.991	0.995	10.079	7.086	0.789	0.890	40.888	33.274	0.908	0.943	26.222	19.066
RBFNN6	0.989	0.994	10.634	7.382	0.864	0.931	34.210	27.469	0.859	0.927	30.937	26.251
GRNN1	0.995	0.998	7.203	5.296	0.941	0.971	21.711	17.087	0.957	0.977	18.111	14.638
GRNN2	0.988	0.993	11.866	9.659	0.934	0.968	22.983	18.233	0.964	0.977	17.547	13.068
GRNN3	0.974	0.985	17.492	14.091	0.905	0.953	27.470	21.793	0.920	0.953	24.671	20.389
GRNN4	0.976	0.987	16.412	13.992	0.914	0.958	26.118	21.508	0.955	0.976	18.070	14.850
GRNN5	0.969	0.981	19.142	16.236	0.911	0.955	26.698	21.536	0.959	0.976	17.852	14.470
GRNN6	0.952	0.972	23.395	20.811	0.883	0.939	30.280	25.665	0.922	0.958	23.485	20.975
LSSVM1	0.989	0.994	10.950	9.258	0.981	0.991	12.443	10.225	0.970	0.983	15.711	12.757
LSSVM2	0.979	0.989	15.075	12.916	0.953	0.978	19.760	16.230	0.955	0.977	18.886	15.330
LSSVM3	0.961	0.979	20.725	18.018	0.915	0.955	26.969	21.465	0.937	0.962	22.636	18.243
LSSVM4	0.975	0.987	16.574	13.843	0.953	0.977	19.970	16.383	0.958	0.978	18.514	16.229
LSSVM5	0.968	0.983	18.754	15.844	0.940	0.971	22.331	17.157	0.955	0.977	19.223	14.833
LSSVM6	0.954	0.975	22.382	19.403	0.922	0.955	27.033	21.023	0.931	0.959	23.650	20.447
ANFIS_GP1	1.000	1.000	0.0005	0.0003	0.936	0.961	25.482	15.929	0.972	0.984	15.924	13.773
ANFIS_GP2	1.000	1.000	0.0008	0.0006	0.921	0.961	25.664	19.772	0.868	0.928	31.983	23.413
ANFIS_GP3	1.000	1.000	0.042	0.026	0.802	0.575	172.71	95.954	0.763	0.861	51.815	44.055
ANFIS_GP4	1.000	1.000	0.009	0.006	0.858	0.785	90.206	69.635	0.789	0.855	56.804	44.608
ANFIS_GP5	0.985	0.992	12.632	9.047	0.908	0.947	32.257	27.087	0.928	0.963	23.886	17.160
ANFIS_GP6	0.993	0.996	8.317	5.994	0.839	0.920	36.517	29.605	0.459	0.657	79.688	50.629
ANFIS_SC1	1.000	1.000	0.000	0.000	0.947	0.973	21.266	16.229	0.966	0.974	19.919	15.786
ANFIS_SC2	1.000	1.000	0.000	0.000	0.942	0.972	22.581	19.208	0.932	0.964	23.016	16.382
ANFIS_SC3	1.000	1.000	0.0003	0.0001	0.859	0.919	36.372	26.556	0.917	0.957	25.113	20.440
ANFIS_SC4	1.000	1.000	0.0002	0.0001	0.906	0.953	29.152	25.931	0.948	0.973	20.336	14.710
ANFIS_SC5	1.000	1.000	0.015	0.009	0.860	0.920	37.386	28.170	0.850	0.905	39.088	27.938
ANFIS_SC6	0.964	0.981	19.730	16.817	0.936	0.965	23.442	19.384	0.926	0.958	23.713	19.266
ANFIS_FC1	0.993	0.997	8.255	6.398	0.986	0.993	11.410	10.531	0.972	0.986	14.265	11.166
ANFIS_FC2	0.985	0.992	12.714	10.074	0.911	0.957	27.113	21.348	0.962	0.978	17.603	14.267
ANFIS_FC3	0.973	0.986	17.246	14.422	0.904	0.954	27.797	24.510	0.916	0.956	24.230	19.706
ANFIS_FC4	0.978	0.988	15.644	12.437	0.912	0.958	26.976	21.441	0.955	0.977	18.139	15.367
ANFIS_FC5	0.973	0.986	17.294	13.762	0.916	0.959	26.506	20.456	0.972	0.985	14.571	11.240
ANFIS_FC6	0.965	0.982	19.554	16.630	0.932	0.962	24.365	20.161	0.924	0.957	23.856	19.318

Pour le modèle ANFIS_GP, notons des différences significatives entre les valeurs de critères de performances qui varient d'un modèle à un autre quand on passe de la phase de

calage à la phase de validation et de test. En apprentissage le R est relativement élevé, souvent supérieur à (98.5%). En phase de validation, on remarque que les meilleures performances des modèles ANFIS_GP est sont obtenus avec ANFIS_GP1 dont les variables d'entrées sont (T_{max} , T_{min} , U_2 , $H\%$, M) avec ($R=0.936$ et $MAE=15.929$ mm), pour les autres modèle la valeur de R varie entre 0.802 et 0.921, pour la partie test les meilleures performances sont toujours fourni par le modèle à cinq entrées ANFIS_GP1 avec ($R=0.972$ et $MAE=13.773$ mm), dont les variables d'entrées sont (T_{max} , T_{min} , U_2 , $H\%$, M), et les plus faibles performances ont été obtenus avec le modèle ANFIS_GP6 avec ($R=0.459$ et $MAE= 50.629$ mm). Dès lors, on pourrait dire que seulement le modèle à cinq entrées ANFIS_GP1 assure une bonne capacité de généralisation par rapport aux autres modèles.

Les résultats présentés au **Tableau V.3** obtenus par le modèle ANFIS_SC sont très acceptables avec MAE varie de 0.000 mm à 28.170 mm durant les trois phases. Pour la partie apprentissage la valeur de MAE ne dépasse pas 16.817mm pour la majorité des modèles, en validation, on note une légère baisse de performances, non significatives pour certains modèles, le modèle à cinq entrées toujours occupe la première place avec ($R=0.947$ et $MAE=16.229$ mm), suivi par le modèle à quatre entrées avec ($R=942$ et $MAE=19.208$ mm), en phase de test les résultats trouvés sont similaires à ceux obtenus en validation. Donc, la comparaison des différents modèles ANFIS_SC indique que les deux modèles ANFIS_SC1 et ANFIS_SC2 ont montré un bon accord entre les valeurs des indices de performances au cours de trois périodes, ce qui indique une fiabilité élevée de ces modèles au niveau du barrage Beni Zid.

D'après le **Tableau V.3**, on remarque une nette amélioration de la modélisation l' E_{pan} mensuelle par le modèle ANFIS_FC par apport aux deux modèles ANFIS_SC et ANFIS_GP. En effet, la valeur de R est supérieure à 90.4% pour les trois phases. Ce qui indique le bon fonctionnement de ce modèle, en particulier le modèle à cinq entrées ANFIS_FC1 qui assure une bonne concordance entre les valeurs de critère de performances au cours de trois périodes avec ($R=0.993$ et $MAE=6.398$ mm), ($R=0.986$ et $MAE=10.531$ mm), ($R=0.972$ et $MAE=11.166$ mm), respectivement. Notons que Les résultats fourni par le modèle LSSVM, présentés au **Tableau V.3** sont très satisfaisants, et que toutes les architectures donnent de meilleures critères de performances, avec une valeur de R varie entre 0.915 et 0.989 durant les trois phases, où nous avons montré que le meilleur résultat est enregistré avec le modèle utilisant toutes les variables d'entrée (LSSVM1), avec ($R=0.989$ et $MAE= 9.258$ mm), ($R=981$ et $MAE= 5.10.225$ mm), ($R=0.970$ et $MAE=12.757$ mm), respectivement. On peut conclure que le modèle LSSVM est recommandé pour la modélisation l' E_{pan} mensuelle au niveau du barrage Beni Zid.

V.2.2.1.Résultats récapitulatif des différents modèles pour barrage Beni Zid

D'après les résultats obtenus par les différents modèles au niveau du barrage Beni Zid on peut conclure ce qui suit (**Tableau V.5**):

1. Les modèles à cinq entrées apportent d'excellentes performances avec R souvent supérieur à 93% en phase de test.
2. Les meilleurs résultats ont été enregistrés avec les modèles utilisant toutes les variables d'entrée (combinaison N°1) durant la phase de validation avec R varient entre 86.6% et

98.6%, sauf le modèle MLPNN, où les meilleures performances ont été fournies par le modèle à quatre variables climatiques MLPNN2 avec $R=94.3\%$.

3. La majorité des modèles de la (combinaison N°1) donne des valeurs de R souvent supérieures à 95.5% durant la phase d'apprentissage.
4. Les plus faibles performances ont été obtenues avec le modèle ANFIS_GP6 45.9% durant la période de test.

Tableau V.5. Résultats récapitulatif des meilleurs modèles pour barrage Beni Zid

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.932	0.941	26.013	20.277	07
RBFNN1	0.955	0.968	19.741	16.188	06
GRNN1	0.957	0.977	18.111	14.638	05
LSSVM1	0.970	0.983	15.711	12.757	03
ANFIS_GP1	0.972	0.984	15.924	13.773	02
ANFIS_SC1	0.966	0.974	19.919	15.786	04
ANFIS_FC1	0.972	0.986	14.265	11.166	01

V.2.3. Résultats de la modélisation pour le Barrage Zit Emba

Le **Tableau V.6** et les **Figures V.5-6** montrent les résultats obtenus au niveau du barrage Zit Emba par les différents modèles. Pour les modèles LSSVM, les résultats obtenus sont très satisfaisants. En période d'apprentissage l'erreur relative a indiqué la supériorité du modèle utilisant cinq variables d'entrée (c'est-à-dire le modèle LSSVM1), avec $MAE=22.870$. Quant aux autres architectures les résultats obtenus sont très proches avec R varie de 0.886 à 0.905. En validation on note une amélioration des performances des différents modèles par rapport à la phase de d'apprentissage, avec R qui oscille entre 0.919 et 0.941, et que les meilleures performances sont toujours fournies par le modèle à cinq entrées (LSSVM1) avec ($R=0.941$ et $MAE=33.601mm$), et le modèle le moins performant est celui à deux entrées LSSVM5 avec ($R=0.919$ et $MAE=37.984mm$). En phase de test, on observe que les résultats obtenus sont de même ordre de grandeur qu'en phase d'apprentissage. Sur la base des résultats, la précision de prédiction de l'approche LSSVM1 était significativement meilleure que les autres modèles. Par comparaison, les modèles RBFNN sont moins performants par rapport aux modèles LSSVM durant les trois périodes, mais les résultats restent acceptables. La plus faible valeur de R est supérieure à 73%. En apprentissage, la valeur de R est relativement élevée, varie entre 0.921 et 0.977. En validation on note une dégradation significative des valeurs de critère de performances. En effet la meilleure valeur de R ne dépasse pas 91% pour tous les modèles, en phase de test, la comparaison a révélé que les résultats obtenus sont similaires qu'en phase de validation. Donc on peut conclure que le modèle RBFNN possède moins de capacité de généralisation par rapport au modèle LSSVM, et les meilleures performances ont été enregistrées avec le modèle à trois entrées RBFNN3 avec ($R=0.951$ et $MAE=20.772mm$), ($R=0.910$ et $MAE=38.031mm$), ($R=0.881$ et $MAE=26.682mm$), respectivement. Les résultats obtenus par les modèles MLPNN étaient relativement similaires aux résultats obtenus avec les LSSVM durant les trois phases. En apprentissage, on note que le modèle proposé MLPNN1 qui employait cinq paramètres d'entrée avait la plus faible RMSE et MAE, et le R le plus élevé ($R=0.940$, $RMSE=29.773$ et $MAE=22.854mm$). En validation on note une légère augmentation

des performances des modèles MLPNN, et les meilleurs résultats sont toujours obtenus par le modèle à cinq entrées avec ($R=0.955$ et $MAE=29.918mm$), en phase de test, on note également que le modèle à cinq entrée MLPNN1 est le plus performant comparé aux autres modèles avec ($R=0.948$ et $MAE=19.786mm$).

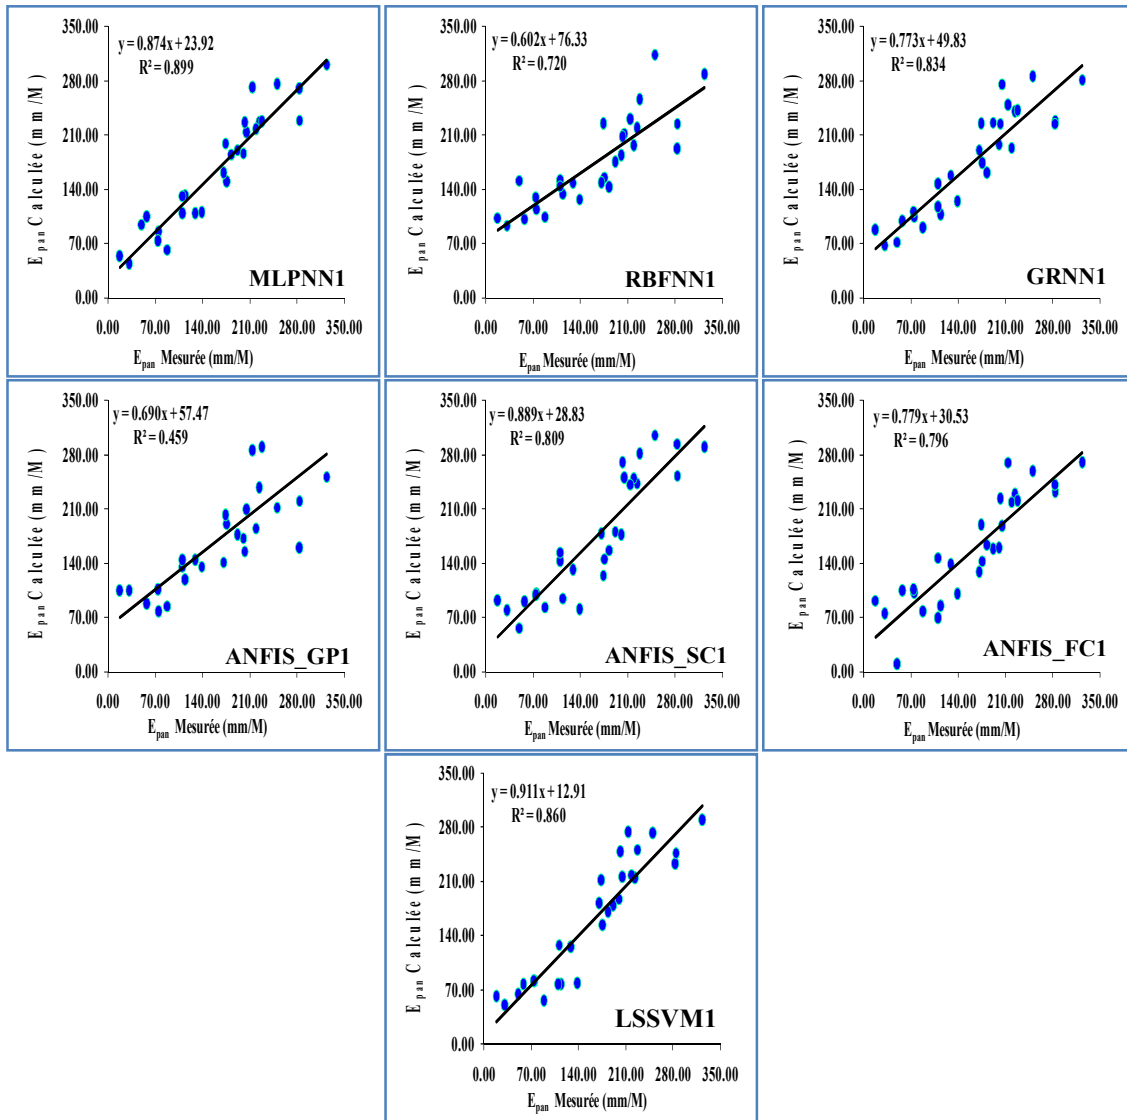


Figure V.5. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.

Pour les modèles GRNN, il est remarquable que le coefficient de corrélation était élevée ($>87.5\%$) durant les trois phases. En apprentissage, les résultats ont montrés que les valeurs prédites calculés par le modèle GRNN1, avec ($R=0.977$ et $MAE=12.348$ mm), alors qu'en validation on constate une certaine amélioration des performance, il apparaît nettement que le modèle GRNN1 garantie les meilleurs résultats avec ($R=0.934$ et $MAE=27.920mm$), en phase de test, les résultats obtenus sont proches à ceux obtenus en phase d'apprentissage, et le

modèle avec toutes les variables d'entrées occupe toujours la première place avec ($R=0.914$ et $MAE= 29.746mm$). Les résultats obtenus par les modèles ANFIS_GP sont faibles à moyenne, à l'exception du modèle ANFIS_GP6 ayant les T_{max} et T_{min} . Les valeurs de R pour la période d'apprentissage sont supérieures à 90.9%, alors quand on passe en période de validation on note une dégradation remarquable des performances des modèles ANFIS_GP1, ANFIS_GP2, ANFIS_GP3 et ANFIS_GP4. La valeur de R est comprise entre 29.4% et 70%, les meilleures performances ont été obtenus par le modèle à deux entrées ANFIS_GP6 ($R=0.914$ et $MAE= 34.827mm$). En phase de test on constate également les mêmes observations soulevées en phase de validation.

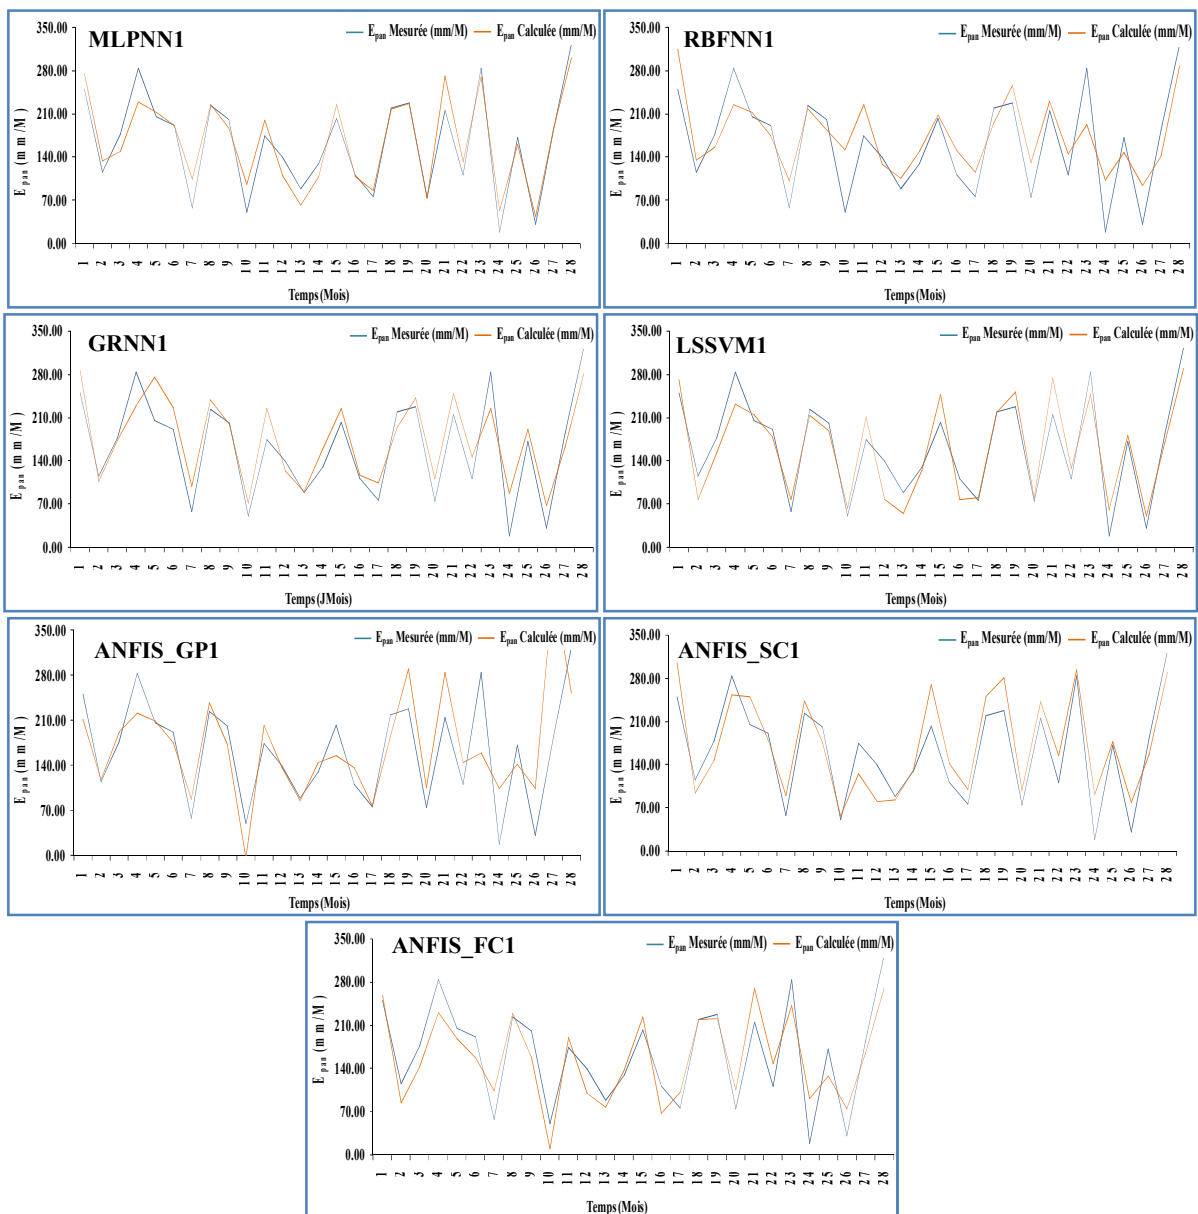


Figure V.6. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps journalier: barrage Zit Emba, phase de test.

Tableau V.6 Performances des modèles mensuels au niveau du Barrage Zit Emba

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.940	0.969	29.773	22.854	0.955	0.971	36.581	29.918	0.948	0.966	25.426	19.786
MLPNN2	0.908	0.931	38.524	31.503	0.930	0.948	41.925	34.195	0.894	0.912	37.590	29.445
MLPNN3	0.920	0.950	34.876	27.984	0.878	0.920	51.806	43.877	0.874	0.866	42.733	32.147
MLPNN4	0.899	0.943	38.989	30.089	0.910	0.953	44.724	35.268	0.847	0.907	43.324	33.748
MLPNN5	0.897	0.938	39.222	30.324	0.917	0.955	41.789	32.927	0.863	0.908	40.136	32.619
MLPNN6	0.908	0.946	37.070	30.265	0.926	0.954	40.821	32.903	0.898	0.914	36.798	29.652
RBFNN1	0.977	0.989	17.065	12.018	0.891	0.933	50.728	40.072	0.848	0.869	44.894	36.809
RBFNN2	0.980	0.989	17.334	12.561	0.730	0.822	76.296	60.331	0.826	0.881	44.820	35.779
RBFNN3	0.951	0.972	27.273	20.772	0.910	0.935	47.194	38.031	0.881	0.916	37.622	26.682
RBFNN4	0.923	0.957	33.454	25.265	0.868	0.916	53.214	42.645	0.843	0.843	46.033	35.535
RBFNN5	0.921	0.959	32.805	25.563	0.883	0.916	51.774	44.550	0.824	0.851	45.841	38.568
RBFNN6	0.935	0.958	33.244	25.583	0.830	0.885	60.068	48.317	0.815	0.843	47.032	37.980
GRNN1	0.977	0.987	18.590	12.348	0.934	0.962	37.971	27.920	0.914	0.934	35.138	29.746
GRNN2	0.910	0.934	38.312	30.353	0.931	0.944	42.923	36.761	0.885	0.904	38.751	31.687
GRNN3	0.905	0.924	40.477	32.294	0.935	0.942	43.083	37.365	0.890	0.904	38.425	30.558
GRNN4	0.891	0.916	42.110	33.798	0.927	0.939	44.442	37.716	0.889	0.901	39.129	30.165
GRNN5	0.883	0.884	46.502	37.364	0.924	0.913	50.359	43.346	0.875	0.864	43.571	34.044
GRNN6	0.888	0.909	43.563	35.290	0.929	0.937	44.573	38.921	0.888	0.897	39.466	30.385
LSSVM1	0.936	0.966	29.963	22.870	0.941	0.950	41.247	33.601	0.928	0.955	29.895	24.807
LSSVM2	0.904	0.945	37.178	28.764	0.922	0.931	46.989	38.681	0.891	0.930	37.514	32.439
LSSVM3	0.905	0.942	38.122	29.621	0.936	0.944	42.984	35.985	0.888	0.927	38.231	32.425
LSSVM4	0.898	0.939	38.854	31.297	0.929	0.945	42.908	35.905	0.891	0.932	37.184	30.990
LSSVM5	0.886	0.931	41.070	32.044	0.919	0.937	45.629	37.984	0.879	0.923	39.298	32.210
LSSVM6	0.894	0.934	40.355	33.109	0.931	0.948	41.964	35.608	0.889	0.930	37.476	31.404
ANFIS_GP1	1.000	1.000	0.0006	0.0004	0.500	0.696	108.923	77.362	0.678	0.747	64.510	44.073
ANFIS_GP2	1.000	1.000	0.001	0.001	0.700	0.834	81.656	64.459	0.415	0.545	92.782	74.736
ANFIS_GP3	0.988	0.994	12.692	7.917	0.323	0.120	1149.08	283.33	0.416	0.267	344.149	151.06
ANFIS_GP4	0.979	0.990	16.340	10.699	0.294	0.289	295.279	166.14	0.259	0.195	285.357	126.14
ANFIS_GP5	0.909	0.949	35.903	27.434	0.845	0.911	60.430	42.968	0.672	0.744	82.340	47.993
ANFIS_GP6	0.915	0.954	34.500	27.627	0.914	0.948	43.003	34.827	0.843	0.882	42.905	33.361
ANFIS_SC1	0.965	0.983	21.628	14.129	0.847	0.903	68.089	50.368	0.899	0.937	36.854	31.691
ANFIS_SC2	0.925	0.959	32.905	24.548	0.922	0.946	43.230	38.204	0.892	0.909	38.043	29.455
ANFIS_SC3	0.927	0.957	33.535	25.924	0.605	0.689	150.248	63.828	0.824	0.871	45.556	33.230
ANFIS_SC4	0.921	0.958	33.049	26.704	0.895	0.939	46.895	39.171	0.834	0.864	44.849	33.588
ANFIS_SC5	0.900	0.938	39.411	29.816	0.887	0.938	48.428	38.947	0.825	0.882	45.553	35.329
ANFIS_SC6	0.905	0.946	37.019	29.357	0.912	0.946	43.734	35.101	0.880	0.905	38.978	30.023
ANFIS_FC1	0.941	0.970	28.529	21.536	0.929	0.962	41.349	32.738	0.892	0.926	36.049	31.423
ANFIS_FC2	0.910	0.950	35.842	28.904	0.905	0.945	44.895	38.605	0.882	0.898	39.473	31.129
ANFIS_FC3	0.918	0.952	35.245	28.890	0.900	0.928	48.358	42.235	0.873	0.890	40.734	32.246
ANFIS_FC4	0.911	0.947	36.674	29.399	0.909	0.948	43.774	36.942	0.873	0.897	40.099	31.886
ANFIS_FC5	0.900	0.938	39.278	29.682	0.894	0.941	46.992	37.026	0.841	0.896	40.841	43.366
ANFIS_FC6	0.904	0.945	37.289	30.285	0.922	0.947	42.680	35.918	0.891	0.905	38.101	29.670

Quant aux modèles ANFIS_SC, on note une amélioration des résultats en phase de validation et en test par rapport à ceux obtenus par les modèles ANFIS_GP. Les meilleurs performances ont été obtenus par le modèle à quatre entrées ANFIS_SC4 avec (R=0.925 et

MAE=24.548mm), (R=0.922, MAE=38.204mm), (R=0.892, MAE=29.455mm), et le mauvais résultat a été obtenu par le modèle ANFIS_SC3 avec R=0.605 en validation. À l'inverse des modèles ANFIS_GP et ANFIS_SC, où nous avons montré que le meilleur résultat est enregistré avec un modèle utilisant deux variables, les résultats obtenus par les modèles ANFIS_FC révèlent que le meilleur modèle est le ANFIS_FC1 avec (R=0.941, MAE=21.536 mm), (R=0.929, MAE=32.738 mm), (R=0.892, MAE=31.423 mm), en phases d'apprentissage, de validation et de test. Donc on peut conclure que le modèle ANFIS_FC s'est révélé plus compétitif que les modèles ANFIS_GP et ANFIS_SC. Autrement dit, la robustesse du modèle ANFIS_FC apparaît mieux pour la modélisation de l' E_{pan} .

V.2.3.1. Résultats récapitulatif des différents modèles pour barrage Zit Emba

D'après les résultats obtenus par les différents modèles développés au niveau du barrage Zit Emba on peut noter ce qui suit:

1. Le modèle MLPNN1 a donné les meilleurs résultats par rapport aux autres modèles, suivi par LSSVM1, GRNN1, ANFIS_SC1, ANFIS_FC1, RBFNN1 et ANFIS_GP1 respectivement
2. Les plus faibles résultats ont été fournis par le modèle ANFIS_GP1.
3. Les meilleurs résultats ont été enregistrés avec les modèles utilisant les quatre variables climatiques et la composante (M) du calendrier Grégorien (combinaison N°1) en entrées durant les trois phases à l'exception des deux modèles RBFNN1 et ANFIS_GP1.
4. Notons que pour les modèles RBFNN, les meilleurs résultats sont obtenus avec le modèle RBFNN3 avec R=0.881 durant la phase de test.
5. On note aussi que le modèle ANFIS_GP6 est le plus performant avec R=0.843 durant la phase de test.

Tableau V.7. Résultats récapitulatif des meilleurs modèles pour barrage Zit Emba

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.948	0.966	25.426	19.786	01
RBFNN1	0.848	0.869	44.894	36.809	06
GRNN1	0.914	0.934	35.138	29.746	03
LSSVM1	0.928	0.955	29.895	24.807	02
ANFIS_GP1	0.678	0.747	64.510	44.073	07
ANFIS_SC1	0.899	0.937	36.854	31.691	04
ANFIS_FC1	0.892	0.926	36.049	31.423	05

V.2.4. Résultats de la modélisation pour le Barrage El Agram

Les résultats obtenus au niveau du barrage El Agram sont reportés dans le [Tableau V.8](#), et les [Figure V.7-8](#). Il ressort que les résultats obtenus sont acceptables. Notons que le modèle RBFNN a donné des résultats relativement acceptables, en effet, la valeur de R est comprise entre 72.9% et 99.9%, soit une moyenne de 86.4% durant les trois phases. En apprentissage, la valeur de RMSE est souvent inférieure à 18.751mm, en phases de validation et de test on note une légère dégradation pour certains modèles avec RMSE inférieur à 37.797mm et 36.579mm, respectivement, donc on peut conclure que la capacité de généralisation pour les différents modèles RBFNN est relativement faible.

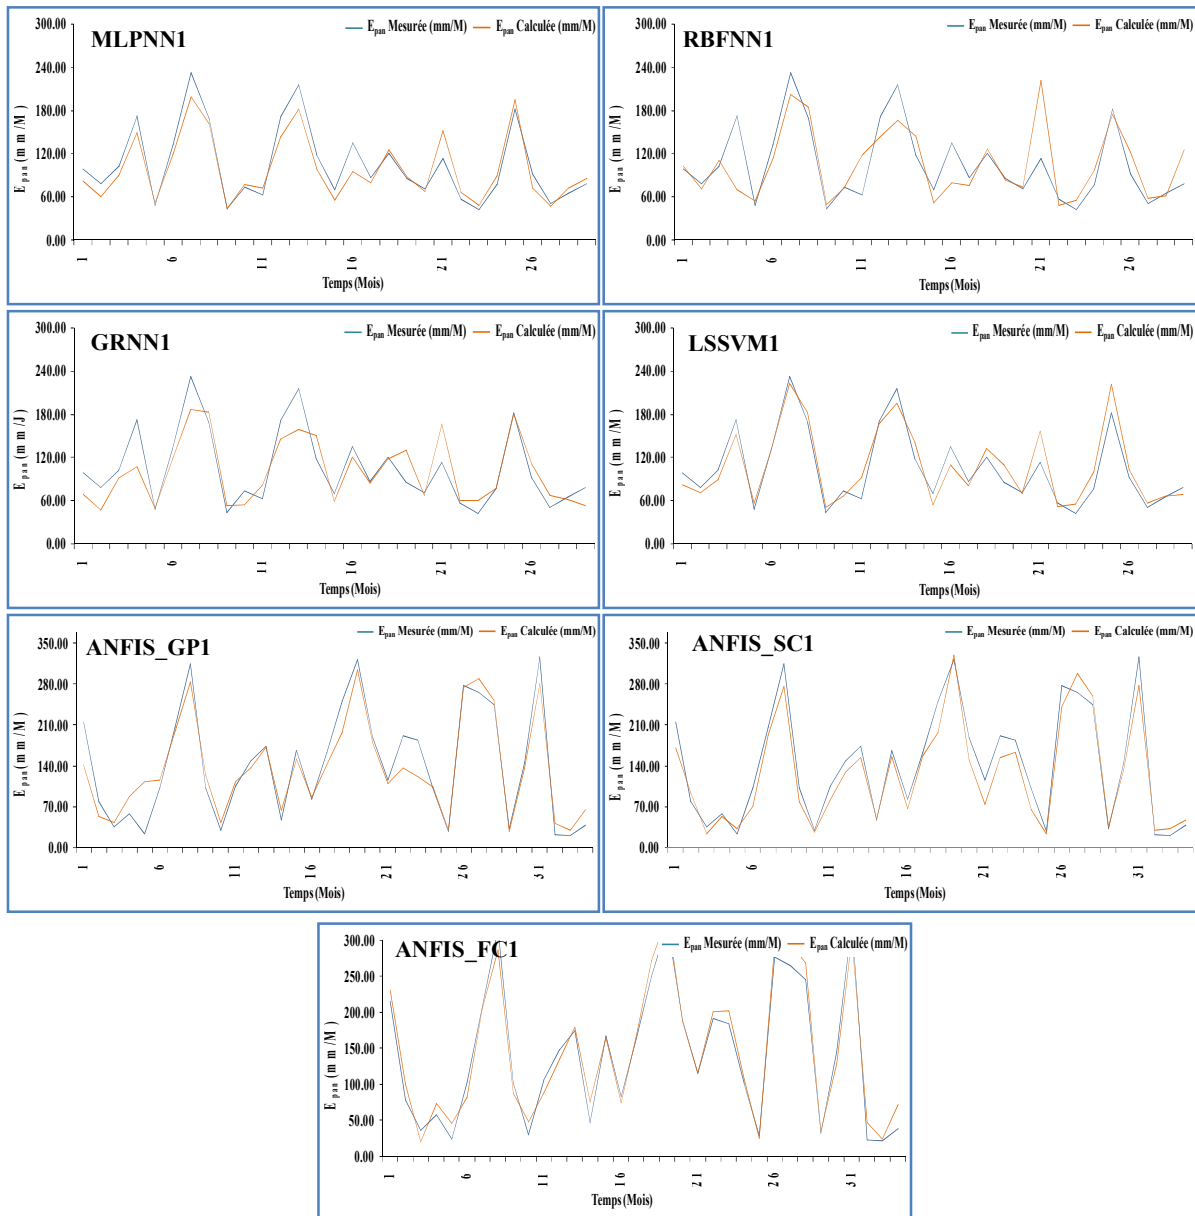


Figure V.7. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage EL Agram, phase de test.

Pour les modèles MLPNN, on note que les résultats (Tableau V.8) obtenus sont très encourageantes comparés à ceux obtenus par les modèles RBFNN cités précédemment. En effet, la valeur de l'indice de conformité (d) est comprise entre 88,3% et 98,4%, soit une moyenne de 93,35%. Le RMSE est inférieur à 25,243mm aux cours de trois phases. En apprentissage, les valeurs des critères de performances sont très élevés avec (d) souvent supérieur à 94% et RMSE inférieure à 23,568mm, le modèle le plus performant est le modèle MLPNN1 avec ($d=0,991$, $RMSE=12,536$ mm). Nous remarquons que les résultats trouvés en phase validation et de test confirment le bon calage des différents modèles MLPNN en particulier le modèle à cinq entrées MLPNN1 avec ($d=0,945$, $RMSE=24,098$ mm) et

($d=0.946$, $RMSE=18.062mm$), respectivement. Donc nous pouvons noter que le modèle MLPNN a montré une bonne capacité à prédire l' E_{pan} mensuel.

Tableau V.8 Performances des modèles mensuels au niveau du Barrage *El Agram*

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.984	0.991	12.536	9.335	0.945	0.968	24.098	16.986	0.946	0.971	18.062	14.148
MLPNN2	0.954	0.975	20.728	16.402	0.939	0.969	24.621	18.809	0.883	0.947	24.432	19.055
MLPNN3	0.954	0.975	20.842	16.307	0.953	0.976	21.900	17.892	0.887	0.948	24.025	19.199
MLPNN4	0.950	0.974	21.548	16.716	0.938	0.966	25.243	19.902	0.896	0.953	23.559	19.366
MLPNN5	0.940	0.968	23.568	19.021	0.939	0.967	24.813	19.678	0.865	0.939	26.624	20.948
MLPNN6	0.942	0.969	23.162	18.607	0.953	0.975	21.848	18.688	0.904	0.957	22.169	17.033
RBFNN1	0.999	0.999	1.874	1.144	0.853	0.924	37.797	28.748	0.729	0.875	36.579	24.188
RBFNN2	0.962	0.980	18.652	13.781	0.904	0.949	30.580	25.228	0.764	0.888	33.302	27.174
RBFNN3	0.962	0.980	18.652	13.781	0.904	0.949	30.580	25.228	0.764	0.888	33.302	33.302
RBFNN4	0.964	0.981	18.252	14.003	0.885	0.939	33.596	24.759	0.731	0.877	36.508	26.346
RBFNN5	0.962	0.980	18.705	14.171	0.907	0.950	30.552	25.616	0.822	0.918	30.266	23.367
RBFNN6	0.962	0.980	18.751	13.495	0.894	0.946	32.296	26.747	0.839	0.905	35.771	25.349
GRNN1	0.992	0.996	8.853	5.299	0.955	0.974	21.936	16.016	0.852	0.931	27.165	20.640
GRNN2	0.921	0.948	27.979	22.279	0.929	0.952	28.334	23.254	0.850	0.923	27.197	21.557
GRNN3	0.903	0.932	31.075	25.036	0.905	0.932	32.523	28.109	0.842	0.918	27.830	21.677
GRNN4	0.912	0.941	29.427	23.675	0.926	0.947	29.343	23.712	0.864	0.931	25.988	21.121
GRNN5	0.913	0.925	31.550	26.061	0.938	0.93	30.960	25.439	0.882	0.929	25.535	21.456
GRNN6	0.900	0.929	31.666	25.272	0.902	0.929	33.034	28.211	0.850	0.920	27.408	21.524
LSSVM1	0.966	0.981	18.011	14.182	0.968	0.981	18.769	14.552	0.941	0.973	17.864	14.298
LSSVM2	0.932	0.962	25.124	19.798	0.939	0.965	25.124	20.264	0.869	0.936	27.237	21.803
LSSVM3	0.926	0.959	26.093	20.821	0.931	0.960	26.783	22.191	0.875	0.940	25.752	19.687
LSSVM4	0.923	0.958	26.510	21.167	0.936	0.962	25.900	21.472	0.882	0.941	26.116	20.473
LSSVM5	0.925	0.959	26.164	20.840	0.942	0.964	25.146	21.077	0.891	0.945	25.191	19.843
LSSVM6	0.921	0.956	26.958	21.515	0.926	0.957	27.550	23.243	0.878	0.941	25.466	19.230
ANFIS_GP1	1.000	1.000	0.020	0.011	0.738	0.855	57.264	43.601	0.644	0.812	48.085	36.494
ANFIS_GP2	0.989	0.994	10.192	7.101	0.632	0.781	74.816	52.708	0.735	0.747	79.084	56.583
ANFIS_GP3	0.963	0.981	18.372	13.684	0.930	0.964	26.658	21.086	0.847	0.928	29.840	23.028
ANFIS_GP4	0.956	0.977	20.004	15.492	0.798	0.894	45.110	29.037	0.785	0.902	33.280	24.578
ANFIS_GP5	0.934	0.965	24.582	20.174	0.951	0.971	22.657	18.017	0.874	0.943	25.206	19.759
ANFIS_GP6	0.938	0.967	23.880	19.157	0.949	0.973	22.651	18.410	0.911	0.960	21.187	16.462
ANFIS_SC1	0.988	0.994	10.504	7.950	0.942	0.970	25.020	19.480	0.947	0.954	21.799	15.631
ANFIS_SC2	0.960	0.979	19.290	14.888	0.944	0.972	23.850	19.823	0.891	0.951	23.583	18.358
ANFIS_SC3	0.961	0.979	19.053	14.537	0.934	0.966	25.939	20.527	0.845	0.930	28.227	19.975
ANFIS_SC4	0.939	0.968	23.541	18.732	0.960	0.977	20.319	16.900	0.897	0.953	23.067	18.446
ANFIS_SC5	0.936	0.966	24.132	18.968	0.936	0.963	25.913	19.909	0.873	0.942	25.596	20.168
ANFIS_SC6	0.939	0.967	23.654	18.797	0.960	0.977	20.438	17.047	0.896	0.953	23.225	18.400
ANFIS_FC1	0.976	0.987	14.884	11.492	0.968	0.981	18.720	13.781	0.947	0.976	16.753	13.553
ANFIS_FC2	0.949	0.973	21.542	17.166	0.949	0.972	22.753	18.307	0.898	0.954	22.678	17.457
ANFIS_FC3	0.949	0.973	21.621	17.233	0.949	0.973	22.545	18.740	0.853	0.932	27.679	20.407
ANFIS_FC4	0.939	0.968	23.542	18.732	0.957	0.976	21.048	17.608	0.897	0.953	23.066	18.440
ANFIS_FC5	0.937	0.966	24.039	18.842	0.936	0.963	25.997	19.883	0.872	0.942	25.718	20.274
ANFIS_FC6	0.938	0.967	23.704	18.843	0.959	0.977	20.694	17.129	0.896	0.953	23.158	18.163

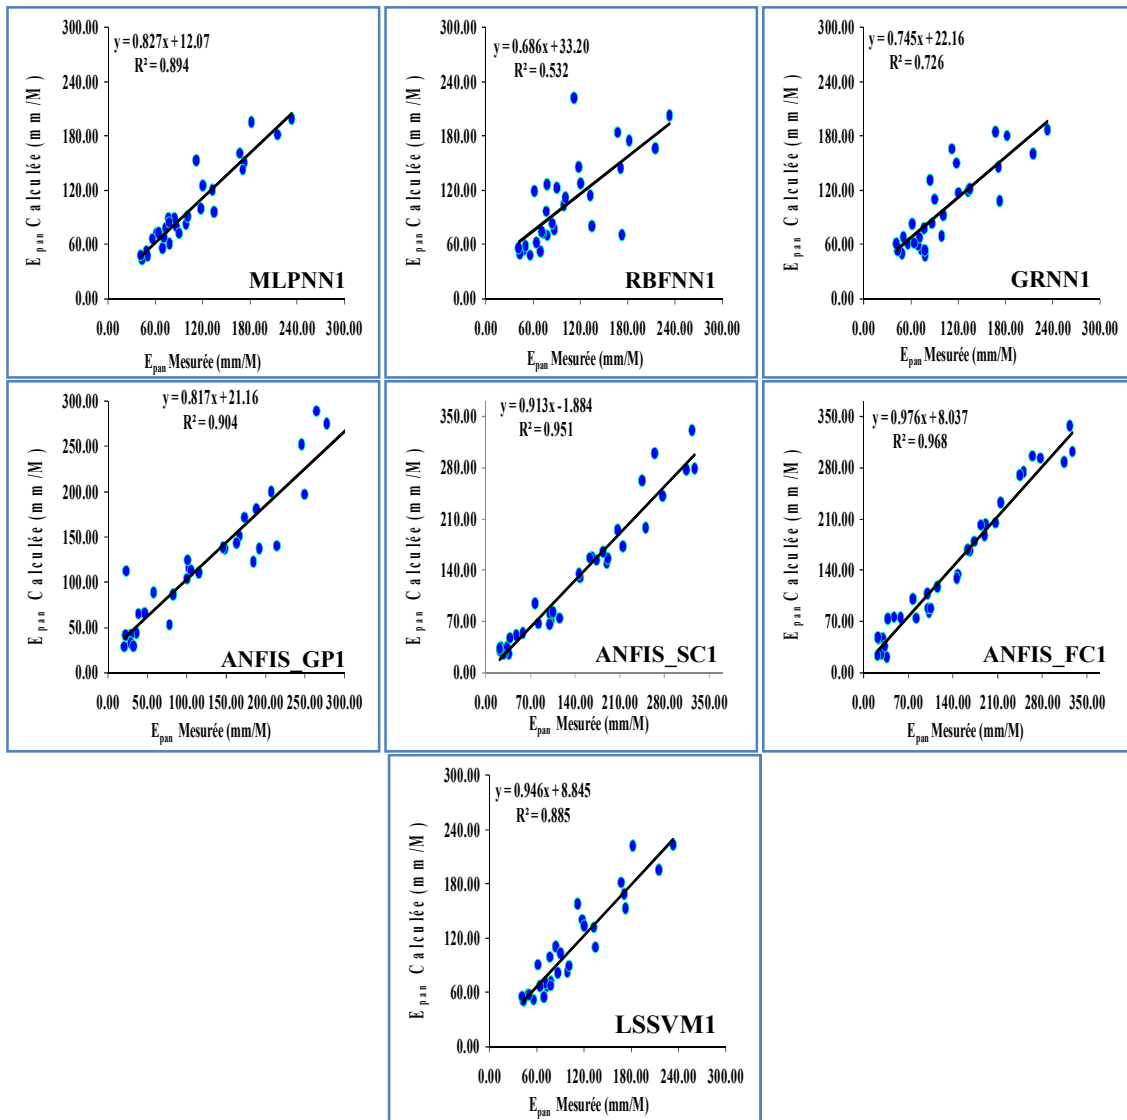


Figure V.8. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage EL Agram, phase de test.

Notons que les résultats obtenus par les modèles GRNN sont légèrement faibles comparés aux résultats obtenus par les modèles MLPNN, mais généralement sont très acceptables avec l'indice de conformité de Willmott (d) supérieur à 84.2% pour les trois phases, et que les performances de la majorité des modèles sont élevés avec R supérieur à 90%. En apprentissage, on note que les différents modèles donnent des résultats sensiblement similaires à ceux obtenus qu'en phase de validation, avec R supérieur à 90.2% et RMSE inférieur à 33.034mm. En phase de test la valeur de R est comprise entre 84.2% et 85.2%. Enfin on conclut que les résultats ont révélé que la corrélation entre les données d'évaporation mesurés et calculés était élevée lors de l'utilisation de GRNN par rapport à la technique RBFNN. De plus, on peut voir que la magnitude d'erreur relative de la méthode GRNN était faible par rapport à celle atteinte par la technique RBFNN. Les résultats montrent que les

modèles LSSVM apporte d'excellentes performances durant les trois phases avec R oscille entre 0.869 et 0.966. Notons que la meilleure prédiction avec les données mensuelles pour les modèles LSSVM est obtenus par le modèle LSSVM1 (R=0.996, RMSE=18.011mm), (R=0.968, RMSE=18.769mm), (R=0.941, RMSE=17.864mm), respectivement. Donc, sur la base des résultats, la précision des modèles LSSVM était significativement meilleure que les modèles GRNN et RBFNN.

La modélisation de l' E_{pan} mensuelle par les modèles ANFIS_GP a donner de bons résultats pour les modèles ANFIS_GP3, ANFIS_GP5, ANFIS_GP6 avec R varie de 0.874 à 1.000 durant les trois phases, et de faibles résultats pour les ANFIS_GP1, ANFIS_GP2, ANFIS_GP4 avec R compris entre 0.632 et 0.798 durant la période de validation et test. Les performances de la majorité des modèles sont très élevés avec R qui dépasse les 93.4% en apprentissage, alors qu'en phase de validation et test, on enregistre une dégradation significative pour certains modèles. Donc on pourrait conclure que sur les modèles à différentes entrées, le modèle qui utilise seulement les deux températures T_{max} et T_{min} ANFIS_GP6 donne l'estimation la plus proche avec (R=0.938, RMSE=23.880mm), (R=0.949, RMSE=22.651mm), (R=0.911, RMSE=21.187mm), respectivement. Les performances du modèle ANFIS_SC semblent être meilleures que celles du modèle ANFIS_GP avec R supérieur à 84.5% pour les trois phases. Cela indique que toutes les variables sont nécessaires pour une meilleure modélisation de l' E_{pan} . La comparaison des modèles indique que le modèle à cinq entrées ANFIS_SC1 est le plus performant avec (R=0.988, RMSE=10.504mm), (R=0.942, RMSE=25.020mm), (R=0.947, RMSE=21.799mm), respectivement.

En apprentissage, on note que les valeurs des RMSE sont inférieures à 23.654 mm et R supérieur à 0.939, en validation et test, les résultats obtenus confirment le bon calage des différents modèles ANFIS_SC avec R supérieur à 0.934 et 0.845, respectivement. Dans l'ensemble, les modèles ANFIS_SC semblent plus adéquats que les modèles ANFIS_GP et RBFNN, et confirme les résultats obtenus par les modèles MLPNN et LSSVM pour l'estimation mensuelle de l'évaporation. Comme le montre le **Tableau V.8**, les valeurs des RMSE, MAE, R et d du modèle ANFIS-FC sont très proches de celles du modèle ANFIS-SC durant les trois périodes, et que le modèle à cinq entrées a une meilleure précision que les autres modèles avec (R=0.976, RMSE=14.884mm), (R=0.968, RMSE=18.720mm), (R=0.947, RMSE=16.753mm), respectivement.

V.2.4.1. Résultats récapitulatif des différents modèles pour barrage *El Agram*

Au regard des résultats obtenus par les différents modèles au niveau du barrage *El Agram* on peut noter ce qui suit:

1. Les modèles à cinq entrées ANFIS_FC1, ANFIS_SC1, MLPNN1 et LSSVM1 ont fourni les mêmes performances et meilleurs résultats par rapport autres modèles avec R supérieur à 0.941, suivi par GRNN1, RBFNN1, et RBFNN1 respectivement alors que le modèle RBFNN et ANFIS_GP1 ont fourni les plus faibles résultats avec R inférieur à 0.729 en phase de test.
2. Les meilleurs résultats ont été obtenus avec les modèles à cinq entrées avec R supérieur à 0.852 durant les trois phases, à l'exception des deux modèles RBFNN1 et ANFIS_GP1 qui ont données de faibles performances.

Tableau V.9. Résultats récapitulatif des meilleures modèles pour barrage El Agram

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.946	0.971	18.062	14.148	03
RBFNN1	0.729	0.875	36.579	24.188	06
GRNN1	0.852	0.931	27.165	20.640	05
LSSVM1	0.941	0.973	17.864	14.298	04
ANFIS_GP1	0.644	0.812	48.085	36.494	07
ANFIS_SC1	0.947	0.954	21.799	15.631	02
ANFIS_FC1	0.947	0.976	16.753	13.553	01

V.2.5. Résultats de la modélisation pour le Barrage Hammam Grouz

La modélisation de l'évaporation mensuelle au niveau du barrage Hammam Grouz utilisant les différentes techniques d'IA sont présentées dans le [Tableau V.11](#), et les [Figure V.9.10](#). Les résultats obtenus par les modèles ANFIS_GP varient d'un modèle à un autre selon le nombre d'entrées utilisées, les modèles ANFIS_GP1, ANFIS_GP3, fournies de bons résultats avec R allant de 0.898 à 1.000 durant les trois phases, alors que les modèles ANFIS_GP2, ANFIS_GP4, ANFIS_GP5, ANFIS_GP5 possèdent de faibles performances aux durant les deux phases de validation et test avec R inférieur à 0.795. Le modèle ANFIS_GP1 est le plus performant, avec (R=1.00, MAE=0.000mm), (R=0.818, MAE=23.295), (R=0.912, MAE=26.920mm), respectivement, ce qui indique que l'ajout de la composante du calendrier Grégorien (M) aux quatre variables climatiques est nécessaire dans l'amélioration de performances du modèle ANFIS_GP. Notons que les résultats obtenus par le modèle ANFIS_SC sont plus que satisfaisants, et que toutes les architectures (combinaisons) possèdent des précisions presque égales durant les trois phases avec R supérieur à 0.945 est MAE inférieur à 19.708 mm, ce qui indique la bonne capacité de généralisation de ces modèles. En effet, en apprentissage la valeur de R varie de 0.977 et 0.994, en validation elle varie de 0.945 à 0.973, et en phase de test le R varie de 0.963 à 0.977. Les résultats obtenus par le modèle ANFIS_FC sont sensiblement similaires à ceux obtenus par le modèle ANFIS_SC durant les trois périodes, en effet, le R est supérieur à 0.941 est le MAE inférieur à 19.787mm.

Les modèles MLPNN ont montré d'excellents résultats, légèrement supérieurs à ceux obtenus par les deux modèles ANFIS_FC et ANFIS_SC en phase de validation et test, toujours avec R supérieur à 0.941 est MAE inférieur à 19.221mm, durant les trois phases, ce qui indique que toutes les variables utilisées en entrées des modèles sont nécessaires en particuliers l'utilisation de cinq entrées à la fois. Nous concluons que le modèle MLPNN est très compétitif dans l'estimation de l' E_{pan} mensuelle au niveau du barrage Hammam Grouz. La simulation de l' E_{pan} mensuelle par modèles RBFNN est très satisfaisantes, en apprentissage, le R est souvent supérieur à 0.985, en validation toutes les valeurs de R dépassent 0.872, sauf pour le modèle à deux entrées (T_{max} , H%) RBFNN5 on note de faibles performances, pour la phase de test, tous les modèles ont enregistré de très bon résultats avec R supérieur à 0.916, et les meilleures résultats ont été obtenus par le modèle RBFNN avec (R=0.979, MAE=16.598mm). Nous concluons que les résultats obtenus par le modèle RBFNN sont très acceptable.

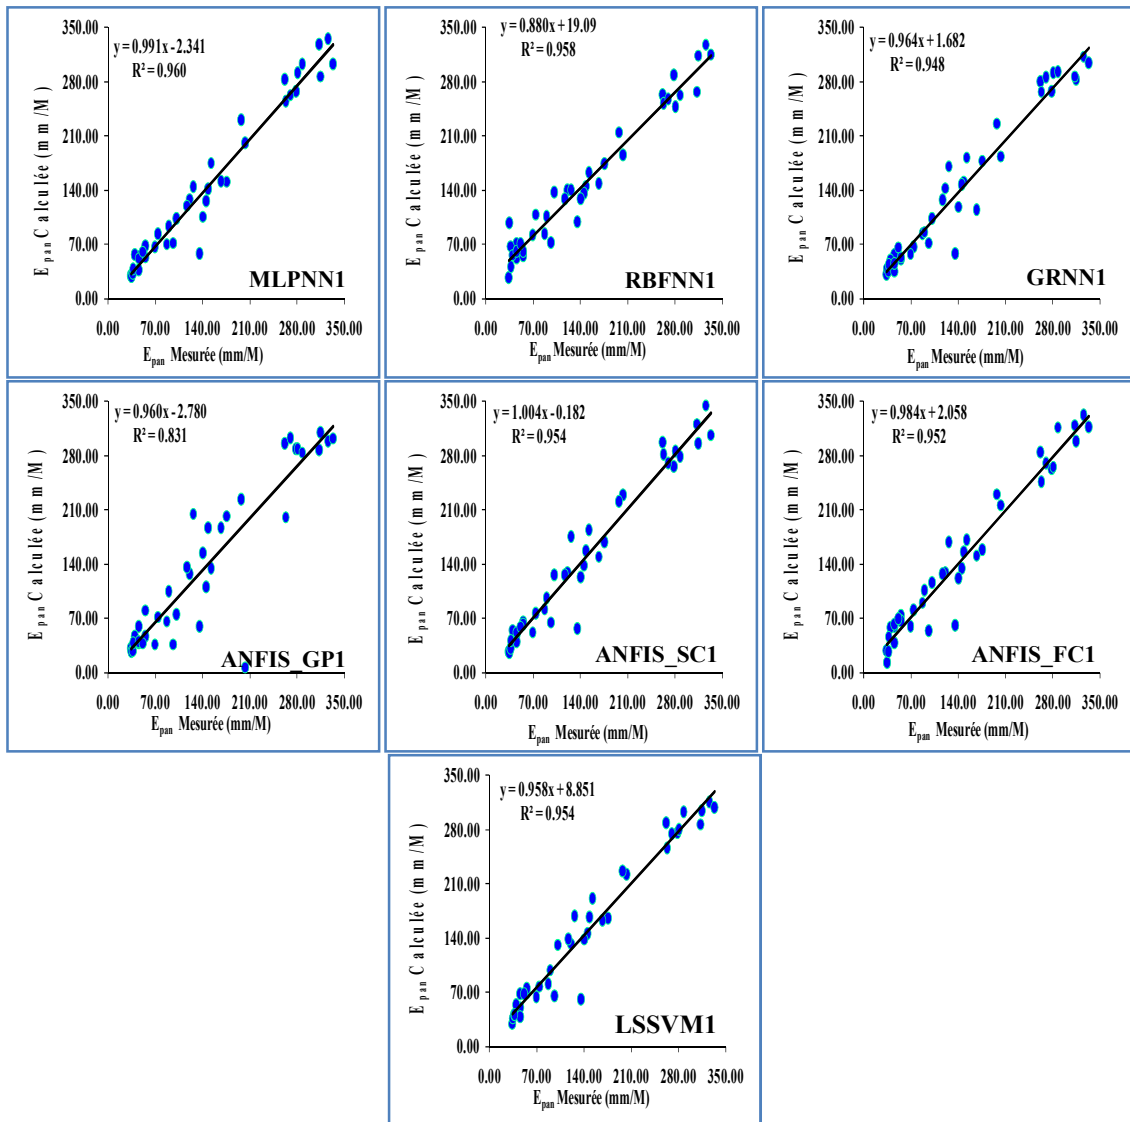


Figure V.9. Scatterplots des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Hammam Grouz, phase de test.

Le **Tableau V.11** présente également les résultats obtenus par les modèles GRNN. Les performances des modèles ont été améliorées lors de l'utilisation de toutes les variables d'entrée avec ($R=0.996$, $MAE=23.880\text{mm}$), ($R=0.960$, $MAE=16.602\text{mm}$), ($R=0.973$, $MAE=15.575\text{mm}$), respectivement. En apprentissage, le MAE est inférieur à 19.645mm et le d supérieur à 0.979 . En validation, le MAE est inférieur à 25.437mm et le d supérieur à 0.951 . Finalement, pour la phase de test, le MAE est inférieur à 25.039mm et le d supérieur à 0.970 .

Tableau V.10 Performances des modèles mensuels au niveau du Barrage Hammam Grouz

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.991	0.994	13.569	9.139	0.973	0.987	17.032	13.118	0.979	0.989	19.986	14.377
MLPNN2	0.987	0.993	15.856	11.186	0.941	0.971	24.960	19.221	0.964	0.982	25.968	20.249
MLPNN3	0.983	0.991	17.934	12.804	0.965	0.983	19.172	14.998	0.973	0.986	22.459	18.551
MLPNN4	0.984	0.991	17.599	12.918	0.969	0.986	18.180	13.839	0.975	0.987	21.679	17.857
MLPNN5	0.973	0.985	22.385	15.449	0.952	0.978	22.272	16.702	0.958	0.978	27.628	21.283
MLPNN6	0.981	0.990	18.856	13.845	0.964	0.983	19.266	14.793	0.975	0.987	21.692	17.016
RBFNN1	0.995	0.997	9.531	6.566	0.944	0.957	28.365	20.067	0.979	0.986	21.321	16.598
RBFNN2	0.996	0.997	8.865	6.209	0.872	0.933	40.717	27.448	0.916	0.956	40.101	29.296
RBFNN3	0.985	0.992	16.744	11.834	0.965	0.983	19.466	15.707	0.962	0.980	27.250	22.013
RBFNN4	0.985	0.991	17.227	12.336	0.951	0.976	24.180	17.448	0.969	0.984	23.983	18.715
RBFNN5	0.985	0.992	16.957	12.074	0.755	0.851	68.215	38.442	0.930	0.960	40.727	28.441
RBFNN6	0.986	0.992	16.767	11.731	0.913	0.928	47.018	24.043	0.937	0.957	43.991	27.577
GRNN1	0.996	0.998	8.252	4.607	0.960	0.978	21.399	16.602	0.973	0.986	22.421	15.577
GRNN2	0.981	0.989	19.585	13.060	0.907	0.955	30.767	23.199	0.961	0.978	27.375	21.912
GRNN3	0.971	0.983	24.038	17.478	0.900	0.951	31.817	25.437	0.943	0.970	32.193	25.039
GRNN4	0.974	0.985	22.359	16.050	0.925	0.965	27.652	20.703	0.967	0.982	24.910	20.112
GRNN5	0.974	0.985	22.211	15.844	0.924	0.964	27.881	20.837	0.970	0.983	23.889	19.072
GRNN6	0.964	0.979	26.425	19.645	0.908	0.957	30.441	24.040	0.948	0.972	30.780	24.298
LSSVM1	0.991	0.995	13.243	8.699	0.975	0.987	17.095	14.318	0.976	0.988	20.986	15.263
LSSVM2	0.983	0.990	18.021	12.573	0.952	0.975	24.154	18.136	0.971	0.985	23.313	18.330
LSSVM3	0.982	0.990	18.418	13.497	0.964	0.981	21.010	15.774	0.970	0.984	23.669	18.737
LSSVM4	0.980	0.989	19.343	13.919	0.959	0.981	21.112	16.054	0.975	0.987	21.507	17.300
LSSVM5	0.977	0.987	20.791	14.930	0.946	0.975	24.096	18.251	0.971	0.985	23.020	18.539
LSSVM6	0.979	0.988	19.851	14.560	0.965	0.983	20.021	14.710	0.974	0.986	22.020	17.547
ANFIS_GP1	1.000	1.000	0.0007	0.0003	0.818	0.917	43.990	23.295	0.912	0.952	42.998	26.920
ANFIS_GP2	1.000	1.000	0.035	0.021	0.785	0.860	67.341	46.835	0.801	0.884	69.235	51.764
ANFIS_GP3	0.993	0.996	11.306	7.155	0.828	0.828	84.919	49.466	0.898	0.939	50.128	33.913
ANFIS_GP4	0.996	0.997	9.011	6.083	0.770	0.780	99.510	54.084	0.833	0.897	67.199	42.728
ANFIS_GP5	0.983	0.991	18.023	13.049	0.649	0.770	91.145	43.586	0.919	0.957	40.715	29.610
ANFIS_GP6	0.984	0.991	17.371	11.637	0.963	0.982	19.971	15.430	0.795	0.872	74.432	32.085
ANFIS_SC1	0.994	0.996	10.787	7.874	0.973	0.986	17.269	13.127	0.977	0.988	21.325	15.379
ANFIS_SC2	0.984	0.992	17.047	12.642	0.953	0.978	22.368	17.445	0.969	0.984	24.410	19.660
ANFIS_SC3	0.981	0.990	18.963	14.409	0.967	0.985	18.584	14.903	0.971	0.985	23.227	19.715
ANFIS_SC4	0.982	0.990	18.082	13.332	0.963	0.984	19.461	15.255	0.973	0.986	22.179	18.383
ANFIS_SC5	0.977	0.987	20.791	15.792	0.945	0.975	23.877	19.708	0.969	0.984	23.836	20.217
ANFIS_SC6	0.980	0.989	19.475	14.534	0.969	0.986	18.016	13.639	0.973	0.986	22.281	18.150
ANFIS_FC1	0.990	0.994	14.139	10.388	0.977	0.986	17.496	12.419	0.976	0.987	214.12	16.810
ANFIS_FC2	0.980	0.989	19.215	15.159	0.962	0.983	19.867	16.609	0.971	0.985	23.289	19.890
ANFIS_FC3	0.980	0.989	19.069	14.651	0.963	0.983	19.487	15.975	0.970	0.985	23.610	20.198
ANFIS_FC4	0.980	0.989	19.353	15.032	0.958	0.981	20.804	17.167	0.968	0.984	24.274	20.008
ANFIS_FC5	0.977	0.987	20.800	15.251	0.941	0.973	24.622	19.787	0.970	0.984	23.447	19.203
ANFIS_FC6	0.980	0.989	19.490	14.498	0.969	0.986	17.870	13.309	0.972	0.986	22.656	18.403

Les résultats (Tableau V.11) obtenus par les modèles LSSVM sont presque égaux à ceux obtenus par les modèles MLPNN avec une grande précision dans l'estimation de l' E_{pan}

mensuelle. En effet, durant les trois phases, apprentissage, validation et en test la majorité des modèles LSSVM ont montré une fiabilité remarquable pour la modélisation de l' E_{pan} avec R supérieur à 94.6%. On note aussi que les différents modèles LSSVM possèdent des performances très proches.

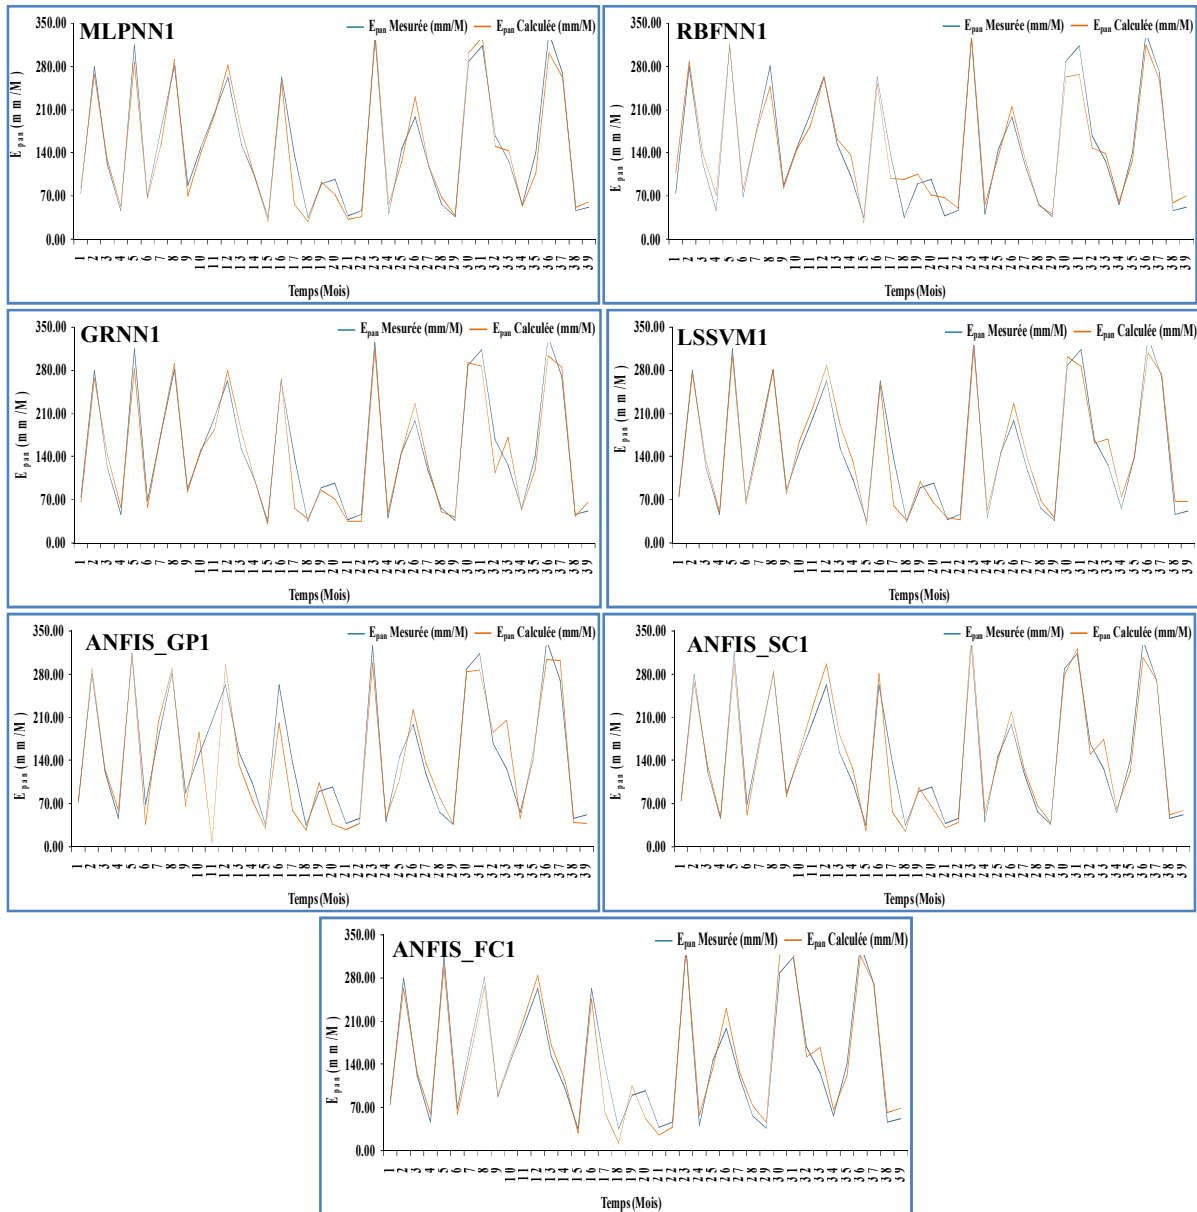


Figure V.10. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel : barrage Hammam Grouz phase de test.

V.2.5.1. Résultats récapitulatif des différents modèles pour barrage Hammam Grouz

Au vu des résultats obtenus par les différents modèles au niveau du barrage Hammam Grouz on peut conclure ce qui suit:

1. Notons que La majorité des modèles donnent d'excellents résultats durant la phase de test avec R supérieur à 91.2%.
2. Les modèle à cinq entrées MLPNN1, LSSVM1, ANFIS_SC1, ANFIS_FC1, GRNN1 ont presque les mêmes performances avec R de l'ordre de 97%, suivi par le modèle ANFIS_GP1 avec R=0.912.
3. On constate aussi que les valeurs des critères de performances des modèles MLPNN1, LSSVM1, ANFIS_SC1, ANFIS_FC1, sont proches pour les différentes combinaisons durant les trois phases.

Tableau V.11. Résultats récapitulatif des meilleures modèles pour barrage Hammam Grouz

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.979	0.989	19.986	14.377	01
RBFNN1	0.979	0.986	21.321	16.598	02
GRNN1	0.973	0.986	22.421	15.577	06
LSSVM1	0.976	0.988	20.986	15.263	04
ANFIS_GP1	0.912	0.952	42.998	26.920	07
ANFIS_SC1	0.977	0.988	21.325	15.379	03
ANFIS_FC1	0.976	0.987	214.12	16.810	05

V.2.6. Résultats de la modélisation pour le Barrage *Bouhamdane*

Les résultats obtenus au niveau du barrage Bouhamdane sont reportés dans Le **Tableau V.13** et les **Figure V.11-12**. Il apparaît clairement que les modèles *MLPNN* au pas de temps mensuel garanties d'excellents résultats quel que soit le nombre de variables en entrées durant les trois phases, d'apprentissage, de validation et test. En apprentissage, le modèle MLPNN1 est le plus performant avec (R=0.992, MAE=7.935mm), donc le fait d'ajouter la composante du calendrier Grégorien (*M*) aux quatre variables climatiques comme étant une cinquième entrée améliore considérablement la performance du modèle, tandis que pour les autre modèles la valeur de R est comprise entre 0.936 à 0.979. En validation et en test, on note aussi que les résultats confirmant le bon calage de différents modèles avec une MAE inférieur à 21.341mm et 22.321mm, respectivement, et que le modèle à cinq entrées est toujours le plus performants par rapport aux autres modèles avec (R=0.950, MAE= 18.497mm), et (R=0.980, MAE= 15.609mm) respectivement, donc on peut dire que la bonne concordance entre les valeurs des critères de performances à travers les trois phases confirme la robustesse, la stabilité et l'efficacité des modèles MLPNN développés. Les modèles RBFNN sont moins performants par rapport aux modèles MLPNN, mais les résultats restent très acceptables. Pour la phase d'apprentissage, on observe que le critère R est plus élevé et dépasse les 0.984, les meilleures performances sont obtenus par le modèle RBFNN1 avec (R=0.975, MAE=12.058mm). En validation et en test, on note aussi que le modèles à cinq entrées est toujours le plus performants par rapport aux autres modèles avec (R=0.934, MAE=26.638mm), (R=0.932, MAE=18.919mm), respectivement. Les résultats obtenus avec les modèles GRNN indiquent que les valeurs des MAE et R variaient de 6.549 à 23.772 mm, et 0.907 à 0,993 respectivement. Le modèle GRNN1 apparaît le plus performant avec (R=0.993, MAE=6.549mm), (R=0.932, MAE=21.275mm),(R=0.922, MAE= 21.327mm) respectivement. En phase d'apprentissage, le R est souvent supérieur à 0.919, on observe que les résultats

obtenus en phase de validation et test sont similaires pour toutes les combinaisons d'entrées avec un R supérieur à 0.907 et MAE inférieure à 23.772mm. On observe que les modèles LSSVM ont été relativement similaire aux modèles MLPNN, légèrement supérieurs aux GRNN et RBFNN, et toutes les architectures donnent de meilleurs critères de performances avec R qui dépasse 0.931 pour les trois phases.

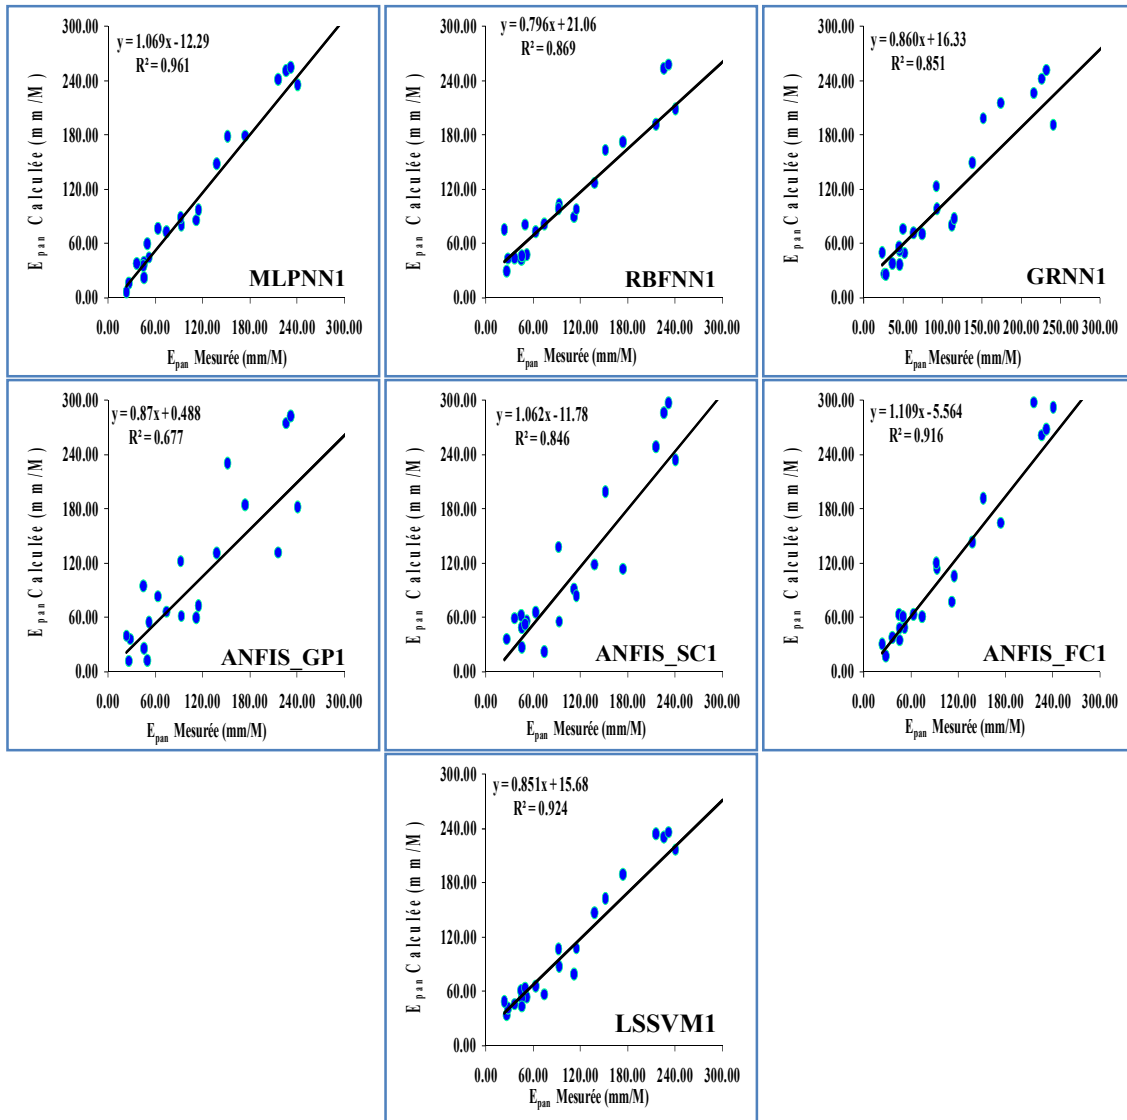


Figure V.11. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Bouhamdane, phase de test.

Les modèles ANFIS_GP sont moins performants durant les deux phases de validation et de test. En apprentissage, on note que les valeurs de R sont toujours élevée ($>98.3\%$), mais en validation on enregistre une dégradation remarquable, en particulier les modèles ANFIS_GP3, ANFIS_GP4, ANFIS_GP6, avec R inférieur à 0.659. Pour les modèles ANFIS_GP1, ANFIS_GP2, ANFIS_GP5, le R varie entre 0.843 et 0.929, en phase de test. On note

également que les performances des différents modèles sont proches qu'en phase de validation. Donc on conclut que le modèle qui assure une bonne capacité de généralisations est le modèle ANFIS_GP5.

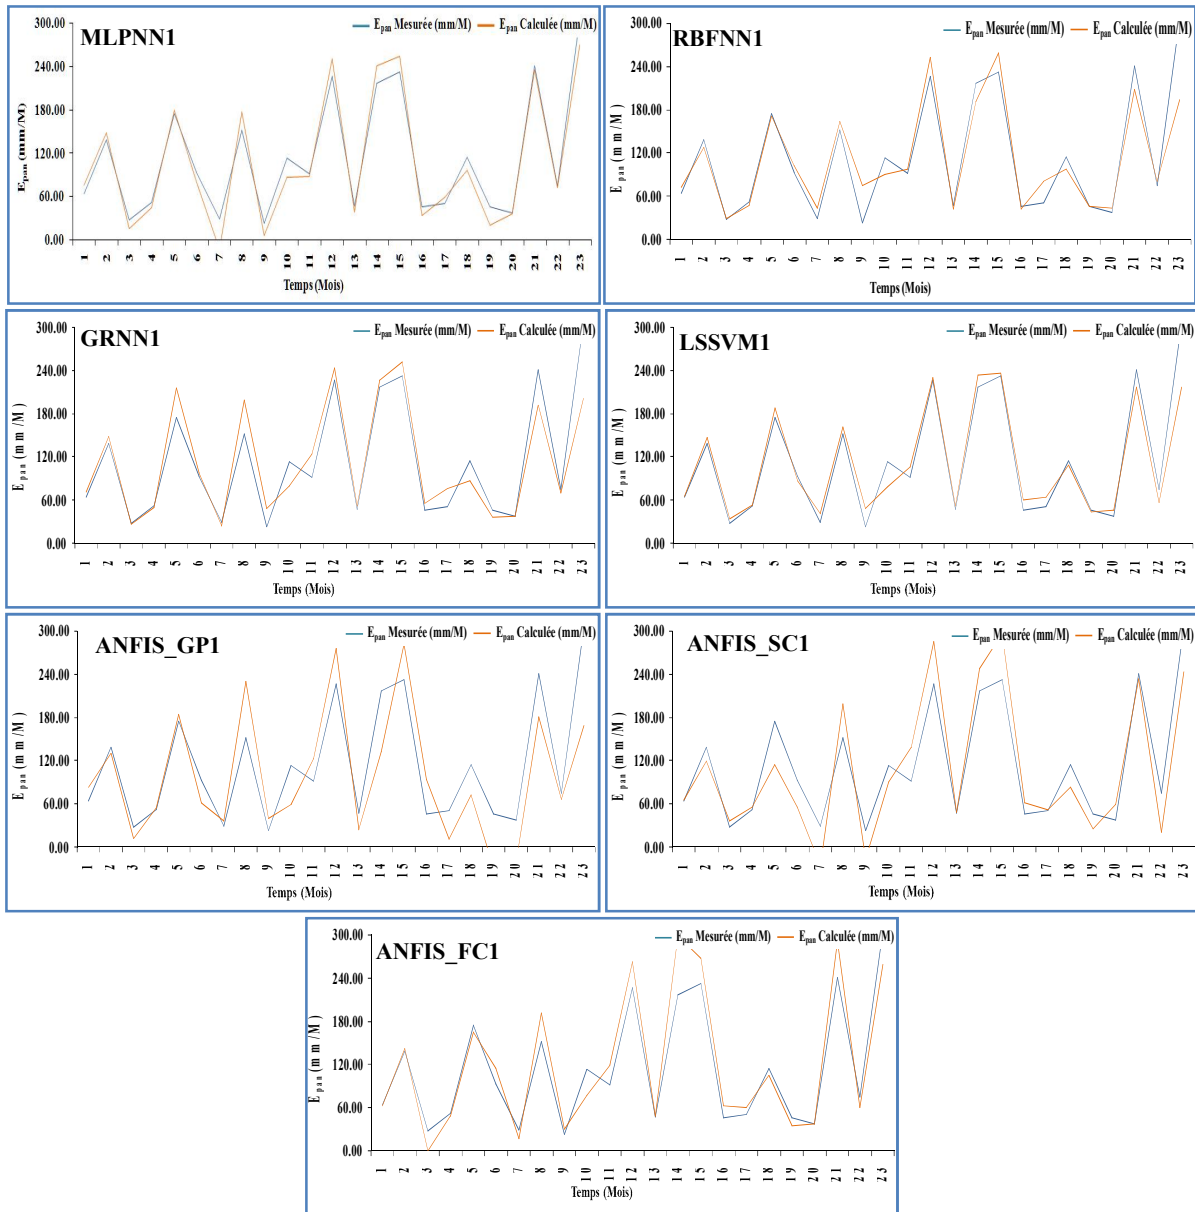


Figure V.12. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel : barrage Bouhamdane, phase de test.

Tableau V.12. Performances des modèles mensuels au niveau du Barrage *Bouhamdane*

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.992	0.995	10.405	7.935	0.950	0.972	25.761	18.497	0.980	0.987	18.903	15.609
MLPNN2	0.973	0.983	18.087	13.008	0.941	0.969	26.647	19.926	0.962	0.980	22.888	18.436
MLPNN3	0.976	0.988	16.098	10.993	0.927	0.961	31.268	21.458	0.955	0.972	28.714	22.321
MLPNN4	0.979	0.989	15.242	10.529	0.931	0.963	30.408	19.541	0.954	0.974	27.523	20.471
MLPNN5	0.936	0.966	26.257	17.599	0.944	0.969	26.017	20.960	0.938	0.968	28.173	19.690
MLPNN6	0.958	0.940	32.021	21.998	0.926	0.955	31.124	21.341	0.958	0.963	29.440	21.791
RBFNN1	0.975	0.987	16.387	12.058	0.934	0.938	32.843	26.638	0.932	0.958	30.077	18.919
RBFNN2	0.993	0.996	8.806	6.657	0.892	0.943	35.762	25.176	0.827	0.905	47.586	33.065
RBFNN3	0.986	0.993	12.271	9.367	0.847	0.891	59.819	40.736	0.864	0.923	46.708	33.144
RBFNN4	0.984	0.992	12.949	9.097	0.865	0.926	42.804	26.147	0.917	0.956	34.265	24.328
RBFNN5	0.959	0.978	21.021	13.217	0.893	0.944	36.809	29.048	0.722	0.824	73.267	41.119
RBFNN6	0.960	0.979	20.610	14.792	0.930	0.963	28.657	21.876	0.949	0.973	25.609	19.783
GRNN1	0.993	0.996	9.303	6.549	0.932	0.961	28.711	21.275	0.922	0.959	31.331	21.327
GRNN2	0.972	0.983	18.279	13.714	0.914	0.952	31.810	22.228	0.937	0.965	28.420	19.554
GRNN3	0.964	0.977	20.828	15.242	0.909	0.949	32.724	23.365	0.934	0.963	29.178	19.688
GRNN4	0.960	0.976	21.611	16.192	0.923	0.958	30.093	21.439	0.957	0.977	23.551	16.256
GRNN5	0.919	0.948	30.418	21.958	0.932	0.955	29.674	23.772	0.965	0.975	23.356	14.688
GRNN6	0.952	0.970	23.767	17.620	0.907	0.947	33.165	23.218	0.930	0.960	30.099	21.212
LSSVM1	0.978	0.985	17.564	12.543	0.942	0.966	26.814	20.084	0.961	0.977	23.156	14.659
LSSVM2	0.969	0.984	18.390	13.350	0.936	0.963	27.852	19.971	0.962	0.978	22.690	14.809
LSSVM3	0.968	0.983	18.813	13.592	0.938	0.965	27.482	19.205	0.961	0.977	22.986	14.750
LSSVM4	0.964	0.981	19.748	14.493	0.934	0.962	28.406	21.311	0.959	0.976	23.637	15.760
LSSVM5	0.926	0.960	28.066	18.710	0.936	0.962	28.211	21.998	0.963	0.978	22.645	14.795
LSSVM6	0.961	0.980	20.528	14.911	0.931	0.958	29.302	20.853	0.947	0.968	26.928	17.977
ANFIS_GP1	1.000	1.000	0.0002	0.0001	0.843	0.916	44.350	28.868	0.823	0.895	51.822	41.160
ANFIS_GP2	1.000	1.000	0.0006	0.0003	0.884	0.939	38.162	27.815	0.879	0.934	41.642	28.174
ANFIS_GP3	1.000	1.000	0.406	0.285	0.659	0.489	262.68	157.28	0.794	0.522	273.46	152.76
ANFIS_GP4	0.998	0.999	3.704	2.531	0.655	0.797	61.346	45.757	0.739	0.835	56.264	38.084
ANFIS_GP5	0.947	0.972	23.749	14.768	0.929	0.960	29.022	22.653	0.920	0.958	32.947	21.476
ANFIS_GP6	0.983	0.991	13.515	9.344	0.502	0.710	77.394	46.549	0.724	0.833	60.286	37.177
ANFIS_SC1	0.983	0.991	13.327	9.505	0.890	0.940	39.683	28.120	0.919	0.952	37.416	30.771
ANFIS_SC2	0.981	0.990	14.153	9.560	0.932	0.965	28.906	20.847	0.955	0.976	25.391	19.629
ANFIS_SC3	0.975	0.987	16.457	10.729	0.926	0.961	29.961	20.363	0.958	0.978	23.958	17.381
ANFIS_SC4	0.974	0.987	16.645	10.988	0.934	0.961	32.490	20.337	0.951	0.966	31.918	23.270
ANFIS_SC5	0.939	0.968	25.455	16.111	0.947	0.972	25.204	20.167	0.963	0.981	21.923	14.977
ANFIS_SC6	0.964	0.981	19.703	14.125	0.938	0.968	27.151	19.276	0.956	0.977	24.144	18.337
ANFIS_FC1	0.978	0.989	15.388	10.090	0.950	0.973	25.803	17.765	0.957	0.971	29.455	21.897
ANFIS_FC2	0.972	0.985	17.466	12.026	0.933	0.965	29.242	20.422	0.963	0.978	24.740	18.702
ANFIS_FC3	0.971	0.985	17.663	12.063	0.929	0.963	30.072	21.023	0.965	0.979	23.910	18.124
ANFIS_FC4	0.969	0.984	18.226	13.425	0.919	0.958	31.438	21.985	0.957	0.977	24.245	19.142
ANFIS_FC5	0.928	0.962	27.557	18.245	0.941	0.968	26.446	21.266	0.959	0.979	22.879	16.046
ANFIS_FC6	0.965	0.981	19.517	13.595	0.940	0.969	26.715	18.966	0.958	0.978	23.677	18.231

Notons que les résultats obtenus par le modèle ANFIS_SC sont meilleurs par rapport à ceux obtenus par le modèle ANFIS_GP avec un bon accord entre les valeurs des critères de performances durant les trois phases, à l'exception du modèle ANFIS_SC1 qui a enregistré une légère dégradation en phase de validation. En apprentissage, les performances des différents modèles sont très élevées avec d supérieur à 0.968 et MAE inférieur 16.111mm. En validation et en test, la valeur du critère d oscille entre 0.940 et 0.9814. Nous concluons que les résultats obtenus par le modèle ANFIS_SC sont très satisfaisant. Finalement, les modèle ANFIS_FC ont donnés des résultats meilleurs par rapport à ceux obtenus par les modèles ANFIS_GP et ANFIS_SC. On note que les différents modèles ayant différent combinaisons ont donnés des résultats similaire durant les trois phases, ce qui reflète le bon fonctionnement de ces modèles, avec R qui dépasse les 92.8% en apprentissage, et 91.9% en validation et en test.

V.2.6.1. Résultats récapitulatif des différents modèles pour barrage *Bouhamdane*

D'après les résultats obtenus par les différents modèles au niveau du barrage *Bouhamdane* on peut noter ce qui suit:

4. Notons que la majorité des modèles à cinq entrées donnent des résultats très acceptable avec R allant de 0.823 jusqu'à 0.980.
5. On observe que le modèle le plus performant est le modèle MLPNN1 avec (R=0.980 et MAE=15.609mm), et les plus faibles performances ont été obtenus par le modèle ANFIS_GP1 avec (R=0.823 et MAE=41.160mm).
6. Les modèles MLPNN, LSSVM, et ANFIS_FC, ont relativement les mêmes performances durant les trois phases.
7. Les mauvais résultats ont été obtenus avec les modèles ANFIS_GP3, ANFIS_GP4, ANFIS_GP6,

Table V.13. Résultats récapitulatif des meilleures modèles pour barrage *Bouhamdane*

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.980	0.987	18.903	15.609	01
RBFNN1	0.932	0.958	30.077	18.919	04
GRNN1	0.922	0.959	31.331	21.327	05
LSSVM1	0.961	0.977	23.156	14.659	03
ANFIS_GP1	0.823	0.895	51.822	41.160	07
ANFIS_SC1	0.919	0.952	37.416	30.771	06
ANFIS_FC1	0.957	0.971	29.455	21.897	02

V.2.1. Résultats de la modélisation pour le Barrage Ain Zada

Les résultats obtenus au niveau du barrage Ain Zada sont résumés dans le [Tableau V.15](#), et illustrés par les [Figure V.13-14](#). Notons que les différents modèles ont garanties des performances très élevées durant les trois phases. Pour les GRNN, on observe que tous les modèles, quel que soit le nombre d'entrées, donnent d'excellents résultats avec R entre 0.971 et 1.000 durant les trois phases, ce qui confirme la nécessité d'utiliser toutes les variables climatiques. En phase d'apprentissage, la valeur de R est supérieure à 0.969, et MAE inférieur

à 19.661mm. En validation et test les résultats sont relativement similaires à ceux obtenus en phase d'apprentissage avec R souvent supérieur à 0.971 et MAE inférieur à 20.159mm. Les résultats obtenus avec les modèles MLPNN étaient relativement similaire à celles obtenus avec les GRNN. Notons que toutes les architectures d'entrées apportent d'excellentes performances. En apprentissage la valeur de R est supérieure à 0.965 et MAE inférieur 23.754. Pour les phases de validation et de test, les résultats obtenus sont à égalités avec celles qu'en phase d'apprentissage avec R supérieur à 0.928.

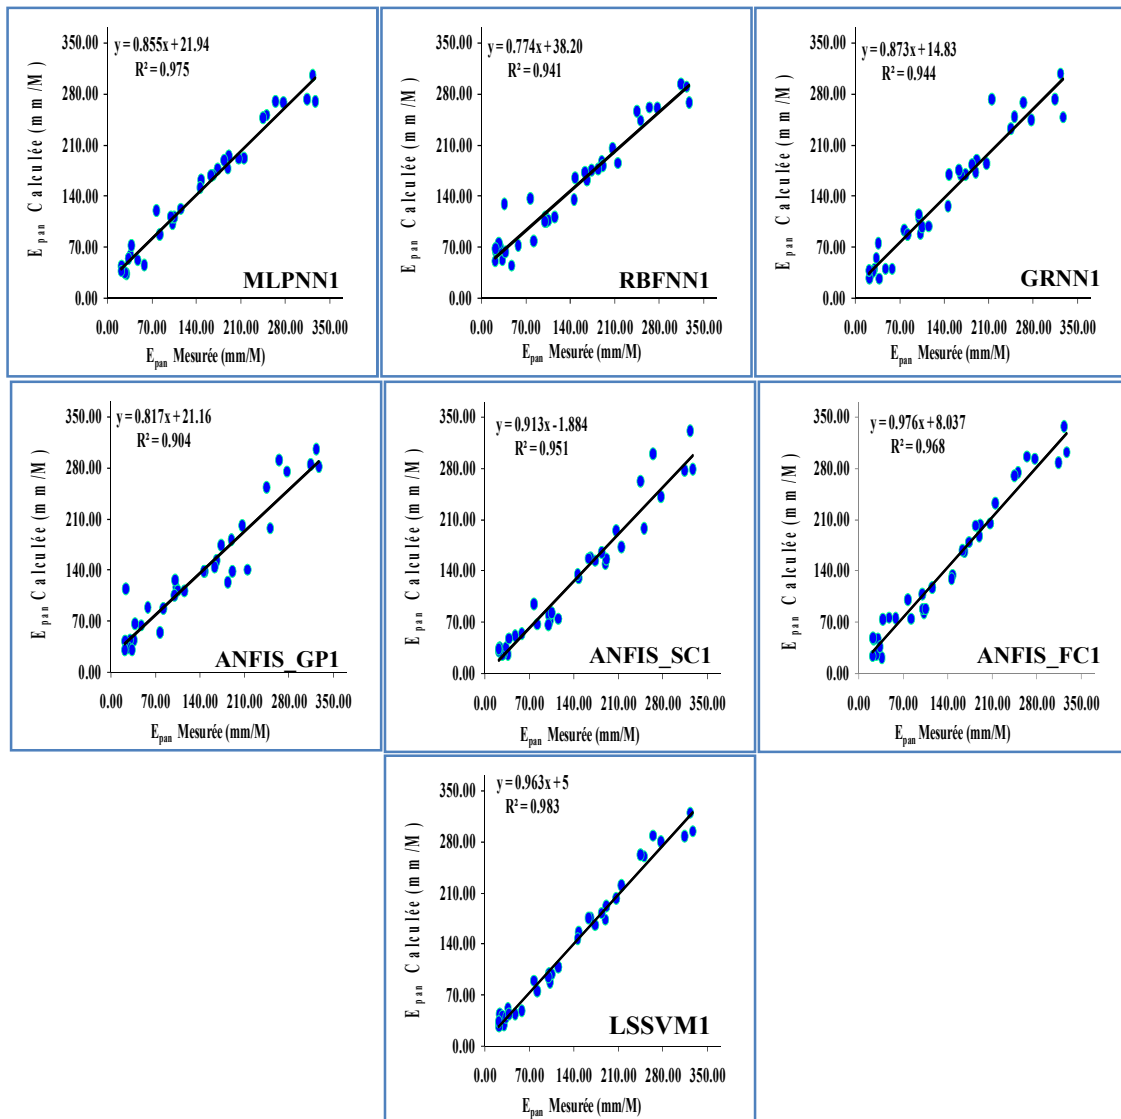


Figure V.13. Scatterplot des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel: barrage Ain Zada, phase de test.

Les valeurs de R obtenus par les modèles RBFNN étaient inférieures à celles obtenus par les MLPNN et GRNN en phases de validation et de test, mais dans l'ensemble les résultats obtenus par la technique RBFNN sont satisfaisants. En apprentissage, on remarque que les performances de tous les modèles sont très élevées, avec R varie de 0.971 à 0.997, et MAE

varie de 5.026mm à 17.824 mm. Les performances en validation et en test sont égales ou légèrement inférieures aux performances obtenues en apprentissage.

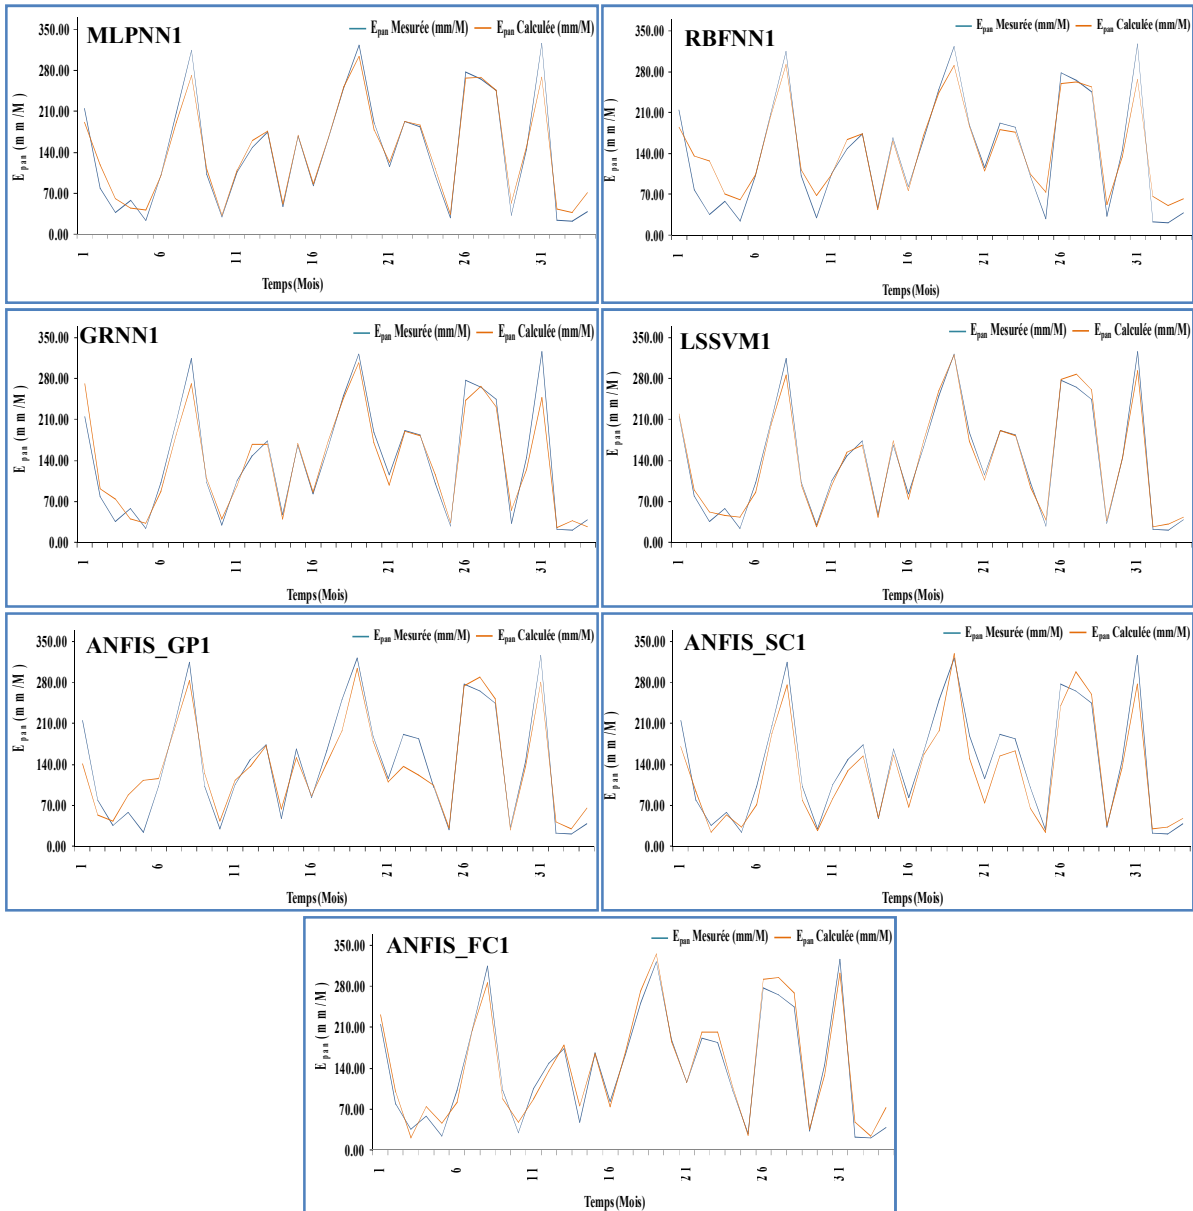


Figure V.14. Courbes de variations des valeurs des E_{pan} mesurées et calculées par les différents modèles au pas de temps mensuel : barrage Ain Zada, phase de test.

Les modèles LSSVM produisent d'excellentes performances comparativement à ceux de la méthode RBFNN, et largement meilleures que ceux relatifs à la technique GRNN et MLPNN. En effet, durant la période d'apprentissage, la valeur de R dépasse les 96.9% et MAE est inférieure à 18.597mm. En validation et test, les résultats obtenus sont similaires qu'en phase d'apprentissage avec R varie de 0.973 à 0.996 et MAE allant de 9.610mm à 18.280mm, on note que les meilleurs résultats ont été obtenus par le modèle LSSVM1, où toute les

variables ont été prise en compte, avec (R=0.995, MAE=6.640mm), (R=0.996, MAE=7.465 mm), (R=0.992, MAE= 9.610mm) respectivement.

Tableau V.14. Performances des modèles mensuels au niveau du Barrage Ain Zada

	Apprentissage (Calage)				Validation				Test			
	R	d	RMSE	MAE	R	d	RMSE	MAE	R	d	RMSE	MAE
MLPNN1	0.994	0.993	15.219	11.679	0.983	0.989	20.542	14.725	0.987	0.989	18.846	13.113
MLPNN2	0.990	0.995	13.396	10.485	0.972	0.985	24.636	18.534	0.989	0.990	17.669	13.910
MLPNN3	0.988	0.994	14.513	10.716	0.971	0.984	25.218	18.477	0.969	0.974	27.835	21.646
MLPNN4	0.983	0.992	17.291	13.846	0.978	0.989	21.934	15.501	0.977	0.988	20.332	15.617
MLPNN5	0.965	0.972	30.106	23.754	0.928	0.899	86.631	73.997	0.946	0.890	86.615	71.264
MLPNN6	0.969	0.984	23.691	17.369	0.973	0.986	24.217	18.790	0.971	0.984	22.661	17.045
RBFNN1	0.997	0.998	6.737	5.063	0.958	0.968	33.075	25.148	0.970	0.971	28.693	20.005
RBFNN2	0.997	0.998	6.626	4.836	0.967	0.983	26.240	21.119	0.944	0.961	34.221	25.105
RBFNN3	0.997	0.998	6.886	4.117	0.728	0.840	90.441	44.245	0.857	0.901	63.050	42.078
RBFNN4	0.997	0.998	6.746	5.026	0.957	0.977	30.327	24.471	0.940	0.953	35.912	27.847
RBFNN5	0.971	0.985	22.566	17.173	0.966	0.983	27.001	21.549	0.965	0.974	27.540	22.376
RBFNN6	0.971	0.985	22.596	17.824	0.964	0.977	30.146	26.126	0.952	0.969	30.653	22.091
GRNN1	1.000	1.000	2.582	1.468	0.973	0.985	25.438	19.633	0.972	0.983	23.505	16.897
GRNN2	0.995	0.997	9.709	7.235	0.977	0.988	22.290	17.991	0.983	0.984	22.003	16.439
GRNN3	0.986	0.993	16.002	12.419	0.977	0.988	22.290	17.991	0.983	0.984	22.003	16.439
GRNN4	0.983	0.991	17.474	13.655	0.984	0.992	18.353	14.501	0.979	0.988	19.900	16.353
GRNN5	0.979	0.989	19.686	15.545	0.984	0.992	18.639	14.370	0.980	0.989	19.385	16.533
GRNN6	0.969	0.983	24.033	19.661	0.973	0.986	23.938	18.808	0.971	0.984	23.062	20.159
LSSVM1	0.995	0.998	9.174	6.640	0.996	0.998	9.887	7.465	0.992	0.996	12.200	9.610
LSSVM2	0.988	0.994	14.711	11.392	0.984	0.992	18.770	13.912	0.988	0.993	15.257	12.002
LSSVM3	0.978	0.989	19.716	14.506	0.972	0.986	24.233	17.568	0.981	0.989	19.280	14.232
LSSVM4	0.980	0.990	19.046	15.002	0.985	0.992	18.468	14.111	0.981	0.990	18.360	14.637
LSSVM5	0.977	0.988	20.378	16.101	0.984	0.991	19.305	15.098	0.980	0.990	19.420	15.701
LSSVM6	0.969	0.984	23.400	18.597	0.973	0.986	24.643	18.280	0.974	0.987	21.273	17.416
ANFIS_GP1	1.000	1.000	0.0002	0.0001	0.961	0.979	28.831	21.091	0.951	0.968	30.801	21.925
ANFIS_GP2	1.000	1.000	0.010	0.006	0.928	0.963	39.185	31.603	0.902	0.945	43.408	33.138
ANFIS_GP3	0.999	0.999	1.925	1.144	0.492	0.519	232.85	102.54	0.770	0.856	78.846	56.129
ANFIS_GP4	0.995	0.997	8.997	6.653	0.866	0.925	60.059	32.003	0.878	0.933	45.495	30.981
ANFIS_GP5	0.987	0.993	15.088	11.492	0.972	0.985	25.335	17.263	0.956	0.976	27.594	22.170
ANFIS_GP6	0.983	0.991	17.493	13.348	0.949	0.974	33.225	22.119	0.927	0.961	35.843	24.390
ANFIS_SC1	0.998	0.999	6.027	4.300	0.967	0.965	39.935	31.894	0.975	0.980	25.411	20.754
ANFIS_SC2	0.990	0.995	12.970	10.190	0.964	0.981	27.649	21.633	0.985	0.990	17.611	13.446
ANFIS_SC3	0.984	0.991	16.967	12.816	0.961	0.979	28.790	19.815	0.983	0.987	19.675	14.986
ANFIS_SC4	0.981	0.990	18.242	14.623	0.984	0.992	18.421	13.403	0.979	0.989	19.211	16.266
ANFIS_SC5	0.977	0.988	20.246	16.047	0.983	0.991	18.986	14.616	0.980	0.989	18.638	15.305
ANFIS_SC6	0.976	0.987	20.629	16.424	0.971	0.985	24.851	17.357	0.972	0.984	22.470	18.878
ANFIS_FC1	0.992	0.996	11.309	7.996	0.961	0.978	30.945	27.806	0.984	0.991	17.490	14.753
ANFIS_FC2	0.984	0.992	16.693	12.894	0.981	0.990	20.206	15.972	0.984	0.991	17.070	14.512
ANFIS_FC3	0.976	0.988	20.499	15.965	0.966	0.982	26.826	20.836	0.979	0.985	21.128	16.328
ANFIS_FC4	0.979	0.989	18.990	15.768	0.983	0.991	18.494	14.414	0.980	0.988	19.271	15.963
ANFIS_FC5	0.977	0.988	20.242	16.049	0.983	0.991	18.987	14.596	0.981	0.989	18.630	15.291
ANFIS_FC6	0.968	0.983	23.718	19.306	0.973	0.986	23.861	18.508	0.972	0.985	22.088	19.083

L'analyse des résultats obtenus par les modèles ANFIS_GP indique que toutes les architectures assurent de bonnes performances sauf le modèle à trois entrées ANFIS_GP3 qui a donné de mauvais résultats en phase de validation. Les valeurs de R en apprentissage sont très élevées pour tous les modèles avec R (>98.3%), en validation et en test, on note une légère dégradation pour certains modèles avec R allant de 0.866 à 0.972, et les plus faibles performances ont été enregistrés avec le modèle ANFIS_GP3, avec R=0.492 et 0.770, respectivement. Finalement on peut dire que le modèle ANFIS_GP est moins performant par rapport aux LSSVM et MLPNN, mais les résultats obtenus par ce dernier sont acceptable. La comparaison des résultats obtenus montre que les valeurs des critères de performances des modèles ANFIS_SC et ANFIS_FC sont relativement égales durant les trois phases, et sont proches à celles obtenus par les modèles MLPNN et GRNN. En effet, pour la phase d'apprentissage R est souvent supérieur à 0.968 et MAE inférieur à 19.306mm. En phase de validation, les résultats obtenus confirment ceux obtenus en apprentissage avec R allant de (0.961 à 0.983) et (0.961 à 0.983), respectivement. En phase de test, les résultats obtenus sont sensiblement similaires qu'en phase de validation pour les deux modèles ANFIS_SC et ANFIS_FC. Donc nous concluons que les deux modèles ANFIS_SC et ANFIS_FC ont montrés une bonne précision dans l'estimation de l' E_{pan} mensuelle au niveau du barrage Ain Zada.

V.2.7.1. Résultats récapitulatif des différents modèles pour barrage Ain Zada

Au vu des résultats obtenus par les différents modèles au niveau du barrage Ain Zada on peut conclure ce qui suit:

1. Notons que tous les modèles à cinq entrées donnent d'excellents résultats durant la phase de test avec des performances très proches, la valeur de R est comprise entre 0.951 et 0.992.
2. Le modèle à cinq entrées LSSVM1 a enregistré les meilleurs résultats par rapport aux autres modèles, avec (R=0.992, MAE=9.610mm), suivi par, les modèles MLPNN1, ANFIS_FC1, ANFIS_SC1, GRNN1 et RBFNN1 respectivement alors que le modèle ANFIS_GP1 a fourni les plus faibles résultats.
3. Les valeurs des critères de performances obtenus étaient relativement égales, ce qui confirme l'importance de toutes les variables climatiques.
4. Les plus faibles résultats ont été obtenus par le modèle ANFIS_GP1.
5. Dans l'ensemble les meilleurs résultats ont été obtenus avec les modèles utilisant les quatre variables climatiques et la composante (M) (combinaison N°1).

Tableau V.15. Résultats récapitulatif des meilleures modèles pour barrage Ain Zada

Modèles	Phase de Test				Ordre
	R	d	RMSE	MAE	
MLPNN1	0.987	0.989	18.846	13.113	02
RBFNN1	0.970	0.971	28.693	20.005	06
GRNN1	0.972	0.983	23.505	16.897	05
LSSVM1	0.992	0.996	12.200	9.610	01
ANFIS_GP1	0.951	0.968	30.801	21.925	07
ANFIS_SC1	0.975	0.980	25.411	20.754	04
ANFIS_FC1	0.984	0.991	17.490	14.753	03

V.3. Conclusion

Dans ce chapitre, nous avons analysés et comparés les capacités et les performances des différents modèles (MLPNN, GRNN, RBFNN, LSSVM, ANFIS_GP, ANFIS_FC, ANFIS_SC) utilisés pour l'estimation de l' E_{pan} mensuelle mesurés au niveau des barrages réservoirs situées dans la région Nord-est Algérie. La sélection de variables d'entrée significatives pour les modèles a été réalisée à l'aide du technique gamma test GT. Les conclusions suivantes peuvent être élaborées:

- 1) La combinaison des quatre variables climatique (T_{min} , T_{max} , $H\%$, U_2) et la composante du calendrier Grégorien (M), a permis d'obtenir les meilleures résultats. On peut aussi dire que toutes ces variables contribuent significativement à l'estimation de l' E_{pan} mensuelle.
- 2) Les performances du modèle LSSVM1 se sont avérées meilleures que les modèles MLPNN1, GRNN1, RBFNN1, ANFIS_FC1, et ANFIS_SC1 au niveau des barrages Chafia, El Agram, et Ain Zada. Pour les barrages Beni Zid, Hammam Grouz, et Bouhamdane les meilleurs résultats ont été obtenus avec le modèle ANFIS_FC1, Le modèle MLPNN1 a donné de meilleurs résultats par rapport aux autres modèles au niveau du barrage Zit Emba.
- 3) Notons que le type d'échelle de temps a eu un effet significatif sur les performances des modèles. Pour cela les différents modèles développés (MLPNN, GRNN, RBFNN, LSSVM, ANFIS_GP, ANFIS_FC, ANFIS_SC) au pas du temps mensuel ont fourni d'excellents résultats par apport à ceux obtenus au pas du temps journalier.
- 4) Les résultats obtenus dans la présente cette étude peuvent être comparés avec les résultats d'autre région d'Algérie, en utilisant d'autres méthodes de modélisation et avec les formules empiriques.
- 5) Par conséquent, selon les résultats de la présente étude, on peut conclure que les modèles à base d'IA peuvent être utilisées de manière efficace pour la modélisation de l'évaporation mensuelle.

Conclusion Générale

Conclusion générale

La modélisation de l'évaporation est un problème hydrologique ancien et difficile à résoudre. Beaucoup de projets de recherche continuent l'étude de cette question et l'amélioration des réponses scientifique à cette problématique qui intervient dans le calcul de la régularisation des apports pour le dimensionnement des barrages et dans les calculs du bilan hydrique de la retenue pendant l'exploitation. De fait, la demande pour une estimation fiable est de plus en plus pressante. C'est dans cette optique que nous avons mené la présente recherche afin de répondre à cette demande, avec des approches prenant en compte les usages des praticiens. Pour cela, nous avons cherché à limiter d'une manière efficace les erreurs d'estimation de l'évaporation en développant des modèles opérationnels à base de l'intelligence artificielle (IA), à savoir les réseaux de neurones, les systèmes Neuro-flous et les machine à supports de vecteurs. Ces modèles basés sur des données Hydro-Climatologiques gérées en temps réel par les services ONM, ANBT, ANRH, et qui sont au nombre de cinq : les températures maximale et minimale de l'air (T_{\max} et T_{\min}), la vitesse du vent (U_2), l'humidité relative (H%), et l'évaporation mesurée dans le bac (E_{pan}). Ces modèles doivent être fiables, robustes, rapides et simples d'usage pour offrir les meilleurs résultats aux hydrologues dans des contextes d'exploitation différents. Nous avons réalisés notre travail à deux échelles de temps, journalier, et mensuel, au niveau de sept barrages réservoirs situé au Nord-Est de l'Algérie: (i) Beni Zid W-Skikda, (ii) Bouhamdane W-Guelma, (iii) Zit Emba W-Skikda, (iv) Hammam Grouz W-Constantine, (v) Ain Zada w-Sétif, (vi) El Agram W-Jijel, (vii) et Chafia W-El Taref. Atteindre les objectifs principaux de cette étude a exigé le passage par plusieurs étapes, chacune d'entre elles ayant un objectif principal indispensable pour réaliser l'étape suivante.

La première étape de ce travail était de réaliser une recherche épistémologique afin de connaître les différentes méthodologies utilisées pour réaliser les études sur ce sujet, nous avons consacré une étude bibliographique sur les concepts généraux de l'évaporation des eaux de surface, les facteurs physique et météorologiques conditionnant l'évaporation, et nous avons également présenté d'une manière générale quelques définitions relatives à l'évaporation et les différentes méthodes de mesure, soit les méthodes directes ou les méthodes indirectes utilisée pour la mesure de l'évaporation. En effet nous avons donné un bilan détaillé sur les méthodes de modélisation de l'évaporation. Dans ce contexte nous avons exposé les techniques de modélisation de l'évaporation les plus couramment utilisées dans la littérature publiés au cours de la période comprise entre 1997 et 2018, basés sur l'application des techniques de l'intelligence artificielles à savoir les réseaux de neurones artificiels, machines à vecteurs de support, les réseaux d'ondelettes, séries temporelles, neuro-floue et les algorithmes évolutionnaires.

Dans la deuxième partie nous avons donné un aperçu sur les outils de l'intelligence artificielle, qui nous permettront de faire une étude comparative (en simulation), dans la modélisation de l'évaporation, puis Nous avons exposé, les notions fondamentales de l'apprentissage et les réseaux de neurones, une description générale sur l'algorithme de Rétro-Propagation. Ensuite, nous avons mis l'accent en détails sur les modèles de calcul de base, leurs applications, leurs classes et leurs caractéristiques.

Dans le troisième nous avons réalisé l'analyse statistique et le traitement de bases des données climatiques utilisées dans cette étude. Ceci repose sur l'application de l'outil Gamma Test (GT). Enfin Nous avons démontré avec succès la capacité informative du Gamma test dans la sélection de variables pertinentes dans la construction de modèles non linéaires d'estimation de l'évaporation, et comme résultats nous avons retenu six modèles ayant différents entrés (inputs).

Dans les quatrième et cinquième chapitres nous avons présentés les résultats obtenus à pas de temps journalier et mensuelle, avec une comparaison entre tous les modèles utilisés dans la présente étude. Cette comparaison a été basée sur des critères de performance: R , d , RMSE, et MAE. Les résultats obtenus ont montrés l'intérêt de cette nouvelle méthodologie dans l'estimation de l'évaporation, ainsi que les limites de la technique IA. Au pas de temps journalier en phase de test, les résultats révèlent que les meilleures performances sont obtenues par le MLPNN avec les modèles (M1) ayant comme entrées toutes les variables climatiques et les composantes du calendrier grégorien au niveau des barrages Beni Zid, Chafia, Hammam Grouz, Ain Zada, avec un coefficient de corrélation R entre 0.87 et 0.93. Pour le barrage de Bouhamdane les meilleures performances ont été obtenues par le GRNN toujours avec les modèles M1, alors que le meilleur R obtenu était de l'ordre de (0.93). Nous notons également que le modèle LSSVM a fourni les meilleures performances au niveau de barrage Zit Emba avec un R de 0.82. Finalement pour le barrage EL Agram les meilleures performances sont obtenues par ANFIS_FC toujours avec les modèles M1 avec R de (0.83).

Au pas de temps mensuel, on enregistre d'excellents résultats obtenus par les différents modèles développés, alors que pour les barrages Zit Emba, et Bouhamdane, on note que les meilleures performances ont été obtenues par le MLPNN toujours avec les modèles M1, le meilleur R obtenu étaient de l'ordre de 0.95, et 0.98, respectivement. Le RBFNN a fourni les meilleures performances au niveau du barrage Hammam Grouz avec le modèle M1 avec R de 0.98. Aussi on note que le ANFIS_GP a fourni les meilleures performances au niveau des barrages Beni Zid et Chafia, toujours avec le modèle M1 avec un R de l'ordre de 0.97. Finalement pour les deux barrages EL Agram et Ain Zada, les meilleures performances ont été obtenues par ANFIS_FC et LSSVM respectivement, toujours avec les modèles M1 avec R de 0.95 et 0.97, respectivement.

Enfin, La qualité des résultats obtenus par les différentes approches de l'intelligence artificielle IA, au niveau des barrages réservoir existants dans la région nord-est d'Algérie, nous permet de conclure que les modèles journalier et mensuel appliqué permettent la modélisation du phénomène de l'évaporation avec succès. Ce type de modèles pourrait être utilisé comme outil de prédiction pour estimer la quantité d'eau évaporée et donc pour tout aménagement hydraulique que ce soit à l'échelle régionale qu'à l'échelle nationale. Ce qui aide à un développement durable des ressources en eau et par la suite un grand intérêt socio-économique du pays.

Références Bibliographique

Références Bibliographique

Abghari H., Ahmadi H., Besharat S., & Rezaverdinejad V. (2012). Prediction of daily pan evaporation using wavelet neural networks. *Water resources management*, 26(12), 3639-3652. <https://doi.org/10.1007/s11269-012-0096-z>

Agalbjörn S., Koncar N., Jones A.J. (1997). A note on the gamma test. *Neural Comput Appl* 5(3):131-133. <http://dx.doi.org/10.1007/>.

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, 332 p. <https://tel.archives-ouvertes.fr/tel-01661489/document>.

Ammar M.Y. (2007). Mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition batch/continu, DEA Procédés et Matériaux (ENSCI, Limoges), Ecole Nationale d'Ingénieurs de Sfax, Tunisie, 194 p. <http://ethesis.inp-toulouse.fr/archive/00000607/01/ammam.pdf>.

Arnaud P., Lavabre J. (1999). Etude de l'évaporation sur la retenue de Serre-Ponçon. Cemagref, Aix-en-Provence, 33pp.

Bazri K., Ouahrani G., Gheribi-Aoulmi Z., COSÍN, D.D. (2013). La diversité des lombriciens dans l'Est algérien depuis la côte jusqu'au désert. *Revue internationale d'écologie méditerranéenne International Journal of Mediterranean Ecology*, 39(2), 5. <https://www.ucm.es/data/cont/media/www/pag26131/2013.%20Bazri%20K%20et%20al.%20La%20diversit%C3%A9%20des%20lombriciens.pdf>.

Beltrando G. (2011). Les climats. Processus, Variabilité et Risques. Armand Colin, Paris, 286 p. <http://journals.openedition.org/tem/1671>

Benkaci T. (2006). Modélisation pluie-débit mensuelle et Journalière par les modèles conceptuels Et les systèmes neuro-flous, application aux bassins algériens. Thèse de doctorat Es Science. Institut National Agronomique D'Alger. 221 p.

Benzineb K. (2017). Modélisation des débits de crues du bassin d'oued ouahrane par les réseaux de neurones artificiels, Thèse de Doctorat, Université Hassiba Benbouali de Chlef, 158 p.

Bishop C. (1995). *Neural networks for pattern recognition*, Oxford University Press, 482 p. <https://dl.acm.org/doi/book/10.5555/525960>.

Blayo F., & Verleysen M. (1996). *Les réseaux de neurones artificiels*, Collection Que-sais-je?, PUF, 1^{re} Edition : 1996, Janvier, Presse Universitaire De France, 1996, 108, Boulevard Saint-Germain, 75006 Paris. ISBN 213 047355 5, 129 p.

Bouaziz M. (2017). Réseaux de neurones récurrents pour la classification de séquences dans des flux audiovisuels parallèles, thèse de doctorat, Avignon, 162 p.

Boutoutaou D. (1995). Evaporation des surfaces des plans d'eau des retenues et barrages en Algérie. Thèse de Doctorat PhD en Sciences Techniques. Institut d'Hydraulique. 200 p. Moscou.

Boutoutaou D. (1995). Méthode de calcul de la tension de vapeur d'eau saturante par la température et la tension de vapeur d'eau et de l'air au niveau des stations météorologiques. Annales de l'Institut de Recherche Agro-Industrie et Information (NIITEI). N° 150 BC-1995. Moscou.

Boutoutaou D. (2011). Note 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 Marbah Ouargla. PP 294-295.

Bruton J.M., McClendon R.W., Hoogenboom G. (2000). Estimating daily pan evaporation with artificial neural networks. Trans. ASAE 43 (2), 491-496. <https://doi.org/10.13031/2013.2730>.

Cherrad S.E. (1994). L'aménagement de l'espace rural en Algérie: Essai de bilan. In: Travaux de l'Institut Géographique de Reims, n°85-86, 1994. Etudes algériennes. pp. 39-48; doi : <https://doi.org/10.3406/tigr.1994.1301>.

Chiang Y.M., Li-Chiu C., Chang F.J. (2004). Comparison of static feed-forward and dynamic-feedback neural networks for rainfall-runoff modeling. Journal of Hydrology 290.297-311. <https://doi:10.1016/j.jhydrol.2005.03.010>

Chiu, S. L. (1994). Fuzzy model identification based on cluster estimation. Journal of Intelligent & Fuzzy Systems, 2(3), 267-278. <https://doi.org/10.3233/IFS-1994-2306>.

Chouai A. Cabassud M., Le Lann M.V., Gourdon C., Casamatta G., (2000). Use of neural networks for liquid-liquid extraction column modeling: an experimental study, Chemical Engineering and Processing, 39, pp. 171-180. [https://doi.org/10.1016/S0255-2701\(99\)00086-0](https://doi.org/10.1016/S0255-2701(99)00086-0)

Corcoran J.J., Wilson I.D., & Ware J.A. (2003). Predicting the geo-temporal variations of crime and disorder. International Journal of Forecasting, 19(4), 623-634. [https://doi.org/10.1016/S0169-2070\(03\)00095-5](https://doi.org/10.1016/S0169-2070(03)00095-5).

Dalton J. (1793). Meteorological observations and essays. W. Pennington, Kendal. <https://www.abebooks.co.uk/9781170125007/Meteorological-Observations-Essays-John-Dalton-117012500X/plp>.

Dalton J. (1802a). Experiments and observations to determine whether the quantity of rain and dew is equal to the quantity of water carried off by the rivers and raised by evaporation, with an enquiry into the origin of springs. Memoirs of the Society Literary and Philosophical Society of Manchester, vol. 5, part 2, 346-372., Royal Meteorological Society, 2003. <https://doi.org/10.1256/wea.202.02>

Dalton J. (1802b). Experimental essays on the constitution of mixed gases; on the force of steam or vapor from water and other liquids in different temperatures; both in a Torricelli and vacuum and in air; on evaporation; and on the expansion of gases by heat. *Memoirs of the Society Literary and Philosophical Society of Manchester*, vol. 5, part 2, 535-602. <https://www.worldcat.org/title/experimental-essays-on-the-constitution-of-mixed-gases-on-the-force-of-steam-or-vapour-from-water-and-other-liquids-in-different-temperatures-both-in-a-torricellian-vacuum-and-in-air-on-evaporation-and-on-the-expansion-of-gases/oclc/639955712>.

Dalton J. D.C.L., F.R.S., (1834). *Meteorological observations and essays*. Manchester Second Edition, 244 p. 2nd Edition, Manchester: Printed by Harrison and Crisfield for Baldwin and Cradock, 1834. <https://www.milestone-books.de/pages/books/002478/johnDalton/meteorological-observations-and-essays>.

Dams. (2000). World Commission on Dams. *Dams and development: A new framework for decision-making: The report of the world commission on dams*. Earthscan. Earthscan Publications Ltd, London and Sterling, VA. 404p. ISBN: 1-85383-798-9 paperback.n https://www.internationalrivers.org/sites/default/files/attachedfiles/world_commission_on_dams_final_report.pdf

Delgrange N., Cabassud C., Cabassud M., Durand-Bourlier L., Lainé J.M. (1998)., Neural networks for prediction of ultra-filtration trans membrane pressure - Application to drinking water production, *Journal of Membrane Science*, 150, pp. 111-123. [https://doi.org/10.1016/S0376-7388\(98\)00217-8](https://doi.org/10.1016/S0376-7388(98)00217-8).

Deo R.C., Samui P. (2017). Forecasting evaporative loss by least-square support-vector regression and evaluation with genetic programming, Gaussian process, and minimax probability machine regression: case study of Brisbane city. *ASCE Journal of Hydrologic Engineering* 22 (6): 05017003. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001506](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001506)

Deo R.C., Samui P., Kim D. (2016). Estimation of monthly evaporative loss using relevance vector machine, extreme learning machine and multivariate adaptive regression spline models. *Stochastic environmental research and risk assessment*, 30(6), 1769-1784. <https://doi.org/10.1007/s00477-015-1153-y>.

Deswal S., Mahesh Pal. (2008). Artificial Neural Network based Modeling of Evaporation Losses in Reservoirs. *Proc. of World Academy of Science, Engineering and Technology*, Vol.29, 279-283. file:///C:/Users/ADEM/Downloads/Artificial_neural_network_based_modeling.pdf.

D.G.F. (2004). Direction Générale Des Forêts. Programme d'Action National sur la lutte contre la désertification. M. A. D. R, 104 p. <http://www.dgf.org.dz/fr/content/missions-et-objectifs>

Djaidir B., Hafaiifa A., & Kouzou A. (2017). Vibration detection in gas turbine rotor using artificial neural network combined with continuous wavelet. In *Advances in Acoustics and Vibration* (pp. 101-113). Springer, Cham. https://doi.org/10.1007/978-3-319-41459-1_10.

- Djeffal A. (2012). Utilisation des méthodes Support Vector Machine (SVM) dans l'analyse des bases de données Thèse de doctorat, Département d'informatique, Université Mohamed Khider-Biskra, 180 p. <http://thesis.univ-biskra.dz/id/eprint/2097>
- Djellouli Y. (1990). Flores et climats en Algérie septentrionale : Déterminismes climatiques de la répartition des plantes, Thèse de doctorat, USTHB, Alger, 210 p.
- Dobson D. (1777). Observations on the annual evaporation at Liverpool in Lancashire ; and on evaporation considered as a test of the dryness of the atmosphere. Philosophical Transactions, LXVII, 244-259. <http://dx.doi.org/10.1098/rstl.1777.0014>.
- Dogan E., Gumrukcuoglu M., Sandalci M., & Opan M. (2010). Modeling of evaporation from the reservoir of Yuvacik dam using adaptive neuro-fuzzy inference systems. Engineering Applications of Artificial Intelligence, 23(6), 961-967. <https://doi.org/10.1016/j.engappai.2010.03.007>.
- Dreyfus D., Martinez J.M., Samuelides M., Gordon M. B., Badran F., Thiria S., Hérault L. (2004). Réseaux de neurones, méthodologie et applications, Eyrolles, 2^{ème} édition, 408p. https://www.eyrolles.com/Informatique/Livre/reseaux-de-neurones_9782212110197/#. (hal 01125016).
- Dreyfus G. (1998). Les Réseaux De Neurones. Mécanique Industrielle et Matériaux, N°51, École Supérieure de Physique et de Chimie Industrielles de la Ville de Paris (ESPCI), Laboratoire d'Électronique 10, rue Vauquelin 75005 paris. https://www.neurones.espci.fr/Articles_PS/GAMI.pdf
- Durrant P.J. (2001). WinGamma: a non-linear data analysis and modelling tool with applications to flood prediction. PhD thesis, Department of Computer Science, Cardiff University, Wales, UK, 261p. <http://users.cs.cf.ac.uk/O.F.Rana/Antonia.J.Jones/GammaArchive/Theses/PJDurrantThesis.pdf>
- Eslamian S.S., Gohari S.A., Biabanaki M., & Malekian R. (2008). Estimation of monthly pan evaporation using artificial neural networks and support vector machines. J Appl Sci, 8(19), 3497-3502. <https://doi.org/10.3923/jas.2008.3497.3502>.
- Evans, D., & Jones A.J. (2002). A proof of the Gamma test. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, 458(2027), 2759-2799. <https://doi.org/10.1098/rspa.2002.1010>.
- Fakhr-Eddine K. (1998). Elaboration d'un capteur logiciel à base de réseaux de neurones pour la régulation thermique et la conduite de réacteurs de LPCVD, Thèse de doctorat, I.N.P. Toulouse, 179p. <http://ethesis.inp-toulouse.fr/archive/00000607/01/ammr.pdf>.
- Fakhr-Eddine K., Cabassud M., Le Lann M.V., Couderc J.P. (1999). Application des réseaux de neurones à la modélisation des réacteurs de LPCVD : dépôt de silicium dopé in situ au bore, Chemical Engineering Journal, 72, pp. 171-182. [https://doi.org/10.1016/S1385-8947\(98\)00153-3](https://doi.org/10.1016/S1385-8947(98)00153-3).

Fakhr-Eddine K., Cabassud M., Le Lann M.V. et Couderc J.P. (2000). Neural Network Structures for Optimal Control of LPCVD Reactors, *Neural Computing & Applications*, 9, pp.172-180. <https://doi.org/10.1007/s005210070010>.

Fitzgerald D. (1886). Evaporation. *Van Nostrand's Engineering Magazine* (1879 1886), 35(211), 41. <https://library.si.edu/digital-library/book/van-nostrands-engineering-magazine>.

Funahashi K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks* 2, 183-214.

https://www.academia.edu/9573599/On_the_approximate_realization_of_continuous_mappings_by_neural_networks.

Galvan I.M. (1996). Zaldivar J. M., Hernandez H., Molga, E., The use of neural network for fitting complex kinetic data. *Computers Chemical Engineering*, 20(12), 1451-1465. [https://doi.org/10.1016/0098-1354\(95\)00231-6](https://doi.org/10.1016/0098-1354(95)00231-6).

Ghennai N. (2014). Etude des rapports et des corrélations entre le régime bioclimatique et les incendies de forêts. Mémoire de fin d'étude en vue de l'obtention du diplôme de Magister. Univ Constantine 1. 111 p, <https://bu.umc.edu.dz/theses/biologie/GHE6617.pdf>.

Ghorbani M. A., Deo R. C., Yaseen Z. M., Kashani M. H., Mohammadi B. (2017). Pan evaporation prediction using a hybrid multilayer perceptron-firefly algorithm (MLP-FFA) model: case study in North Iran. *Theor Appl Climatol*. <https://doi.org/10.1007/s00704-017-2244-0>.

Goyal M. K., Bharti B., Quilty J., Adamowski J., & Pandey A. (2014). Modeling of daily pan evaporation in sub-tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert systems with applications*, 41(11), 5267-5276. <https://doi.org/10.1016/j.eswa.2014.02.047>.

Grossberg S. (1988). Nonlinear neural networks: Principles, mechanisms, and architectures. *Neural networks*, 1(1), 17-61. [https://doi.org/10.1016/0893-6080\(88\)90021-4](https://doi.org/10.1016/0893-6080(88)90021-4).

Güven A., & Kisi Ö. (2011). Daily pan evaporation modeling using linear genetic programming technique. *Irrigation science*, 29(2), 135-145. <https://doi.org/10.1007/s00271-010-0225-5>.

Hafaifa A., Mouloud G., & Boulanouar S. (2016). Monitoring system based on real data acquisition for vibrations control in gas turbine system. *Nature & Technology*, (14), 13. *Revue « Nature & Technologie »*. A- Sciences fondamentales et Engineering, n° 14/ Janvier 2016. Pages 13 à 18 https://www.univ-chlef.dz/RevueNatec/issue-14/Article_A/Article349.pdf.

Halley E. (1691). On the circulation of the watery vapours of the sea and the origin of springs. *Philosophical Transactions of the Royal Society*, n° 192, 17, 468-473.

Halley E. (1694). An account of the evaporation of water as it was experimented in Gresham Colledge in the year 1693. With some observations thereon. *Philosophical Transactions of the Royal Society*, n° 212, 18, 183-190. <https://doi.org/10.1098/rstl.1694.0037>

Halley E. (1687). An estimate of the quantity of vapour raised out of the sea by the warmth of the sun; derived from an experiment shown before the Royal Society at one of their late meetings. *Philosophical Transactions of the Royal Society*, n° 189, 16, 468-473.

<https://www.jstor.org/stable/i206881>

Han H., and P. Felker. (1997). Estimation of daily soil water evaporation using an artificial neural network. *Journal of Arid Environments*. 37(2): 251-260.

<https://doi.org/10.1006/jare.1997.0269>.

Hani A., Lallahem S., Mania J., Djabri L. (2006). On the use of finite-difference and neural network models to evaluate the impact of underground water overexploitation. *Hydrol Process*. 20, 4381-4390. <https://doi.org/10.1002/hyp.6173>.

Haykin S. (1994). *Neural Networks, A comprehensive foundation*. Macmillan College Publishing Company, Inc. USA. 696 p. ISBN 10: 0023527617 / ISBN 13: 9780023527616, Published by NY: Macmillan College Publishing, 1994. <https://www.abebooks.com/first-edition/Neural-Networks-Comprehensive-Foundation-Haykin-Simon/890264239/bd>.

Haykin S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice-Hall, Inc., Upper Saddle River, N.J., 2nd edition, 842p. <https://www.worldcat.org/title/neural-networks-a-comprehensive-foundation/oclc/38908586>.

Hebb D.O. (1949). *The organization of behavior*, Wiley, New-york, Volume 50, Issues 5-6, November-December 1999, Page 437. [https://doi.org/10.1016/S0361-9230\(99\)00182-3](https://doi.org/10.1016/S0361-9230(99)00182-3)

Hines J., Tsoukalas L.H., & Uhrig R.E. (1997). *MATLAB supplement to fuzzy and neural approaches in engineering*. John Wiley & Sons, Inc. ISBN: 978-0-471-19247-3 June 1997 224 Pages. <https://www.wiley.com/engb/MATLAB+Supplement+to+Fuzzy+and+Neural+Approaches+in+Engineering-p-9780471192473>.

Hopfield J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558. <https://doi.org/10.1073/pnas.79.8.2554>.

Hornik K. (1991) Approximation capabilities of multilayer feedforward networks, *Neural Networks*, vol.4, pp. 251-257. [https://doi.org/10.1016/0893-6080\(91\)90009-T](https://doi.org/10.1016/0893-6080(91)90009-T).

Hornik K., Stinchcombe M., & White H. (1989). Multilayer feedforward neural networks are universal approximators. *Neural Networks* 2, 359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8).

Horton R.E. (1919). Rainfall interception. *Mon. Weather Rev.*, 47, 603-623. [https://doi.org/10.1175/1520-0493\(1919\)47<603:RI>2.0.CO2](https://doi.org/10.1175/1520-0493(1919)47<603:RI>2.0.CO2).

Jaafar W. W., & Han D. (2011). Variable selection using the gamma test forward and backward selections. *Journal of Hydrologic Engineering*, 17(1), 182-190. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000403](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000403)

Jang J.S.R. (1993). ANFIS: adaptive-network-based fuzzy inference system' IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23 No.3, pp. 665-685.
<https://doi.org/10.1109/21.256541>.

Jones, A.J., Tsui, A., & De Oliveira, A.G. (2002). Neural models of arbitrary chaotic systems: construction and the role of time delayed feedback in control and synchronization. Complexity international, 9(2002).<https://pdfs.semanticscholar.org/2644/d9c74565e26ddb089b630c371ab56c130919.pdf>

Keskin, M.E., Terzi, Ö. (2006). Artificial neural network models of daily pan evaporation. Journal of Hydrologic Engineering, 11(1), 65-70. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2006\)11:1\(65\)](https://doi.org/10.1061/(ASCE)1084-0699(2006)11:1(65)).

Kim S., Shiri J, Kisi O. (2012). Pan Evaporation Modeling Using Neural Computing Approach for Different Climatic Zones. Water Resour Manage 26:3231-3249.
<https://doi.org/10.1007/s11269-012-0069-2>.

Kim S., Kim H.S. (2008). Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. Journal of Hydrology. 351 (3-4), 299-317.<http://dx.doi.org/10.1016/j.jhydrol.2007.12.014>.

Kim S., Shiri J., Kisi O., Singh V.P. (2013). Estimating Daily Pan Evaporation Using Different Data-Driven Methods and Lag-Time Patterns. Water Resour Manage 27:2267-2286.
<https://doi.org/10.1007/s11269-013-0287-2>.

Kisi O. (2013). Evolutionary neural networks for monthly pan evaporation modeling. Journal of Hydrology 498:36-45. <http://dx.doi.org/10.1016/j.jhydrol.2013.06.011>.

Kisi O., & Tombul, M. (2013). Modeling monthly pan evaporations using fuzzy genetic approach. Journal of hydrology, 477, 203-212.<https://doi.org/10.1016/j.jhydrol.2012.11.030>.

Kisi O., & Tombul, M. (2013). Modeling monthly pan evaporations using fuzzy genetic approach. Journal of hydrology, 477, 203-212.<https://doi.org/10.1016/j.jhydrol.2012.11.030>.

Kisi O.(2006). Daily pan evaporation modelling using a neuro-fuzzy computing technique. Journal of hydrology, 2006, vol. 329, no 3-4, p. 636 646
<https://doi.org/10.1016/j.jhydrol.2006.03.015>.

Kohonen T. (1982)., Self organized formation of topologically correct feature maps, Biol Cybernetics, Vol. 43, pp. 59-69, (1982).

Koli B.Z. (2016). Initiation à l'hydrologie, Institut de Géographie Tropicale, Cours Licence 2 Et Fip 2 Géographie, 39p. <https://www.ufhb-igt.net/uplfile/ArticleFileUploaded/Hydrologie-format-dy-finitif-et-retenu-2016.pdf>.

Koncar N. (1997). Optimisation methodologies for direct inverse neurocontrol. PhD thesis, Department of Computing, Imperial College of Science, Technology and Medicine, University of London, 191p. <http://users.cs.cf.ac.uk/O.F.Rana/Antonia.J.Jones/Theses/NenadKoncarThesis.pdf>.

- Kuan, C.M., & White, H. (1994). Artificial neural networks: An econometric perspective. *Econometric reviews*, 13(1), 1-91. <https://doi.org/10.1080/07474939408800273>.
- Lafdani E.K., Nia A.M., & Ahmadi, A. (2013). Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478, 50-62. <https://doi.org/10.1016/j.jhydrol.2012.11.048>.
- Lallahem S., & Mania J. (2003). A nonlinear Rainfall-Runoff Model using Neural Network Technique: Exemple in Fractured Porous Media. *Mathematical and Computer Modelling* 37. 1047-1061. [https://doi.org/10.1016/S0895-7177\(03\)00117-1](https://doi.org/10.1016/S0895-7177(03)00117-1).
- Lambert R. (1996). *Géographie du cycle de l'eau*. Presses Universitaires du Mirail, Toulouse, 439 p. ISSN : 1764-9169, ISSN : 2-858161-273-5.
- Lauer F., Bloch G. (2006). Méthodes SVM pour l'identification, in: Journées Identification Et Modélisation Expérimentale, JIME'2006, Poitiers, France, p. CDRom. [hal-00110344](https://hal.archives-ouvertes.fr/hal-00110344) <https://hal.archives-ouvertes.fr/hal-00110344>.
- Legates, D.R., McCabe Jr, G.J. (1999). Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), 233-241. <https://doi.org/10.1029/1998WR900018>.
- Linacre E.T. (1977). A simple formula for estimating evaporation rates in various climates, using temperature data alone. *Agricultural Meteorology*, 18: 409-424. [https://doi.org/10.1016/0002-1571\(77\)90007-3](https://doi.org/10.1016/0002-1571(77)90007-3)
- Linacre E.T. (1994). Estimating U.S. Class-A pan evaporation from few climate data. *Water International*, 19: 5-14. <https://doi.org/10.1080/02508069408686189>.
- Lippman R.P. (1987). An Introduction to Computing with Neural Nets, *IEEE ASSP Magazine*, pp.4-22. [Doi: 10.1109/MASSP.1987.1165576](https://doi.org/10.1109/MASSP.1987.1165576)
- LLamas J.M.(1993). *Hidrologia general: Principios y aplicaciones*/José Llamas. Univ. Pais Vasco. 1ª Edición / Rústica / Castellano / Libro, 636p, ISBN 9788475854359. <https://www.agapea.com/libros/Hidrologia-general-Principios-y-aplicaciones-9788475854359-i.htm>
- Maidemnt D.R. (1993). *Handbook of hydrology* (Vol. 9780070, p. 397323). New York: McGraw-Hill. ISBN-10: 0070397325, ISBN-13: 978-0070397323. <https://www.amazon.fr/Handbook-Hydrology-David-R-Maidment/dp/0070397325>.
- Makkink, G.F. (1957). Testing the Penman formula by means of Lysimeters. *J. Instn Wat. Engrs*, 11: 277-288. NII Article ID (NAID) 10025640651. <https://ci.nii.ac.jp/naid/10025640651/#cit>.
- Malik A., Kumar A. (2015). Pan Evaporation Simulation Based on Daily Meteorological Data Using Soft Computing Techniques and Multiple Linear Regression. *Water Resour Manage* 29:1859-1872. <http://dx.doi.org/10.1007/s11269-015-0915-0>.

- Malik A., Kumar A., Rai P. (2018). Weekly pan-evaporation simulation using MLP, CANFIS, MLR and Climate based models at Pantnagar. *Indian Journal of Ecology* 45 2 143: 292-298. <http://indianecologicalsociety.com/society/wp-admin/pdf/p10.pdf>.
- Mc Culloch W.S., Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity, *Bulletin of Math. Biophysics*, vol.5, pp. 115-133. <https://doi.org/10.1007/BF02478259>.
- McCarthy J. (1956). The inversion of functions defined by Turing machines. *Automata studies*, 177-181, Princeton University Press. <http://jmc.stanford.edu/articles/inversion/inversion.pdf>
- Mebarki A. (2005). Hydrologie des bassins de l'Est-algérien : ressources en eaux, aménagement et environnement, Thèse de doctorat d'état, Université Constantine 1 ex Mentouri, 360p. <http://www.univ-tebessa.dz/fichiers/umc/MEBARKI1.pdf>.
- Mebarki A. (2010). Apport des cours d'eau et cartographie du bilan hydrologique: cas des bassins de l'Algérie orientale. *Science et changements planétaires/Sécheresse*, 21(4), 301-308. <http://dx.doi.org/10.1684/sec.2010.0265>.
- Meyer A.F. (1915). Computing runoff from rainfall and other physical data. *Transactions of the American Society of Civil Engineers*, 78(2), 1056-1155. <https://cedb.asce.org/CEDBsearch/record.jsp?dockey=0355095>.
- Meyer A.F. (1942). Evaporation from lakes and reservoirs: Minnesota resources comm. St. Paul, Minn.
- Minsky, M., Papert, S. A. (2017). *Perceptrons: An introduction to computational geometry*. MIT press, 316p. ISBN-10: 0262534770, ISBN-13: 978-0262534772. <https://www.amazon.com/Perceptrons-MIT-Press-Introduction-Computational/dp/0262534770>.
- Moghaddamnia A., Gousheh M.G., Piri J., Amin S., Han D. (2009a) Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Adv. Water Resour* 32(1):88-97. <https://doi.org/10.1016/j.advwatres.2008.10.005>.
- Moghaddamnia A., Remesan R., Kashani M. H., Mohammadi M., Han D., & Piri, J. (2009b). Comparison of LLR, MLP, Elman, NNARX and ANFIS Models-with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71(8-9), 975-982. <https://doi.org/10.1016/j.jhydrol.2011.02.021>.
- Moody J., Darken C.J. (1989). Fast learning in networks of locally-tuned processing units. *Neural computation*, 1(2), 281-294. ISSN: 0899-7667E-ISSN: 1530-888X. <https://doi.org/10.1162/neco.1989.1.2.281>.
- Morton F.I. (1983). Operational estimates of lake evaporation. *Journal of Hydrology*, 66, 77-100. [https://doi.org/10.1016/0022-1694\(83\)90178-6](https://doi.org/10.1016/0022-1694(83)90178-6).
- Morton F.I. (1967). Evaporation from large deep lakes. *Water Resources Research*, 3(1): 181-200. <https://doi.org/10.1029/WR003i001p00181>.

- Morton F.I. (1979). Climatological estimates of lake evaporation. *Water Resources Research*, 15(1): 64-76. <https://doi.org/10.1029/WR015i001p00064>.
- Morton F.I. (1983a). Operational estimates of areal evapotranspiration and their significance to the science and practice of hydrology. *Journal of Hydrology*, 66(1-4): 1-76. [https://doi.org/10.1016/0022-1694\(83\)90177-4](https://doi.org/10.1016/0022-1694(83)90177-4).
- Morton F.I. (1983b). Operational estimates of lake evaporation. *Journal of Hydrology*, 66(1-4) : 77-100. [https://doi.org/10.1016/0022-1694\(83\)90178-6](https://doi.org/10.1016/0022-1694(83)90178-6).
- Morton F. I. (1986). Practical estimates of lake evaporation. *Journal of Climate and Applied Meteorology*, 25(3): 371-387. [https://doi.org/10.1175/1520-0450\(1986\)025<0371:PEOLE>2.0.CO;2](https://doi.org/10.1175/1520-0450(1986)025<0371:PEOLE>2.0.CO;2).
- MRE. (2019). Ministère des Ressources en Eau. <http://www.mre.gov.dz/>
- Musy A. (2005). Cours « Hydrologie générale » Laboratoire d'Hydrologie et Aménagements (HYDRAM) Institut des Sciences et Technologies. Ecole polytechnique fédérale de Lausanne. <https://echo2.epfl.ch/e-drologie/general/tmchapitres.html>.
- Nedjraoui D. (2003). Profil fourrager de l'Algérie. Université des Sciences et de la Technologie, Houari Boumediene, Alger. 30 p.
- Noori R., Karbassi A.R., Moghaddamnia A., Han D., Zokaei-Ashtiani M.H., Farokhnia, A., & Gousheh, M.G. (2011). Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*, 401(3-4), 177-189. <https://doi.org/10.1016/j.jhydrol.2011.02.021>.
- Oliveira A.G. (1999). Synchronization of chaos and applications to secure communications. PhD thesis, Department of Computing, Imperial College of Science, Technology and Medicine, University of London.
- OMM. (2003). Manual on the global observing system. Volume 1, WMO-No. 544, Geneva. ISBN 92-63-13544-4. <https://www.wmo.int/pages/prog/www/OSY/Manual/WMO544.pdf>.
- ONM. (2015). Office National Météorologique, synthèse de données climatiques. <https://www.meteo.dz/climatenalgerie.php>.
- Ozlem T., Erol Keskin M. (2005). Modeling of daily pan evaporation. *Journal of applied sciences* 5 (2), 368-372. <https://doi.org/10.3923/jas.2005.368.372>.
- Pammar L., Deka, P. C. (2017). Daily pan evaporation modeling in climatically contrasting zones with hybridization of wavelet transforms and support vector machines. *Paddy and water environment*, 15(4), 711-722. <https://doi.org/10.1007/s10333-016-0571-x>

- Parizeau M. (2004). Le perceptron multicouche et son algorithme de rétro-propagation des erreurs. Département de génie électrique et de génie informatique, Université de Laval, 8p.
<https://reussirlem1.info.files.wordpress.com/2012/05/mlp.pdf>.
- Parizeau M. (2004). Réseaux de neurones. GIF-21140 et GIF-64326, 127p. Département de génie électrique et de génie informatique, Université de Laval.
http://frostiebek.free.fr/docs/Reseaux%20de%20neurones/RNF_fzzy.pdf.
- Penman H.L. (1948). Natural evaporation from open water, bare soil and grass. *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, 193(1032), 120-145. Print ISSN:0080-4630, Online ISSN:2053-9169. <https://doi.org/10.1098/rspa.1948.0037>.
- Poggio T., Girosi F. (1990). Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, 247(4945), 978-982.pp. 12-14.
Doi: [10.1126/science.247.4945.978](https://doi.org/10.1126/science.247.4945.978).
- Press W.H., Teukolsky S.A., Vetterling W.T., Flannery B.P. (1992). *Numerical Recipes in C: the Art of Computing*, Cambridge University Press, 40 W. 20 St. New York, NY, United States ISBN: 978-0-521-43108-8.
https://www.cec.uchile.cl/cinetica/pcordero/MC_libros/NumericalRecipesinC.pdf.
- Priestley, C.H.B., Taylor, R.J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly weather review*, 100(2), 81-92.
[https://doi.org/10.1175/1520-0493\(1972\)100<0081:OTAOSH>2.3.CO2](https://doi.org/10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO2).
- Raham D. (2001). Les structures spatiales de l'Est-algérien : les maillages territoriaux, urbains et routiers. Thèse de Doctorat d'Etat. Université Constantine 1 ex Mentouri, 279p.
<https://tel.archives-ouvertes.fr/tel-00288867>.
- Remesan R., & Mathew J. (2016). *Hydrological data driven modelling*. Springer International Pu.
<https://doi.org/10.1007/978-3-319-09235-5>.
- Remesan R., Shamim M.A., & Han D. (2008). Model data selection using gamma test for daily solar radiation estimation. *Hydrological Processes*, 22(21), 4301-4309.
<https://doi.org/10.1002/hyp.7044>.
- Riad S. (2003). Typologie et analyse hydrologique des eaux superficielles à partir de quelques bassins versants représentatifs du Maroc, Université Lille1-Sciences et Technologies,
<http://orinuxeo.univ-lille1.fr/nuxeo/site/esupversions/e5d351a6-ce4c-4b64-b891-84d85f3d8f02>.
- Riou C. (1975). La détermination pratique de l'évaporation. Application à l'Afrique centrale, Paris, Mémoire ORSTOM n°80, 228 p. MEM. O.R.S.T.O.M.; FR.; DA. 1975; NO 80; PP. 1-236; BIBL. 2 P.; ISBN 2709903695
<http://pascal-francis.inist.fr/vibad/index.php?action=getRecordDetail&idt=PASCAL7630211176>
- Riou C. (1967). Calcul de l'évaporation par la méthode du bilan énergétique en zone sahélienne. *Cahiers ORSTOM, série Hydrologie*, 4 (2) : 37-46. ISSN 0008-0381.

http://horizon.documentation.ird.fr/exl-doc/pleins_textes/pleins_textes_4/hydrologie/14841.pdf
<http://www.documentation.ird.fr/hor/fdi:14841>

Riou C. (1970). Evaporation en bac et évapotranspiration potentielle. Expression de l'évaporation d'une petite nappe d'eau en fonction des données sous abri. Cahiers ORSTOM, série Hydrologie, 7 (3) : 73-87. <https://doi.org/10.1080/02626667109493048>

Riou C. (1977). Remarques sur l'évaporation des surfaces naturelles et son évaluation. La Météorologie, 6(11) : 17-23.

Roche M. (1963). Hydrologie de surface, Villars Editeur, Paris : Gauthier-Villars; ORSTOM, 430 p. http://horizon.documentation.ird.fr/exl-doc/pleins_textes/divers09-11/02081.pdf.

Rohwer E. (1931). Evaporation from free water surfaces. United States Department of Agriculture Technical Bulletin, No. 271, 96 p. <https://naldc.nal.usda.gov/download/CAT86200265/PDF>

Romanenko, V.A. (1961). Computation of the autumn soil moisture using a universal relationship for a large area. *Proc. of Ukrainian Hydrometeorological Research Institute*, 3, 12-25.

Rosenblatt F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>.

Rumelhart D.E. (1986). Parallel distributed processing: Explorations in the microstructure of cognition. Learning internal representations by error propagation, 1, 318-362. NII Article ID (NAID) 10020896998.

Rumelhart D.E., Hinton G.E., Williams R.J. (1986). Learning Internal Representations by Error Propagation: Parallel Distributed Processing: Explorations in the Microstructures of Cognition. MIT Press, Cambridge, pp. 318-362. <https://apps.dtic.mil/dtic/tr/fulltext/u2/a164453.pdf>.

Salehnia N., Falahi M.A., Seifi A., & Adeli M.H.M. (2013). Forecasting natural gas spot prices with nonlinear modeling using Gamma test analysis. *Journal of Natural Gas Science and Engineering*, 14, 238-249. <https://doi.org/10.1016/j.jngse.2013.07.002>.

Sanikhani H., Kisi O., Nikpour M. R., & Dinpashoh Y. (2012). Estimation of daily pan evaporation using two different adaptive neuro-fuzzy computing techniques. *Water Resources Management*, 26(15), 4347-4365. <https://doi.org/10.1007/s11269-012-0148-4>.

Sanikhani H., Kisi O., Nikpour M.R., & Dinpashoh, Y. (2012). Estimation of daily pan evaporation using two different adaptive neuro-fuzzy computing techniques. *Water Resources Management*, 26(15), 4347-4365. <https://doi.org/10.1007/s11269-012-0148-4>.

Sayed T., Tavakolie A., & Razavi A. (2003). Comparison of adaptive network based fuzzy inference systems and B-spline neuro-fuzzy mode choice models. *Journal of computing in civil engineering*, 17(2), 123-130. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2003\)17:2\(123\)](https://doi.org/10.1061/(ASCE)0887-3801(2003)17:2(123))

- Seghouane A.K., & Fleury G. (2003). Apprentissage de réseaux de neurones à fonctions radiales de base avec un jeu de données à entrées-sorties bruitées. *Traitement du Signal*, 20(4), 414. ISSN: 0765-0019. <https://documents.irevues.inist.fr/bitstream/handle/2042/2240/Seghouane.pdf?sequence=1>.
- Shalamu A. S., Cui C., King J. P., Moreno J., & Bawazir, A. S. (2011). Modeling of daily pan evaporation using partial least squares regression. *Science China technological sciences*, 54(1), 163-174. <https://doi.org/10.1007/s11431-010-4205-z>.
- Shirsath P.B., Singh A.K. (2010). A comparative study of daily pan evaporation estimation using ANN, regression and climate based models. *Water Resour Manag* 24:1571-1581. <https://doi.org/10.1007/s11269-009-9514-2>.
- Simon L.L., Hunger Buhler, K. (2010). Industrial batch dryer data mining using intelligent pattern classifiers: neural network, neuro-fuzzy and Takagi-Sugeno fuzzy models. *Chemical Engineering Journal*, 157(2-3), 568-578. <https://doi.org/10.1016/j.cej.2010.01.018>.
- Singh V.P., Xu C.Y. (1997). Evaluation and generalization of 13 mass-transfer equations for determining free water evaporation. *Hydrological Processes*, 11, 311-323. [https://doi.org/10.1002/\(SICI\)1099-1085\(19970315\)11:3<311::AID-HYP446>3.0.CO;2-Y](https://doi.org/10.1002/(SICI)1099-1085(19970315)11:3<311::AID-HYP446>3.0.CO;2-Y).
- Sivapragasam, C., Pallikonda Rajasekaran, M., & Vinotha, M. (2017). A conceptual framework for real time estimation of WFP for small hydroelectric power plant. *Water Policy*, 19(6), 1049-1062. <https://doi.org/10.2166/wp.2017.289>.
- Stan F-L., Neculau G., Zaharia L., Ioana-Toroimac G., Mihalache S., (2016). Study on the evaporation and evapotranspiration measured on the Caldarusani Lake (Romania). *Procedia Environmental Sciences*, 32, 281-289. <https://doi.org/10.1016/j.proenv.2016.03.033>
- Stan F-L., Zaharia L., Neculau G., Ioana-Toroimac G. (2015). Variabilité spatiale et temporelle de l'évaporation dans la Plaine roumaine. Actes du Colloque de l'Association Internationale de Climatologie, 28, 621-626.
- Stefánsson A., Končar N., & Jones A. J. (1997). A note on the gamma test. *Neural Computing & Applications*, 5(3), 131-133. <https://doi.org/10.1007/BF01413858>.
- Tan, S. B. K., Shuy, E.B., & Chua, L.H.C. (2007). Modelling hourly and daily open-water evaporation rates in areas with an equatorial climate. *Hydrological Processes: An International Journal*, 21(4), 486-499. <https://doi.org/10.1002/hyp.6251>
- Segal L., Burstein L. (2010). Retardation of water evaporation by a protective float. *Water resources management*, 24(1), 129. <https://doi.org/10.1007/s11269-009-9440-3>.
- Stephens J.C., Stewart, E.H. (1963). A comparison of procedures for computing evaporation and evapotranspiration. Intern. Assoc. Sci. Hydrol., Trans. Intern. Union of Geodesy and Geophysics. Barkley, California, USA. (62):123-136. https://iahs.info/uploads/dms/iahs_062_0123.pdf

- Sudheer K.P., Gosain A. K., Rangan D. M., Saheb, S.M., (2002). Modelling evaporation using an artificial neural network algorithm. *Hydrological Processes* 16 (16), 3189-3202. <https://doi.org/10.1002/hyp.1096>.
- Sudheer, K. P., Gosain, A. K., Mohana Rangan, D., & Saheb, S. M. (2002). Modelling evaporation using an artificial neural network algorithm. *Hydrological Processes*, 16(16), 3189-3202. <https://doi.org/10.1002/hyp.1096>
- Tabari H., Marofi S., Sabziparvar A.(2010). Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Int 9*, p. tsui01:1-9 *Irrig Sci* 28:399-406. <https://doi.org/10.1007/s00271-009-0201-0>.
- Tabet S. (2008). Le changement climatique en Algérie orientale et ses conséquences sur la végétation forestière, Mémoire Magister, Université Constantine 1 ex Mentouri, 125 p.
- Tebbi F.Z. (2014). Modélisation de la régularisation des barrages dans la région des Aurès. Doctorat En Sciences, Université Hadj Lakhdar Batna, 140p.
- Touzet C. (1992). Les réseaux de neurones artificiels. Introduction au connexionnisme. Cours, exercice et travaux pratiques, Collection de l'EERIE, N. Giambiasi. hal-01338010.
- Terzi O., Erol Keskin, M., & Dilek Taylan, E.(2006). Estimating evaporation using ANFIS. *Journal of Irrigation and Drainage Engineering*, 132(5), 503-507. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2006\)132:5\(503\)](https://doi.org/10.1061/(ASCE)0733-9437(2006)132:5(503))
- Tschirhart F. (2010). Réseaux de neurones formels appliqués à l'intelligence artificielle et au jeu, Mémoire de recherche. École supérieure de génie informatique, 127p,
- Tsui A.P., Jones A.J., & De Oliveira, A.G. (2002). The construction of smooth models using irregular embeddings determined by a gamma test analysis. *Neural Computing & Applications*, 10(4), 318-329. <https://doi.org/10.1007/s005210200004>.
- Turc L. (1954). Le bilan de l'eau des sols : relations entre les précipitations, l'évaporation et l'écoulement. Thèse de docteur ès Sc. Physiques, Inra éditions, Paris, 252 p.
- Vachala S. (2008). Évaporation sur les retenues EDF du Sud de la France. Université Pierre et Marie Curie, Mémoire de Master Sciences de l'Univers, Écologie et Environnement Parcours Hydrologie Hydrogéologie, 50 p.
- Vapnik, V.N. (1998). *Statistical Learning Theory*. John Wiley & Sons Inc, 732p, ISBN: 978-0-471-03003-4. <http://read.pudn.com/downloads161/ebook/733192/Statistical-Learning-Theory.pdf>
- Vapnik V.N. (1999a). *The Nature of Statistical Learning Theory*, 2nd ed. Springer, 314p ISBN 978-1-4757-3264-1.

- Vapnik V.N. (1999b). An overview of statistical learning theory. *IEEE Transactions on Neural Networks* 10, 988-999p. PMID: 18252602. <https://doi.org/10.1109/72.788640>.
- Viennet E. (2006). Réseaux à fonctions de base radiales. Younes Bennani. *Apprentissage connexionniste*, Lavoisier, pp.105, 2006, I2C Hermès. (hal-00085092). <https://hal.archives-ouvertes.fr/hal-00085092>.
- Wang L., Kisi O., Zounemat-Kermani M., Li H. (2017b). Pan Evaporation modeling using six different heuristic computing methods in different climates of China. *Journal of Hydrology* 544:407-427. <http://dx.doi.org/10.1016/j.jhydrol.2016.11.059>.
- Wang L., Kisi O., Zounemat-Kermani M., Gan Y. (2016). Comparison of six different soft computing methods in modeling evaporation in different climates. *Hydrol. Earth Syst. Sci. Discuss.* <https://doi.org/10.5194/hess-2016-247>.
- Wang L., Niu Z., Kisi O., Li C., Yu D. (2017a). Pan evaporation modeling using four different heuristic approaches. *Computers and Electronics in Agriculture* 140: 203-213. <http://dx.doi.org/10.1016/j.compag.2017.05.036>.
- Wasserman P.D. (1993). *Advanced methods in neural computing*. John Wiley & Sons, Inc., 250 p. <https://dl.acm.org/doi/book/10.5555/562821>.
- Widrow B., & Hoff M.E. (1960). Adaptive switching circuits (No. TR-1553-1). Stanford Univ Ca Stanford Electronics Labs.
- Willmott, C.J. (1981). On the validation of models. *Physical geography*, 2(2), 184-194. <https://doi.org/10.1080/02723646.1981.10642213>.
- Winter T.C. (1981). Uncertainties in estimating the water balance of lakes. *Water Resources Bulletin*, 17 (1), 82-115. <https://doi.org/10.1111/j.1752-1688.1981.tb02593.x>.
- Winter, T.C., Buso, D.C., Rosenberry, D.O., Likens, G.E., Sturrock, A.J.M., & Mau, D.P. (2003). Evaporation determined by the energy-budget method for Mirror Lake, New Hampshire. *Limnology and Oceanography*, 48(3), 995-1009. <https://doi.org/10.4319/lo.2003.48.3.0995>.
- White H. (1992). *Artificial neural networks*, Blackwell, New York.
- Winter, T.C., Rosenberry, D.O., & Sturrock, A.M. (1995). Evaluation of 11 equations for determining evaporation for a small lake in the north central United States. *Water Resources Research*, 31(4), 983-993. <https://doi.org/10.1029/94WR02537>.
- WMO. (1997). World Meteorological Organization: *Estimation of Areal Evaporation*. Technical Reports in Hydrology and Water Resources No. 56, WMO/ TD-No. 785, Geneva. http://www.agrolan.co.il/uploadfiles/wmo_chapter10_evaporation.pdf
- Xu, C.Y., & Singh, V.P. (1998). Dependence of evaporation on meteorological variables at different time-scales and intercomparison of estimation methods. *Hydrological processes*, 12(3),

429-442. [https://doi.org/10.1002/\(SICI\)1099-1085\(19980315\)12:3<429::AID-HYP581>3.0.CO;2-A](https://doi.org/10.1002/(SICI)1099-1085(19980315)12:3<429::AID-HYP581>3.0.CO;2-A).

Xu, C.Y., & Singh, V.P. (2000). Evaluation and generalization of radiation-based methods for calculating evaporation. *Hydrological processes*, 14(2), 339-349. [https://doi.org/10.1002/\(SICI\)1099-1085\(20000215\)14:2<339::AID-HYP928>3.0.CO;2-O](https://doi.org/10.1002/(SICI)1099-1085(20000215)14:2<339::AID-HYP928>3.0.CO;2-O).

Xu, C.Y., Singh, V.P. (2001). Evaluation and generalization of temperature-based methods for calculating evaporation. *Hydrological processes*, 15(2), 305-319. <https://doi.org/10.1002/hyp.119>.

Xu, C.Y., & Singh, V.P. (2002). Cross comparison of empirical equations for calculating potential evapotranspiration with data from Switzerland. *Water Resources Management*, 16(3), 197-219. <https://doi.org/10.1023/A:1020282515975>.

Yager, R.R., & Filev, D.P. (1994). Generation of fuzzy rules by mountain clustering. *Journal of Intelligent & Fuzzy Systems*, 2(3), 209-219. <https://doi.org/10.3233/IFS-1994-2301>.

Yonaba H. (2009). Modélisation hydrologique hybride: réseau de neurones-modèle conceptuel. Thèse de doctorat, Université Laval, 182p. <http://hdl.handle.net/20.500.11794/21255>.