

Ministère de l'enseignement Supérieur et de la recherche Scientifique

Badji Mokhtar Annaba University

Université Badji Mokhtar – Annaba



Faculté de Technologie

Département Hydraulique

## Thèse

Présentée pour obtenir le diplôme de

## Doctorat En-Sciences

Spécialité : Hydraulique

Par :

**BENCHAIBA LEILA**

Thème :

# EXPLORATION DES METHODES DE PREVISION DES APPORTS LIQUIDES DANS LES BARRAGES DE L'ALGERIE

Thèse soutenue le 30/05/2023 devant le jury composé de :

Nom et Prénom	Grade	Etablissement	Qualité
<b>MEKSAOUINE Mohamed</b>	Pr.	Univ. de Annaba	Président
<b>HOUICHI Larbi</b>	Pr.	Univ. de Batna 2	Rapporteur
<b>AMARCHI HOCINE</b>	Pr.	Univ. de Annaba	Co-Rapporteur
<b>LAOUACHERIA Fares</b>	MCA	Univ. de Annaba	Examineur
<b>ZEGHADNIA Lotfi</b>	Pr.	Univ. de Souk Ahras	Examineur
<b>MAROUF Nadir</b>	Pr.	Univ. de Oum el Bouaghi	Examineur

## Dédicaces

*Je dédie ce travail :*

*A Ma tendre Mère*

*A Mon cher Père*

*A mes sœurs et frères : Houria, Zakia, Sihem, Mouna*

*Belkacem, Mostafa et Mohamed*

*A mes tantes Ouarda, Malika et Hakima*

*A mon mari Ghodbane Bachir, et mes enfants Rania, Abd*

*Erraouf et Mohamed*

*A tous ceux qui me sont chers.*

*Leila BENCHAIBA*

## Remerciements

*Je tiens tout d'abord à remercier Dieu le tout puissant, qui m'a donné la force et la patience d'accomplir ce travail.*

*Un remerciement tout spécial à mon directeur de thèse Mr. **Larbi HOUICHI**, professeur à l'université de Batna 2 qui m'a encadré et suivi toutes les étapes de ma recherche tout le long des années de préparation de la présente thèse, j'exprime ma profonde gratitude et mes sincères remerciements pour ses qualités humaines et scientifiques. Je ne pourrai jamais oublier sa gentillesse, sa générosité, son esprit de recherche et ses commentaires efficaces. Un grand merci de m'avoir donné la chance de réaliser cette thèse.*

*Je tiens vivement à remercier également le **Pr. Amarchi Hocine** mon co-directeur de thèse et les membres du jury pour l'honneur qu'ils m'ont fait en acceptant de juger et d'évaluer mon travail.*

*Je remercie bien vivement Monsieur **Ghodbane Bachir** pour son aide et ces encouragements.*

*Je tiens à remercier Mr. **Tarfaya Chafai** pour son aide.*

*Mes remerciements vont à toute l'équipe de l'Agence Nationale des Barrages et Transferts ANBT pour la collaboration affichée lors de la nécessité de support.*

*Enfin, tous mes remerciements vont à ma famille et mes amis qui m'ont encouragé.*

## " إستكشاف طرق التنبؤ بكميات المياه الوافدة للسدود في الجزائر "

### الملخص:

ترشيد تخزين المياه السطحية يستدعي جهودا متظافرة من الباحثين لتطوير أساليب عملية فعالة لإدارة الموارد المائية، وهو بالنسبة للجزائر أمر أساس. لنمذجة البيانات الهيدرومترية والتنبؤ بها تم اقتراح أنواع مختلفة من الطرائق فكانت النماذج العشوائية وغير العشوائية من بين أولى التقنيات التي تم استخدامها. ومع ذلك، نادراً ما يتم التحقق من قابليتها للتطبيق وصلاحيتها عبر دراسات في سياق جزائري يقتضي اقتراح مبادئ توجيهية وتوصيات مرتبطة بتصنيف واستخدام نماذج التنبؤ بكميات المياه الوافدة لبحيرات السدود. تقدم هذه الأطروحة نهجاً عشوائياً خطياً مخصصاً للتنبؤ بالوافدات الشهرية ومقاربات غير عشوائية تستخدم للتنبؤ بالوافدات المائية اليومية لثلاثة سدود خزانة تمثل بدورها ثلاث مناخات متميزة في الجزائر؛ سد خزان حمام بوغرارة للمناخ شبه الجاف وسد خزان بني هارون للمناخ شبه الرطب وسد خزان تاكسبت للمناخ الرطب. تعتمد التقنيات العشوائية للتنبؤ بكميات المياه الوافدة شهريا لبحيرات السدود على نوعين من أنواع نماذج السلاسل الزمنية، وهما نموذج الانحدار الذاتي مع المتوسط المتحرك وإدراج التأخر الزمني (ARIMA) ونموذج التجانس الأسّي المثلثي مع تحويل Box-Cox وأخطاء ARMA والاتجاه والمكونات الموسمية (TBATS). أما بالنسبة للنماذج غير الخطية فقد تم تطبيق ثلاث تقنيات تعتمد على الذكاء الاصطناعي للتنبؤ بكميات المياه الوافدة يوميا لبحيرات السدود وهي: (1) الشبكات العصبية الاصطناعية متعددة الطبقات من نوع (ANN)، (2) طرق التجميع القائمة على قواعد الغابة العشوائية (RF)، وأخيراً (3) طرق التصنيف القائمة على خوارزمية آلة المتجهات الداعمة (SVM). توضح النتائج النهائية أنه يمكن تقديم نماذج TBATS كبديل لنماذج ARIMA التي لا تأخذ في الاعتبار تعقيد السلسلة الزمنية للوافد المائي الشهري لبحيرات السدود في الجزائر في المناطق المناخية الثلاث. ومن جهة أخرى تظهر النتائج عدم صلاحية نماذج ANN و RF و SVM للتنبؤ بالوافدات المائية اليومية في الحالة شبه الجافة، بينما هي ذات صلاحية واضحة وسيلة جيدة للتنبؤات في حالة المناخ الرطب وتحديدًا شبه الرطب.

### الكلمات المفتاحية:

سد خزان، وافد مائي، شهري، يومي، عشوائي، غير عشوائي، نمذجة، تنبؤ، مناخ، ذكاء إصطناعي.

# « Exploration des méthodes de prévision des apports liquides dans les barrages de l'Algérie »

## Résumé :

La rationalisation du stockage des eaux de surface requiert des efforts intensifs des chercheurs pour développer des méthodes efficacement opérationnelles en vue la gestion de la ressource hydrique qui constitue un enjeu essentiel pour l'Algérie. Divers types de modèles ont été proposés pour la modélisation et la prévision des données hydrométriques. Les modèles stochastiques et non stochastiques ont été parmi les premiers à être utilisés. Cependant, leur applicabilité est rarement validée par des études dans un contexte Algérien où il est nécessaire de proposer des directives et des recommandations liées à la classification et à l'utilisation des modèles de prévisions des apports liquides. Cette thèse présente une approche stochastique linéaire consacrée à la prévision des apports liquides mensuels et une tentative non stochastique utilisée pour la prévision des apports liquides journaliers parvenant aux trois barrages réservoirs représentant trois climats distincts en Algérie ; le barrage réservoir de Hammam Boughrara pour le cas semi-aride, le barrage réservoir de Beni Haroun pour le cas subhumide et le barrage réservoir de Taksebt pour le cas humide. L'approche stochastique, pour prévoir les apports liquides mensuels, consistait en deux types de modèles de séries temporelles, il s'agit en l'occurrence du modèle autorégressif à moyenne mobile intégrée (ARIMA) et du modèle à lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers (TBATS). Pour l'approche non linéaire, trois techniques basées sur l'intelligence artificielle ont été considérées pour prévoir les apports liquides journaliers, à savoir : (1) Réseaux de neurones artificiels type perceptron multicouches (ANN), (2) méthodes ensembles à base de règles type forêts aléatoires (RF), et finalement (3) méthodes de classification appliquées aux régressions type machines à vecteurs de support (SVM). Les résultats finaux démontrent que les modèles TBATS peuvent à la limite se présenter comme alternative aux modèles ARIMA qui ne tiennent pas compte de la complexité des séries temporelles des apports liquides mensuels en Algérie dans les trois régions climatiques. Les résultats montrent aussi que les modèles non stochastiques ANN, RF et SVM ne peuvent pas assister à prévoir les apports liquides à l'échelle journalière dans le cas semi-aride. Néanmoins, ces modèles peuvent être considérés comme moyens de prévisions qualifiés de très bonnes performances pour le cas à climat humide et particulièrement à climat subhumide.

**Mots-clés :** Barrage-réservoir, apport liquide, mensuel, journalier, stochastique, non stochastique, modélisation, prévision, climat, intelligence artificielle.

## « Exploration of inflows forecasting methods in Algerian dams »

### **Abstract:**

The rationalization of surface water storage requires intensive efforts of researchers to develop effective operational methods for the management of water resources which is a key issue for Algeria. Various types of models have been proposed for modeling and forecasting hydrometric data. Stochastic and non-stochastic models were among the first to be used. However, their applicability is rarely validated by studies in an Algerian context where there is a need to propose guidelines and recommendations related to the classification and use of liquid supply forecasting models. This thesis presents a linear stochastic approach dedicated to the prediction of monthly inflows and a non-stochastic attempt used for the prediction of daily inflows to three reservoir dams representing three distinct climates in Algeria; Hammam Boughrara reservoir dam for the semi-arid case, Beni Haroun reservoir dam for the sub-humid case and Taksebt reservoir dam for the humid case. The stochastic approach, to predicting the monthly inflows, consisted of two types of time series models, namely: the autoregressive integrated moving average model (ARIMA), and the trigonometric exponential smoothing model with Box-Cox transformation, ARMA errors, trend and seasonal components (TBATS). For the non-linear approach, three artificial intelligence-based techniques were considered to predict daily inflows, so-called: (1) Artificial neural networks with the multilayer perceptron (ANN), (2) rule-based ensemble methods with the random forest (RF) models, and finally (3) classification methods applied to support vector machines (SVM) regression algorithms. The final results show that TBATS models can ultimately be presented as an alternative to ARIMA models that do not take into account the complexity of the time series of monthly inflows in Algeria's dams in the three climatic regions. The results also show that the non-stochastic ANN, RF, and SVM models cannot assist in predicting daily inflows in the semi-arid case. Nevertheless, these models can be considered as forecasting means qualified for very good performances for the humid climate case, and particularly for the sub-humid climate.

**Keywords:** Dam-reservoir, inflow, monthly, daily, stochastic, non-stochastic, modelling, forecasting, climate, artificial intelligence.

## Table des matières

Dédicaces.....	ii
Remerciements .....	iii
الملخص.....	iv
Résumé .....	v
Abstract.....	vi
Table des matières.....	vii
Liste des tableaux.....	xi
Liste des figures.....	xiii
Liste des sigles .....	xix
Introduction générale .....	1
<b>Chapitre I</b>	
<b>Présentation des zones d'études : barrages choisis pour l'étude</b>	
I.1. Introduction .....	7
I.2. Zones d'étude et descriptions brèves des barrages choisis pour l'étude.....	8
I.2.1 Le barrage de Hammam Boughrara (climat semi-aride).....	8
I.2.2 Le barrage de Beni Haroun (climat subhumide) .....	9
I.2.3 Le barrage de Taksebt (climat humide) .....	11
I.3. Conclusion .....	12
<b>Chapitre II</b>	
<b>Généralités sur la théorie des modèles de prévision:</b>	
<b>Modèles stochastiques et modèles basés sur l'intelligence artificiels</b>	
II.2. Généralités sur la théorie des modèles de prévision .....	16
II.2.1. Modèles stochastiques de séries temporelles.....	16
II.2.1.1. Modèles ARIMA.....	16
II.2.1.2. Modèles TBATS .....	17
II.2.2.2. Modèles RF (Random Forest) .....	21
II.2.2.3. Modèles SVM.....	22
II.3. Critère de choix entre modèles candidats ARIMA/TBATS.....	24
II.4. Critères de performance des modèles de prévision .....	24
II.4.1. Les critères numériques .....	24
II.4.1.1. Coefficient de corrélation.....	25
II.4.1.2. Erreur quadratique moyenne .....	25

II.4.1.3. Erreur absolue moyenne .....	25
II.4.1.4. Erreur moyenne absolue en pourcentage .....	25
II.4.1.5. Coefficient de Nash-Sutcliffe .....	26
II.4.1.6. Coefficient de Kling-Gupta .....	26
II.4.1.7. Gain relatif .....	27
II.4.2. Les critères graphiques.....	27
II.4.2.1. Diagramme de Taylor.....	28
II.4.2.2. Boîtes en violon.....	28
II.5. Notion et utilité de la technique de cross-validation .....	29
II.6. Conclusions .....	29

### **Chapitre III**

#### **Présentation des données et essai de compréhension des structures internes des séries temporelles**

III.1. Introduction .....	32
III.2. Acquisition des données d'exploitation.....	32
III.2.1. Paramètres mesurés .....	32
III.2.2. Paramètres estimés .....	33
III.3. Etablissement du bilan hydraulique de la retenue.....	34
III.3.1. Apports ou affluents négatifs .....	34
III.3.2. Composantes .....	35
III.4. Structures internes des séries temporelles.....	35
III.4.1. Objectifs principaux .....	35
III.4.2. Description schématique de l'étude complète d'une série chronologique .....	36
III.4.3. Décomposition STL quasiment inspirée du document.....	36
III.5. Données journalières .....	38
III.6. Données mensuelles.....	45
III.7. Matrices de corrélation entre les apports liquides journaliers décalés jusqu'à cinq jours et la pluie décalée d'une journée .....	53
III.8. Conclusion.....	55



## Chapitre IV

### Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

IV.1. Introduction .....	58
IV.2. Données .....	59
IV.3 Critère de choix entre modèles candidats ARIMA/TBATS .....	60
IV.4. Résultats et interprétations .....	60
IV.4.1 Résultats liés au barrage de Hammam Boughrara .....	60
IV.4.2 Résultats liés au barrage de Beni Haroun .....	62
IV.4.3 Résultats liés au barrage de Taksebt .....	64
IV.5. Conclusion .....	66

## Chapitre V

### Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

V.1. Introduction .....	70
V.2. Normalisation des données .....	70
V.3. Critère de choix entre les modèles des réseaux de neurones de type perceptrons multicouches .....	71
V.4. Prévision des apports journaliers basée sur les variables endogènes (apports décalés dans le temps) et influence de la pluie ponctuelle (variable exogène) par les réseaux de neurones de type perceptrons multicouches .....	71
V.4.1. Prévision des apports journaliers du barrage de Hammam Boughrara (représentant le climat semi-aride) par les réseaux de neurones artificiels de type perceptrons multicouches .....	71
V.4.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les réseaux de neurones artificiels de type perceptrons multicouches .....	77
V.4.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les réseaux de neurones artificiels de type perceptrons multicouches .....	82
V.5. Conclusions .....	88

## Chapitre VI

### Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

VI.1. Introduction .....	90
VI.2. Critère de choix entre les modèles des forêts aléatoires.....	90
VI.3. Prévision des apports journaliers basée sur les variables endogènes (apports décalés) et influence de la pluie ponctuelle (variable exogène) par les forêts aléatoires.....	90
VI.3.1. Prévision des apports journaliers du barrage de Hammam Bouhrara (représentant le climat semi-aride) par les modèles des forêts aléatoires.....	91
VI.3.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les modèles des forêts aléatoires .....	95
VI.3.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les modèles des forêts aléatoires.....	99
VI.4. Conclusions.....	103

## Chapitre VII

### Prévisions des apports liquides journaliers par les machines à vecteurs de support

VII.1. Introduction.....	105
VII.2. Critère de choix entre les modèles des machines à vecteurs de support ..	105
VII.3. Prévision des apports journaliers basée sur les variables endogènes (apports décalés) et influence de la pluie ponctuelle (variable exogène) par les machines à vecteurs de support.....	105
VII.3.1. Prévision des apports journaliers du barrage de Hammam Bouhrara (représentant le climat semi-aride) par les modèles des machines à vecteurs de support .....	106
VII.3.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les modèles des machines à vecteurs de support .....	110
VII.3.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les modèles des machines à vecteurs de support .....	114
VII.4. Conclusions .....	118
Conclusion générale.....	120
Références bibliographiques.....	130

## Liste des tableaux

### Chapitre I

**Tableau I. 1.** Diverses caractéristiques du Barrage de Hammam Boughrara ..... 8

**Tableau I. 2.** Diverses caractéristiques du Barrage de Beni Haroun ..... 10

**Tableau I.3.** Diverses caractéristiques du Barrage de Taksebt ..... 11

### Chapitre III

**Tableau III.1.** Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Hammam Boughrara ..... 53

**Tableau III.2.** Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Beni Haroun ..... 54

**Tableau III.3.** Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Taksebt ..... 54

### Chapitre IV

**Tableau IV.1.** Résultats de l'application des modèles ARIMA/ TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Hammam Boughrara..... 62

**Tableau IV.2.** Résultats de l'application des modèles ARIMA/ TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Beni Haroun..... 64

**Tableau IV.3.** Résultats de l'application des modèles ARIMA/ TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Taksebt ..... 66

**Tableau IV.4.** Catégorisation et interprétation des valeurs typiques du MAPE selon Lewis (1982)..... 68

### Chapitre V

**Tableau V.1.** Les résultats des modèles ANN dans le barrage de Hammam Boughrara ; ..... 73

**Tableau V.2.** Comparaison des performances des modèles ANN compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara)..... 77

**Tableau V.3.** Les résultats des modèles ANN dans le barrage de Beni Haroun ; ..... 78

<b>Tableau V.4.</b> Comparaison des performances des modèles ANN compétitifs de prévision des apports journaliers (barrage de Beni Haroun).....	82
<b>Tableau V.5.</b> Les résultats des modèles ANN dans le barrage de Taksebt ; .....	84
<b>Tableau V.6.</b> Performances du modèle ANN de prévision des apports journaliers (barrage de Taksebt).....	87

## Chapitre VI

<b>Tableau VI.1.</b> Les résultats des modèles RF dans le barrage de Hammam Boughrara ; .....	92
<b>Tableau VI.2.</b> Comparaison des performances des modèles RF compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara).....	95
<b>Tableau VI.3.</b> Les résultats des modèles RF dans le barrage de Beni Haroun ; .....	96
<b>Tableau VI.4.</b> Comparaison des performances des modèles RF compétitifs de prévision des apports journaliers (barrage de Beni Haroun).....	99
<b>Tableau VI.5.</b> Les résultats des modèles RF dans le barrage de Taksebt ; .....	100
<b>Tableau VI.6.</b> Performances du modèle RF de prévision des apports journaliers (barrage de Taksebt).....	103

## Chapitre VII

<b>Tableau VII.1.</b> Les résultats des modèles SVM dans le barrage de Hammam Boughrara ; .....	107
<b>Tableau VII.2.</b> Comparaison des performances des modèles SVM compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara).....	110
<b>Tableau VII.3.</b> Les résultats des modèles SVM dans le barrage de Beni Haroun ; ..	111
<b>Tableau VII.4.</b> Comparaison des performances des modèles SVM compétitifs de prévision des apports journaliers (barrage de Beni Haroun).....	114
<b>Tableau VII.5.</b> Les résultats des modèles SVM dans le barrage de Taksebt ; .....	115
<b>Tableau VII.6.</b> Performances du modèle SVM de prévision des apports journaliers (barrage de Taksebt).....	118

## Liste des figures

Chapitre I	
<b>Figure I.1.</b> Situation géographique du bassin versant et Barrage Hammam Boughrara .....	9
<b>Figure I.2.</b> Situation géographique du bassin versant et Barrage Beni Haroun.....	10
<b>Figure I.3.</b> Situation géographique du bassin versant et Barrage de Taksebt .....	12
Chapitre II	
<b>Figure II.1.</b> Schéma exemple du processus global des modèles ANN adoptés (sortie graphique du package « neuralnet » ; Fritsch et al., 2019) .....	20
<b>Figure II.2.</b> Schéma exemple du processus global des modèles RF adoptés (conçu par l'auteur).....	22
<b>Figure II. 3.</b> Schéma exemple du processus global des modèles SVM adoptés. ....	24
Chapitre III	
<b>Figure III. 1.</b> Schéma du bilan des barrages-réservoirs (Bengora, 2019).....	34
<b>Figure III.2.</b> Visualisation des apports liquides journaliers du barrage de Hammam Boughrara pour la période d'exploitation (01/01-2002-31/12/2012).....	39
<b>Figure III. 3.</b> Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Hammam Boughrara pour la période d'exploitation (01/01-2002-31/12/2012), la ligne en pointillé bleu indique l'apport moyen journalier interannuel (0.12771 Mm <sup>3</sup> ).....	39
<b>Figure III.4.</b> Visualisation des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019).....	40
<b>Figure III.5.</b> Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019), la ligne en pointillé bleu indique l'apport moyen journalier interannuel (3.0356 Mm <sup>3</sup> )	40
<b>Figure III.6.</b> Visualisation des apports liquides journaliers du barrage Taksebt pour la période d'exploitation (01/01/2003-31/12/2013) .....	41
<b>Figure III.7.</b> Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013), la ligne en pointillé bleu indique l'apport moyen journalier interannuel (0.589 Mm <sup>3</sup> ).....	41
<b>Figure III.8.</b> Décomposition STL de la série des apports liquides journaliers du barrage de Hammam Boughrara pour la période d'exploitation (01/01-2002-31/12/2012)...	42

<b>Figure III. 9.</b> Décomposition STL de la série des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019) .....	43
<b>Figure III.10.</b> Décomposition STL de la série des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013) .....	43
<b>Figure III.11.</b> Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Hammam Boughrara .....	44
<b>Figure III. 12.</b> Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Beni Haroun .....	45
<b>Figure III.13.</b> Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Taksebt.....	45
<b>Figure III. 14.</b> Visualisation des apports liquides mensuels du barrage de Hammam Boughrara pour la période d'exploitation (01/01/2002-31/12/2012).....	47
<b>Figure III.15.</b> Visualisation en boîtes à moustaches des apports liquides mensuels du barrage de Hammam Boughrara pour la période d'exploitation (01/01/2002-31/12/2012), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel (3.9877 Mm <sup>3</sup> ).....	47
<b>Figure III.16.</b> Visualisation des apports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019) .....	48
<b>Figure III.17.</b> Visualisation en boîtes à moustaches des apports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel (93.392 Mm <sup>3</sup> ) ..	48
<b>Figure III. 18.</b> Visualisation des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013) .....	49
<b>Figure III.19.</b> Visualisation en boîtes à moustaches des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel (17.485 Mm <sup>3</sup> ).....	49
<b>Figure III.20.</b> Décomposition STL de la série des apports liquides mensuels du barrage de Hammam Boughrara pour la période d'exploitation (01/01-2002-31/12/2012)...	50
<b>Figure III.21.</b> Décomposition STL de la série des apports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01-2009-31/12/2019) .....	51
<b>Figure III.22.</b> Décomposition STL de la série des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013) .....	51

<b>Figure III. 23.</b> Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du barrage de Hammam Boughrara .....	52
<b>Figure III.24.</b> Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du Barrage de Beni Haroun.....	52
<b>Figure III.25.</b> Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du Barrage de Taksebt.....	53

#### Chapitre IV

<b>Figure IV.1.</b> Comparaison des apports mensuels prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ARIMA (à gauche) et TBATS (à droite)	61
<b>Figure IV.2.</b> Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Hammam Boughrara .....	61
<b>Figure IV. 3.</b> Comparaison des apports mensuels prédits et observés au barrage réservoir de Beni Haroun : Modèles ARIMA (à gauche) et TBATS (à droite).....	63
<b>Figure IV.4.</b> Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Beni Haroun.....	64
<b>Figure IV.5.</b> Comparaison des apports mensuels prédits et observés au barrage réservoir de Taksebt : Modèles ARIMA (à gauche) et TBATS (à droite).....	65
<b>Figure IV.6.</b> Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Taksebt.....	66

#### Chapitre V

<b>Figure V.1.</b> Schéma du modèle ANN1r retenu pour la prévision des apports journaliers au sein du barrage réservoir de Hammam Boughrara .....	74
<b>Figure V.2.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de calage) .....	74
<b>Figure V.3.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de calage) .....	75
<b>Figure V.4.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de validation) ...	75
<b>Figure V.5.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de validation) ...	76
<b>Figure V.6.</b> Schéma du modèle ANN3r retenu pour la prévision des apports journaliers au sein du barrage réservoir de Beni Haroun.....	79

<b>Figure V.7.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de calage).....	80
<b>Figure V.8.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de calage).....	80
<b>Figure V.9.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de validation).....	81
<b>Figure V.10.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de validation).....	81
<b>Figure V.11.</b> Schéma du modèle ANN4 retenu pour la prévision des apports journaliers au sein du barrage réservoir de Taksebt.....	85
<b>Figure V.12.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de calage) .....	85
<b>Figure V.13.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de calage) .....	86
<b>Figure V.14.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de validation) .....	86
<b>Figure V.15.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de validation) .....	87

## Chapitre VI

<b>Figure VI.1.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de calage).....	93
<b>Figure VI.2.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de calage).....	93
<b>Figure VI.3.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de validation) .....	94
<b>Figure VI.4.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de validation) .....	94
<b>Figure VI.5.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de calage) .....	97
<b>Figure VI.6.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de calage) .....	97



<b>Figure VI.7.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de validation).....	98
<b>Figure VI.8.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de validation).....	98
<b>Figure VI.9.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de calage) .....	101
<b>Figure VI.10.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de calage) .....	101
<b>Figure VI.11.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de validation) .....	102
<b>Figure VI.12.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de validation) .....	102

## Chapitre VII

<b>Figure VII.1.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de calage) .....	108
<b>Figure VII.2.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de calage) .....	108
<b>Figure VII.3.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de validation) ..	109
<b>Figure VII.4.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de validation) ..	109
<b>Figure VII.5.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de calage).....	112
<b>Figure VII.6.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de calage).....	112
<b>Figure VII.7.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de validation).....	113
<b>Figure VII.8.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de validation).....	113
<b>Figure VII.9.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de calage) .....	116

<b>Figure VII.10.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de calage) .....	116
<b>Figure VII.11.</b> Comparaison des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de validation) .....	117
<b>Figure VII.12.</b> Nuage de points des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de validation) .....	117

### Conclusion générale

<b>Figure 1.</b> Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Hammam Boughrara (cas semi-aride) .....	124
<b>Figure 2.</b> Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Hammam Boughrara (cas semi-aride) .....	124
<b>Figure 3.</b> Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Beni Haroun (cas subhumide) .....	125
<b>Figure 4.</b> Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Beni Haroun (cas subhumide) .....	126
<b>Figure 5.</b> Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Taksebt (cas humide).....	127
<b>Figure 6.</b> Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Taksebt (cas humide).....	127

## Liste des sigles

<b>ANBT</b>	Agence Nationale des Barrages et Transferts
<b>BCR</b>	Barrage en béton compacté roulé
<b>ARIMA</b>	Moyenne mobile intégrée autorégressive
<b>TBATS</b>	Lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA composants de tendance et saisonniers
<b>ANN</b>	Artificial Neural Network (réseaux de neurones artificiels)
<b>RF</b>	Random Forest (Les algorithmes des forêts aléatoires)
<b>SVM</b>	Support Vector Machines (les machines à vecteurs de support)
<b>ACF</b>	Fonction d'auto corrélation
<b>PACF</b>	Fonction d'auto corrélation partielle

## Liste des abréviations

R	Coefficient de corrélation
<i>RMSE</i>	L'erreur quadratique moyenne ( $Mm^3$ )
<i>MAE</i>	L'erreur absolue moyenne ( $Mm^3$ )
<i>MAPE</i>	Erreur moyenne absolue en pourcentage (%)
<i>NSE</i>	Coefficient de Nash-Sutcliffe
KGE	Coefficient de Kling-Gupta
AIC	Critère d'information de Akaike
<i>APP</i>	Volume des apports globaux entrant dans le barrage
<i>V<sub>final</sub></i>	Volume stocké au temps ( $t+1$ )
<i>V<sub>initial</sub></i>	Volume stocké au temps ( $t$ )
<i>AEP</i>	Volume alloué à l'alimentation en eau potable
<i>IRR</i>	Volume alloué à l'irrigation
<i>EVAP</i>	Volume évaporé
<i>VID</i>	Volume de vidange
<i>FUI</i>	Volume des fuites
<i>EVAC</i>	Volume déversé.
<i>Ap<sub>t</sub></i>	Apport journalier actuel
<i>Ap<sub>t-i</sub></i>	Apport journalier décalé de $i$ jour
<i>P<sub>t-1</sub></i>	Pluie journalière décalée d'un jour
$y = Ap_t$	Apport journalier actuel
$ari = Ap_{t-i}$	Apport journalier décalé de $i$ jour
$rain1 = P_{t-1}$	Pluie journalière décalée d'un jour

# *Introduction Générale*

### Introduction générale

#### Problématique

La mobilisation des ressources en eau est un enjeu essentiel pour l'Algérie et la maîtrise des techniques de rationalisation du stockage des eaux de surface requiert des efforts intensifs des chercheurs pour développer des méthodes efficacement opérationnelles en vue de la conception, la régulation et la gestion.

Le fonctionnement hydrologique des bassins versants reste à nos jours un phénomène qui échappe à la maîtrise, malgré les études de terrain menées depuis des décennies et qui ont permis de présenter des éléments de réponses, plus ou moins satisfaisants.

La modélisation est définie comme étant une représentation mathématique d'un phénomène physique simple ou complexe, qui permet en faisant appel à des processus élémentaires, de reconstituer et reproduire ce phénomène.

Les techniques de simulation des apports liquides permettent de répondre aux besoins des gestionnaires des ressources en eau. Le principe des modèles de simulation est d'utiliser des générateurs de variables aléatoires, tels que les apports liquides, qui respectent la structure statistique, historiquement observée, des processus à reproduire.

Divers types de modèles ont été proposés pour la modélisation, la simulation et la prévision des séries hydrométriques (débits ou apports). Les modèles stochastiques et non stochastiques ont été parmi les premiers à être utilisés, cependant, et à notre connaissance, leur applicabilité est rarement explorée au travers les tests moyennant les données hydrologiques des bassins versants alimentant les barrages en Algérie. Toujours dans le contexte Algérien, rares sont les directives et les recommandations liées à la classification et à l'utilisation des modèles de prévisions des apports liquides, selon des critères bien précis tels que cités par [Fortin et al.,1997](#), à savoir : la validité des hypothèses pour l'application de chaque type de modèle de prévision, la facilité de son utilisation, la complexité des calculs à chaque type, les incertitudes entachant les valeurs prévues, les besoins en information (taille de la base de données) et l'adaptabilité des modèles à se mettre à jour à travers leurs paramètres.

### Objectifs de l'étude

Pour les besoins d'estimation des volumes régularisables des différents ouvrages hydrauliques en Algérie, une mise en place d'une stratégie d'estimation des chroniques des apports aux différents pas de temps s'avère indispensable. Cette stratégie se base logiquement sur les diverses techniques de modélisation, de simulation et de prévision des apports liquides. A priori, nous n'avons aucune restriction scientifiquement fondée au travers les travaux de recherche intrinsèques ayant pour objet les apports des barrages en Algérie.

La présente thèse se propose d'apporter des éléments de réponse concernant :

- Les types de modèles de prévision des apports (stochastiques ou non stochastiques), pour quel pas de temps (journalier ou mensuel) et pour quelle dimension d'information requise (tailles des séries chronologiques).
- Le type de climat (semi-aride subhumide ou humide), a-t-il une influence directe ou indirecte sur la catégorie du modèle de prévision des débits à adopter ?
- Selon les critères cités dans la problématique : Est-il possible d'aboutir en finalité à des directives ou du moins des recommandations de classification des modèles de prévisions des apports liquides dans les barrages réservoirs en Algérie ?
- Quelle validité et persistance des modèles de prévisions des apports liquides aux différents pas de temps alimentant les retenus des barrages réservoirs en Algérie ?
- Peut-on déceler et détecter des priorités, en termes de fiabilité et facilité, de certains types de modèles de prévision des apports liquides (stochastiques ou non stochastiques) ?

### Structure de la thèse :

La structure finale de la présente thèse s'est arrêtée définitivement comme suit :

Une introduction générale, sept chapitres et une conclusion générale.

Le chapitre premier est intitulé : « Présentation des zones d'études : barrages choisis pour l'étude » où il sera dédié à la présentation des trois barrages objets d'étude et qui sont :

(1) Barrage de Hammam Boughrara qui représente le climat semi-aride (pluviométrie moyenne annuelle de l'ordre de 400 mm), (2) barrage de Beni Haroun qui représente le climat subhumide (pluviométrie moyenne annuelle de l'ordre de 600 mm) et (3) barrage de Taksebt qui représente le climat humide (pluviométrie moyenne annuelle de l'ordre de 1000 mm). La localisation, la délimitation, les caractéristiques techniques du barrage ainsi que les utilisateurs de l'eau seront également détaillées.

Le deuxième chapitre intitulé : « Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels », est consacré aux descriptions de deux catégories de modèles ; 1) stochastiques paramétriques dits : « moyenne mobile intégrée autorégressive » (ARIMA) et « lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers » (TBATS) et 2) non stochastiques provenant de l'apprentissage machine supervisé. On donnera aussi les définitions succinctes des critères de performances qui évaluent les validités des différents modèles de prévisions.

Le troisième chapitre intitulé : « Présentation des données et essai de compréhension des structures internes des séries temporelles », où on s'intéresse à l'acquisition, le contrôle de la fiabilité et le traitement des données utilisées sous formes d'apports liquides journaliers et mensuels, mesurés en million de mètre cube ( $Mm^3$ ) pour une visée d'élaboration des modèles de prévision des apports au sein de trois barrages réservoirs choisis consciemment pour présenter trois climats distincts de l'Algérie.

Le quatrième chapitre intitulé : « Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles », ayant pour l'évaluations des capacités prévisionnelles de deux modèles de séries temporelles (stochastiques) désignés par ARIMA et TBATS, et ce à travers la prévision mensuelle des apports liquides dans les barrages réservoirs en question. Les modèles stochastiques sont généralement classés dans la catégorie des modèles linéaires et prennent également en compte la composante aléatoire des données dans la modélisation hydrologique (Moeeni et al., 2017a ; Machekposhti et al., 2017). Dans la littérature, Il existe plusieurs approches pour modéliser les séries temporelles, les méthodes de prévision les plus fréquemment utilisés sont celles basées sur les modèles de lissage exponentiel



(Winters, 1976), modèles ARIMA (autorégressif à moyenne mobile intégrée) (Box et al., 2008), modèles TBATS (lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers) (De Livera et al., 2011).

Dans les chapitres cinq, six et sept, on signalera que les recherches liées à la prévision de la variable dite (inflow : apport ou affluent), qui est déduite indirectement de l'équation du bilan hydrique et qui est similaire à la variable désignée par (streamflow : écoulement), sont établies à différentes échelles du temps, notamment à l'échelle journalière et avec divers modèles, spécialement ceux issus de l'intelligence artificielle. Contrairement aux prévisions des écoulement des rivières (streamflow), mesurés directement au sein des stations hydrométriques et qui ont fait l'objet de nombreuses études antérieures et qui implémentaient et appliquaient divers modèles basés sur la technique de l'intelligence artificielle tels que : (Wang et al., 2006 ; Rasouli et al., 2012 ; Can et al., 2012 ; Yin et al., 2018 ; Azad et al., 2018 ; Siddiqi et al., 2021 ; Zounemat-Kermani et al., 2021). La variable « apport » (inflow) dans un barrage-réservoir, déduite de l'équation de la balance hydrique, basée sur le principe de conservation de volume, nécessite encore plus d'efforts de modélisations et des estimations moyennant des techniques plus performantes au profit de la pratique de la gestion des ressources en eau.

L'utilisation des valeurs prévues des apports liquides dans le processus de prise de décision menant à la gestion rationnelle doivent améliorer les modalités de planification des ressources hydriques stockées au niveau des barrages-réservoirs. C'est d'ailleurs l'objet de cette étude dans ces derniers trois chapitres qui traitent comme cas d'étude trois barrages-réservoirs situés dans des zones à climats distincts à savoir : (1) le barrage réservoir de Hammam Boughrara qui représente dans la présente exploration la zone à climat semi-aride, (2) le barrage réservoir de Beni Haroun qui représente à son tour la zone à climat subhumide et (3) le barrage réservoir de Taksebt qui représente finalement la zone à climat humide. A cet effet, on retiendra délibérément trois types de techniques basées sur l'intelligence artificielle et de l'apprentissage machine, il s'agit de : (1) Réseaux de neurones artificiels type perceptron multicouches désignés par (ANN), (2) Méthodes ensembles à base de règles type forêts aléatoires désignées par (RF), (Random Forest) et finalement (3)

Méthodes de classification appliquées aux régressions type machines à vecteurs de support désignées par (SVM), (Support Vector Machine).

Concernant quelques études élaborées à l'échelle journalières, on citera à titre d'exemple certaines publications ayant évaluées les réseaux de neurones artificiels comme modèles de prévision ([Coulibaly et al., 2000](#) ; [Zhang et al., 2009](#) ; [Karimi-Googhari et al., 2010](#) ; [Termite et al., 2013](#) ; [Esmaeilzadeh et al., 2017](#) ; [Apaydin et al., 2020](#) ; [Karunanayake et al., 2020](#)). La modélisation des apports journalières aux seins des trois barrages sera réalisée dans le chapitre cinq.

On citera encore à titre d'exemple des publications ayant évaluées les modèles des forêts aléatoires et hybrides retenus comme modèles de prévision ([Bai et al., 2016](#) ; [Bai et al., 2018](#) ; [Yang et al., 2016](#) ; [Papacharalampous et Tyrakis, 2018](#) ; [Khosravi et al., 2021](#) ; [Matrenin et al., 2022](#)). La modélisation des apports journalières aux seins des trois barrages sera accomplie dans ce cas dans le chapitre six.

On citera finalement quelques publications ayant appréciées les modèles hybrides ou à base des machines à vecteurs de support maintenus comme modèles de prévision ([Babaei et al., 2019](#) ; [Nazir et al., 2019](#) ; [Moeini and Babaei, 2020](#) ; [Latif et al., 2021](#) ; [Alquraish et al., 2021](#) ; [Ibrahim et al., 2022](#)). La modélisation des apports journalières aux seins des trois barrages sera effectuée finalement dans le chapitre sept.

La conclusion générale doit englober tous les résultats et les recommandations ainsi que des éventuelles perspectives de recherches dans le thème traité.

# *Chapitre I*

*Présentation des zones  
d'études : barrages choisis  
pour l'étude*

### I.1. Introduction

L'importance de l'eau en tant qu'une ressource vitale et facteur prépondérant dans le développement d'un pays est mondialement reconnue. Sa quantification et sa gestion doit manifestement être rigoureuse (Bouanani, 2004). Dans ce contexte, on comprend facilement la nécessité de mettre au point des modèles comme des outils d'aide à la gestion et à la décision (Perin, 2000). L'accès à l'eau potable est un besoin humain essentiel à satisfaire des communautés présentes et futures, dans ce contexte, l'Algérie a construit des dizaines de barrages pour satisfaire les besoins croissants aux ressources hydriques.

La gestion intégrée de ces ressources nécessite des techniques de simulation des apports liquides permettant de répondre aux soucis des gestionnaires. Le principe des modèles de simulation est d'utiliser des générateurs de variables aléatoires, tels que les apports liquides, qui respectent la structure statistique, historiquement observée, des processus à reproduire.

Trois barrages ont été proposés pour la modélisation et la simulation des séries temporelles d'apports ou affluents, à deux échelles (mensuelle et journalière), ces trois barrages-réservoirs sont sélectionnés parmi les barrages de l'Algérie sur la base des deux critères suivants :

- La disponibilité et la fiabilité des données.
- Le type du climat.

Donc ce chapitre est dédié à la présentation des trois barrages objets d'étude et qui sont :

(1) Barrage de Hammam Boughrara qui représente le climat semi-aride (pluviométrie moyenne annuelle de l'ordre de 400 mm), (2) barrage de Beni Haroun qui représente le climat subhumide (pluviométrie moyenne annuelle de l'ordre de 600 mm) et (3) barrage de Taksebt qui représente le climat humide (pluviométrie moyenne annuelle de l'ordre de 1000 mm). La localisation, la délimitation, les caractéristiques techniques du barrage ainsi que les utilisateurs de l'eau seront détaillées dans ce qui suit.

**I.2. Zones d'étude et descriptions brèves des barrages choisis pour l'étude**

**I.2.1 Le barrage de Hammam Bouhrara (climat semi-aride)**

Le barrage en terre de Hammam Bouhrara est localisé par les coordonnées géographiques : Latitude 34° 53' 10'' Nord, Longitude 1° 38' 56'' Ouest. Il est situé sur l'oued Tafna à 13 km à l'Est de la ville de Maghnia à l'Ouest de l'Algérie et à la confluence de la rivière Mouillah avec l'oued Tafna. Il est mis à l'eau officiellement en 1999, avec une capacité initiale de 177 Mm<sup>3</sup>, ayant pour objectif principal l'alimentation en eau potable des villes d'Oran et Maghnia. Le barrage reçoit les eaux de surface du bassin versant de l'oued Mouillah (2000 km<sup>2</sup>) partagé entre le territoire algérien et le territoire marocain (figure I.1). Ce bassin est composé dans sa majorité par les plaines d'Angad (Oujda, Maroc) et de Zrigua (Maghnia, Algérie), (Dahmani et al., 2018). Le barrage est destiné, principalement, à satisfaire les besoins d'alimentation en eau potable des villes d'Oran (33 Mm<sup>3</sup>) et de Maghnia (17 Mm<sup>3</sup>). Pour l'irrigation (9 Mm<sup>3</sup>) sont prévus.

Les diverses caractéristiques du barrage sont récapitulées dans le tableau I.1

**Tableau I. 1. Diverses caractéristiques du Barrage de Hammam Bouhrara**

<b>Diverses caractéristiques</b>	<b>Informations</b>
Année de construction	1994
Année de mise en eau	1999
Nom de l'Oued	Tafna
Capacité initiale (Mm <sup>3</sup> )	177
Capacité dernier levé (2003) (Mm <sup>3</sup> )	175.45
Apport moyen annuel (Mm <sup>3</sup> /an)	71.5
Envasement annuel (Mm <sup>3</sup> /an)	0.43
Surface du bassin versant (Km <sup>2</sup> )	4000
Type du barrage (-)	En terre
Hauteur du barrage (m)	61
Longueur du barrage (m)	1100
Côte retenue normale (mNGA)	305
Côte plus hautes eaux (mNGA)	309.95
Déversoir à seuil libre (m <sup>3</sup> /s)	2700
Vidange de fond (m <sup>3</sup> /s)	310

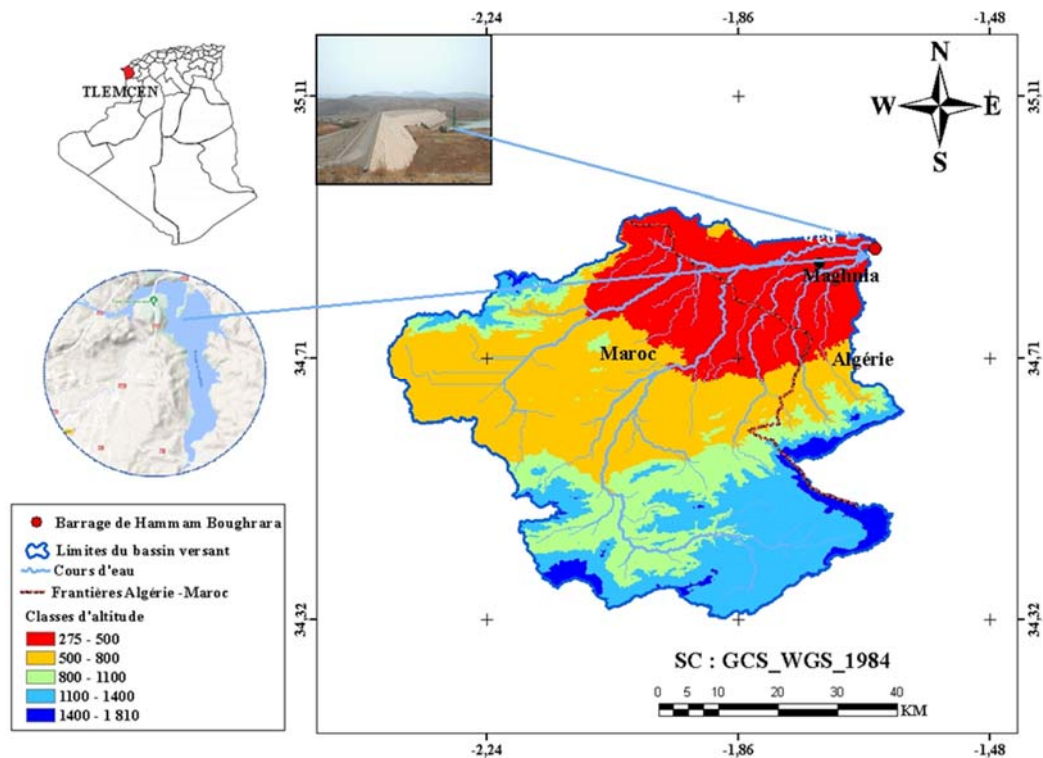


Figure I. 1. Situation géographique du bassin versant et Barrage Hammam Boughrara

### I.2.2 Le barrage de Beni Haroun (climat subhumide)

Le barrage en béton compacté roulé (BCR) de Beni Haroun est un grand ouvrage hydraulique stratégique en Algérie (figure I.2). Le volume total de sa retenue est de 997 Mm<sup>3</sup>, il permet la régularisation d'environ 435 Mm<sup>3</sup> par an. Le site dudit barrage est localisé dans la wilaya de Mila, à l'Est de l'Algérie sur l'Oued El Kebir ayant comme coordonnées géographiques : Latitude 36° 34' 06'' Nord, Longitude 6° 16' 30'' Est. La retenue engendrée par la digue du barrage se trouve au Sud de ce dernier. Elle est située à environ 40 km au Nord/Nord-Ouest de la ville de Constantine et à 350 km à l'Est d'Alger. Le bassin total de l'Oued Kebir au site du barrage totalise une superficie de 7725 km<sup>2</sup>. Tenant compte qu'une partie du bassin du Rhumel est mobilisée par le barrage de Hammam Grouz, la superficie relative au barrage de Beni Haroun est d'environ 6595 km<sup>2</sup> (LEM, 2013). Le barrage assure l'alimentation en eau potable des villes de Mila, Constantine, Jijel, Oum-El-Bouaghi, Khenchela et Batna ainsi que l'irrigation des vergers de Mila.

Les diverses caractéristiques du barrage sont récapitulées dans le tableau I.2

Tableau I. 2. Diverses caractéristiques du Barrage de Beni Haroun

Diverses caractéristiques	Informations
Année de construction	1996
Année de mise en eau	2003
Nom de l'Oued	Kebir
Capacité initiale (Mm <sup>3</sup> )	960
Apport moyen annuel (Mm <sup>3</sup> /an)	435
Envasement annuel (Mm <sup>3</sup> /an)	6
Surface du bassin versant (Km <sup>2</sup> )	7725
Type du barrage (-)	Béton BCR
Hauteur du barrage (m)	118
Longueur du barrage (m)	710
Côte retenue normale (mNGA)	200
Côte plus hautes eaux (mNGA)	214.74
Déversoir à seuil libre (m <sup>3</sup> /s)	16000
Vidange de fond (m <sup>3</sup> /s)	2*335

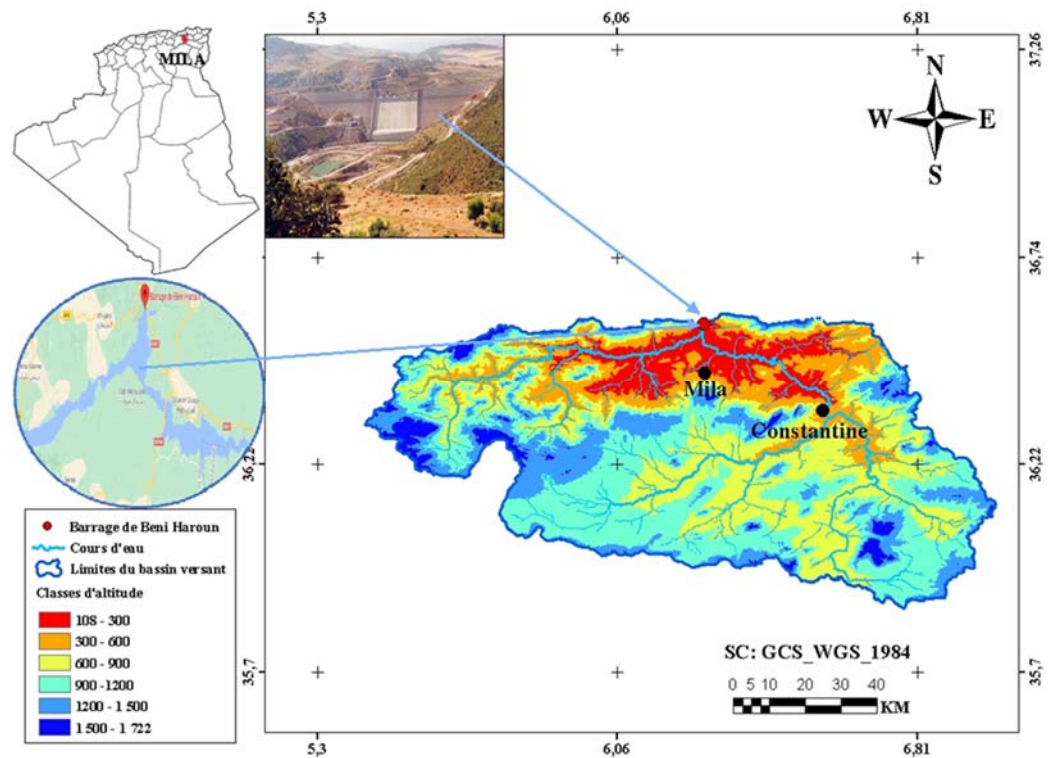


Figure I.2. Situation géographique du bassin versant et Barrage Beni Haroun



**I.2.3 Le barrage de Taksebt (climat humide)**

Le barrage en terre de Taksebt est situé sur l'oued Aissi à 10 km à l'Est de la ville de Tizi-Ouzou parmi les barrages du centre de l'Algérie (figure I.3). Il est localisé par les coordonnées géographiques suivantes : Latitude 36° 40' 22'' Nord Longitude 4° 07' 16'' Est. Il est mis en eau en 2001 pour assurer l'alimentation en eau potable des villes de Tizi-Ouzou et Alger. Le barrage reçoit en moyenne annuelle un apport de 196 Mm<sup>3</sup> provenant d'un bassin versant d'une surface drainée de 448 km<sup>2</sup>. Le barrage de Taksebt a grandement contribué à l'amélioration de l'alimentation en eau potable à raison de 73 Mm<sup>3</sup> annuellement rien que pour la wilaya de Tizi-Ouzou l'équivalent de 20 000 m<sup>3</sup>/jour, ainsi que les autres bassins irrigués, Alger, Blida et Boumerdès (Smadi et Abrika, 2018). Le bassin versant de l'oued Aissi, est située au Sud-Est du chef-lieu de la wilaya de Tizi-Ouzou. Localisée sur le flanc Nord du Djurdjura, elle se caractérise par un relief accidenté. A part son exposition aux vents humides provenant de la mer méditerranée, elle recèle d'importantes ressources en eaux de surface et souterraines, générées par des précipitations certes irrégulières mais conséquentes (pluviométrie moyenne annuelle = 1014 mm).

Les diverses caractéristiques du barrage sont récapitulées dans le tableau I.3

**Tableau I.3. Diverses caractéristiques du Barrage de Taksebt**

Diverses caractéristiques	Informations
Année de construction	1994
Année de mise en eau	2001
Nom de l'Oued	Aissi
Capacité initiale (Mm <sup>3</sup> )	175
Capacité dernier levé (2004) (Mm <sup>3</sup> )	181.02
Apport moyen annuel (Mm <sup>3</sup> /an)	196
Envasement annuel (Mm <sup>3</sup> /an)	0.27
Surface du bassin versant (Km <sup>2</sup> )	448
Type du barrage (-)	Terre
Hauteur du barrage (m)	94
Longueur du barrage (m)	515
Côte retenue normale (mNGA)	165
Côte plus hautes eaux (mNGA)	169.62
Déversoir à seuil libre (m <sup>3</sup> /s)	2500
Vidange de fond (m <sup>3</sup> /s)	210



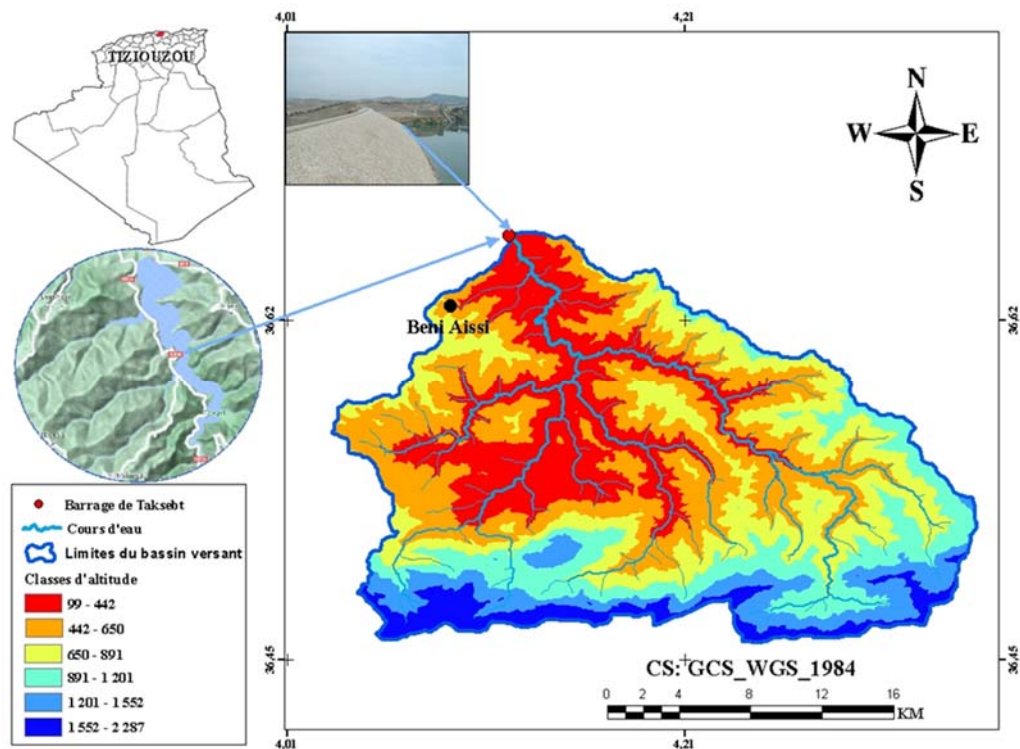


Figure I.3. Situation géographique du bassin versant et Barrage de Taksebt

### I.3. Conclusion

Le présent chapitre a en premier lieu décrit sommairement les barrages choisis : Barrage de Beni Haroun, Barrage de Taksebt et le barrage de Hammam Boughrara et leurs bassins versant.

Les trois barrages en question sont décrits historiquement et techniquement. Ils ont été choisis en fonction de la situation climatique de la région : le barrage de Hammam Boughrara dans la Wilaya de Tlemcen, caractérisé par un climat semi-aride, la moitié de la superficie de son bassin versant est situé dans l'état du Maroc qui est d'environ 4000 Km<sup>2</sup>, le volume stocké est d'environ de 170 Mm<sup>3</sup>. Le deuxième barrage a été choisi dans la Wilaya de Mila, c'est le barrage de de Beni Haroun situé au climat sub-humide, il est considéré comme le plus grand barrage au niveau national, il est construit en BCR et il qui mobilise plus de 960 Mm<sup>3</sup> d'eau, sa retenue reçoit les eaux de l'oued Kebir Rhumel drainée par une superficie de 7725 km<sup>2</sup>. Quant au troisième barrage, il a été choisi dans la région de Tizi Ouzou, c'est le barrage de Taksebt, au climat humide, il est conçu en terre dont le volume d'eau stockée est d'environ de 181Mm<sup>3</sup>.

Le choix de ces étages de climat différents est dans le but de comparer les modèles utilisés dans l'étude pour la meilleure gestion des ressources en eau.

## Chapitre II

*Généralités sur la théorie  
des modèles de prévision :*

*Modèles stochastiques et  
modèles basés sur  
l'intelligence artificiels*

### II.1. Introduction

Dans le contexte de la prévision des écoulements entre autres les apports liquides au sein des barrages réservoirs, une large gamme de méthodes sont à tester et à évaluer à savoir : les modèles stochastiques tels que définis par [Feller \(1968\)](#) : il s'agit de tous les modèles utilisant la théorie des probabilités pour représenter l'incertitude ([Fortin et al., 1997](#)). Et non stochastiques comme les approches plus créatrices basées sur l'aspect de l'intelligence artificielle.

On se limitera dans cette thèse à appliquer deux catégories de modèles ; 1) stochastiques paramétriques dits : « moyenne mobile intégrée autorégressive » (ARIMA) et « lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers » (TBATS) et 2) non stochastiques provenant de l'apprentissage machine supervisé. L'apprentissage supervisé est une technique de calage automatique permettant de créer une fonction à partir de données réservées à cette phase. Les données d'apprentissage consistent en des paires d'objets d'entrée (généralement des vecteurs) et de sorties souhaitées (cibles). La sortie de la fonction peut être une valeur continue (comme dans la régression), ou peut prédire une étiquette de classe de l'objet d'entrée (pour la classification). La tâche de l'apprenant supervisé est de prédire la valeur de la fonction pour tout point d'entrée valide après avoir vu un nombre fini d'exemples d'entraînement.

Les principaux algorithmes d'apprentissage supervisé sont : les réseaux de neurones artificiels (perceptron multicouches par exemple, désignés par ANN), l'apprentissage par arbre de décision (forêts aléatoires par exemple, désignées par RF), considérés parmi les modèles à base de règles et dits aussi modèles ensembles et les machines à vecteurs de support, considérés principalement pour la classification (Classifier), (réservés à la régression par exemple, désignés par SVM), ces trois algorithmes vont être décrits succinctement dans ce chapitre, implémentés et appliqués dans les prochains chapitres et ce après l'introduction des modèles stochastiques ARIMA et TBATS.

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

Ensuite, nous allons définir succinctement les critères d'évaluation des modèles utilisés, à savoir les métriques numériques telles que le coefficient de corrélation  $R$ , Erreur quadratique moyenne  $RMSE$ , erreur absolue moyenne  $MAE$ , erreur moyenne absolue en pourcentage  $MAPE$ , coefficient de Nash-Sutcliffe ( $NSE$ ), et le coefficient de Kling-Gupta ( $KGE$ ). Deux types de critères graphiques de visualisation permettant de réunir plus d'une métrique numérique déjà utilisée seront présentés, et ce sur des graphiques uniques sous forme de diagrammes et de boîtes dits de Taylor et en violon, respectivement. Le but est toujours avoir plus d'illustration sur le choix des modèles les plus adéquats de prévision des apports liquides journaliers au sein de la zone en question. La notion et l'utilité de la technique de cross-validation sera mise en exergue.

### II.2. Généralités sur la théorie des modèles de prévision

#### II.2.1. Modèles stochastiques de séries temporelles

##### II.2.1.1. Modèles ARIMA

L'un des moyens les plus populaires de modélisation des séries chronologiques est la modélisation de la moyenne mobile intégrée autorégressive (ARIMA) introduite par Box et Jenkins pour prévoir les séries chronologiques (Box et Jenkins, 1976).

Les modèles ARIMA ou Box-Jenkins sont relativement faciles à implémenter (Hyndman et Khandakar, 2008). Un modèle ARIMA saisonnier est noté ARIMA (Autoregressive Integrated Moving Average : (autorégressif à moyenne mobile intégrée),  $(p,d,q) (P, D,Q)s$ , la série dépend d'une part des valeurs précédentes (partie non saisonnière) et d'autre part des valeurs à la même période des années précédentes (partie saisonnière) où  $s$  la période saisonnière qui est égale à 12 pour le cas d'une série mensuelle.

Un modèle ARIMA( $p,d,q$ ) (partie non saisonnière) peut rendre compte de la dépendance temporelle de plusieurs manières. Premièrement, la série temporelle est différenciée pour la rendre stationnaire. Si  $d = 0$ , les observations sont modélisées directement, et si  $d = 1$ , les différences entre observations consécutives sont modélisées. Deuxièmement, la dépendance temporelle du processus stationnaire  $y_t$

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

est modélisée en incluant  $p$  modèles autorégressifs. Troisièmement,  $q$  sont des termes des modèles à moyenne mobile. Le processus prend en charge l'observation des erreurs précédentes. Enfin, en combinant ces trois modèles, on obtient le modèle ARIMA. Ainsi, la forme générale des modèles ARIMA est donnée par :

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (\text{II.1})$$

Où  $y_t$  et  $y_{t-i}$  sont des processus stochastiques stationnaires au temps  $t$  et  $t-i$ ,  $c$  est la constante qui détermine le niveau de la série chronologique,  $\varepsilon_t$  est le terme d'erreur ou de bruit blanc,  $\phi_i$  signifient les coefficients autorégressifs et  $\theta_j$  sont les coefficients de moyenne mobile. Pour une série temporelle saisonnière, ces étapes peuvent être répétées selon la période du cycle, quel que soit l'intervalle de temps. Le processus est le même pour la partie saisonnière quant  $D \neq 0$ .

### II.2.1.2. Modèles TBATS

Le principal inconvénient de l'approche ARIMA est que la saisonnalité est forcée d'être périodique, alors qu'un modèle TBATS permet des saisonnalités multiples, complexes et dynamiques dans les séries temporelles (Gould et al., 2008). TBATS (lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers), en anglais (Trigonometric Exponential smoothing state space model with Box-Cox transformation, ARMA errors, Trend and Seasonal components), est une alternative développée par (De Livera et al., 2011). Ce modèle utilise une combinaison de termes de Fourier avec un modèle d'espace d'état de lissage exponentiel et une transformation de Box-Cox, de manière complètement automatisée (Hyndman, 2017). Le modèle BATS peut être exprimé de la manière suivante :

Pour une série temporelle  $y_t$  de  $N$  données observées, on définit une transformation de Box-Cox avec le paramètre  $\omega$  comme suit :

$$y_t^{(\omega)} = \begin{cases} \frac{y_t^{(\omega)} - 1}{\omega}, & \omega \neq 0 \\ \log(y_t), & \omega = 0. \end{cases} \quad (\text{II.2})$$

Ensuite on a :

$$y_t^{(\omega)} = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^V S_{t-m_i}^{(i)} + d_i \quad (\text{II.3})$$

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

Où  $l_t = l_{t-1} + \phi b_{t-1} + \alpha d_t$  est le niveau local dans la période  $t$ ,  $b_t = (1 - \phi)b + \phi b_{t-1} + \beta d_t$  est la tendance à court terme de la période  $t$  avec  $b$  est la tendance à long terme,  $d_t = \sum_{i=1}^p \phi_i d_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$  désigne un modèle ARMA( $p, q$ ) avec les paramètres  $\phi_i$  (pour  $i = 1, \dots, p$ ),  $\theta_i$  (pour  $i = 1, \dots, q$ ) et  $\varepsilon_t$  un bruit blanc. La  $i$ -ème composante saisonnière au temps  $t$  est définie comme :  $S_t^{(i)} = S_{t-m_i}^{(i)} + \gamma_i d_t$ . Les paramètres de lissage sont donnés par  $\alpha, \beta, \gamma_i$ , pour  $i = 1, \dots, V$ , pour déterminer l'étendue de l'effet des composantes irrégulières sur les états  $b_t^{(i)}, l_t^{(i)}$  et  $S_t^{(i)}$ , respectivement. La principale différence entre TBATS et les autres modèles saisonniers consiste en l'utilisation d'ARMA et de la transformation de Box-Cox, cela permet de capturer des informations supplémentaires dans les données. De plus, [Livera et al., \(2011\)](#) ont introduit une représentation trigonométrique des composantes saisonnières basée sur la forme de série de Fourier proposée par [West et Harrison \(1997\)](#), fournissant le modèle TBATS ( $\omega, \phi, p, q, \{m_1, k_1\}, \{m_2, k_2\}, \dots, \{m_V, k_V\}$ ), ([Gos et al., 2020](#)). Le terme  $k_i$  est le nombre d'harmoniques pour la composante saisonnière  $S_t^{(i)}$ . TBATS est un acronyme pour les principales caractéristiques du modèle, où 'T' désigne la représentation trigonométrique des composantes saisonnières, 'B' représente la transformation de Box-Cox, 'A' indique le résidu ARMA, 'T' pour la composante de tendance et 'S' pour composante saisonnière. Le modèle TBATS gère les caractéristiques non linéaires typiques qui sont souvent observées dans les séries en temps réel et s'adapte à toute autocorrélation dans les résidus. L'avantage du modèle TBATS est que la fonction trigonométrique peut être utilisée pour des modèles avec une fréquence saisonnière élevée. Le modèle TBATS est basé aussi sur la transformation de Fourier. Dans ce modèle, la  $i$ -ème composante saisonnière  $S_t^{(i)}$  est défini en suivant un système d'équations qui s'écrit :

$$\begin{cases} S_t^{(i)} = \sum_{j=1}^{k_i} S_{j,t}^{(i)}, \\ S_{j,t}^{(i)} = S_{j,t-1}^{(i)} \cos \lambda_j^{(i)} + S_{j,t-1}^{*(i)} \sin \lambda_j^{(i)} + \gamma_1^{(i)} d_t, \\ S_{j,t}^{*(i)} = -S_{j,t-1}^{(i)} \sin \lambda_j^{(i)} + S_{j,t-1}^{*(i)} \cos \lambda_j^{(i)} + \gamma_2^{(i)} d_t \end{cases} \quad (\text{II.4})$$

Où  $\gamma_1^{(i)}$  et  $\gamma_2^{(i)}$  sont les paramètres de lissage et  $\lambda_j^{(i)} = \frac{2\pi j}{m_i}$  décrit le niveau stochastique de la  $i$ -ème composante saisonnière comme étant  $S_{j,t}^{(i)}$  et  $S_{j,t}^{*(i)}$  s'agissant

de la croissance stochastique de la  $i$ -ème composante saisonnière et décrit les changements saisonniers dans le temps. Le nombre d'harmoniques  $k_i$  requis pour la  $i$ -ème composante saisonnière est défini de la manière suivante :

$$k_i = \begin{cases} \frac{m}{2}, & m \text{ pair} \\ \frac{m-1}{2}, & m \text{ impair} \end{cases} \quad (\text{II.5})$$

### II.2.2. Modèles basés sur l'intelligence artificiels

#### II.2.2.1. Modèles ANN (Artificial Neural Network)

Le premier modèle de neurone formel proposé en 1943 par le mathématicien W. Pitts et le neurophysiologue Mc Culloch ([McCulloch et Pitts, 1943](#)), c'est ce modèle qui a initié les recherches en réseaux de neurones formels. Les modèles des réseaux de neurones artificiels désignés ici par ANN sont des modèles de calcul inspirés de la biologie des fonctions du cerveau humain ([Solomatine et al., 2008](#)). Typiquement, ils se composent de trois couches, à savoir la couche d'entrée, les couches cachées et la couche de sortie. Les relations entre les entrées et les sorties et l'état des réseaux sont extraites des données elles-mêmes pendant l'apprentissage des modèles ([Dumedah et al., 2014](#)). Une mise en correspondance entrée-sortie est effectuée à l'aide d'un ensemble de traitements interconnectés à travers les couches cachées ([Ghumman et al., 2018](#)). Chaque neurone de la couche cachée reçoit des signaux d'autres neurones et sera traité par une fonction dite d'activation. La fonction d'activation couramment utilisée est la fonction logistique, la fonction linéaire ou la fonction sigmoïde. Les données sont traitées de l'entrée à la sortie à travers la couche cachée successivement dans ce qui est appelé rétropropagation (feedforward). L'algorithme de la rétropropagation, qui a été principalement développé, documenté et appliqué dans ([Hornik et al., 1989](#) ; [Hornik, 1991](#) ; [Werbos, 1990](#) ; [Werbos, 1994](#)), est l'algorithme d'apprentissage le plus couramment utilisé dans les réseaux neuronaux à action directe ([Kasabov, 1996](#)). Cet algorithme minimise l'erreur entre les valeurs de sortie modélisées et réelles grâce à un algorithme d'optimisation par descente de gradient. Un ajustement des connexions pondérées entre les couches est défini après chaque épisode de formation jusqu'à ce que l'erreur dans l'ensemble de données de validation commence à augmenter ([Dawson et Wilby, 2001](#)).



## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

Plus loin dans un chapitre à part, les réseaux de perceptions multicouches avec une couche d'entrée qui contient un nombre de neurone égal au nombre de variables prédictives (inputs) et deux couches cachées utilisant l'algorithme d'apprentissage de la rétropropagation seront entraînés pour établir les modèles ANN dans le but pour prédire les apports journaliers dans les trois barrages objets d'étude. La fonction identité est la plus simple possible ; le résultat est appelé un **assocateur linéaire**. Une **fonction d'activation linéaire** est une **fonction d'activation** nulle : les unités de sortie sont identiques à leurs niveaux d'**activation**. Cette fonction sera utilisée dans les deux couches cachées et aussi une fonction linéaire dans la couche de sortie (la couche de sortie ayant un seul neurone qui correspond à la variable à prédire (output)). Le processus des modèles ANN, est globalement schématisé comme exemple par la figure suivante (Fritsch et al., 2019):

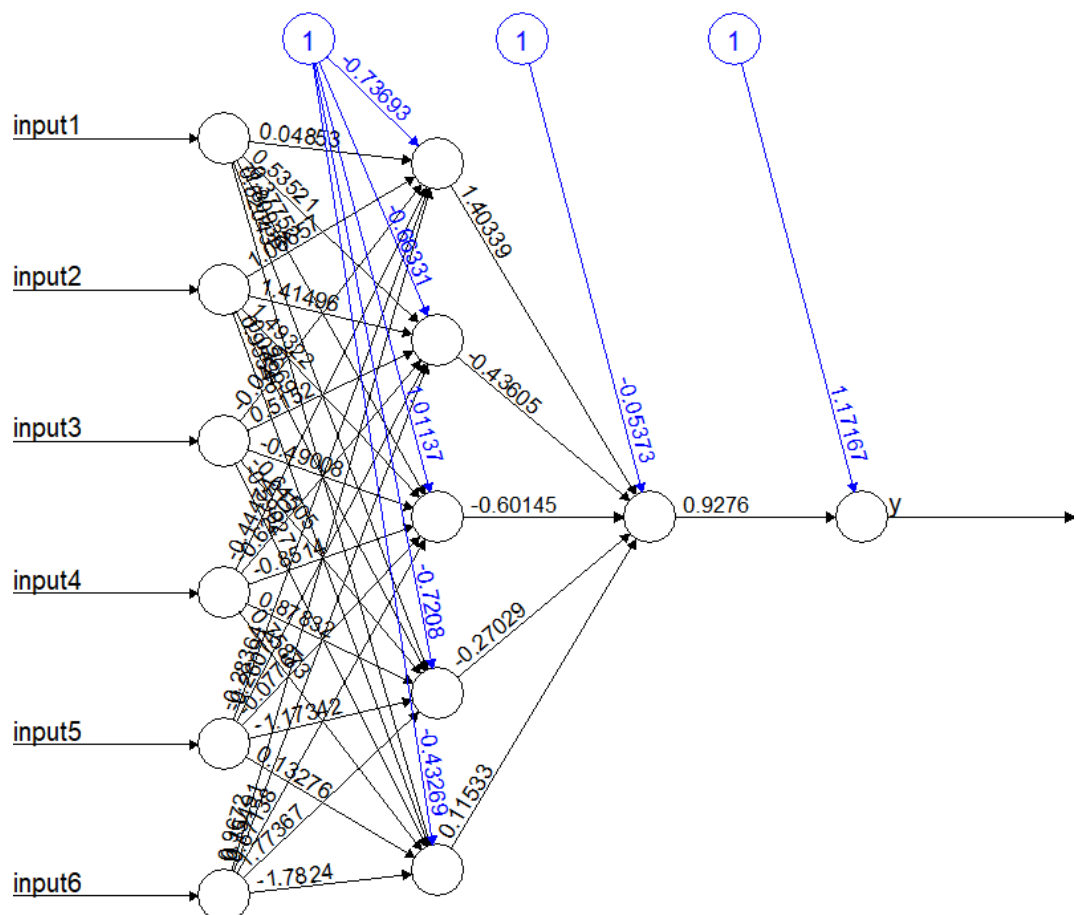


Figure II.1. Schéma exemple du processus global des modèles ANN adoptés (sortie graphique du package « neuralnet » ; Fritsch et al., 2019)



### II.2.2.2. Modèles RF (Random Forest)

Les algorithmes des forêts aléatoires (Random Forest) sont parmi les algorithmes d'apprentissage d'ensemble les plus puissants (Al-Mukhtar, 2019). Breiman (2001) a construit un algorithme unifié appelé forêts aléatoires. Il a proposé cet algorithme en ajoutant une couche supplémentaire d'aléatoire à la méthode dite mise en sac (bagging). Le modèle qui se base sur RF fonctionne en construisant de multiples arbres de décision et les prédictions finales sont obtenues à partir de la moyenne des résultats. Chaque arbre est construit en utilisant un échantillon tiré au sort (bootstrap) différent des données en adoptant des changements dans la façon dont les arbres de classification ou de régression sont construits. Ces changements sont représentés par l'échantillonnage aléatoire des prédicteurs candidats et le choix de la meilleure répartition entre les variables (Breiman, 2001). Par conséquent, deux paramètres sont primordiaux dans la RF, à savoir *ntree* et *mtry*. *ntree* est le nombre d'arbres dans la forêt, tandis que *mtry* est le nombre de variables dans le sous-ensemble aléatoire à chaque nœud. Dans cette étude, les valeurs prises par : *ntree* sont 70 et *mtry* variant de 1 à 7 pour avoir une erreur quadratique minimale, tandis que les valeurs par défaut de *ntree* et *mtry* soient 500 et  $p/3$ , respectivement, où  $p$  est le nombre de prédicteurs (Kuhn and Johnson, 2013). Breiman (2001) a aussi prouvé que les forêts aléatoires sont protégées contre le surapprentissage (overfitting) (Al-Mukhtar, 2019) ; par conséquent, le modèle ne sera pas affecté négativement si un grand nombre d'arbres sont construits pour la forêt.

L'algorithme de RF commence par le tirage d'un échantillon bootstrap *ntree* à partir des données. Ensuite, un arbre de classification ou de régression non coupé est développé pour chaque échantillon bootstrap (Ouedraogo et al., 2019). Ensuite, à chaque nœud, un échantillon aléatoire des prédicteurs doit être pris et la meilleure division parmi ces variables (prédicteurs) est choisie. Enfin, une nouvelle donnée est prédite en agrégeant la prédiction des arbres *ntree* (Liaw et Wiener, 2003).

Le processus des modèles RF, est globalement schématisé comme exemple par la figure suivante (conçu par l'auteur) :

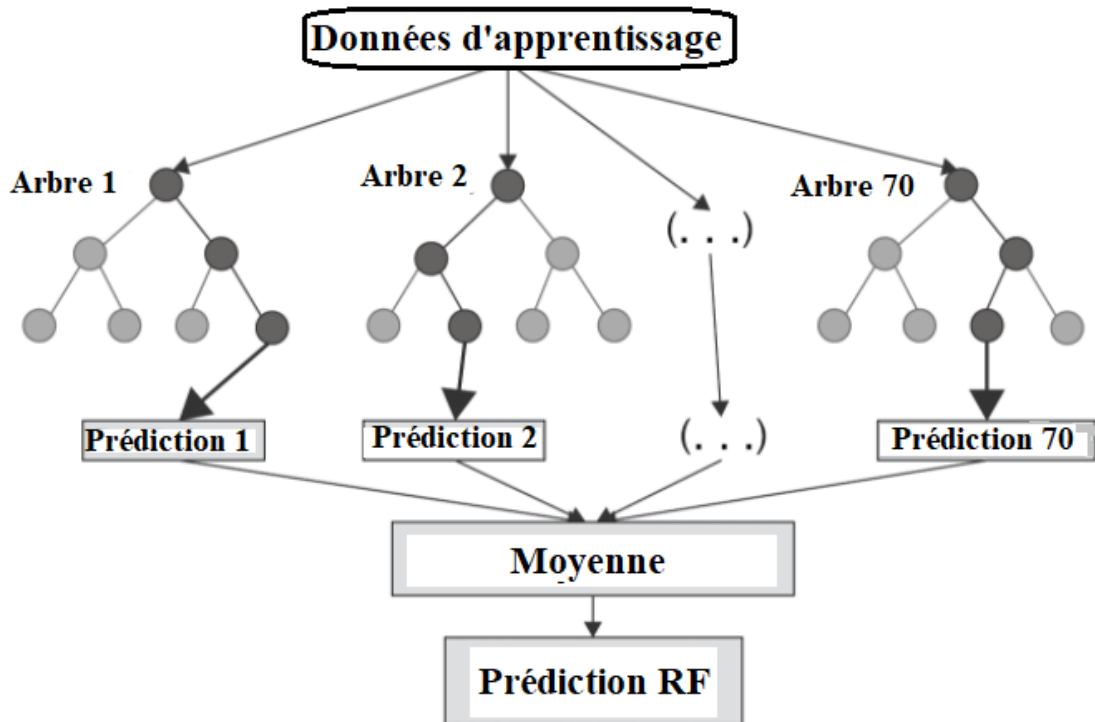


Figure II.2. Schéma exemple du processus global des modèles RF adoptés (conçu par l'auteur)

### II.2.2.3. Modèles SVM

Les machines à vecteurs de support (Support Vector Machines) souvent traduit par l'appellation de Séparateur à Vaste Marge (SVM) sont une catégorie d'algorithmes d'apprentissage supervisé initialement définis pour la classification (prévision d'une variable qualitative binaire). Ils ont été ensuite étendus aux problèmes de régression (prévision d'une variable quantitative). Le modèle SVM est une méthode d'intelligence artificielle développée par Vapnik (1995). Cette méthode a été utilisée avec succès dans la régression (Kecman, 2001). Il existe différents types de fonction noyau dans la régression par vecteur de support dit (SVR), à savoir : linéaire, polynomiale et à fonction de base radiale (RBF) (Lan, 2014). La fonction de base radiale est préférée quand il s'agit de mieux gérer les cas où les relations entre les entrées et les sorties sont non linéaires (Lin et al., 2006). A cet effet, le noyau RBF, communément utilisé, est adopté dans cette étude de thèse dans un chapitre plus loin. Ci-dessous une description succincte du RBF-SVM, également appelé  $\epsilon$ -SVR. La forme de régression pour le SVR est (Al-Mukhtar, 2019):

$$f(x) = w_i \varphi_i(x) + b \quad (\text{II.6})$$

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

Où  $w_i$  et  $b$  sont le vecteur de poids et le biais, respectivement, et  $\varphi_i$  est la fonction de convertisseur non linéaire utilisée pour tracer les vecteurs d'entrée dans un espace à haute dimension. La minimisation de l'équation (II.7) est réalisée par une fonction d'optimisation convexe donnée par l'équation (II.8) avec une fonction de perte d'insensibilité  $\varepsilon$  pour produire finalement le noyau non linéaire RBF dans l'équation (II.10), où  $\sigma$  est tel que défini habituellement dans une distribution gaussienne, correspondant à l'écart-type.

$$\frac{1}{2} \|W\|^2 + C(\sum_i^N (\xi_i + \xi_i^*)) \quad (II.7)$$

$$\begin{cases} w_i \varphi_i(x) + b_i - y_i \leq \varepsilon + \xi_i^*, & i = 1, 2, \dots, N \\ y_i - w_i \varphi_i(x) - b_i \leq \varepsilon + \xi_i, & i = 1, 2, \dots, N \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (II.8)$$

Où  $C$  est le facteur de coût qui définit l'erreur empirique dans le problème d'optimisation.  $\|W\|^2$  est un vecteur lisse euclidien.  $\xi_i$  et  $\xi_i^*$  sont des variables covariées qui causent l'erreur de formation pour les points de perte pour déterminer l'erreur de tolérance  $\varepsilon$  par la fonction de perte. Dans cette étude, la valeur prise par  $\varepsilon$  est égale à 0.1, tandis que les valeurs prises par  $\sigma$  et  $C$  varient de 0.005 à 0.01 par une incrémentation de 0.015 et de 1 à 25 par une incrémentation de 0.015 de 1, respectivement, et ce pour avoir une erreur quadratique minimale.

$$|\xi_\varepsilon| = |y - f(x)|_\varepsilon = \begin{cases} 0 & \text{si } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{sinon} \end{cases} \quad (II.9)$$

$$K(x, y) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (II.10)$$

Le processus des modèles SVM, est globalement schématisé comme exemple par la figure suivante :




Figure II. 3. Schéma exemple du processus global des modèles SVM adoptés ([https://www.researchgate.net/figure/Schematic-of-the-one-dimensional-support-vector-regression-SVR-model-Only-the-points\\_fig5\\_320916953](https://www.researchgate.net/figure/Schematic-of-the-one-dimensional-support-vector-regression-SVR-model-Only-the-points_fig5_320916953))

### II.3. Critère de choix entre modèles candidats ARIMA/TBATS

Les meilleurs modèles de prévision type ARIMA/TBATS sont ceux qui répondent au critère de qualité le plus reconnu dit le critère d'information de Akaike (AIC), (Akaike, 1974). Ce dernier critère aboutit au choix du modèle ayant la plus petite erreur quadratique moyenne en lui appliquant une pénalité qui est fonction du nombre de paramètres inconnus qui doivent être estimés. Ce critère favorise donc les modèles parcimonieux et il est calculé par la relation suivante :

$$AIC = 2k - 2 \log(L) \quad (II.11)$$

Où  $k$  est le nombre de paramètres estimés dans le modèle et  $L$  désigne la valeur maximale de la fonction de vraisemblance pour le modèle.

### II.4. Critères de performance des modèles de prévision

#### II.4.1. Les critères numériques

Diverses mesures statistiques ont été développées et utilisées dans la littérature. Pour évaluer l'ajustement et la précision prédictive des modèles dans la présente contribution, les ensembles de données ont été évalués mathématiquement en calculant et se limitant aux cinq critères de performance suivants : Le coefficient de corrélation ( $R$ ), la racine carrée de l'erreur quadratique moyenne ( $RMSE$ ), la

moyenne des erreurs absolues (*MAE*), l'erreur absolue moyenne en pourcentage (*MAPE*), et les critères de Nash-Sutcliffe (*NSE*) et de Kling-Gupta (*KGE*) ; exprimés par les équations suivantes et définis comme suit :

#### II.4.1.1. Coefficient de corrélation

Le degré d'association linéaire mesuré entre deux variables est communément qualifié par le coefficient de corrélation (Pearson) (*R*) (Carslaw, 2015). Il est donné par :

$$R = \frac{\frac{1}{N} \sum_{i=1}^N (M_i - M_m)(P_i - P_m)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (M_i - M_m)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - P_m)^2}} \quad (\text{II.12})$$

#### II.4.1.2. Erreur quadratique moyenne

L'erreur quadratique moyenne (*RMSE*) est une métrique généralement utilisée, elle donne une bonne mesure de la proximité entre les valeurs modélisées et les valeurs prédites (Carslaw, 2015). Elle est exprimée par la relation suivante :

$$RMSE = \left( \frac{\sum_{i=1}^N (P_i - M_i)^2}{N} \right)^{1/2} \quad (\text{II.13})$$

#### II.4.1.3. Erreur absolue moyenne

L'erreur absolue moyenne (*MAE*) est la différence moyenne entre les valeurs prédites et les valeurs observées (Willmott et Matsuura, 2005). Sa formulation est la suivante :

$$MAE = \frac{\sum_{i=1}^N |P_i - M_i|}{N} \quad (\text{II.14})$$

#### II.4.1.4. Erreur moyenne absolue en pourcentage

L'une des métriques les plus couramment utilisées pour mesurer la précision des prévisions d'un modèle est *MAPE*, qui correspond à l'erreur moyenne absolue en pourcentage. Cet indicateur de performance est facile à interpréter. Par exemple, une valeur *MAPE* de  $x$  % signifie que la différence moyenne entre la valeur prévue et la valeur réelle est de  $x$  %. Néanmoins, il faut être prudent lors de l'utilisation de cette métrique, car si les séries temporelles ont des valeurs nulles, *MAPE* donne des résultats indéfinis en raison de la division par zéro.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{(M_i - P_i)}{M_i} \right| * 100 \quad (\text{II.15})$$

### II.4.1.5. Coefficient de Nash-Sutcliffe

Le coefficient d'efficacité de Nash-Sutcliffe (*NSE*) est fréquemment utilisé pour l'évaluation des modèles hydrologiques. Il s'agit d'une métrique normalisée qui fixe la plage relative de la variance du résidu liée à la modification des données mesurées (Nash et Sutcliffe, 1970). Il s'exprime comme suit (Zambrano-Bigiarini, 2020) :

$$NSE = \left( 1 - \frac{\sum_{i=1}^N (P_i - M_i)^2}{\sum_{i=1}^N (M_i - M_m)^2} \right) \quad (\text{II.16})$$

La valeur de Nash-Sutcliffe va de  $-\infty$  à 1. Essentiellement, plus elle est proche de 1, plus le modèle est performant.

$NSE = 1$ , correspond à une parfaite concordance entre le modèle et les données mesurées.

$NSE = 0$ , indique que les prévisions du modèle sont homologues à la moyenne des données mesurées.

$-\infty < NSE < 0$ , indique que la moyenne des données mesurées est meilleure que les prévisions du modèle.

### II.4.1.6. Coefficient de Kling-Gupta

Le coefficient d'efficacité de de Kling-Gupta a été développée par Gupta et al., (2009) pour fournir une décomposition intéressante du point de vue diagnostique de l'efficacité de Nash-Sutcliffe (et donc de l'MSE), ce qui facilite l'analyse de l'importance relative de ses différentes composantes (corrélation, biais et variabilité) dans le contexte de la modélisation hydrologique Kling et al., (2012), ont proposé une version révisée de cet indice, pour s'assurer que les ratios de biais et de variabilité ne sont pas corrélés entre eux (Zambrano-Bigiarini, 2020).

$$KGE = 1 - \sqrt{(R - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (\text{II.17})$$

Où :

$R$  : le coefficient de corrélation de Pearson. La valeur idéale est  $R = 1$

$\alpha$  : le rapport entre l'écart type des valeurs simulées (prédites) et l'écart type des valeurs observées (mesurées). La valeur idéale est  $\alpha = 1$ .

$\beta$  : le rapport entre la moyenne des valeurs prédites et la moyenne des valeurs mesurées. La valeur idéale est  $\beta = 1$ .

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

La valeur de Kling-Gupta va à son tour de  $-\infty$  à 1. Essentiellement, plus elle est proche de 1, plus le modèle est performant.

$KGE = 1$ , correspond à une parfaite concordance entre le modèle et les données mesurées.

$KGE = 0$ , indique que les prévisions du modèle sont homologues à la moyenne des données mesurées.

$-\infty < KGE < 0$ , indique que la moyenne des données mesurées est meilleure que les prévisions du modèle.

Dans (Knoben et al., 2019), les auteurs affirment que les valeurs KGE supérieures à -0,41 indiquent qu'un modèle améliore la référence du débit moyen - même si la valeur KGE du modèle est négative. Les valeurs NSE et KGE ne peuvent pas être comparées directement, car leur relation n'est pas unique et dépend en partie du coefficient de variation de la série chronologique observée.

Dans toutes les formulations précédentes  $N$  est le nombre de points de données (tailles des séries temporelles),  $M_i$  les valeurs mesurées et  $P_i$  est les valeurs prédites correspondantes.  $M_m$  et  $P_m$  sont les valeurs moyennes des  $M_i$  et  $P_i$ .

### II.4.1.7. Gain relatif

Le gain relatif (GR) reflète le pourcentage d'amélioration ou non en performance, en comparant pour chaque indice de performance (IP), des modèles  $M_i$  sans introduction de la variable exogène avec des modèles  $M_j$  avec introduction de la variable exogène.

$$GR = 100 \frac{IP_{M_i} - IP_{M_j}}{IP_{M_i}} \quad (7)$$

### II.4.2. Les critères graphiques

Pour évaluer la performance d'un modèle, on peut se concentrer sur la fluctuation journalière de l'apport liquide par exemple comme on peut se concentrer sur les cas extrêmes de basses et de hautes eaux dans les retenus des barrages-réservoirs, et la persistance de ces événements extrêmes. Par conséquent, les résultats ne sont pas entièrement défendables si on ne se concentre que sur une seule métrique de performance et faire des déductions qui ignorent de nombreux autres composants du système. A cet effet, on va exposer une technique de

visualisation qui permet de dessiner trois métriques du système sur le même graphique. Ce graphique s'appelle diagramme de Taylor.

Une autre visualisation graphique aussi informative concerne les boîtes en violon (violin plot) sera également présentée et utilisée ultérieurement.

Finalement, quel que soit le modèle, ou le pas de temps utilisé, l'analyse graphique est indispensable et primordiale, pour juger de la qualité du modèle, cela est obtenu en ajustant graphiquement les courbes des apports observés avec celles des apports calculés par le modèle.

### II.4.2.1. Diagramme de Taylor

Le diagramme de Taylor n'est pas vraiment une solution au problème de choix global des métriques de performance des modèles de prévision, mais il fournit quand même un moyen systématique et mathématiquement fondé de démontrer quelques mesures usuelles de qualité d'ajustement. Le diagramme de Taylor comprend trois mesures de performance : *i*) l'écart type des valeurs prédites par rapport aux observées ; *ii*) le coefficient de corrélation entre valeurs prédites et observées et *iii*) l'erreur quadratique moyenne centrée (*CRMSE*).

L'équation ci-dessous met les trois métriques en relation :

$$CRMSE = \sigma_M^2 + \sigma_P^2 - 2\sigma_M\sigma_P R \quad (II.18)$$

Où  $\sigma_M$  et  $\sigma_P$  sont les écarts types des données mesurées (observées) et prédites, respectivement et  $R$ , le coefficient de corrélation correspondant.

### II.4.2.2. Boîtes en violon

Un diagramme en violon (violin plot) est une méthode de représentation graphique de données numériques. Il est similaire à une boîte à moustache (box plot), qui donne quatre caractéristiques principales d'une variable : le centre, la dispersion, l'asymétrie et les valeurs aberrantes, avec l'ajout d'un graphique de densité de noyau de chaque côté. Le diagramme en violon, introduit dans cet thèse, combine alors et en synergie le diagramme en boîte à moustache et la trace de densité (ou histogramme lissé) en un seul affichage qui révèle la structure des données.



### II.5. Notion et utilité de la technique de cross-validation

L'étape principale de la détermination des valeurs des paramètres dans tout processus de modélisation consiste à trouver un moyen approprié et de voir comment un modèle se comporte. La validation croisée est un moyen de répondre à cette question. L'utilisation de la validation croisée répétée est avant tout recommandée lorsqu'elle est réalisable sur le plan informatique (Rodriguez et al., 2010). Les modèles choisis doivent être ajustés avec leurs hyperparamètres les plus fins afin d'éviter le surajustement. La méthode de validation très utilisée, connue sous le nom de K-fold CV répétée, a été utilisée dans le processus de réglage des hyperparamètres afin d'éviter un biais de sélection des données (Sathishkumar et Yongyun, 2020 ; Hagenauer et al., 2019 ; Thanh Noi et al., 2017). Bien qu'il n'existe pas de règle stricte pour déterminer la valeur de K (Kuhn et Johnson, 2013), une valeur de K=10 s'avère optimale dans de nombreuses recherches et elle est plus intéressante du point de vue de l'efficacité informatique (Kuhn et Johnson, 2013). Zhang et Yang ont considéré que la 5-CV est aussi normalement utilisée pour la sélection de modèles (Zhang et Yang, 2015), tandis que Jung a recommandé la valeur entière de  $\log(n)$  comme règle de sélection de K (Jung, 2018). Par conséquent, nous choisissons le  $\log(n=3647)$ -fold (= huit-folds) CV selon la taille des échantillons (des apports liquides journaliers des barrages-réservoirs étudiés) et les variables maintenus (jusqu'à six variables). Ainsi, la CV à huit répertoires a été appliquée une seule fois (pour la rapidité d'exécution) pour réduire la dispersion de la performance estimée, et les résultats ont été moyennés pour les modèles implémentés. Pour effectuer une validation croisée et décider des meilleurs paramètres, nous avons utilisé les échantillons de la phase calage (apprentissage) de l'ensemble des données. Ensuite, en utilisant les paramètres adoptés, le modèle définitif est retenu. Enfin, pour prédire la sortie (Apport), les données réservées à la validation ont été appliquées aux modèles pour réaliser les prévisions souhaitées au sein de chaque barrage.

### II.6. Conclusions

Ce chapitre a été rédigé sous forme de rappels des notions liées aux techniques de modélisation issues des modèles des séries temporelles stochastiques

## Chapitre II : Généralités sur la théorie des modèles de prévision : Modèles stochastiques et modèles basés sur l'intelligence artificiels

---

paramétriques dits : « moyenne mobile intégrée autorégressive » (ARIMA) et « lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers » (TBATS), et les modèles basés sur l'intelligence artificielle étalés principalement sur les réseaux de neurones artificiels à perceptrons multicouches (désignés par ANN), l'apprentissage par arbres de décision à base de règles ou modèles d'ensemble dites forêts aléatoires (désignées par RF), et les machines à vecteurs de support (désignés par SVM).

Ensuite, nous avons présenté les critères d'évaluation des modèles utilisés, à savoir les métriques numériques telles que le coefficient de corrélation  $R$ , Erreur quadratique moyenne  $RMSE$ , erreur absolue moyenne  $MAE$ , erreur moyenne absolue en pourcentage  $MAPE$ , coefficient de Nash-Sutcliffe ( $NSE$ ), et le coefficient de Kling-Gupta ( $KGE$ ).

Il faut signaler que lors de l'utilisation du  $MAPE$  que cette métrique pose problème des valeurs indéfinies, car si les séries temporelles ont des valeurs nulles, la métrique donne des résultats (Inf.) en raison de la division par zéro ce qui n'encourage pas son utilisation lors de la modélisation à l'échelle journalière à cause de la présence des apports journaliers nuls (pas d'apports ou affluents nuls). En revanche le critère  $KGE$  sera déterminant. La métrique  $MAPE$  sera réservée à l'affirmation des modèles à l'échelle mensuelle.

Enfin, nous avons exposé deux types de critères graphiques de visualisation qui permettent d'englober plus d'une métrique numérique déjà utilisée et ce sur des graphiques uniques sous forme de diagramme de Taylor et sur des boites en violon et tout cela pour plus d'illustration et d'affirmation portant sur le choix des meilleurs modèles de prévision des apports liquides journaliers au sein de la zone d'étude. Le point a été mis sur la notion et l'utilité de la technique de cross-validation.

## *Chapitre III*

*Présentation des données  
et essai de compréhension  
des structures internes des  
séries temporelles*

### III.1. Introduction

Ce chapitre s'intéresse à l'acquisition, le contrôle de la fiabilité et le traitement des données utilisées sous formes d'apports liquides journaliers et mensuels, mesurés en million de mètre cube (Mm<sup>3</sup>) pour une finalité d'élaboration des modèles de prévision des apports au sein de trois barrages réservoirs choisis délibérément pour présenter trois climats distincts de l'Algérie (Kassoul et al., 1997). Il s'agit du barrage de Hammam Boughrara situé à l'ouest du pays avec une pluviométrie moyenne annuelle de 400 mm environ (présentant un climat semi-aride), du barrage de Beni Haroun situé à l'est du pays avec une pluviométrie moyenne annuelle de 600 mm environ (présentant un climat subhumide) et du barrage de Taksebt situé au centre du pays avec une pluviométrie moyenne annuelle de 1000 mm environ (présentant un climat humide).

Les données fournies par l'Agence Nationale des Barrages et Transferts (ANBT, 2019) constituent la source principale pour l'élaboration des travaux de cette thèse. Elles sont composées des données d'exploitation des barrages choisis, et sur une période de onze ans.

### III.2. Acquisition des données d'exploitation

Dans le but d'établir le bilan hydraulique du réservoir et de mettre en place un outil de suivi de la disponibilité en eau, une série de mesures est réalisée par l'exploitant du barrage au pas de temps journalier (tous les matins à 8 heures). Ces données sont portées régulièrement sur une fiche préétablie intitulée « *état de la réserve* », puis saisies sous format numérique (Excel) pour être exploité par la suite.

#### III.2.1. Paramètres mesurés

Les variables accessibles à l'observation sont :

1. La côte du plan d'eau : mesurée par un levé direct en utilisant un appareil topographique installé sur un point, qui sert de référence, situé sur la dalle en béton de la tour de prise d'eau, ou bien lecture directe sur l'échelle hydrographique graduée ;
2. L'évaporation : déterminée de façon manuelle par l'observateur à partir d'un bac d'évaporation ;

## Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

3. Les fuites de l'ouvrage récupérables : mesurées sur le canal principal de collecte des fuites moyennant un déversoir triangulaire ;
4. Les lâchers pour l'irrigation et la vidange : déterminées à partir de la loi d'ouverture de la vanne de vidange de fond ;
5. Les lâchers pour l'Alimentation en Eau Potable : déterminées à partir de la loi d'ouverture de la vanne de prise ;
6. Les volumes d'eau déversés : calculés en fonction de la courbe  $Q_{\text{déversé}} = f(h)$ .

### III.2.2. Paramètres estimés

Les variables estimées sont :

- a. Le volume stocké dans le réservoir et la surface du plan d'eau : déduits des courbes « Hauteur - Capacité - Surface » ;
- b. **b.** L'évaporation au niveau du barrage : estimée de la manière suivante :  
$$Evap\ barrage\ (m^3) = [Evap\ bac\ (m) * 0,8464(m^2)] * Surface\ d'(m^2) * 0,78$$
  
(III.1)
- c. L'apport entrant dans le réservoir qui découle du principe de la conservation des volumes d'eau exprimés en  $hm^3$  (Albergel et al.,1997) soit :

$$APP = (V_{final} - V_{initial}) + (AEP + IRR + EVAP + VID + FUI + EVAC) \quad (III.2)$$

**Avec :**

*APP* : volume des apports globaux entrant dans le barrage ;

*V<sub>final</sub>* : volume stocké au temps (*t+1*)

*V<sub>initial</sub>* : volume stocké au temps (*t*)

*AEP* : volume alloué à l'alimentation en eau potable ;

*IRR* : volume alloué à l'irrigation ;

*EVAP* : volume évaporé ;

*VID* : volume de vidange ;

*FUI* : volume des fuites ;

*EVAC* : volume déversé.

Signalons que les apports globaux entrant dans le barrage regroupent les volumes ruisselés, les apports souterrains et les apports pluviométriques sur la retenue.

## Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

Les apports liquides journaliers ou mensuels des barrages réservoirs sont alors déduits de l'équation (III.2) adoptée par l'Agence Nationale des Barrages et Transferts (ANBT, 2019) pour gérer tous les barrages en Algérie en termes de ressources hydriques.

### III.3. Etablissement du bilan hydraulique de la retenue

Le bilan des volumes d'un réservoir consiste en une balance d'eau effectuée jour par jour ou mois par mois à partir des données d'exploitation du barrage.

La figure III.1 schématise les états possibles de variation de la capacité du réservoir du barrage en utilisant l'expression (III.2) et les données d'exploitation.




Figure III. 1. Schéma du bilan des barrages-réservoirs (Bengora, 2019)

#### III.3.1. Apports ou affluents négatifs

Les apports ou les affluents négatifs sont conceptuellement impossibles et doivent être corrigés/ajustés (Wurbs, 2012). Les calculs des débits entrants et sortants des réservoirs donnent parfois lieu à des estimations des apports entrants négatifs, ce qui peut être dû à plusieurs raisons, comme une petite erreur dans la

## Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

mesure du niveau du réservoir, une mauvaise prise en compte du stockage du réservoir à n'importe quelle altitude, une erreur dans l'enregistrement des débits sortants ou d'autres variables, etc. Cette incohérence des données de débit entrant doit être traitée avant d'utiliser les données de débit pour une analyse plus approfondie. Dans ce qui suit toutes les valeurs négatives des apports sont prises comme valeurs nulles.

### III.3.2. Composantes

- **Gain de capacité** = Augmentation du volume de la retenue au début du jour «  $j+1$  » ou bien du mois «  $m+1$  » ;
- **Perte de capacité** = Diminution du volume de la retenue au début du jour «  $j+1$  » ou bien du mois «  $m+1$  » ;
- **Défluent** = Somme des sorties du barrage au jour «  $j+1$  » ou bien du mois «  $m+1$  » ;  
= Consommation + évaporation + fuites + vidange + déversement ;
- **Affluent** = Somme des entrées = Apport du jour «  $j+1$  » ou bien du mois «  $m+1$  »).

### III.4. Structures internes des séries temporelles

#### III.4.1. Objectifs principaux

L'étude d'une série chronologique permet d'analyser, de décrire et d'expliquer un phénomène au cours du temps et d'en tirer des conséquences pour des prises de décision. Mais l'un des objectifs principaux de l'étude d'une série chronologique est la prévision qui consiste à prévoir les valeurs futures de la série chronologique à partir de ses valeurs observées

Une série chronologique ( $X_t$ ) est la résultante de différentes composantes fondamentales :

- **La tendance (trend)** ( $Z_t$ ) représente l'évolution à long terme de la série étudiée. Elle traduit le comportement « moyen » de la série.
- **La composante saisonnière (saisonal)** (ou saisonnalité) ( $S_t$ ) correspond à un phénomène qui se répète à intervalles de temps réguliers (périodiques). En

## Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

général, c'est un phénomène saisonnier d'où le terme de variations saisonnières.

- **La composante résiduelle (remainder)** (ou bruit ou résidu) ( $\varepsilon_t$ ) correspond à des fluctuations irrégulières, en général de faible intensité mais de nature aléatoire.

### III.4.2. Description schématique de l'étude complète d'une série chronologique

Comme nous venons de le voir, l'un des objectifs principaux de l'étude d'une série chronologique est la prévision des valeurs futures de cette série. Pour cela, on a besoin de connaître ou tout au moins de modéliser le mécanisme de production de la série chronologique.

Schématiquement, les principales étapes de traitement d'une série chronologique sont les suivantes :

1. Correction des données (nettoyage des données)
2. Visualisation graphique des données à différentes échelles du temps.
3. Décomposition des séries temporelles en vue d'une compréhension des structures internes.
4. Analyse des séries temporelles à partir de leurs composantes.
5. Constatation des phénomènes caractérisant les séries ainsi analysées.

### III.4.3. Décomposition STL quasiment inspirée du document :

(<https://doc.arcgis.com/fr/insights/latest/analyze/stl.htm>)

La décomposition STL est une méthode développée par (Cleveland et al., 1990). STL est un acronyme pour "Seasonal and Trend decomposition using LOESS". C'est une approche polyvalente et robuste de décomposition des séries temporelles utilisant la technique dite LOESS (LOcally Estimated Scatterplot Smoothing) : (modèles de régression ajustés localement) pour décomposer et extraire des estimations lissées des trois composants (saisonniers, tendance et résidus), (saisonal, trend and remainder), d'une série chronologique. LOESS est une façon d'estimation des relations non linéaires. La décomposition STL est fréquemment employée dans les analyses économiques et environnementales, elle possède les avantages suivants :



### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

- a. La composante saisonnière peut évoluer dans le temps, le taux de variation étant contrôlé par l'utilisateur.
- b. Le lissage de la tendance-cycle peut également être contrôlé par l'utilisateur.
- c. Il peut être robuste aux valeurs aberrantes, de sorte que des observations inhabituelles n'affecteront pas les estimations des composantes tendance-cycle et saisonnière. Elles affecteront cependant la composante du résidu (remainder).
- d. La STL peut gérer tout type de saisonnalité.

L'algorithme STL effectue un lissage sur la série temporelle en utilisant LOESS en deux étapes ; la première étape est une boucle interne qui réalise une itération entre le lissage saisonnier et de tendance et la deuxième étape est une boucle externe qui réduit l'effet des points aberrants. Au cours de la boucle interne, le composant saisonnier est calculé d'abord, puis supprimé pour calculer le composant de tendance. Le reste est calculé en soustrayant les composants saisonniers et de tendance de la série chronologique.

- Le composant saisonnier (saisonal) d'une sortie de décomposition STL illustre le modèle temporel **récurrent** présent dans les données en fonction de la saisonnalité choisie. Si un modèle saisonnier existe, il prend généralement la forme d'une vague ou d'une **oscillation**.
- Le composant de tendance (trend) est le deuxième composant calculé au cours de la boucle interne. Les valeurs du composant saisonnier sont extraites des valeurs brutes, ce qui élimine la variation saisonnière de la série temporelle. Une ligne de tendance lissée est ensuite créée en appliquant LOESS aux valeurs résiduelles.
- Le composant résidu (remainder) est calculé en soustrayant les valeurs du composant saisonnier et du composant de tendance de la série chronologique. Les valeurs des résidus quantifient le bruit présent dans les données. Les valeurs proches de zéro indiquent que les composants saisonniers et de tendance sont exacts dans leur description de la série temporelle, tandis que des valeurs importantes indiquent la présence de bruit. Le composant résidu est également utilisé pour identifier les points

### **Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles**

---

aberrants dans les données, qui apparaissent sous forme de valeurs positives ou négatives relativement importantes par rapport aux autres valeurs résiduelles.

#### **III.5. Données journalières**

Les apports liquides journaliers des trois barrages-réservoirs maintenus pour l'étude dans ce travail de thèse sont adoptés par l'Agence Nationale des Barrages et Transferts (ANBT) pour gérer tous les barrages en Algérie en termes de ressources hydriques. La période à l'échelle journalière servant ainsi de base pour la suite de ce chapitre s'étale du 01/01/2002 au 31/12/2012, 01/01/2009 au 31/12/2019 et 01/01/2003 au 31/12/2013, soit 11 ans d'observation pour les trois barrages Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Les tailles des trois séries sont identiques ce qui écarte l'influence directe de la longueur de l'échantillon en faveur d'une influence attendue et probable du climat. Les valeurs numériques des apports journaliers au sein des trois barrages varient de 0 à 17.6 Mm<sup>3</sup>, de 0 à 76,45 Mm<sup>3</sup> et de 0 à 12.02 Mm<sup>3</sup> pour les barrages de Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Les valeurs numériques des pluies journalières ponctuelles au sein des trois barrages varient de 0 à 73.2 mm, de 0 à 80 mm et de 0 à 91 mm pour les barrages de Hammam Boughrara, Beni Haroun et Taksebt, respectivement.

Les séries temporelles à l'échelle journalière des apports des trois barrages sont illustrées par les figures qui suivent, sous forme d'évolutions temporelles (Figures : III.2, III.4 et III.6) et sous formes de boîtes à moustaches (Figures : III.3, III.5 et III.7) pour les barrages de Hammam Boughrara, Beni Haroun et Taksebt, respectivement.




Figure III.2. Visualisation des apports liquides journaliers du barrage de Hammam Bouhrara pour la période d'exploitation (01/01-2002-31/12/2012)

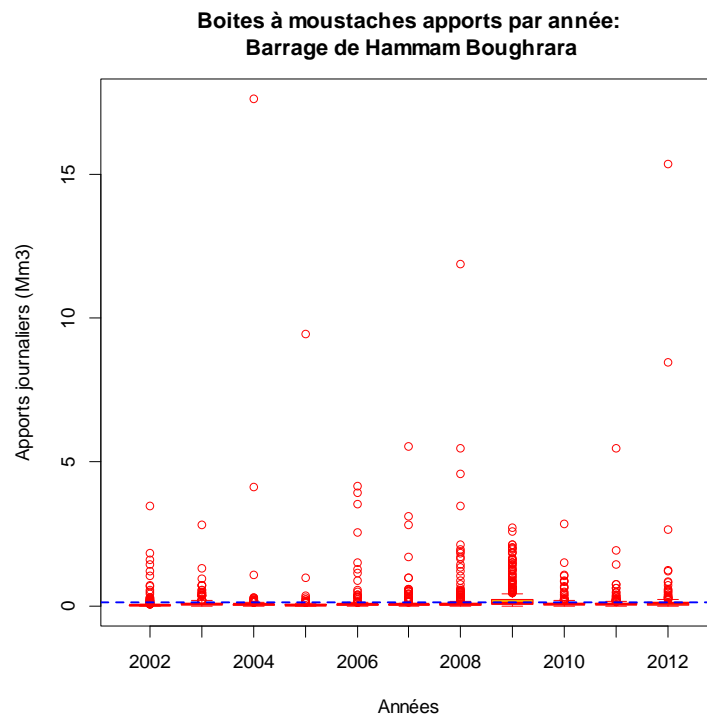


Figure III. 3. Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Hammam Bouhrara pour la période d'exploitation (01/01-2002-31/12/2012), la ligne en pointillé bleu indique l'apport moyen journalier interannuel (0.12771 Mm<sup>3</sup>)




Figure III.4. Visualisation des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019)

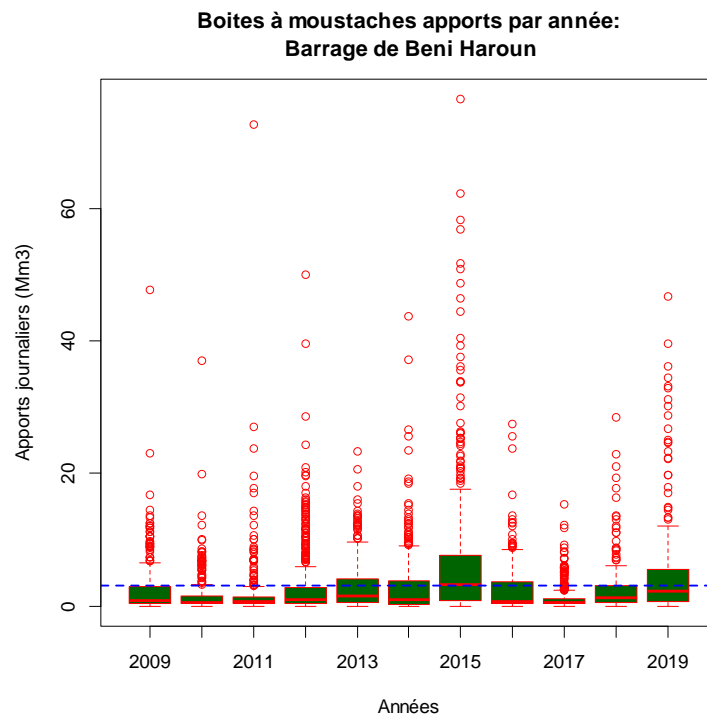


Figure III.5. Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019), la ligne en pointillé bleu indique l'apport moyen journalier interannuel ( $3.0356 \text{ Mm}^3$ )




Figure III.6. Visualisation des apports liquides journaliers du barrage Taksebt pour la période d'exploitation (01/01/2003-31/12/2013)

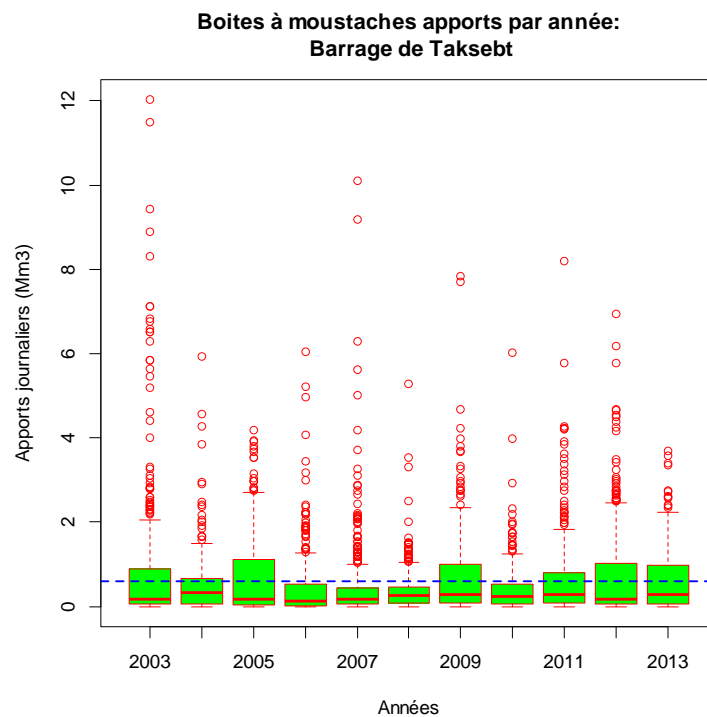



Figure III.7. Visualisation en boîtes à moustaches des apports liquides journaliers du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013), la ligne en pointillé bleu indique l'apport moyen journalier interannuel ( $0.589 \text{ Mm}^3$ )

### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

Les séries temporelles initiales des apports liquides journaliers des trois barrages peuvent être décomposées par la méthode STL de la façon illustrative sur les figures qui suivent, où on peut constater des périodicités très claires dans les données journalières des trois barrages et des doubles tendances (2002-2009, 2009-2012) pour le barrage de Hammam Boughrara ; (2009-2015 ; 2015-2019) pour le barrage de Beni Haroun) et une quasi-stationnarité (2004-2013) pour le barrage de Taksebt. Les valeurs restantes (remainder) tracées illustrent également des points aberrants clairs et considérables (des piques) pour les trois barrages (Figures III.8, III.9 et III.10), respectivement.



**Figure III.8. Décomposition STL de la série des apports liquides journaliers du barrage de Hammam Boughrara pour la période d'exploitation (01/01-2002-31/12/2012)**




Figure III. 9. Décomposition STL de la série des apports liquides journaliers du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019)





Figure III.10. Décomposition STL de la série des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013)

### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

Les fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports des trois barrages sont illustrées par les figures qui suivent où les ACF reflètent aussi les périodicités déjà remarquées dans les données journalières et des autocorrélations visualisées par les PACF, prononcées et prolongées au cours des cinq à six premiers jours, (Figures III.11, III.12 et III.13), pour les trois barrages ; Hammam Boughrara, Beni Haroun et Taksebt, respectivement.



**Figure III.11. Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Hammam Boughrara**






Figure III. 12. Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Beni Haroun




Figure III.13. Fonctions ACF et PACF des séries temporelles à l'échelle journalière des apports liquides du barrage de Taksebt

### III.6. Données mensuelles

Les apports liquides mensuels des barrages-réservoirs maintenus pour l'étude dans le présent travail de thèse sont alors déduits de l'équation (III.2)

### **Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles**

---

adoptée par l'Agence Nationale des Barrages et Transferts (ANBT) pour gérer tous les barrages en Algérie en termes de ressources hydriques. La période à l'échelle mensuelle servant ainsi de base pour la suite de cette contribution s'étale du 01/01/2002 au 31/12/2012, 01/01/2009 au 31/12/2019 et 01/01/2003 au 31/12/2013, soit 11 ans d'observation pour les trois barrages Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Les tailles des trois séries sont identiques (132 mois) ce qui écarte l'influence directe de la longueur de l'échantillon en faveur d'une influence attendue et probable du climat. Les valeurs numériques des apports mensuels au sein des trois barrages varient de 0,446 à 44.569 Mm<sup>3</sup>, de 7,614 à 686,034 Mm<sup>3</sup> et de 0,297 à 102,028 Mm<sup>3</sup> pour de Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Pour les modèles considérés dans cette contribution, la phase de calage s'étale sur les dix premières années et la phase de validation concerne la dernière année pour chaque barrage étudié à part.

Les séries temporelles à l'échelle mensuelle des apports des trois barrages sont illustrées par les figures qui suivent, sous forme d'évolutions temporelles (Figures : III.14, III.16 et III.18) et sous formes de boîtes à moustaches (Figures : III.15, III.17 et III.19) pour les barrages de Hammam Boughrara, Beni Haroun et Taksebt, respectivement. On constate que le barrage de Hammam Boughrara est mieux alimenté pendant les mois de mars et avril (la saison du printemps) et pendant les mois de septembre, octobre, novembre (période de crue en automne). Le barrage de Beni Haroun est abondamment alimenté pendant les mois de décembre jusqu'au mois de mai (la saison d'hiver et du printemps). Quant au barrage de Taksebt, il est de même amplement alimenté pendant la saison d'hiver et du printemps. Ces constatations sont basées sur la comparaison numérique vis-à-vis les valeurs moyennes interannuelles des apports mensuels correspondant à chaque barrage pris à part.




Figure III. 14. Visualisation des apports liquides mensuels du barrage de Hammam Bougrara pour la période d'exploitation (01/01/2002-31/12/2012)

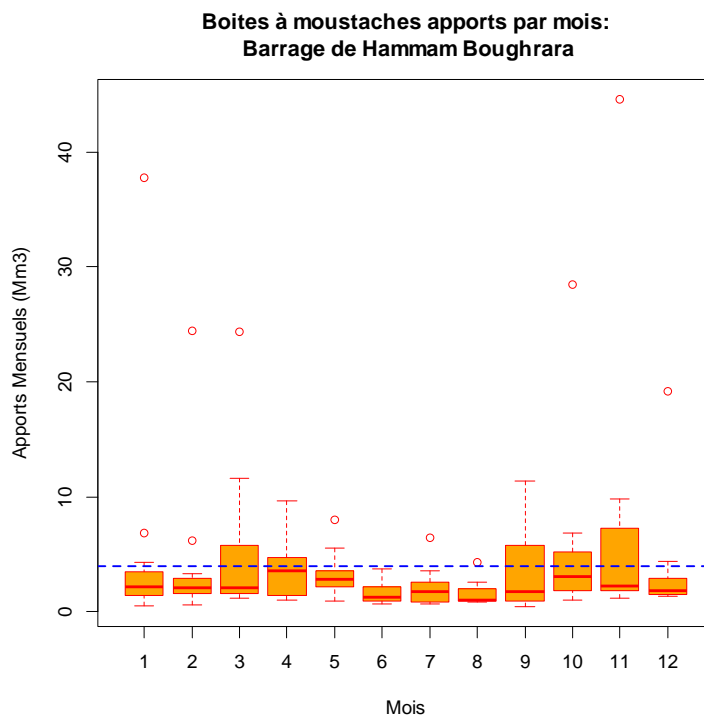


Figure III.15. Visualisation en boîtes à moustaches des apports liquides mensuels du barrage de Hammam Bougrara pour la période d'exploitation (01/01/2002-31/12/2012), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel ( $3.9877 \text{ Mm}^3$ )




Figure III.16. Visualisation des appports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019)

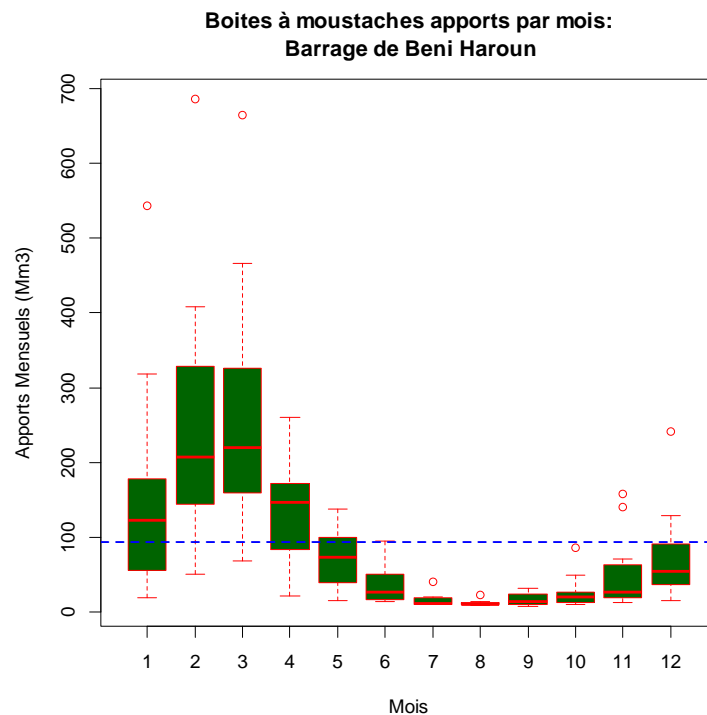


Figure III.17. Visualisation en boîtes à moustaches des appports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01/2009-31/12/2019), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel (93.392 Mm<sup>3</sup>)




Figure III. 18. Visualisation des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013)

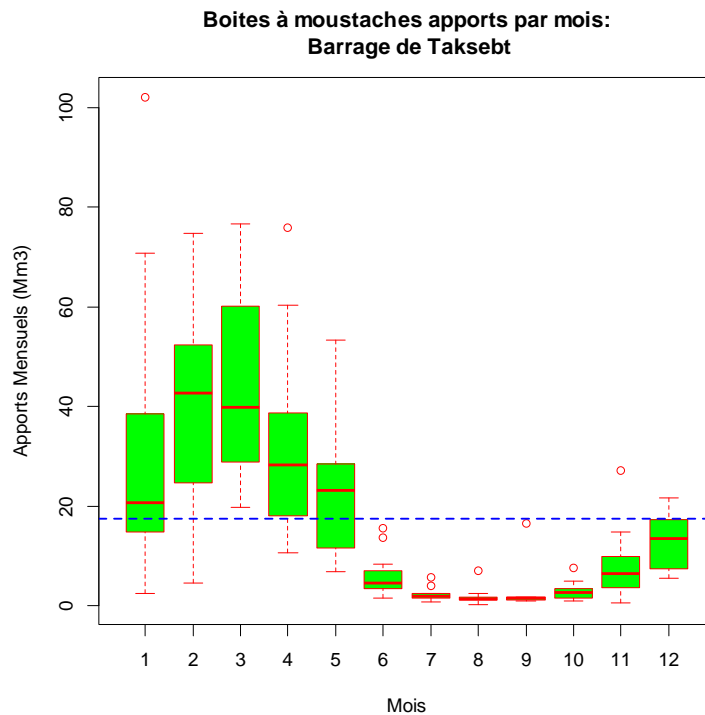



Figure III.19. Visualisation en boîtes à moustaches des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013), la ligne en pointillé bleu indique l'apport moyen mensuel interannuel (17.485 Mm<sup>3</sup>)

### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

Les séries temporelles initiales des apports liquides mensuels des trois barrages peuvent être décomposées par la méthode STL de la façon illustrative sur les figures qui suivent, où on peut constater des périodicités très claires dans les données mensuelles des trois barrages et des doubles tendances (2002-2009 ; 2009-2012) pour le barrage de Hammam Bouhrara ; (2009-2015 ; 2015-2019) pour le barrage de Beni Haroun) et une quasi-stationnarité (2004-2013) pour le barrage de Taksebt. Les valeurs restantes (remainder) gardent une certaine périodicité non récupérée par la composante de saisonnalité, elles illustrent également des points aberrants clairs et considérables (des piques) pour les trois barrages (Figures III.20, III.21 et III.22), respectivement.



**Figure III.20. Décomposition STL de la série des apports liquides mensuels du barrage de Hammam Bouhrara pour la période d'exploitation (01/01-2002-31/12/2012)**




Figure III.21. Décomposition STL de la série des apports liquides mensuels du barrage de Beni Haroun pour la période d'exploitation (01/01-2009-31/12/2019)






Figure III.22. Décomposition STL de la série des apports liquides mensuels du barrage de Taksebt pour la période d'exploitation (01/01/2003-31/12/2013)

### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

Les fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports des trois barrages sont illustrées par les figures qui suivent où les ACF reflètent aussi les périodicités déjà remarquées dans les données journalières et des autocorrélations visualisées par les PACF, d'ordre un pour le barrage de Hammam Boughrara, d'ordre deux pour le barrage de Beni Haroun et d'ordre quatre pour le barrage de Taksebt (Figures III.23, III.24 et III.25).



**Figure III. 23. Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du barrage de Hammam Boughrara**



**Figure III.24. Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du Barrage de Beni Haroun**






Figure III.25. Fonctions ACF et PACF des séries temporelles à l'échelle mensuelle des apports liquides du Barrage de Taksebt

### III.7. Matrices de corrélation entre les apports liquides journaliers décalés jusqu'à cinq jours et la pluie décalée d'une journée

Les intercorrélations entre les valeurs des apports journaliers décalés jusqu'à cinq jours et les valeurs des pluies ponctuelles décalées d'une journée, mesurées aux seins des trois barrages en question, sont consignées dans les tableaux qui suivent :

Tableau III.1. Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Hammam Boughrara

	$Ap_t$	$Ap_{t-1}$	$Ap_{t-2}$	$Ap_{t-3}$	$Ap_{t-4}$	$Ap_{t-5}$	$P_{t-1}$
$Ap_t$	1						
$Ap_{t-1}$	0,369	1					
$Ap_{t-2}$	0,103	0,369	1				
$Ap_{t-3}$	0,079	0,103	0,369	1			
$Ap_{t-4}$	0,067	0,079	0,103	0,370	1		
$Ap_{t-5}$	0,074	0,067	0,079	0,103	0,370	1	
$P_{t-1}$	0,363	0,082	0,027	0,001	0,024	0,027	1

Pour le barrage de Hammam Boughrara les intercorrélations entre variables deviennent de plus en plus faibles à partir d'un décalage de deux jours soit endogène entre apports ou exogène entre apports et pluies (tableau III.1).

**Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles**

---

**Tableau III.2. Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Beni Haroun**

	$Ap_t$	$Ap_{t-1}$	$Ap_{t-2}$	$Ap_{t-3}$	$Ap_{t-4}$	$Ap_{t-5}$	$P_{t-1}$
$Ap_t$	1						
$Ap_{t-1}$	0,858	1					
$Ap_{t-2}$	0,762	0,858	1				
$Ap_{t-3}$	0,704	0,762	0,858	1			
$Ap_{t-4}$	0,652	0,704	0,762	0,858	1		
$Ap_{t-5}$	0,618	0,652	0,703	0,761	0,858	1	
$P_{t-1}$	0,445	0,351	0,140	0,091	0,067	0,063	1

Pour le barrage de Beni Haroun les intercorrélations entre variables deviennent de plus en plus faibles à partir d'un décalage de cinq jours entre apports et à partir de deux jours entre apports et pluies (tableau III.2).

**Tableau III.3. Matrice de corrélation des apports journaliers décalés jusqu'à cinq jours et la pluie ponctuelle décalée d'une journée dans le barrage de Taksebt**

	$Ap_t$	$Ap_{t-1}$	$Ap_{t-2}$	$Ap_{t-3}$	$Ap_{t-4}$	$Ap_{t-5}$	$P_{t-1}$
$Ap_t$	1						
$Ap_{t-1}$	0,862	1					
$Ap_{t-2}$	0,754	0,862	1				
$Ap_{t-3}$	0,674	0,754	0,862	1			
$Ap_{t-4}$	0,617	0,674	0,754	0,862	1		
$Ap_{t-5}$	0,572	0,617	0,674	0,754	0,862	1	
$P_{t-1}$	0,167	0,117	0,079	0,067	0,058	0,056	1

Pour le barrage de Taksebt les intercorrélations entre variables deviennent de plus en plus faibles à partir d'un décalage de cinq jours entre apports et à partir d'un jour entre apports et pluies (tableau III.3).

$Ap_t$  : Apport journalier actuel,  $Ap_{t-1}$  : Apport journalier décalé d'un jour,  $Ap_{t-2}$  : Apport journalier décalé de deux jours,  $Ap_{t-3}$  : Apport journalier décalé de trois

### Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles

---

jours,  $Ap_{t-4}$  : Apport journalier décalé de quatre jours,  $Ap_{t-5}$  : Apport journalier décalé de cinq jours,  $P_{t-1}$  : Pluie journalière décalée d'un jour.

Dans ce qui suit, on désignera par :  $y = Ap_t$  : Apport journalier actuel,  $ar1 = Ap_{t-1}$  : Apport journalier décalé d'un jour,  $ar2 = Ap_{t-2}$  : Apport journalier décalé de deux jours,  $ar3 = Ap_{t-3}$  : Apport journalier décalé de trois jours,  $ar4 = Ap_{t-4}$  : Apport journalier décalé de quatre jours,  $ar5 = Ap_{t-5}$  : Apport journalier décalé de cinq jours,  $rain1 = P_{t-1}$  : Pluie journalière décalée d'un jour.

#### III.8. Conclusion

La base de données d'exploitation des barrages en question qui nous a été fourni par l'ANBT comporte des erreurs aussi bien systématiques qu'accidentelles. L'ensemble des données a subi un traitement afin de les rendre plus fiables et plus exploitables. Ce traitement nous a permis d'établir la cohérence des résultats du modèle développé dans le cadre de cette recherche. En outre, après le traitement des données d'exploitation, nous avons procéder à une visualisation graphique de l'évolution dans le temps des apports a différentes échelle (journalière et mensuelle) et sous formes de boites à moustaches où toutes les figures reflètent des fluctuations remarquables.

Après la visualisation graphique, nous avons procéder à une décomposition des séries d'apports par la méthode STL a différentes échelle (journalière et mensuelle). Il semble aussi plus judicieux d'avoir une vision plus critique sur les fonctions (ACF et PACF), qui montrent des auto corrélations dans les apports des trois barrages étudiés.

Les matrices de corrélation, entre les apports liquides journaliers décalés jusqu'à cinq jours et la pluie décalée d'une journée, mesurée aux seins des barrages réservoirs, maintenus pour l'aboutissement de cette étude, ont été donnée sous forme de tableaux. Ces tableaux de valeurs montrent clairement des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue des trois barrages (pris comme exemple). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein des barrages en question et les apports journaliers au temps  $t$  et au temps  $t-1$ . Les tableaux des

### **Chapitre III : Présentation des données et essai de compréhension des structures internes des séries temporelles**

---

matrices de corrélation renvoient des multi colinéarités, à l'exception du barrage de Hammam Boughrara, qui indiquent au préalable à ne pas adopter les modèles de régression linéaire multiple usuels et incitent à chercher d'autres alternatives de modélisations non linéaires.

Les barrages constituant la zone d'étude étaient : le barrage de Hammam Boughrara situé à l'ouest du pays présentant un climat semi-aride, le barrage de Beni Haroun situé à l'est du pays présentant un climat subhumide et le barrage de Taksebt situé au centre du pays présentant un climat humide.

## *Chapitre IV*

*Modélisation des apports  
liquides mensuels par les  
modèles stochastiques de  
séries temporelles*

### IV.1. Introduction

Nous rappelons que les prévisions hydrologiques par divers modèles ont pour objectif de permettre une décision plus éclairée, le but à ne pas rater est toujours la bonne gestion et la planification rationnelle.

Les modèles stochastiques sont généralement classés dans la catégorie des modèles linéaires et prennent également en compte la composante aléatoire des données dans la modélisation hydrologique (Moeeni et al., 2017a ; Machekposhti et al., 2017).

Dans la littérature, Il existe plusieurs approches pour modéliser les séries temporelles, les méthodes de prévision les plus fréquemment utilisés sont celles basées sur les modèles de lissage exponentiel (Winters, 1976), modèles ARIMA (autorégressif à moyenne mobile intégrée) (Box et al., 2008), modèles TBATS (lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers) (De Livera et al., 2011).

Parmi les nombreux algorithmes implémentés pour la prévision, les méthodes de lissage exponentiel jouent un rôle important dans l'identification du modèle pour les données annuelles, trimestrielles et mensuelles. Cependant, la plupart de ces méthodes sont généralement incapables de traiter des séries temporelles de tailles très grandes, enregistrées avec une fréquence élevée, telles que les données à l'échelle journalière ou horaire (Gos et al., 2020).

Les modèles stochastiques sont essentiellement utilisés pour analyser les variations des ruissellements des rivières (Adnan et al., 2017) et par analogie sont adaptés pour prévoir les apports liquides au sein des retenues des barrages réservoirs à différentes échelles du temps (Dahkal, 2015 ; Abd Saleh, 2013 ; More et al., 2019 ; Gupta et Kumar, 2020). Les modèles stochastiques largement utilisés pour la modélisation et la prévision de séries chronologiques dénommés ARIMA sont également connus sous le nom de modèles stochastiques linéaires de Box-Jenkins (Box et Jenkins, 1976 ; Moeeni et al., 2017b). Ces modèles sont préférables en raison de la recherche systématique à chaque étape (identification, estimation, diagnostic) d'un modèle approprié (Zhang, 2003). Lesdits modèles nécessitent des

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

---

données de séries chronologiques longues pour l'analyse, au moins 50 à 100 observations sont nécessaires pour un résultat vigoureux.

Les modèles TBATS sont également utilisés dans plusieurs domaines de recherche formant ainsi une alternative aux types ARIMA à travers la possibilité de traitement des variables chronologiques à saisonnalité complexe et dynamique (Gould et al., 2008 ; Taylor, et Snyder, 2009 ; De Livera et al., 2011 ; Gos et al., 2020 ; Herbert et al., 2021). Ces modèles régissent les phénomènes non linéaires spécifiques qui sont souvent observées dans les séries en temps réel et s'adapte à toute autocorrélation dans les résidus. L'avantage essentiel des modèles TBATS est que la fonction trigonométrique peut être utilisée pour des données avec une fréquence saisonnière élevée.

Le but de ce chapitre est d'évaluer les capacités prévisionnelles de deux modèles de séries temporelles désignés par ARIMA et TBATS, et ce à travers la prévision mensuelle des apports liquides. Les apports liquides mensuels réels à modéliser sont déduits de l'équation du bilan hydrique basée sur la conservation de masse adoptée par l'agence nationale des barrages et transferts (ANBT) pour gérer tous les barrages en Algérie en termes de ressources hydriques, entre autres la gestion des trois barrages : Hammam Boughrara, Beni Haroun et Taksebt, objets de la présente étude, qui sont respectivement sélectionnés sur la base d'une variabilité climatique du semi-aride, subhumide à humide selon la classification de (Hildebert, 1950). Les trois barrages réservoirs permettent de mobiliser et de réguler l'eau pour de multiples usages.

### IV.2. Données

La base de données utilisée a été recueillie auprès de l'Agence Nationale des Barrages et Transferts (ANBT). Elle consiste en séries temporelles concernant les éléments constituant le bilan hydrique au sein des trois barrages Hammam Boughrara, Beni Haroun et Taksebt exprimés en millions de mètre cube (Mm<sup>3</sup>), selon l'équation III.2 de conservation de masse ou de volume (Cf. Chapitre III).

Les apports liquides mensuels des réservoirs en question sont alors déduits de l'équation (III.2) adoptée par l'Agence Nationale des Barrages et Transferts (ANBT) pour gérer tous les barrages en Algérie en termes de ressources hydriques.

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

---

La période à l'échelle mensuelle servant ainsi de base pour la suite de cette contribution s'étale du 01/01/2002 au 31/12/2012, 01/01/2009 au 31/12/2019 et 01/01/2003 au 31/12/2013, soit 11 ans d'observation pour les trois barrages Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Les tailles des trois séries sont identiques (132 mois) ce qui écarte l'influence directe de la longueur de l'échantillon en faveur d'une influence attendue et probable du climat. Les valeurs numériques des apports mensuels au sein des trois barrages varient de 0,446 à 44.569 Mm<sup>3</sup>, de 7,614 à 686,034 Mm<sup>3</sup> et de 0,297 à 102,028 Mm<sup>3</sup> pour de Hammam Boughrara, Beni Haroun et Taksebt, respectivement. Pour les modèles considérés dans cette contribution, la phase de calage s'étale sur les dix premières années et la phase de validation concerne la dernière année pour chaque barrage étudié à part.

### IV.3 Critère de choix entre modèles candidats ARIMA/TBATS

Les meilleurs modèles de prévision type ARIMA/TBATS sont ceux qui répondent au critère de qualité le plus reconnu dit le critère d'information de Akaike (*AIC*), ([Cf. Chapitre II](#)). Les performances retenues sont celles évaluées numériquement selon les formulations données aussi dans le chapitre II ([Cf. Chapitre II](#)). Il s'agit de la racine carrée de l'erreur quadratique moyenne (*RMSE*), la moyenne des erreurs absolues (*MAE*) et l'erreur absolue moyenne en pourcentage (*MAPE*).

### IV.4. Résultats et interprétations

#### IV.4.1 Résultats liés au barrage de Hammam Boughrara

Afin de pouvoir tester un modèle ARIMA à la série des apports liquides mensuels du barrage de Hammam Boughrara, la série a été subdivisée en phase de calage (du 01/01/2002 au 31/12/2011) et en phase de validation (du 01/01/2012 au 31/12/2012), comme ci-indiqué auparavant. La fonction `auto.arima` ([R Core Team, 2021](#)) confronte plusieurs modèles et fait retourner celui qui minimise le Critère d'Information d'Akaike *AIC* ([Akaike, 1974](#)): plus de précision avec moins de paramètres (principe de parcimonie). L'application des modèles candidats types ARIMA a abouti au résultat final issu du modèle optimal à cet effet, désigné par  $ARIMA(2,1,0)(3,1,0)[12]$ . Quant au modèle TBATS, la fonction `tbats` ([R Core Team,](#)



## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

2021) confronte également plusieurs modèles différents types TBATS et aboutit à son tour au résultat final issu du modèle optimal correspondant désigné par  $TBATS(0, \{0,0\}, 0.876, \{<12,2>\})$ . Les résultats des deux modèles ARIMA/TBATS sont représentés graphiquement par la figure IV.1 qui indiquent que les apports extrêmes échappent à la modélisation.

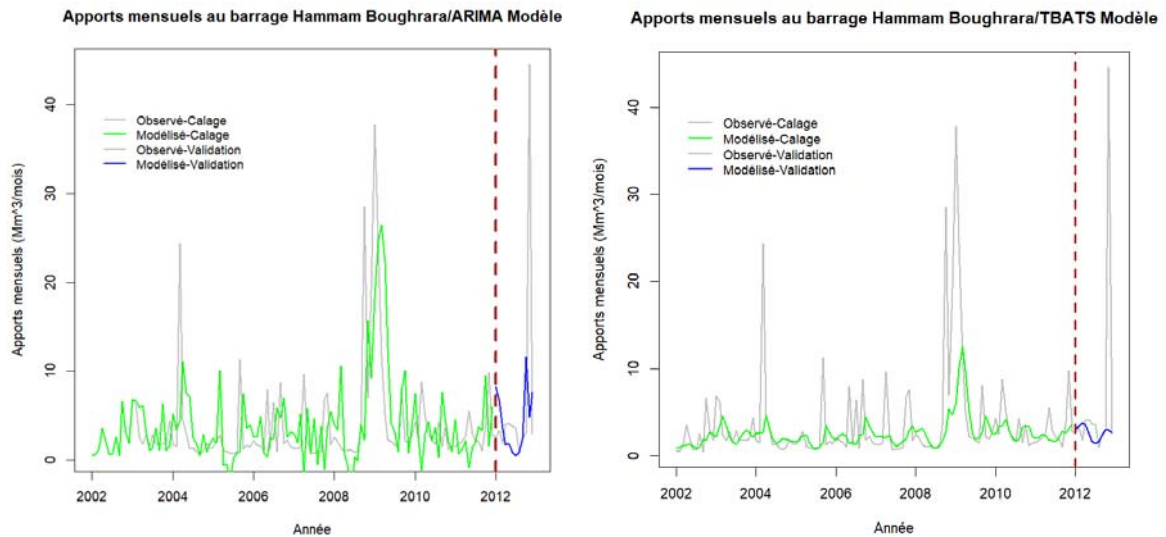


Figure IV.1. Comparaison des apports mensuels prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ARIMA (à gauche) et TBATS (à droite)

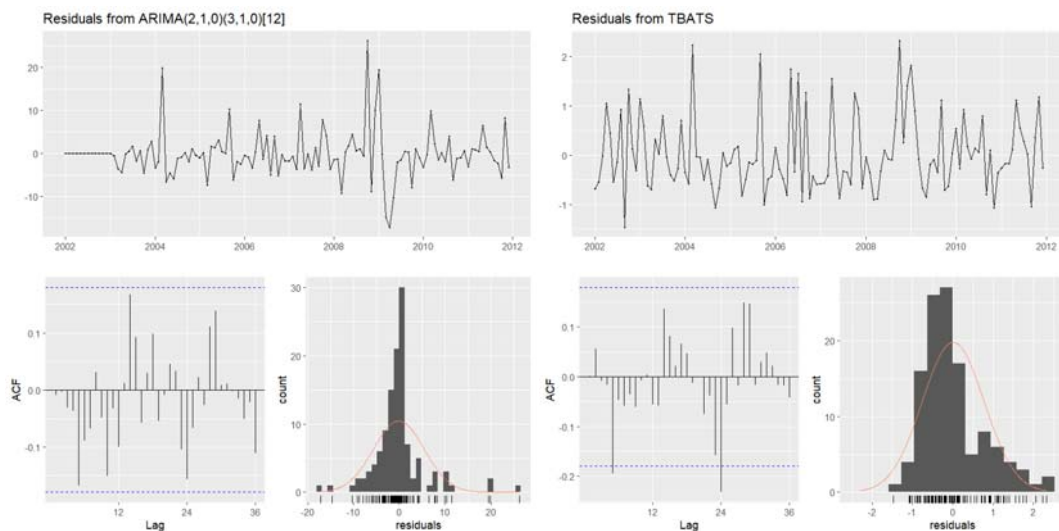


Figure IV.2. Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Hammam Boughrara

Les graphiques de la figure IV.1 montrent que les deux modèles ARIMA et TBATS produisent des prévisions qui semblent tenir compte de toutes les

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

informations disponibles. Il n'y a pas d'auto-corrélation significative dans la série des résidus pour le modèle ARIMA comme il semble y avoir plus de structure AR pour le modèle TBATS. Les histogrammes ont des apparences non normales. La figure IV.2 indique aussi que les résidus issus du modèle TBATS(0, {0,0}, 0.876, {<12,2>}) ont une allure plus normale que leurs homologues issus du modèle ARIMA(2,1,0)(3,1,0)[12].

Les résultats récapitulés dans le tableau IV.1 indiquent que le modèle TBATS(0, {0,0}, 0.876, {<12,2>}) de prévision des apports mensuels qui parviennent à la retenue du barrage de Hammam Boughrara est peu différent du modèle ARIMA(2,1,0)(3,1,0)[12] en termes des valeurs de *RMSE*, cependant il est nettement plus performant que le modèle ARIMA(2,1,0)(3,1,0)[12] en considérant les valeurs de *MAE* et *MAPE*. Néanmoins, la capacité prédictive demeure modeste (*MAPE* = 39.956 %) et le recours aux modèles plus adéquats s'avère fortement recommandé pour ce cas d'étude qui concernait une région à climat semi-aride à l'Ouest de l'Algérie.

**Tableau IV.1. Résultats de l'application des modèles ARIMA/TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Hammam Boughrara**

Modèles ARIMA(p,d,q)(P,D,Q) <sub>s</sub> SBATS	ARIMA(2,1,0)(3,1,0)[12]		TBATS(0, {0,0}, 0.876, {<12,2>})	
	01/01/2002 - 31/12/2011	01/01/2012 - 31/12/2012	01/01/2002 - 31/12/2011	01/01/2012 - 31/12/2012
Critères de performances	Calage	Validation	Calage	Validation
<b>RMSE (Mm<sup>3</sup>)</b>	5.520	12.087	5.150	12.056
<b>MAE (Mm<sup>3</sup>)</b>	3.281	6.212	2.312	4.303
<b>MAPE (%)</b>	118.299	103.465	58.838	<b>39.956</b>

### IV.4.2 Résultats liés au barrage de Beni Haroun

Le test d'un modèle ARIMA à la série des apports liquides mensuels du barrage de Beni Haroun, a également nécessité que sa série soit subdivisée en phase de calage (du 01/01/2009 au 31/12/2018) et en phase de validation (du 01/01/2019 au 31/12/2019). La fonction `auto.arima` (R Core Team, 2021) compare plusieurs

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

modèles différents et donne celui qui minimise l'AIC. L'application des modèles concurrents a abouti au résultat final issu du modèle optimal désigné par ARIMA(0,1,3)(1,1,0)[12]. La fonction `tbats` (R Core Team, 2021) confronte aussi des modèles distincts types TBATS et aboutit à son tour au résultat final indiqué par `TBATS(0, {0,1}, -, {<12,2>})`.

Les résultats des évolutions temporelles des apports observés et prédits sont illustrés graphiquement par la figure IV.3 et l'analyse des résidus des modèles retenus est résumée par la figure IV.4. La figure IV.3 montre que les deux modèles ARIMA et TBATS reproduisent les valeurs extrêmes des apports mensuels d'une manière acceptable. La figure IV.4 indique que des auto-corrélation significatives persistent dans la série des résidus. Les histogrammes ne semblent pas être normaux. Les résultats récapitulés dans le tableau IV.2 montrent que le modèle `TBATS(0, {0,1}, -, {<12,2>})` de prévision des apports mensuels qui parviennent à la retenue du barrage de Beni Haroun est nettement meilleur que le modèle ARIMA(0,1,3)(1,1,0)[12] en termes des valeurs des MAE, RMSE et MAPE. En tenant compte de la valeur MAPE, la capacité prédictive du modèle `TBATS(0, {0,1}, -, {<12,2>})` est toujours modeste (MAPE = 34.786 %) et la recherche d'autres moyens de modélisation plus consistants s'avère nécessaire pour ce cas d'étude qui concernait une région à climat subhumide à l'Est de l'Algérie.




Figure IV. 3. Comparaison des apports mensuels prédits et observés au barrage réservoir de Beni Haroun : Modèles ARIMA (à gauche) et TBATS (à droite)

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

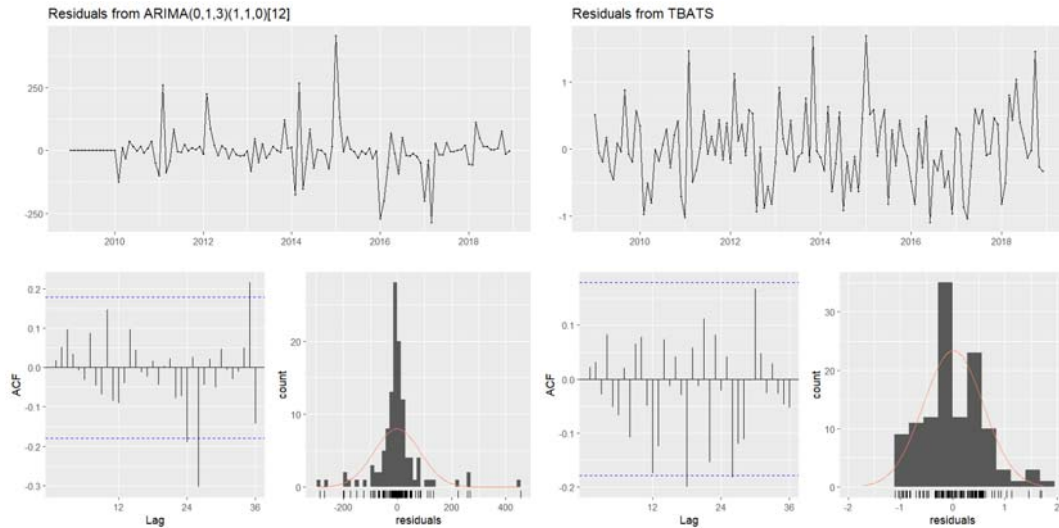


Figure IV.4. Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Beni Haroun

Tableau IV.2. Résultats de l'application des modèles ARIMA/TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Beni Haroun


Modèles ARIMA(p,d,q)(P,D,Q) <sub>s</sub> SBATS	ARIMA(0,1,3)(1,1,0)[12]		TBATS(0, {0,1}, -, {<12,2>})	
	01/01/2002 - 31/12/2011	01/01/2012 - 31/12/2012	01/01/2002 - 31/12/2011	01/01/2012 - 31/12/2012
Critères de performances	Calage	Validation	Calage	Validation
RMSE (Mm <sup>3</sup> )	84.946	137.145	78.883	93.617
MAE (Mm <sup>3</sup> )	45.263	90.383	39.788	61.236
MAPE (%)	94.593	53.204	47.155	<b>34.786</b>

### IV.4.3 Résultats liés au barrage de Taksebt

Finalement l'évaluation du modèle ARIMA à la série d'apports liquides mensuels du barrage de Taksebt, passe par la subdivision de la série en question en phase de calage (du 01/01/2003 au 31/12/2012) et en phase de validation (du 01/01/2013 au 31/12/2013). La fonction `auto.arima` (R Core Team, 2021) examine plusieurs modèles et fait ressortir celui qui minimise l'AIC. L'application des divers modèles ARIMA a mené au résultat final désigné par ARIMA(2,0,1)(0,0,1)[12]. La fonction `tbats` (R Core Team, 2021) évalue plusieurs modèles types TBATS et converge à son tour au résultat optimal TBATS(0.032, {0,1}, -, {<12,2>}).

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

Les comparaisons observés/prédits sont données graphiquement par la figure IV.5.



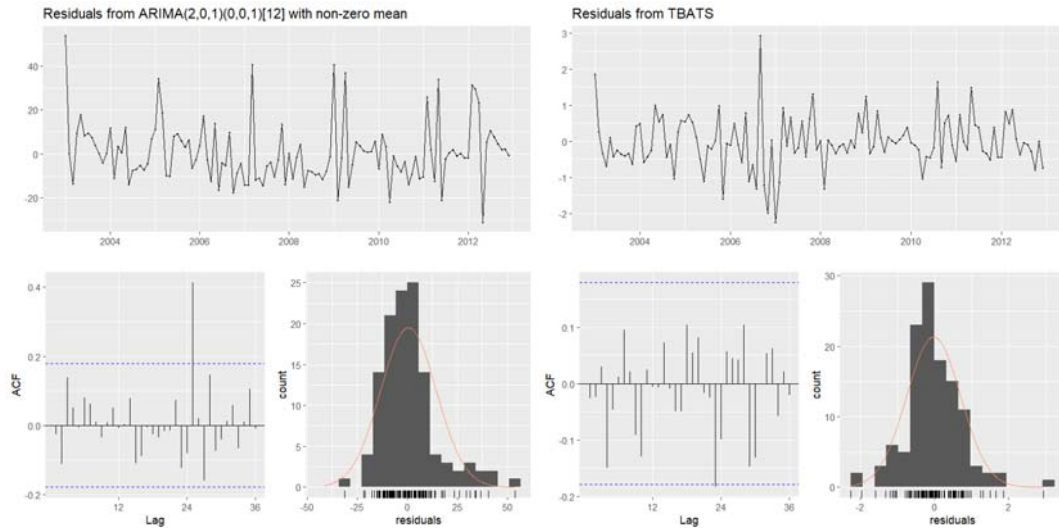
**Figure IV.5. Comparaison des apports mensuels prédits et observés au barrage réservoir de Taksebt : Modèles ARIMA (à gauche) et TBATS (à droite)**

Les deux graphiques de la figure IV.5 montrent que les deux modèles ARIMA et TBATS reproduisent à peine les pics des apports mensuels au sein du barrage de Taksebt, quoi que les évolutions temporelles (monté/descente) soient quasi-parfaites.

L'analyse des résidus est résumée par la figure IV.6 où il est aisé de constater l'absence presque totale des auto-corrélations significatives dans les séries des résidus, particulièrement pour le modèle TBATS. Les prévisions des apports mensuels pour ce cas d'étude semblent très acceptables par le modèle TBATS quant au modèle ARIMA, il est à rejeter surtout en termes de valeurs des MAPE qui dépassent 300%.

Les résultats récapitulés dans le tableau IV.3 indiquent que le modèle TBATS(0.032, {0,1}, -, {<12,2>}) de prévisions des apports mensuels qui parviennent à la retenue du barrage de Taksebt est très différent du modèle ARIMA(2,0,1)(0,0,1)[12] en termes des valeurs des MAE, RMSE et MAPE. L'habileté de prévision est acceptable (MAPE = 29.99 %) et le recours aux modèles plus appropriés s'avère toujours utile même pour ce cas qui concernait un climat humide au centre de l'Algérie.

## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles



**Figure IV.6. Analyse des résidus des modèles ARIMA (à gauche) et TBATS (à droite) : barrage de Taksebt**

**Tableau IV.3. Résultats de l'application des modèles ARIMA/ TBATS pour la prévision en phase de calage et de validation des apports liquides mensuels au sein du barrage de Taksebt**

Modèles ARIMA(p,d,q)(P,D,Q) <sub>s</sub> SBATS	ARIMA(2,0,1)(0,0,1)[12]		TBATS(0.032, {0,1}, -, {<12,2>})	
	01/01/2003 - 31/12/2012	01/01/2013 - 31/12/2013	01/01/2003 - 31/12/2012	01/01/2013 - 31/12/2013
Critères de performances	Calage	Validation	Calage	Validation
RMSE (Mm <sup>3</sup> )	13.882	15.638	13.961	9.324
MAE (Mm <sup>3</sup> )	9.995	12.963	7.494	5.514
MAPE (%)	201.117	310.551	60.836	<b>29.990</b>

### IV.5. Conclusion

Dans la présente étude, la recherche d'un moyen relativement efficace pour la prévision des apports liquides mensuels a été achevée aux seins des trois barrages réservoirs situés dans des régions climatiques distinctes : barrage de Hammam Boughrara (semi-aride à l'Ouest de l'Algérie), barrage de Beni Haroun (subhumide à l'Est de l'Algérie) et barrage de Taksebt (humide au centre de l'Algérie). Les modèles évalués se classent parmi les types stochastiques linéaires bien explorés dans la littérature. Il s'agit du modèle autorégressif à moyenne mobile intégrée



## Chapitre IV: Modélisation des apports liquides mensuels par les modèles stochastiques de séries temporelles

---

(ARIMA) et du modèle à lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers (TBATS).

La série temporelle de 132 mois (11 ans) est analysée avec un seul découpage qui exploite les 120 mois premiers (10 ans) dans la phase de calage des deux modèles et les 12 mois de la dernière année seront en conséquence utilisés pour la phase de validation des meilleurs modèles ARIMA/TBATS. Les résultats d'évaluation des deux modèles envisagés démontrent que le types ARIMA et TBATS ne reproduisent pas cas d'une manière fidèle la variabilité des apports mensuels en cas de piques pour les trois barrages pris en charge par cette investigation. Les résidus issus des modèles retenus sont loin d'être des bruits blancs et les auto-corrélations dans lesdits résidus ne sont pas complètement capturées. Les modèles TBATS quant à eux peuvent à la limite se présenter comme remède aux modèles qui ne tiennent pas compte de la complexité et de la dynamique de la saisonnalité des séries temporelles des apports liquides mensuels en Algérie dans trois régions climatiques différentes (semi-aride, subhumide et humide), toutefois ce remède demeure limité en termes de capacité de prévision et en reproduction des valeurs extrêmes fortes prouvée par la métrique *MAPE* qui décroît de 40%, à 35% et à 30% selon que le cas soit semi-aride, subhumide ou l'humide. La meilleure valeur n'a pas baissé au-dessous de 30% qui se considère quand même comme erreur notable à raffiner (prévision raisonnable) reflétant ainsi l'exigence de faire recours aux modèles plus appropriés pour prévoir les apports liquides mensuels au sein des barrages en Algérie. Les modèles ARIMA et notamment TBATS peuvent à la limite être considérés comme outils de prévision dans une planification préliminaire de gestion des ressources hydriques à l'échelle mensuelle. Ces avis sont basés sur la catégorisation de la qualité des prévisions reliée aux valeurs *MAPE* telles qu'elles mentionnées dans l'étude de [Lewis \(1982\)](#) et discutées dans [Blasco et al., 2013](#) (Cf. [Tableau IV.4](#)).

**Tableau IV.4. Catégorisation et interprétation des valeurs typiques du MAPE selon Lewis (1982)**

<b>MAPE (%)</b>	<b>Catégorisation</b>
< 10	Prévision très précise
10 - 20	Bonne prévision
20 - 50	Prévision raisonnable
> 50	Prévision inexacte



## *Chapitre V*

*Prévisions des apports  
liquides journaliers par les  
réseaux de neurones  
artificiels de type  
perceptrons multicouches*

### V.1. Introduction

L'utilisation des valeurs prévues des apports liquides dans le processus de prise de décision menant à la gestion rationnelle doivent améliorer les modalités de planification des ressources hydriques stockées au niveau des barrages-réservoirs. C'est d'ailleurs l'objet de cette étude dans ce chapitre qui traite comme cas d'étude trois barrages-réservoirs situés dans des zones à climats distincts à savoir : (1) le barrage réservoir de Hammam Boughrara qui représente dans la présente exploration la zone à climat semi-aride, (2) le barrage réservoir de Beni Haroun qui représente à son tour la zone à climat subhumide et (3) le barrage réservoir de Taksebt qui représente finalement la zone à climat humide. Dans ce chapitre, on appliquera les modèles des réseaux de neurones artificiels, type perceptron multicouches, désignés par (ANN).

### V.2. Normalisation des données

On normalise souvent les variables lorsqu'on effectue un type d'analyse dans lequel on a plusieurs variables qui sont mesurées ou observées sur des échelles différentes et on veut que chacune des variables ait la même plage. Cela permet d'éviter qu'une variable n'ait une influence excessive, surtout si les variables sont mesurées dans des unités différentes (par exemple, si une variable est mesurée en  $Mm^3$  et une autre en mm). Il convient également de noter qu'on va utiliser une méthode connue sous le nom de normalisation min-max pour les modèles ANN pour normaliser les valeurs des données. Ladite normalisation s'effectue en appliquant l'équation suivante :

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (V.1)$$

Où *norm*, *min* et *max* sont les valeurs normalisées, minimales et maximales de *X* compte tenu de son étendu. Ce type de normalisation est souvent connue sous le nom de mise à l'échelle des caractéristiques, où les valeurs d'une plage numérique d'une caractéristique de données, c'est-à-dire une propriété, sont réduites à une échelle comprise entre 0 et 1.

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

---

### V.3. Critère de choix entre les modèles des réseaux de neurones de type perceptrons multicouches

Les meilleurs modèles de prévision type perceptrons multicouches sont ceux qui répondent aux critères de qualité les plus reconnus reflétant les performances numériquement meilleures selon les formulations données et décrites dans le chapitre II ([Cf. Chapitre II, paragraphe II.3](#)). Il s'agit du coefficient de corrélation ( $R$ ), la racine carrée de l'erreur quadratique moyenne ( $RMSE$ ), la moyenne des erreurs absolues ( $MAE$ ) et les critères d'efficacité de Nash-Sutcliffe ( $NSE$ ) et Kling-Gupta ( $KGE$ ).

### V.4. Prévision des apports journaliers basée sur les variables endogènes (apports décalés dans le temps) et influence de la pluie ponctuelle (variable exogène) par les réseaux de neurones de type perceptrons multicouches

Les modèles à tester sont notés de la manière suivante :

ANNi : Modèles de Réseaux de Neurones Artificiels (Artificial Neural Network (ANN)) d'une seule entrée ( $i=1$ ) à cinq entrées ( $i=5$ ) sans prise en compte de l'entrée pluie décalée d'un jour (modèles à variables endogènes).

ANNir : Modèles de Réseaux de Neurones Artificiels (Artificial Neural Network (ANN)) d'une seule entrée ( $i=1 : Ap_{t-1}$ ) à cinq entrées ( $i=5 : Ap_{t-5}$ ) avec prise en compte de l'entrée pluie décalée d'un jour ( $P_{t-1}$ ) (modèles à variables endogènes et exogènes). On désignera par :  $y=Ap_t$  : Apport journalier actuel,  $ar1=Ap_{t-1}$  : Apport journalier décalé d'un jour,  $ar2=Ap_{t-2}$  : Apport journalier décalé de deux jours,  $ar3=Ap_{t-3}$  : Apport journalier décalé de trois jours,  $ar4 =Ap_{t-4}$  : Apport journalier décalé de quatre jours,  $ar5=Ap_{t-5}$  : Apport journalier décalé de cinq jours,  $rain1=P_{t-1}$  : Pluie journalière décalée d'un jour.

#### V.4.1. Prévision des apports journaliers du barrage de Hammam Boughrara (représentant le climat semi-aride) par les réseaux de neurones artificiels de type perceptrons multicouches

La période à l'échelle journalière servant de base pour le barrage de Hammam Boughrara s'étale du 01/01/2002 au 31/12/2012 et ce, pour les apports liquides et la pluie ponctuelle au sein dudit barrage. La matrice de corrélation du tableau III.1 ([Cf. Chapitre III, paragraphe III.7](#)), indique des liaisons à évaluer entre

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

---

la variable à prévoir (l'apport journalier ( $y = Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Hammam Boughrara (pris comme exemple dans un climat semi-aride). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation approuve dès le départ à éviter les modèles de régression linéaire multiple ordinaire et pousse à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les réseaux de neurones artificiels (Artificial Neural Network (ANN)), type perceptrons multicouches.

L'application des divers modèles ANN donne les résultats de prévision des apports journaliers au sein du barrage de Hammama Boughrara en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau V.1. Le meilleur modèle est ANN1r qui est un modèle à deux entrées, l'une est endogène ( $ar1=Ap_{t-1}$ ), l'autre est exogène ( $rain1=P_{t-1}$ ). Les performances médiocres du modèle retenu en phase validation (même en phase calage) indiquent qu'il est vraiment loin de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude où il s'agit d'un barrage situé dans un climat semi-aride. Le schéma du modèle adopté pour la prévision des apports liquides journaliers au sein du barrage est réalisé par la sortie graphique du package « neuralnet » sous le code libre R, visualisé par la figure V.1. Les confrontations graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle ANN1r adopté sont illustrées par la figure V.2 en phase de calage et par la figure V.4 en phase de validation. Les nuages de points sont visualisés respectivement par les figures V.3 et V.5 en calage et validation.

**Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches**

---

**Tableau V.1. Les résultats des modèles ANN dans le barrage de Hammam Boughrara ;**

**Nombre de couches cachées = 2, nombre de nœuds dans la première couche = 5, nombre de nœuds dans la deuxième couche = 1, temps = 3s (meilleur modèle : ANN1r)**

Barrage		Hammam Boughrara					Paramètres
Critères de performance/Modèles	R	RMSE	MAE	NSE	KGE	Couches/Noeuds	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)		
<b>Calage</b>	ANN1	0.316	0.479	0.110	0.10	0.03	<b>2/(5,1)</b>
	<b>ANN1r</b>	0.447	0.451	0.099	0.20	0.22	
	ANN2	0.317	0.479	0.110	0.10	0.03	
	ANN2r	0.447	0.451	0.098	0.20	0.22	
	ANN3	0.325	0.477	0.108	0.11	0.04	
	ANN3r	0.453	0.450	0.097	0.21	0.23	
	ANN4	0.327	0.477	0.107	0.11	0.05	
	ANN4r	0.454	0.449	0.097	0.21	0.23	
	ANN5	0.330	0.476	0.106	0.11	0.05	
	ANN5r	0.457	0.449	0.096	0.21	0.23	
<b>Validation</b>	ANN1	0.525	0.811	0.136	0.23	0.14	<b>2/(5,1)</b>
	<b>ANN1r</b>	<b><u>0.689</u></b>	<b><u>0.735</u></b>	<b><u>0.130</u></b>	<b><u>0.37</u></b>	<b><u>0.27</u></b>	
	ANN2	0.514	0.814	0.137	0.23	0.14	
	ANN2r	0.680	0.738	0.130	0.36	0.27	
	ANN3	0.507	0.817	0.140	0.22	0.14	
	ANN3r	0.674	0.740	0.135	0.36	0.27	
	ANN4	0.501	0.818	0.141	0.22	0.14	
	ANN4r	0.667	0.741	0.136	0.35	0.27	
	ANN5	0.500	0.819	0.141	0.22	0.14	
	ANN5r	0.660	0.745	0.138	0.27	0.35	

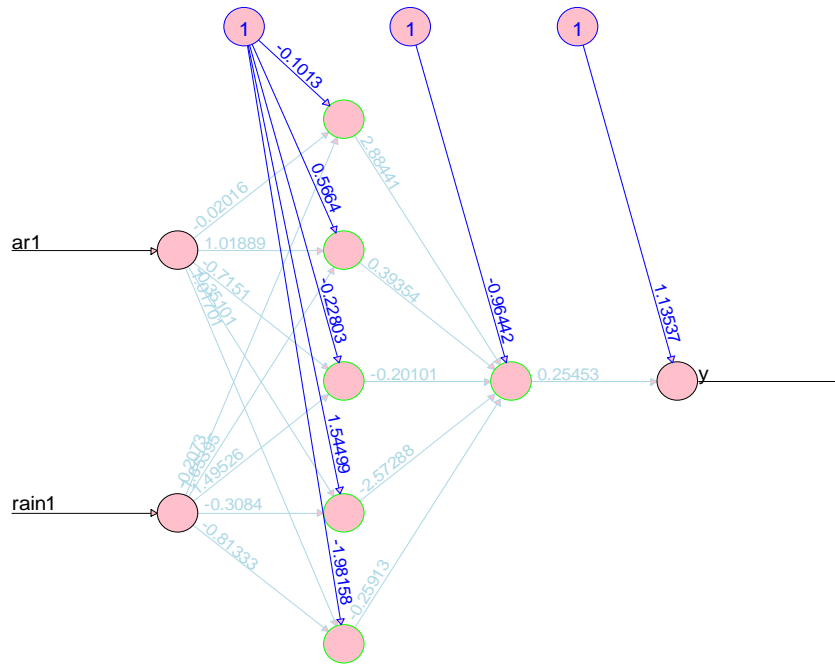


Figure V.1. Schéma du modèle ANN1r retenu pour la prévision des apports journaliers au sein du barrage réservoir de Hammam Boughrara




Figure V.2. Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de calage)




Figure V.3. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de calage)





Figure V.4. Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de validation)



**Figure V.5. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle ANN1r adopté (phase de validation)**

Quoi que le modèle ANN1r retenu soit incapable de prévoir les apports liquides journaliers au sein du barrage de Hammam Boughrara pour le cas de climat semi-aride, il est toujours utile d'examiner l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage. Le tableau V.2 affiche numériquement ces améliorations calculées pour tous les indices et les critères. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle ANN2 ( $ar1=Ap_{t-1}$  et  $rain1=P_{t-1}$ ) et ANN1r ( $ar1=Ap_{t-1}$  et  $rain1=P_{t-1}$ ). Selon le gain relatif du modèle ANN1r rapporté au modèle ANN2, il s'avère que l'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est très bien justifiée.



## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

**Tableau V.2. Comparaison des performances des modèles ANN compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)
ANN2	0.514	0.814	0.137	0.23	0.14
ANN1r	<u>0.689</u>	<u>0.735</u>	<u>0.130</u>	<u>0.37</u>	<u>0.27</u>
Gain relatif (%)	34	10	5	61	93

### V.4.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les réseaux de neurones artificiels de type perceptrons multicouches

La période à l'échelle journalière servant de base pour le barrage de Beni Haroun s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.2 ([Cf. Chapitre III, paragraphe III.7](#)) indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison notable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète aussi une multi colinéarité qui aide dès le départ à éviter les modèles de régression linéaire multiple et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les réseaux de neurones artificiels (Artificial Neural Network (ANN)), type perceptrons multicouches.

L'application des divers modèles ANN donne aussi les résultats de prévision des apports journaliers au sein du barrage de Beni Haroun en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau V.3. Le meilleur modèle est ANN3r qui est un modèle à quatre entrées, trois endogènes ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$  et  $ar3=Ap_{t-3}$ ), l'autre est exogène ( $rain1=P_{t-1}$ ). Les performances formidables du modèle retenu en phase validation (et même en phase calage)

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

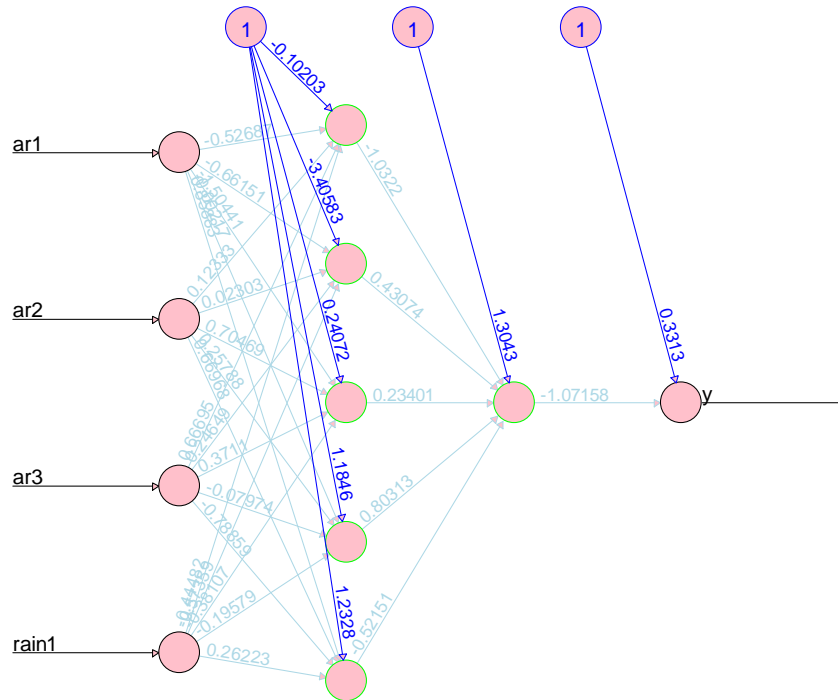
indiquent qu'il est vraiment possible de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude dont il s'agit d'un barrage situé dans un climat subhumide. Le schéma du modèle adopté pour la prévision des apports liquides journaliers au sein du barrage est aussi réalisé par la sortie graphique du package « neuralnet » sous le code libre R, visualisé par la figure V.5. Les confrontations graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle ANN3r adopté sont illustrées par la figure V.6 en phase de calage et par la figure V.8 en phase de validation. Les nuages de points sont visualisés respectivement par les figures V.7 et V.9 en calage et validation.

**Tableau V.3. Les résultats des modèles ANN dans le barrage de Beni Haroun ;  
Nombre de couches cachées = 2, nombre de nœuds dans la première couche = 5,  
nombre de nœuds dans la deuxième couche = 1, temps = 3.3s (meilleur modèle :  
ANN3r)**

Barrage		Beni Haroun					Paramètres
Critères de performance/Modèles	R	RMSE	MAE	NSE	KGE	Couches/Noeuds	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)		
<b>Calage</b>	ANN1	0.857	2.790	0.898	0.74	<b>2/(5,1)</b>	
	ANN1r	0.867	2.706	0.908	0.75		
	ANN2	0.859	2.776	0.885	0.74		
	ANN2r	0.873	2.647	0.882	0.76		
	ANN3	0.861	2.755	0.875	0.74		
	<b>ANN3r</b>	0.877	2.601	0.869	0.77		
	ANN4	0.862	2.753	0.873	0.74		
	ANN4r	0.877	2.601	0.864	0.77		
	ANN5	0.862	2.746	0.869	0.74		
	ANN5r	0.879	2.590	0.860	0.77		
<b>Validation</b>	ANN1	0.883	3.144	1.319	0.78	<b>2/(5,1)</b>	
	ANN1r	0.916	2.695	1.177	0.84		
	ANN2	0.882	3.162	1.319	0.78		
	ANN2r	0.922	2.600	1.155	0.85		
	ANN3	0.882	3.157	1.344	0.78		
	<b>ANN3r</b>	<b><u>0.924</u></b>	<b><u>2.558</u></b>	<b><u>1.166</u></b>	<b><u>0.85</u></b>		<b><u>0.88</u></b>

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

	ANN4	0.882	3.154	1.341	0.78	0.82	
	ANN4r	0.925	2.549	1.166	0.85	0.88	
	ANN5	0.885	3.114	1.325	0.78	0.82	
	ANN5r	<b>0.927</b>	<b>2.503</b>	<b>1.148</b>	<b>0.86</b>	<b>0.88</b>	



**Figure V.6. Schéma du modèle ANN3r retenu pour la prévision des apports journaliers au sein du barrage réservoir de Beni Haroun**




Figure V.7. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de calage)




Figure V.8. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de calage)




Figure V.9. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de validation)




Figure V.10. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN3r adopté (phase de validation)

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

Le modèle ANN3r sélectionné est bien capable de prévoir les apports liquides journaliers au sein du barrage de Beni Haroun pour le cas de climat subhumide, il est très utile d'examiner également l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage. Le tableau V.4 présente quantitativement ces améliorations calculées pour tous les indices et les critères des performances. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle ANN4 ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ) et ANN3r ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $rain1=P_{t-1}$ ). Selon le gain relatif du modèle ANN3r rapporté au modèle ANN4, il s'avère que l'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est justifiée.

**Tableau V.4. Comparaison des performances des modèles ANN compétitifs de prévision des apports journaliers (barrage de Beni Haroun)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (%)
ANN4	0,882	3,154	1,341	0,78	0,82
ANN3r	<u>0,924</u>	<u>2,558</u>	<u>1,166</u>	<u>0,85</u>	<u>0,88</u>
Gain relatif (%)	5	19	13	9	7

### V.4.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les réseaux de neurones artificiels de type perceptrons multicouches

La période à l'échelle journalière servant de base pour le barrage de Taksebt s'étale du 01/01/2003 au 31/12/2013 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage, La matrice de corrélation du tableau III.3 (Cf. Chapitre III, paragraphe III.7) indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide), On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les

## Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches

---

apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète une multi colinéarité qui aide dès le départ à éviter les modèles de régression linéaire multiple ordinaire et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les réseaux de neurones artificiels (Artificial Neural Network (ANN)), type perceptrons multicouches.

L'application des divers modèles ANN donne finalement les résultats de prévision des apports journaliers au sein du barrage de Taksebt en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau V.5. Le meilleur modèle est ANN4 qui est un modèle à quatre entrées endogènes ( $ar1=Ap_{t-1}$ ,  $ar2= Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ). Les performances notables du modèle retenu en phase validation (et même en phase calage) indiquent qu'il est raisonnable de faire des prévisions des apports journaliers dans ce cas d'étude dont il s'agit d'un barrage situé dans un climat humide. Le schéma du modèle adopté pour la prévision des apports liquides journaliers au sein du barrage est identiquement réalisé par la sortie graphique du package « neuralnet » sous le code libre R, visualisé par la figure V.11. Les confrontations graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle ANN4 adopté sont illustrées par la figure V.12 en phase de calage et par la figure V.14 en phase de validation. Les nuages de points sont visualisés par les figures V.13 et V.15 en calage et validation, respectivement.

**Chapitre V : Prévisions des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches**

---

**Tableau V.5. Les résultats des modèles ANN dans le barrage de Taksebt ;  
 Nombre de couches cachées = 2, nombre de nœuds dans la première couche =  
 5, nombre de nœuds dans la deuxième couche = 1, temps = 4,26s (meilleur  
 modèle : ANN4)**

Barrage		Taksebt					Paramètres
Critères de performance/Modèles	R	RMSE	MAE	NSE	KEG	Couches/Noeuds	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)		
<b>Calage</b>	ANN1	0.860	0.510	0.183	0.74	<b>2/(5,1)</b>	
	ANN1r	0.863	0.505	0.182	0.74		
	ANN2	0.860	0.509	0.182	0.74		
	ANN2r	0.863	0.504	0.180	0.75		
	ANN3	0.861	0.508	0.181	0.74		
	ANN3r	0.864	0.503	0.178	0.75		
	<b>ANN4</b>	0.861	0.508	0.178	0.74		
	ANN4r	0.864	0.502	0.177	0.75		
	ANN5	0.861	0.507	0.179	0.74		
	ANN5r	0.864	0.502	0.177	0.75		
<b>Validation</b>	ANN1	0.900	0.317	0.168	0.81	<b>2/(5,1)</b>	
	ANN1r	0.897	0.321	0.172	0.80		
	ANN2	0.901	0.316	0.166	0.81		
	ANN2r	0.898	0.320	0.170	0.81		
	ANN3	0.901	0.315	0.165	0.81		
	ANN3r	0.898	0.319	0.169	0.81		
	<b>ANN4</b>	<b><u>0.903</u></b>	<b><u>0.311</u></b>	<b><u>0.162</u></b>	<b><u>0.81</u></b>		<b><u>0.84</u></b>
	ANN4r	0.900	0.316	0.166	0.81		
	ANN5	0.904	0.311	0.161	0.82		
	ANN5r	0.900	0.316	0.165	0.81		



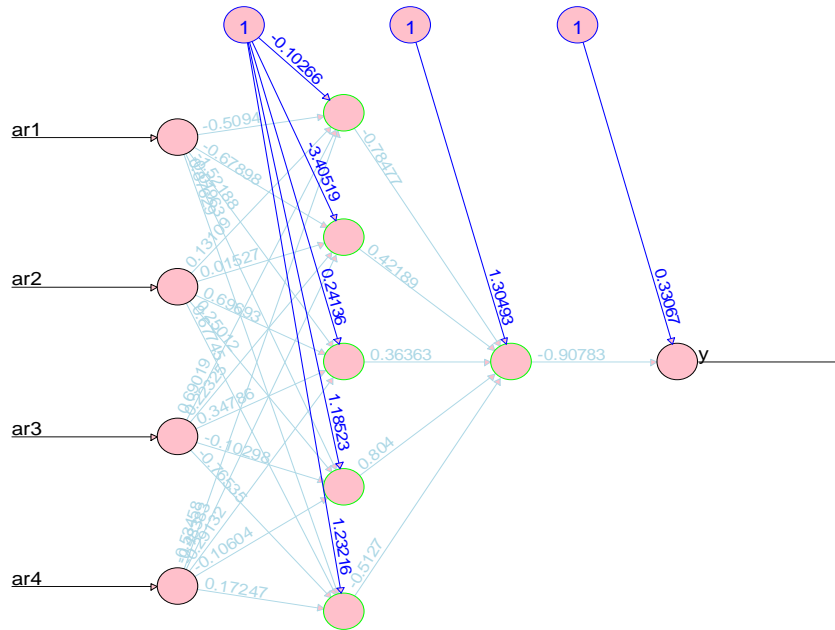


Figure V.11. Schéma du modèle ANN4 retenu pour la prévision des apports journaliers au sein du barrage réservoir de Taksebt




Figure V.12. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de calage)




Figure V.13. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de calage)




Figure V.14. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de validation)




Figure V.15. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle ANN4 adopté (phase de validation)

Le modèle ANN4 distingué est éprouvé de prévoir les apports liquides journaliers au sein du barrage de Taksebt pour le cas de climat humide. Le modèle ANN4 dépasse son homologue ANN3r (avec l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage). En effet il est inutile d'examiner l'amélioration en performance due à l'introduction de ladite variable. Le tableau V.6 montre quantitativement les performances du modèle adopté uniquement.

Tableau V.6. Performances du modèle ANN de prévision des apports journaliers (barrage de Taksebt)

Critères / Modèles	R	RMSE	MAE	NSE	KGE
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)
ANN4	<u>0.903</u>	<u>0.311</u>	<u>0.162</u>	<u>0.81</u>	<u>0.84</u>

### V.5. Conclusions

Dans ce chapitre, la prévision des apports liquides journaliers par les réseaux de neurones artificiels de type perceptrons multicouches (désignés par ANN) a été implémentée et achevée pour trois types de climats (semi-aride, subhumide et humide) dans trois barrages réservoirs (Hammam Boughrara, Beni Haroun et Taksebt). Les résultats montrent que les modèles ANN, ne peuvent pas aider à prévoir les apports liquides à l'échelle journalière quand il s'agit d'un cas semi-aride. Cependant les modèles ANN peuvent être considérés comme des moyens de prévisions avec de bonnes performances quand il s'agit d'un cas subhumide ou humide. Ces constatations sont valables pour les modèles ANN à entrées endogènes ( $Ap_{t-i}$ ) ou exogènes. L'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est bien justifiée notamment pour le cas subhumide représenté par le barrage réservoir de Beni Haroun où l'amélioration a pu atteindre 19% pour le critère RMSE.

## *Chapitre VI*

*Prévisions des apports  
liquides journaliers par les  
forêts aléatoires prises  
comme modèle d'ensemble*

### VI.1. Introduction

Dans le but d'avoir des valeurs prévues des apports liquides qui rentrent dans le processus de prise de décision menant à son tour à la gestion prudente qui doit réformer les solutions de planification des ressources hydriques stockées au niveau des barrages-réservoirs. Ce chapitre qui traite les mêmes cas d'étude qui sont les trois barrages-réservoirs situés dans des zones à climats distincts : (1) le barrage réservoir de Hammam Boughrara qui représente dans la présente exploration la zone à climat semi-aride, (2) le barrage réservoir de Beni Haroun qui représente à son tour la zone à climat subhumide et (3) le barrage réservoir de Taksebt qui représente finalement la zone à climat humide. Néanmoins, on appliquera, dans ce chapitre, les méthodes ensembles à base de règles, type forêts aléatoires, désignées par (RF), (Random Forest).

### VI.2. Critère de choix entre les modèles des forêts aléatoires

Il est de même ; comme pour le chapitre précédent, les meilleurs modèles de prévision des forêts aléatoires sont ceux qui répondent aux critères de qualité les plus reconnus reflétant les performances numériquement meilleures selon les formulations décrites aussi dans le chapitre II ([Cf. Chapitre II, paragraphe II.3](#)). Il s'agit bien entendu du coefficient de corrélation ( $R$ ), la racine carrée de l'erreur quadratique moyenne ( $RMSE$ ), la moyenne des erreurs absolues ( $MAE$ ) et les critères d'efficacité de Nash-Sutcliffe ( $NSE$ ) et Kling-Gupta ( $KGE$ ).

### VI.3. Prévision des apports journaliers basée sur les variables endogènes (apports décalés) et influence de la pluie ponctuelle (variable exogène) par les forêts aléatoires

Les modèles à tester sont notés de la manière suivante :

RF $_i$  : Modèles de Forêts aléatoires (Random Forrest (RF)) d'une seule entrée ( $i=1$ ) à cinq entrées ( $i=5$ ) sans prise en compte de l'entrée pluie décalée d'un jour (modèles à variables endogènes).

RF $_{ir}$  : Modèles de Forêts aléatoires (Random Forrest (RF)) d'une seule entrée ( $i=1 : Ap_{t-1}$ ) à cinq entrées ( $i=5 : Ap_{t-5}$ ) avec prise en compte de l'entrée pluie décalée d'un jour ( $P_{t-1}$ ) (modèles à variables endogènes et exogènes). Dans ce qui suit, on

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

---

désignera par :  $y = Ap_t$  : Apport journalier actuel,  $ar1 = Ap_{t-1}$  : Apport journalier décalé d'un jour,  $ar2 = Ap_{t-2}$  : Apport journalier décalé de deux jours,  $ar3 = Ap_{t-3}$  : Apport journalier décalé de trois jours,  $ar4 = Ap_{t-4}$  : Apport journalier décalé de quatre jours,  $ar5 = Ap_{t-5}$  : Apport journalier décalé de cinq jours,  $rain1 = P_{t-1}$  : Pluie journalière décalée d'un jour.

### VI.3.1. Prévision des apports journaliers du barrage de Hammam Boughrara (représentant le climat semi-aride) par les modèles des forêts aléatoires

La période à l'échelle journalière servant de base pour le barrage de Hammam Boughrara s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.1 (Cf. Chapitre III, paragraphe III.7), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation aide dès le départ à éviter les modèles de régression linéaire multiple habituels et pousse à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Forêts aléatoires (Random Forest (RF)).

L'application des divers modèles RF donne les résultats de prévision des apports journaliers au sein du barrage de Hammama Boughrara en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau VI.1. Le meilleur modèle est RF1r qui est un modèle à deux entrées l'une est endogène ( $ar1 = Ap_{t-1}$ ) et l'autre est exogène ( $rain1 = P_{t-1}$ ). Les performances médiocres du modèle retenu en phase validation (Quoi qu'en phase de calage sont acceptables) indiquent qu'il est sûrement loin de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude ou il s'agit d'un barrage situé dans un climat semi-aride. Les confrontations graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle RF1r adopté, sont illustrées par la figure VI.1 en phase de calage et par la figure VI.3 en phase de validation. Les

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

nuages de points sont visualisés respectivement par les figures VI.2 et VI.4 en calage et validation.

Bien que le modèle RF1r retenu soit incapable de prévoir les apports liquides journaliers au sein du barrage de Hammam Boughrara pour le cas de climat semi-aride, il est toujours bénéfique d'examiner l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $\text{rain1} = P_{t-1}$ ) mesurée au sein du barrage. Le tableau VI.2, annonce numériquement ces renforcements calculés pour tous les indices et les critères de qualité. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle RF2 ( $\text{ar1} = Ap_{t-1}$  et  $\text{rain1} = P_{t-1}$ ) et RF1r ( $\text{ar1} = Ap_{t-1}$  et  $\text{rain1} = P_{t-1}$ ). Selon le gain relatif du modèle RF1r rapporté au modèle RF2, il s'avère que l'introduction de la variable exogène ( $\text{rain1} = P_{t-1}$ ) n'est pas bien approuvée.

**Tableau VI.1. Les résultats des modèles RF dans le barrage de Hammam Boughrara ;  
n<sub>tree</sub> = 70, n<sub>odesize</sub> = 5, m<sub>try</sub> à optimiser, temps = 43. 6 s (meilleur modèle : RF1r)**

Barrage		Hammam Boughrara					Paramètres
Critères de performance/Modèles	R	RMSE	MAE	NSE	KGE	m <sub>try</sub>	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)		
Calage	RF1	0.913	0.228	0.052	0.80	0.71	2
	<b>RF1r</b>	0.866	0.277	0.061	0.70	0.62	1
	RF2	0.921	0.236	0.047	0.78	0.65	1
Validation	RF1	0.250	0.897	0.171	- 0.06	-0.10	2
	<b>RF1r</b>	<u><b>0.595</b></u>	<u><b>0.816</b></u>	<u><b>0.140</b></u>	<u><b>0.22</b></u>	<u><b>0.09</b></u>	<u><b>1</b></u>
	RF2	0.631	0.783	0.161	0.28	0.19	1






Figure VI.1. Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de calage)






Figure VI.2. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle RF1r adopté (phase de calage)



## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

**Tableau VI. 2. Comparaison des performances des modèles RF compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)
RF2	0.631	0.783	0.161	0.28	0.19
RF1r	<u>0.595</u>	<u>0.816</u>	<u>0.140</u>	<u>0.22</u>	<u>0.09</u>
Gain relatif (%)	-6	-4	13	-21	-53

### VI.3.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les modèles des forêts aléatoires

La période à l'échelle journalière servant de base pour le barrage de Beni Haroun s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.2 (Cf. [Chapitre III, paragraphe III.7](#)), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ )) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète une multi colinéarité qui aide dès le départ à éviter les modèles de régression linéaire multiple et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Forêts aléatoires (Random Forest (RF)).

L'application des divers modèles RF aboutit aux résultats de prévision des apports journaliers au sein du barrage de Beni Haroun en phase de calage et en phase de validation. Tous les résultats quantitatifs sont récapitulés dans le tableau VI.3. Le meilleur modèle est RF3r qui est un modèle à quatre entrées, trois endogènes ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$  et  $ar3=Ap_{t-3}$ ), l'autre est exogène ( $rain1=P_{t-1}$ ). Les performances très satisfaisantes du modèle adopté en phase validation (et en phase calage) montrent qu'il est certainement possible de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude où il s'agit d'un barrage situé dans un climat

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

---

subhumide. Les comparaisons graphiques des apports journaliers prédits et observés au barrage réservoir avec le modèle RF3r adopté sont illustrées par la figure VI.5 en phase de calage et par la figure VI.7 en phase de validation. Les nuages de points sont visualisés respectivement par les figures VI.6 et VI.8 en calage et validation.

**Tableau VI.3. Les résultats des modèles RF dans le barrage de Beni Haroun ;  
ntree = 70, nodesize = 5, mtry à optimiser, temps = 1.114308 mins (meilleur  
modèle : RF3r)**

Barrage		Beni Haroun					Paramètres
Critères de performance/Modèles	R	RMSE	MAE	NSE	KGE	mtry	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)		
Calage	RF3	0.969	1.384	0.433	0.93	0.90	1
	<b>RF3r</b>	0.971	1.355	0.487	0.94	0.89	1
	RF4	0.970	1.348	0.416	0.94	0.91	2
Validation	RF3	0.877	3.211	1.454	0.77	0.84	1
	<b>RF3r</b>	<u><b>0.925</b></u>	<u><b>2.539</b></u>	<u><b>1.244</b></u>	<u><b>0.86</b></u>	<u><b>0.91</b></u>	<u><b>1</b></u>
	RF4	0.882	3.159	1.435	0.78	0.86	2




Figure VI.5. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de calage)




Figure VI.6. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de calage)




Figure VI.7. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de validation)




Figure VI.8. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF1r adopté (phase de validation)

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

Le modèle **RF3r** choisi est bien apte de prévoir les apports liquides journaliers au sein du barrage de Beni Haroun pour le cas de climat subhumide, il est de même utile d'explorer l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage. Le tableau VI.4 présente en chiffre ces améliorations recensées pour tous les indices et les critères des performances. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle RF4 ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ) et RF3r ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $rain1=P_{t-1}$ ). Selon le gain relatif du modèle RF3r rapporté au modèle RF4, il s'avère que l'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est effectivement justifiée.

**Tableau VI.4. Comparaison des performances des modèles RF compétitifs de prévision des apports journaliers (barrage de Beni Haroun)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (%)
<b>RF4</b>	0.882	3.159	1.435	0.78	0.86
<b>RF3r</b>	<u>0.925</u>	<u>2.539</u>	<u>1.244</u>	<u>0.86</u>	<u>0.91</u>
<b>Gain relatif (%)</b>	<b>5</b>	<b>20</b>	<b>13</b>	<b>10</b>	<b>6</b>

### VI.3.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les modèles des forêts aléatoires

La période à l'échelle journalière servant de base pour le barrage de Beni Haroun s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.3 (Cf. Chapitre III, paragraphe III.7), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète une multi colinéarité qui aide dès le départ à éviter les modèles

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

de régression linéaire multiple et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Forêts aléatoires (Random Forest (RF)).

L'application des divers modèles RF termine décidément par les résultats de prévision des apports journaliers au sein du barrage de Taksebt en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau VI.5. Le meilleur modèle est RF4 qui est un modèle à quatre entrées endogènes ( $ar1=Ap_{t-1}$ ,  $ar2= Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ). Les performances importantes du modèle admis en phase validation (et même en phase calage) démontrent qu'il est sensé de faire des prévisions des apports journaliers dans ce cas d'étude dont il s'agit d'un barrage situé dans un climat humide. Les similitudes graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle RF4 préféré sont illustrées par la figure VI.9 en phase de calage et par la figure VI.11 en phase de validation. Les nuages de points sont visualisés par les figures VI.10 et VI.12 en calage et validation, respectivement.

**Tableau VI.5. Les résultats des modèles RF dans le barrage de Taksebt ;  
n<sub>tree</sub> = 70, nodesize = 5, mtry à optimiser, temps = 1.16 mins (meilleur modèle :  
RF4)**

Barrage		Taksebt				Paramètres	
Critères de performance/Modèles		R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)	mtry
<b>Calage</b>	<b>RF4</b>	0.973	0.237	0.084	0.94	0.91	3
	RF4r	0.970	0.248	0.083	0.94	0.91	3
	RF5	0.973	0.240	0.084	0.94	0.91	3
<b>Validation</b>	<b>RF4</b>	<u>0.890</u>	<u>0.339</u>	<u>0.173</u>	<u>0.78</u>	<u>0.88</u>	3
	RF4r	0.887	0.348	0.179	0.77	0.87	<u>3</u>
	RF5	0.894	0.337	0.173	0.78	0.88	3






Figure VI.9. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de calage)

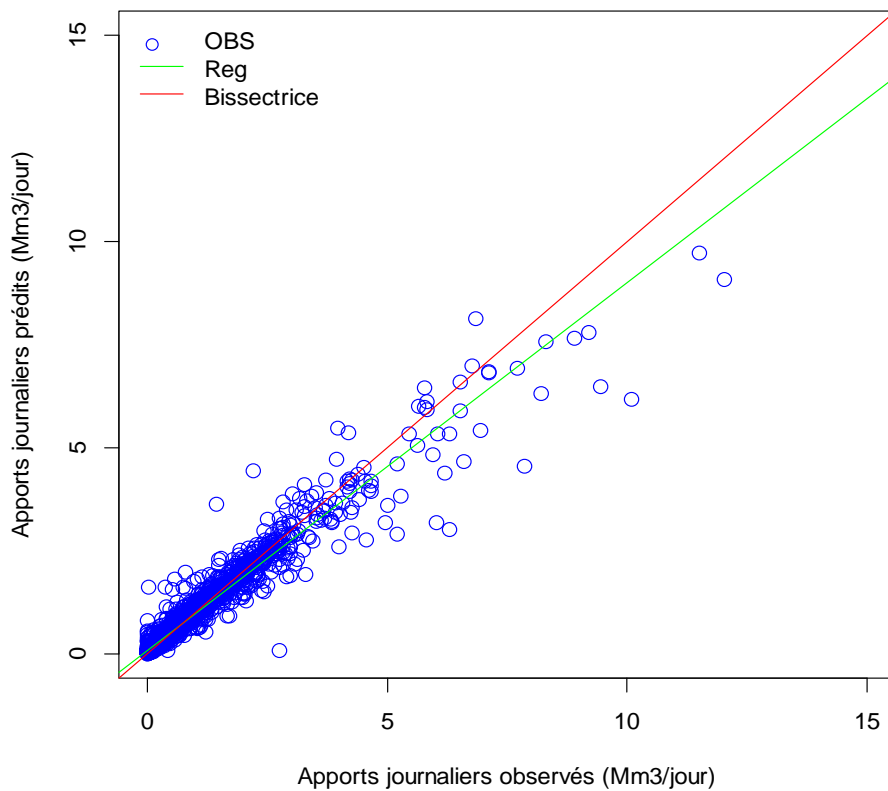


Figure VI.10. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de calage)




Figure VI.11. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de validation)




Figure VI.12. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle RF4 adopté (phase de validation)

## Chapitre VI : Prévisions des apports liquides journaliers par les forêts aléatoires prises comme modèle d'ensemble

---

Le modèle **RF4** maintenu est confiant à prévoir les apports liquides journaliers au sein du barrage de Taksebt pour le cas de climat humide. Le modèle RF4 dépasse son homologue RF3r (avec l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage). En effet il est sans profit d'observer l'amélioration en performance due à l'introduction de ladite variable. Le tableau VI.6 montre seulement les performances du modèle ainsi adopté.

**Tableau VI.6. Performances du modèle RF de prévision des apports journaliers (barrage de Taksebt)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)
<b>RF4</b>	<u><b>0.890</b></u>	<u><b>0.339</b></u>	<u><b>0.173</b></u>	<u><b>0.78</b></u>	<u><b>0.88</b></u>

### VI.4. Conclusions

Dans cet avant-dernier chapitre, la prévision des apports liquides journaliers par les modèles des forêts aléatoires (désignés par RF) a été adaptée et accomplie pour trois types de climats (semi-aride, subhumide et humide) dans trois barrages réservoirs (Hammam Boughrara, Beni Haroun et Taksebt). Les résultats montrent que les modèles RF ne peuvent pas aider à prévoir les apports liquides à l'échelle journalière quand il s'agit d'un cas semi-aride. Cependant les modèles RF peuvent être retenus comme des moyens de prévisions avec de très bonnes réussites quand il s'agit d'un cas subhumide ou humide. Ces constats sont acceptables pour les modèles RF à entrées endogènes ( $Ap_{t-i}$ ) ou exogènes. L'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est aussi bien justifiée particulièrement pour le cas subhumide représenté par le barrage réservoir de Beni Haroun où l'amélioration a pu atteindre 20% pour le critère de performance RMSE.

## *Chapitre VII*

*Prévisions des apports  
liquides journaliers par les  
machines à vecteurs de  
support*

### VII.1. Introduction

Les valeurs prévues des apports liquides jouent un rôle crucial dans le processus d'aide à la décision qui aboutit à la gestion pertinente des ressources hydriques stockées au niveau des barrages-réservoirs. Comme dernier cas des types machines learning, l'objet de ce chapitre est de prévoir les apports liquides journaliers dans les trois barrages-réservoirs situés dans des zones à climats distincts et déjà pris comme exemples dans les deux derniers chapitres. Il s'agit du : (1) barrage réservoir de Hammam Boughrara qui représente dans la présente exploration la zone à climat semi-aride, (2) barrage réservoir de Beni Haroun qui représente à son tour la zone à climat subhumide et (3) barrage réservoir de Taksebt qui représente finalement la zone à climat humide. Dans ce chapitre, on appliquera cette fois ci les méthodes de classification appliquées aux régressions, type machines à vecteurs de support désignées par (SVM), (Support Vector Machine).

### VII.2. Critère de choix entre les modèles des machines à vecteurs de support

Pour des raisons de comparaison les meilleurs modèles de prévision des machines à vecteurs de support sont également ceux qui répondent aux critères de qualité les plus reconnus reflétant les performances numériquement meilleures selon les formulations données au chapitre II ([Cf. Chapitre II, paragraphe II.3](#)). Il s'agit du coefficient de corrélation ( $R$ ), la racine carrée de l'erreur quadratique moyenne ( $RMSE$ ), la moyenne des erreurs absolues ( $MAE$ ) et les critères d'efficience de Nash-Sutcliffe ( $NSE$ ) et Kling-Gupta ( $KGE$ ).

### VII.3. Prévision des apports journaliers basée sur les variables endogènes (apports décalés) et influence de la pluie ponctuelle (variable exogène) par les machines à vecteurs de support

Les modèles à tester sont notés de la manière suivante :

SVM<sub>i</sub> : Modèles de Machines à Vecteurs de Support (Support Vector Machine (SVM)) d'une seule entrée ( $i=1$ ) à cinq entrées ( $i=5$ ) sans prise en compte de l'entrée pluie décalée d'un jour (modèles à variables endogènes).

SVM<sub>ir</sub> : Modèles de Machines à Vecteurs de Support (Support Vector Machine (SVM)) d'une seule entrée ( $i=1 : Ap_{t-1}$ ) à cinq entrées ( $i=5 : Ap_{t-5}$ ) avec prise en compte

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

---

de l'entrée pluie décalée d'un jour ( $P_{t-1}$ ) (modèles à variables endogènes et exogènes). Dans ce qui suit, on désignera par :  $y = Ap_t$  : Apport journalier actuel,  $ar1 = Ap_{t-1}$  : Apport journalier décalé d'un jour,  $ar2 = Ap_{t-2}$  : Apport journalier décalé de deux jours,  $ar3 = Ap_{t-3}$  : Apport journalier décalé de trois jours,  $ar4 = Ap_{t-4}$  : Apport journalier décalé de quatre jours,  $ar5 = Ap_{t-5}$  : Apport journalier décalé de cinq jours,  $rain1 = P_{t-1}$  : Pluie journalière décalée d'un jour.

### VII.3.1. Prévision des apports journaliers du barrage de Hammam Boughrara (représentant le climat semi-aride) par les modèles des machines à vecteurs de support

La période à l'échelle journalière servant de base pour le barrage de Hammam Boughrara s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.1 (Cf. Chapitre III, paragraphe III.7), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ )) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation aide dès le départ à éviter les modèles de régression linéaire multiple usuels et encourage à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Modèles de Machines à Vecteurs de Support (Support Vector Machine (SVM)).

L'application des divers modèles SVM donne les résultats de prévision des apports journaliers au sein du barrage de Hammama Boughrara en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau VII.1. Le meilleur modèle est SVM1r qui est un modèle à deux entrées l'une est endogène ( $ar1 = Ap_{t-1}$ ) l'autre est exogène ( $rain1 = P_{t-1}$ ). Les performances médiocres du modèle retenu en phase validation (même phase de calage) indiquent qu'il est sûrement loin de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude dont il s'agit d'un barrage situé dans un climat semi-aride. Les confrontations graphiques

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle SVM1r adopté sont illustrées par la figure VII.1 en phase de calage et par la figure VII.3 en phase de validation. Les nuages de points sont visualisés respectivement par les figures VII.2 et VII.4 en calage et validation.

Bien que le modèle SVM1r retenu soit incapable de prévoir les apports liquides journaliers au sein du barrage de Hammam Boughrara pour le cas de climat semi-aride, il est toujours bénéfique d'examiner l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $\text{rain1} = P_{t-1}$ ) mesurée au sein du barrage. Le tableau VII.2, annonce numériquement ces renforcements calculés pour tous les indices et les critères de qualité. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle SVM2 ( $\text{ar1} = Ap_{t-1}$  et  $\text{rain1} = P_{t-1}$ ) et SVM1r ( $\text{ar1} = Ap_{t-1}$  et  $\text{rain1} = P_{t-1}$ ). Selon le gain relatif du modèle SVM1r rapporté au modèle SVM2, il s'avère que l'introduction de la variable exogène ( $\text{rain1} = P_{t-1}$ ) est bien accordée.

**Tableau VII.1. Les résultats des modèles SVM dans le barrage de Hammam Boughrara ;**  
 $\varepsilon = 0.1$ ,  $\sigma$  et  $C$  à optimiser ; temps = 4.3 mins (meilleur modèle : SVM1r)

Barrage		Hammam Boughrara					Paramètres	
Critères de performance/Modèles	R	RMSE	MAE	NSE	KGE	$\sigma$	$C$	
	(-)	(Mm <sup>3</sup> /jour)	(Mm <sup>3</sup> /jour)	(-)	(-)			
<b>Calage</b>	SVM1	0.428	0.466	0.081	0.16	0.05	0.01	3
	<b>SVM1r</b>	0.580	0.417	0.073	0.32	0.28	0.01	22
	SVM2	0.424	0.460	0.079	0.17	0.09	0.01	18
<b>Validation</b>	SVM1	0.346	0.894	0.137	0.07	-0.17	0.01	3
	<b>SVM1r</b>	<b><u>0.663</u></b>	<b><u>0.809</u></b>	<b><u>0.127</u></b>	<b><u>0.23</u></b>	<b><u>0.07</u></b>	<b><u>0.01</u></b>	<b><u>22</u></b>
	SVM2	0.427	0.896	0.134	0.06	-0.17	0.01	18




Figure VII.1. Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de calage)




Figure VII.2. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de calage)






Figure VII.3. Comparaison des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de validation)




Figure VII.4. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Hammam Boughrara : Modèle SVM1r adopté (phase de validation)

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

Tableau VII.2. Comparaison des performances des modèles SVM compétitifs de prévision des apports journaliers (barrage de Hammam Boughrara)

Critères / Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)
SVM2	0.427	0.896	0.134	0.06	-0.17
SVM1r	<u>0.663</u>	<u>0.809</u>	<u>0.127</u>	<u>0.23</u>	<u>0.07</u>
Gain relatif (%)	55	10	5	>100	>100

### VII.3.2. Prévision des apports journaliers du barrage de Beni Haroun (représentant le climat subhumide) par les modèles des machines à vecteurs de support

La période à l'échelle journalière servant de base pour le barrage de Beni Haroun s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.2 ([Cf. Chapitre III, paragraphe III.7](#)), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ )) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète une multi colinéarité qui aide dès le départ à éviter les modèles de régression linéaire multiple et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Modèles de Machines à Vecteurs de Support (Support Vector Machine (SVM)).

L'application des divers modèles SVM aboutit aux résultats de prévision des apports journaliers au sein du barrage de Beni Haroun en phase de calage et en phase de validation. Tous les résultats quantitatifs sont récapitulés dans le tableau VII.3. Le meilleur modèle est SVM3r qui est un modèle à quatre entrées, trois endogènes ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$  et  $ar3=Ap_{t-3}$ ), l'autre est exogène ( $rain1=P_{t-1}$ ). Les performances très satisfaisantes du modèle adopté en phase validation (et en phase

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

---

calage) montrent qu'il est certainement possible de pouvoir faire des prévisions des apports journaliers dans ce cas d'étude où il s'agit d'un barrage situé dans un climat subhumide. Les comparaisons graphiques des apports journaliers prédits et observés au barrage réservoir avec le modèle SVM3r adopté sont illustrées par la figure VII.5 en phase de calage et par la figure VII.7 en phase de validation. Les nuages de points sont visualisés respectivement par les figures VII.6 et VII.8 en calage et validation.

**Tableau VII.3. Les résultats des modèles SVM dans le barrage de Beni Haroun ;  $\varepsilon = 0.1$ ,  $\sigma$  et  $C$  à optimiser, temps = 7.5 mins (meilleur modèle : SVM3r)**

Barrage		Beni Haroun					Paramètres	
Critères de performance/Modèles		R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)	$\sigma$	$C$
Calage	SVM3	0.876	2.647	0.782	0.76	0.76	0.005	18
	SVM3r	0.898	2.414	0.731	0.80	0.80	0.005	25
	SVM4	0.875	2.656	0.780	0.76	0.76	0.005	14
Validation	SVM3	0.884	3.174	1.322	0.77	0.77	0.005	18
	SVM3r	<b><u>0.931</u></b>	<b><u>2.449</u></b>	<b><u>1.140</u></b>	<b><u>0.87</u></b>	<b><u>0.88</u></b>	<b><u>0.005</u></b>	<b><u>25</u></b>
	SVM4	0.884	3.165	1.323	0.78	0.77	0.005	14




Figure VII.5. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de calage)




Figure VII.6. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de calage)




Figure VII.7. Comparaison des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de validation)




Figure VII.8. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Beni Haroun : Modèle SVM3r adopté (phase de validation)

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

Le modèle SVM3r choisi est bien apte de prévoir les apports liquides journaliers au sein du barrage de Beni Haroun pour le cas de climat subhumide, il est de même utile d'explorer l'amélioration en performance due à l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage. Le tableau VII.4 présente en chiffre ces améliorations recensées pour tous les indices et les critères des performances. La comparaison en phase de validation est achevée entre modèles ayant le même nombre de variables d'entrées, c'est alors entre le modèle SVM4 ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ) et SVM3r ( $ar1=Ap_{t-1}$ ,  $ar2=Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $rain1=P_{t-1}$ ). Selon le gain relatif du modèle SVM3r rapporté au modèle SVM4, il s'avère que l'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est effectivement justifiée.

**Tableau VII.4. Comparaison des performances des modèles SVM compétitifs de prévision des apports journaliers (barrage de Beni Haroun)**

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (%)
SVM4	0.884	3.165	1.323	0.78	0.77
SVM3r	<u>0.931</u>	<u>2.449</u>	<u>1.140</u>	<u>0.87</u>	<u>0.88</u>
Gain relatif (%)	5	23	14	12	14

### VII.3.3. Prévision des apports journaliers du barrage de Taksebt (représentant le climat humide) par les modèles des machines à vecteurs de support

La période à l'échelle journalière servant de base pour le barrage de Taksebt s'étale du 01/01/2009 au 31/12/2019 et ce, pour les apports liquides et la pluie ponctuelle au sein du barrage. La matrice de corrélation du tableau III.3 (Cf. Chapitre III, paragraphe III.7), indique des liaisons non négligeables entre la variable à prévoir (l'apport journalier ( $Ap_t$ ) et les variables endogènes décalées de  $i$  jours ( $i=5$ ) déduites de l'équation du bilan hydrique de la retenue du barrage de Beni Haroun (pris comme exemple dans un climat subhumide). On constate aussi une liaison remarquable entre la pluie ponctuelle journalière mesurée au sein du barrage et les apports journaliers au temps  $t$  et au temps  $t-1$ . La matrice de corrélation reflète une multi colinéarité qui aide dès le départ à éviter les modèles

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

de régression linéaire multiple et incite à chercher d'autres alternatives de modélisation non linéaire issues dans le cas présent de l'intelligence artificielle telles que : les Modèles de Machines à Vecteurs de Support (Support Vector Machine (SVM)).

L'application des divers modèles SVM termine décidément par les résultats de prévision des apports journaliers au sein du barrage de Taksebt en phase de calage et en phase de validation. Tous les résultats sont récapitulés dans le tableau VII.5. Le meilleur modèle est SVM4 qui est un modèle à quatre entrées endogènes ( $ar1=Ap_{t-1}$ ,  $ar2= Ap_{t-2}$ ,  $ar3=Ap_{t-3}$  et  $ar4=Ap_{t-4}$ ). Les performances importantes du modèle admis en phase validation (et même en phase calage) démontrent qu'il est sensé de faire des prévisions des apports journaliers dans ce cas d'étude dont il s'agit d'un barrage situé dans un climat humide. Les similitudes graphiques de comparaison des apports journaliers prédits et observés au barrage réservoir avec le modèle SVM4 préféré sont illustrées par la figure VII.9 en phase de calage et par la figure VII.11 en phase de validation. Les nuages de points sont visualisés par les figures VII.10 et VII.12 en calage et validation, respectivement.

**Tableau VII.5. Les résultats des modèles SVM dans le barrage de Taksebt ;  $\epsilon = 0.1$ ,  $\sigma$  et  $C$  à optimiser ; temps = 5.4 mins (meilleur modèle : SVM4)**

Barrage		Taksebt				Paramètres		
Critères de performance/Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)	$\sigma$	$C$	
Calage	SVM4	0.865	0.506	0.161	0.74	0.76	0.005	5
	SVM4r	0.867	0.500	0.159	0.75	0.77	0.005	4
	SVM5	0.870	0.495	0.157	0.75	0.77	0.01	15
Validation	SVM4	<u>0.905</u>	<u>0.301</u>	<u>0.150</u>	<u>0.82</u>	<u>0.84</u>	<u>0.005</u>	<u>5</u>
	SVM4r	0.905	0.309	0.150	0.82	0.86	0.005	4
	SVM5	0.906	0.307	0.149	0.82	0.86	0.01	15




Figure VII.9. Comparaison des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de calage)




Figure VII.10. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de calage)






Figure VII.11. Comparaison des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de validation)




Figure VII.12. Nuage de points des apports journaliers prédits et observés au barrage réservoir de Taksebt : Modèle SVM4 adopté (phase de validation)

## Chapitre VII: Prévisions des apports liquides journaliers par les machines à vecteurs de support

Le modèle SVM4 maintenu est confiant à prévoir les apports liquides journaliers au sein du barrage de Taksebt pour le cas de climat humide. Le modèle SVM4 dépasse son homologue SVM3r (avec l'introduction de la variable exogène qui est la pluie ponctuelle décalée d'une journée ( $rain1=P_{t-1}$ ) mesurée au sein du barrage). En effet il est sans profit d'observer l'amélioration en performance due à l'introduction de ladite variable. Le tableau VII.6 montre seulement les performances du modèle ainsi adopté.

Tableau VII.6. Performances du modèle SVM de prévision des apports journaliers (barrage de Taksebt)

Critères Modèles	R (-)	RMSE (Mm <sup>3</sup> /jour)	MAE (Mm <sup>3</sup> /jour)	NSE (-)	KGE (-)
SVM4	<u>0.905</u>	<u>0.301</u>	<u>0.150</u>	<u>0.82</u>	<u>0.84</u>

### VII.4. Conclusions

Dans ce dernier chapitre, la prévision des apports liquides journaliers par les machines à vecteurs de support (désignés par SVM) a été adaptée et accomplie pour trois types de climats (semi-aride, subhumide et humide) dans trois barrages réservoirs (Hammam Boughrara, Beni Haroun et Taksebt). Les résultats montrent que les modèles SVM ne peuvent pas aider à prévoir les apports liquides à l'échelle journalière quand il s'agit d'un cas semi-aride. Cependant les modèles SVM peuvent être retenus comme des moyens de prévisions avec de très bonnes réussites quand il s'agit d'un cas subhumide ou humide. Ces constats sont acceptables pour les modèles SVM à entrées endogènes ( $Ap_{t-i}$ ) ou exogènes. L'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est aussi bien justifiée particulièrement pour le cas subhumide représenté par le barrage réservoir de Beni Haroun où l'amélioration a pu atteindre 23% pour le critère de performance RMSE.

# *Conclusion générale*

## **Conclusion générale**

Les efforts des prévisions élaborés par les chercheurs dans le domaine des ressources hydriques visent particulièrement l'optimisation des composantes de l'équation de conservation des volumes d'eau entrant/sortant aux seins des cuvettes des barrages-réservoirs. Les estimations relativement exactes de ces composantes mènent favorablement à la maîtrise de la gestion et de la planification tribulaire d'une meilleure prise en charge de la ressource. La prévision des affluents (apports liquides) parvenant aux retenus des barrages-réservoirs, sert quant à elle à cerner les informations utiles pour les processus de prise de décision liées aux volumes d'eau alloués à l'alimentation en eau potable, à l'irrigation et à d'autres utilisations de la ressource hydrique. Ce souci de prévisions concerne toutes les zones à climats distincts : semi-arides, subhumides et humides.

L'utilisation des valeurs prévues des apports liquides dans le processus de prise de décision menant à la gestion rationnelle doivent améliorer les modalités de planification des ressources hydriques stockées au niveau des barrages-réservoirs. C'est d'ailleurs l'objet de cette étude thèse dans les quatre derniers chapitres qui traitent comme cas d'étude trois barrages-réservoirs situés dans des zones à climats distincts à savoir : (1) le barrage réservoir de Hammam Boughrara qui représente dans la présente exploration la zone à climat semi-aride, (2) le barrage réservoir de Beni Haroun qui représente à son tour la zone à climat subhumide et (3) le barrage réservoir de Taksebt qui représente finalement la zone à climat humide. A cet effet, Il a été retenu délibérément, outre les deux types de modèles de séries temporelles classées parmi les modèles stochastiques, il s'agit du modèle autorégressif à moyenne mobile intégrée (ARIMA) et du modèle à lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers (TBATS) pour prévoir les apports liquides mensuels. Trois autres types de techniques basées sur l'intelligence artificielle et de l'apprentissage machine pour prévoir les apports liquides journaliers, à savoir : (1) Réseaux de neurones artificiels type perceptron multicouches désignés par (ANN), (2) Méthodes ensembles à base de règles type forêts aléatoires désignées par (RF),

(Random Forest) et finalement (3) Méthodes de classification appliquées aux régressions type machines à vecteurs de support désignées par (SVM), (Support Vector Machine).

Les apports liquides journaliers et mensuels des trois réservoirs en question sont évalués par l'équation de continuité (entrants = sortants), dénommée équation du bilan hydrique ou hydraulique adoptée par l'Agence Nationale des Barrages et Transferts (ANBT) pour gérer tous les barrages en Algérie en termes de ressources hydriques. Les tailles des trois séries sont identiques ce qui écarte l'influence directe de la longueur de l'échantillon en faveur d'une influence attendue et probable du climat.

Pour tous les modèles considérés dans cette contribution, la phase de calage s'étale sur les dix premières années et la phase de validation concerne la dernière année pour chaque barrage et chaque modèle étudié à part. La limite de décalage dans le temps pour les apports liquides journaliers est motivée par la considération de la mémoire de la série temporelle à savoir une limite de cinq jours (environ une semaine) d'influence d'apports successifs et non pas nécessairement l'aspect statistique qui ne considère pas forcément la réalité physique du phénomène. Quant à la pluie, elle est juste prise décalée d'une journée pour avoir des modèles à données traitables et faciles à obtenir avec plus de certitudes. Il est très important de préciser qu'il ne s'agit pas de précipitations spatialement pondérées (arithmétique, Thiessen ou isohyètes) au niveau des bassins versants alimentant les réservoirs des barrages considérés, mais plutôt des pluies à valeurs ponctuelles mesurées directement sur les sites des trois barrages pris en compte cas par cas.

Tous les types de modèles de prévision des apports journaliers et mensuels dans les trois barrages- réservoirs à climats distincts comme suscités, seront implémentés dans le code *R* et appliqués dans les quatre chapitres qui suivent trois premiers chapitres.

Pour plus amples informations et détails sur le présent travail de thèse, on peut signaler dans cette conclusion générale qu'après avoir écrit les chapitres qui décrivent la zone d'étude, la collecte des données et la théorie et les méthodes liées aux modèles de prévision stochastiques et non stochastique (chapitre 1, 2 et 3), un

quatrième chapitre a été consacré exclusivement aux modèles des séries temporelles qui consistent en la recherche d'un moyen relativement efficace pour la prévision des apports liquides mensuels aux seins des trois barrages réservoirs situés dans des régions climatiques distinctes : barrage de Hammam Boughrara (semi-aride à l'Ouest de l'Algérie), barrage de Beni Haroun (subhumide à l'Est de l'Algérie) et barrage de Taksebt (humide au centre de l'Algérie). Les modèles évalués se classent parmi les types stochastiques linéaires bien explorés dans la littérature. Il s'agit du modèle autorégressif à moyenne mobile intégrée (ARIMA) et du modèle à lissage exponentiel trigonométrique avec transformation de Box-Cox, erreurs ARMA, composants de tendance et saisonniers (TBATS).

Les résultats d'évaluation des deux modèles envisagés démontrent que les types ARIMA et TBATS ne reproduisent pas cas d'une manière fidèle la variabilité des apports mensuels en cas de piques pour les trois barrages pris en charge par cette investigation. Les résidus issus des modèles retenus sont loin d'être des bruits blancs et les auto-corrélations dans lesdits résidus ne sont pas complètement capturées. Les modèles TBATS quant à eux peuvent à la limite se présenter comme remède aux modèles qui ne tiennent pas compte de la complexité et de la dynamique de la saisonnalité des séries temporelles des apports liquides mensuels en Algérie dans trois régions climatiques différentes (semi-aride, subhumide et humide), toutefois ce remède demeure limité en termes de capacité de prévision et en reproduction des valeurs extrêmes fortes prouvée par la métrique *MAPE* (Erreur moyenne absolue en pourcentage) qui décroît de 40%, à 35% et à 30% selon que le cas soit semi-aride, subhumide ou l'humide. La meilleure valeur n'a pas baissé au-dessous de 30% qui se considère quand même comme erreur notable à raffiner (prévision raisonnable) reflétant ainsi l'exigence de faire recours aux modèles plus appropriés pour prévoir les apports liquides mensuels au sein des barrages en Algérie. Les modèles ARIMA et notamment TBATS peuvent à la limite être considérés comme outils de prévision dans une planification préliminaire de gestion des ressources hydriques à l'échelle mensuelle.

Dans les trois derniers chapitres (chapitre 5, 6 et 7) les modèles au nombre de trois utilisés sont issus de la technique de l'intelligence artificielle qui sont : les

réseaux de neurones artificiels de type perceptrons multicouches (ANN), les forêts aléatoires prises comme modèle d'ensemble (RF) et les machines à vecteurs de support (SVM).

Les diagrammes de Taylor et les boîtes de violon (violin box plot), déjà décrits, sont exploités pour évaluer et comparer les performances des trois modèles.

A cet effet [La figure 1](#) montre que les prévisions en phase de validation des apports journaliers au sein du barrage de Hammam Boughrara par les modèles ANN), RF et SVM sont de plus en plus proches aux valeurs observées, et ce par ordre de mérite. Bien que les prévisions des modèles RF et SVM soient très similaires, il ressort que le modèle ANN est le meilleur bien qu'il soit médiocre en performances et ne peut être maintenu pour faire des prévisions raisonnables des apports journaliers au sein du barrage de Hammam Boughrara. L'écart-type des données de prévision indique que les trois modèles ne sont plus capables de prédire fidèlement les fluctuations des apports journaliers observés, cette dernière constatation est aussi confirmée par les boîtes à moustaches sous forme de diagramme en violon visualisées par [la figure 2](#) qui montre les boîtes à moustaches (type violon) de la distribution des valeurs apports journaliers d'entrée du réservoir de Hammam Boughrara prévues par les modèles ANN, RF et SVM, comparées aux valeurs des apports observés dans la phase de validation. Les boîtes affichent les valeurs extrêmes des propriétés des apports journaliers prévus et observés où elles sont étirées vers l'extérieur des quartiles supérieurs indiquant ainsi des valeurs extrêmes suite aux crues vécus par le barrage réservoir. Ces résultats indiquent que la distribution des valeurs des apports prévues par le modèle ANN est relativement proche des valeurs observées dans la phase de validation.




Figure 1. Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Hammam Bouhrara (cas semi-aride)

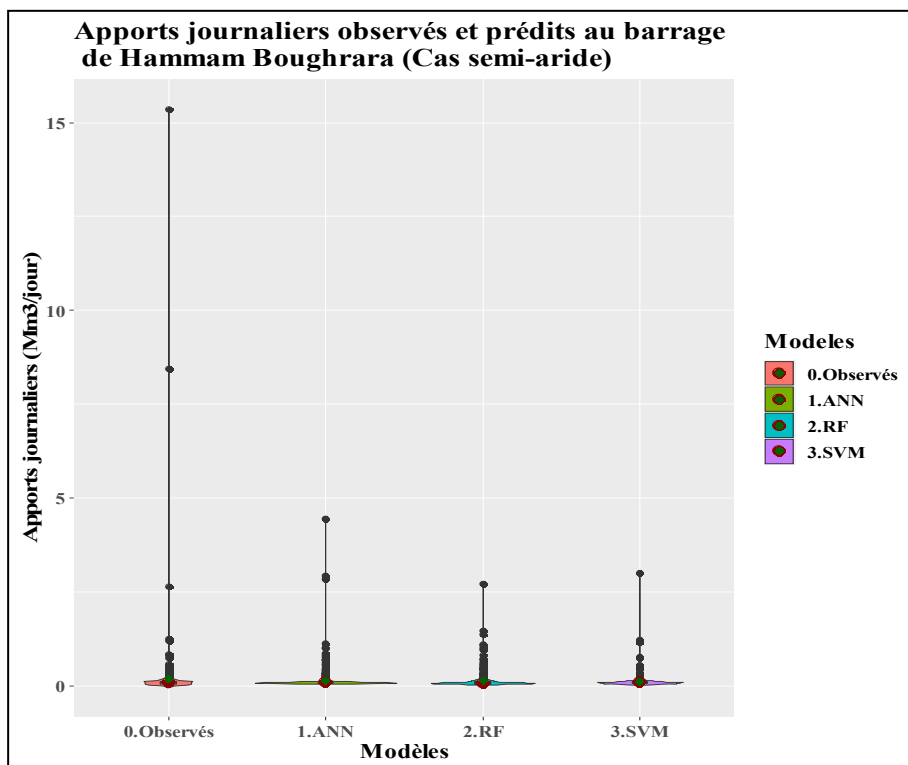


Figure 2. Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Hammam Bouhrara (cas semi-aride)



La figure 3 montre que les prévisions en phase de validation des apports journaliers au sein du barrage de Beni Haroun par les modèles RF, SVM et ANN sont en accord avec les valeurs observées, et ce par ordre de mérite. Quoique les prévisions des modèles ANN et SVM soient très similaires, il ressort que le modèle RF est le meilleur en performances et peut être retenu pour faire des prévisions plausibles des apports journaliers au sein du barrage de Beni Haroun. L'écart-type des données de prévision indique que les trois modèles sont de proche en proche éprouvés de prédire fidèlement les fluctuations des apports journaliers observés, cette dernière constatation est aussi confirmée par les boîtes à moustaches en diagrammes de violon visualisées par la figure 4 qui montre les boîtes à moustaches (type violon) de la distribution des valeurs apports journaliers d'entrée du réservoir de Beni Haroun prévues par les modèles RF, SVM et ANN, comparées aux valeurs des apports observés dans la phase de validation. Les boîtes affichent les valeurs extrêmes des propriétés des apports journaliers prévus et observés où elles sont traînées vers l'extérieur des quartiles supérieurs indiquant subséquemment des valeurs extrêmes suite aux crues réelles survenues dans le site du barrage réservoir. Ces résultats indiquent que la distribution des valeurs des apports prévues par le modèle RF est très proche des valeurs observées dans la phase de validation.





Figure 3. Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Beni Haroun (cas subhumide)



**Figure 4. Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Beni Haroun (cas subhumide)**

La figure 5 montre que les prévisions en phase de validation des apports journaliers au sein du barrage de Taksebt par les modèles RF, SVM et ANN sont en accord avec les valeurs observées, et ce par ordre de mérite. Quoique les prévisions des modèles ANN et SVM soient très similaires, il ressort que le modèle RF est le meilleur en performances et peut être retenu pour faire des prévisions plausibles des apports journaliers au sein du barrage de Taksebt. L'écart-type des données de prévision indique que les trois modèles sont de proche en proche assurés de prédire fidèlement les fluctuations des apports journaliers observés, ce dernier constat est également confirmé par les boîtes à moustaches en Diagramme en violon visualisées par la figure 6 qui montre les boîtes à moustaches (type violon) de la distribution des valeurs apports journaliers d'entrée du réservoir de Taksebt prévues par les modèles RF, SVM et ANN, comparées aux valeurs des apports observés dans la phase de validation. Les boîtes affichent les valeurs extrêmes des propriétés des apports journaliers prévus et observés où elles sont traînées vers l'extérieur des quartiles supérieurs indiquant ensuite des valeurs extrêmes qui sont des conséquences aux crues concrètes arrivées au site du barrage réservoir. Ces résultats

indiquent que la distribution des valeurs des apports prévues par le modèle RF est vraiment proche des valeurs observées dans la phase de validation.




Figure 5. Diagramme de Taylor pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Taksebt (cas humide)




Figure 6. Diagramme en violon pour la comparaison des modèles de prévision des apports journaliers en phase de validation au barrage de Taksebt (cas humide)

Les résultats montrent que les modèles ANN, RF et SVM ne peuvent pas aider à prévoir les apports liquides à l'échelle journalière quand il s'agit d'un cas semi-aride. Cependant ces modèles peuvent être considérés comme des moyens de prévisions avec de très bonnes performances quand il s'agit d'un cas subhumide ou humide. Ces constatations sont valables pour les modèles ANN, RF et SVM à entrées endogènes ( $Ap_{t-i}$ ) ou exogènes. L'introduction de la variable exogène ( $rain1=P_{t-1}$ ) est bien justifiée notamment pour le cas subhumide représenté par le barrage réservoir de Beni Haroun où les améliorations ont pu atteindre 19%, 20% et 23% pour le critère RMSE pour les modèles ANN, RF et SVM, respectivement.

*Références  
bibliographiques*

**Références bibliographiques**

- Abd Saleh, Z. (2013). Forecasting by Box-Jenkins (ARIMA) Models to Inflow of Haditha Dam. *Journal of Babylon University, Engineering Sciences*. Vol. 21, No. 5.
- Adnan, R. M., Yuan, X., Kisi, O., & Curtef, V. (2017). Application of time series models for streamflow forecasting. *Civil and Environmental Research*, 9(3), 56-63.
- Agence Nationale des Barrages et Transferts (ANBT). (2019). Alger, Algérie.
- Akaike, H. (1974). A New-Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, AC- 19, 716-723.
- Albergel, J., Gueguen, N., & Pepin, Y. (1997). Comment faire le suivi hydrologique d'un petit barrage. *Note technique*. Tunis: ORSTOM, 30 p.
- Al-Mukhtar, M. (2019). Random forest, support vector machine, and neural networks to modelling suspended sediment in Tigris River-Baghdad. *Environmental Monitoring and Assessment*, 191(11), 1-12.
- Alquraish, M. M., Abuhasel, K. A., Alqahtani, A. S., & Khadr, M. (2021). A Comparative Analysis of Hidden Markov Model, Hybrid Support Vector Machines, and Hybrid Artificial Neural Fuzzy Inference System in Reservoir Inflow Forecasting (Case Study: The King Fahd Dam, Saudi Arabia). *Water*, 13(9), 1236.
- Apaydin, H., Feizi, H., Sattari, M. T., Colak, M. S., Shamshirband, S., & Chau, K. W. (2020). Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting. *Water*, 12(5), 1500.
- Azad, A., Farzin, S., Kashi, H., Sanikhani, H., Karami, H., & Kisi, O. (2018). Prediction of river flow using hybrid neuro-fuzzy models. *Arabian Journal of Geosciences*, 11(22), 1-14.
- Babaei, M., Moeini, R., & Ehsanzadeh, E. (2019). Artificial neural network and support vector machine models for inflow prediction of dam reservoir (case study: Zayandehroud dam reservoir). *Water Resources Management*, 33(6), 2203-2218.

- Bai, Y., Chen, Z., Xie, J., & Li, C. (2016). Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models. *Journal of hydrology*, 532, 193-206.
- Bai, Y., Sun, Z., Zeng, B., Long, J., Li, C., & Zhang, J. (2018). Reservoir inflow forecast using a clustered random deep fusion approach in the Three Gorges Reservoir, China. *Journal of hydrologic engineering*, 23(10), 04018041.
- Bengora, Dj. (2019). Optimisation de la gestion du barrage hammam Debagh (Guelma) dans la Seybouse-Algérie. Thèse de doctorat. EPN, Algérie.
- Blasco, B.C., Moreno, J.J.M., Pol, A.P., Abad, A.S. (2013). Using the R-MAPE index as a resistant measure of forecast accuracy. *Psicothema*, 25(4), pp.500-506.
- Bouanani, A. (2004). Hydrologie, transport solide et modélisation : étude de quelques sous bassins de la Tafna (NW - Algérie). Doctorat d'état, Université Abou Bekr Belkaid Tlemcen, Algérie. 250 pages.
- Box, G. E., Jenkins, G. M. (1976). *Series analysis forecasting and control*. Holden-Day, San Francisco, 575.
- Box, G.E., Jenkins, G.M., & Reinsel, G.C. (2008). *Time Series Analysis: Forecasting and Control*, 4<sup>th</sup> ed. Wiley, Hoboken, N.J.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Can, İ., Tosunoğlu, F., & Kahya, E. (2012). Daily streamflow modelling using autoregressive moving average and artificial neural networks models: case study of Ç oruh basin, Turkey. *Water and Environment Journal*, 26(4), 567-576.
- Carslaw, D.C. (2015). *The openair manual-open-source tools for analysing air pollution data. Manual for version 1.1-4*, King's College London.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. J. (1990). STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, 6(1), 3-33.
- Coulibaly, P., Anctil, F., & Bobée, B. (2000). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230(3-4), 244-257.

- Dahkal, I (2015). Ajustement des modèles de séries temporelles pour prévoir les apports liquides du Barrage Hammam. Mémoire de Magister. En Hydrologie et Aménagement des Bassins Versants. Univ de Chlef. Algérie.
- Dahmani, S., Ferhait, A., Yebdri, Dj., Bounoua, R., & Djafer Khodja, H. (2018). Development of Reservoir Management Optimal Rules: Case of Hammam Boughrara Dam, Wilaya of Tlemcen, Algeria. P. Gourbesville et al. (eds.), *Advances in Hydroinformatics, Springer Water*.
- Dawson, C. W., & Wilby, R. L. (2001). Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, 25(1), 80-108.
- De Livera, A.M., Hyndman, R.J., & Snyder, R. D. (2011). Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American Statistical Association*, 106(496), 1513-1527.
- Dumedah, G., Walker, J. P., & Chik, L. (2014). Assessing artificial neural networks and statistical methods for infilling missing soil moisture records. *Journal of Hydrology*, 515, 330-344.
- Esmaeilzadeh, B., Sattari, M. T., & Samadianfard, S. (2017). Performance evaluation of ANNs and an M5 model tree in Sattarkhan Reservoir inflow prediction. *ISH Journal of Hydraulic Engineering*, 23(3), 283-292.
- Feller, W. (1968). *An Introduction to Probability Theory and Its Applications*. Volume I, 3<sup>e</sup> éd., Wiley.
- Fortin, V., Ouarda, T. B. M. J., Rasmussen, P., & Bobée, B. (1997). Revue bibliographique des méthodes de prévision des débits. *Revue des sciences de l'eau/Journal of Water Science*, 10(4), 461-487.
- Fritsch, S., Guenther, F., & Guenther, M. F. (2019). Package 'neuralnet'. *Training of Neural Networks*.
- Ghumman, A. R., Ahmad, S., & Hashmi, H. N. (2018). Performance assessment of artificial neural networks and support vector regression models for stream flow predictions. *Environmental Monitoring and Assessment*, 190(12), 704.
- Gos, M., Krzyszczak, J., Baranowski, P., Murat, M., & Malinowska, I. (2020). Combined TBATS and SVM model of minimum and maximum air



- temperatures applied to wheat yield prediction at different locations in Europe. *Agricultural and Forest Meteorology*, Volume 281.107827.
- Gould, P. G., Koehler, A. B., Ord, J. K., Snyder, R. D., Hyndman, R. J. & Vahid-Araghi, F. (2008). Forecasting time series with multiple seasonal patterns. *European Journal of Operational Research* 191(1), 207-222.
- Gupta, A., Kumar, A. (2020). Two-step Daily Reservoir Inflow Prediction Using ARIMA-Machine Learning and Ensemble Models. *Earth and Space Science Open Archive*. 25 pages.
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, 377(1-2), 80-91.
- Hagenauer, J., Omrani, H., Helbich, M. (2019). Assessing the performance of 38 machine learning models: the case of land consumption rates in Bavaria, Germany. *International Journal of Geographical Information Science*, 33:7, 1399-1419.
- Herbert, Z.C., Asghar, Z., & Oroza, C.A. (2021). Long-term Reservoir Inflow Forecasts: Enhanced Water Supply and Inflow Volume Accuracy Using Deep Learning, *Journal of Hydrology*, Volume 601.
- Hildebert, I. (1950). La répartition saisonnière des pluies en Algérie. In: *Annales de Géographie*, t. 59, n°317, 1950. pp. 354-361.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251-257.
- Ibrahim, K. S. M. H., Huang, Y. F., Ahmed, A. N., Koo, C. H., & El-Shafie, A. (2022). A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting. *Alexandria Engineering Journal*, 61(1), 279-303.
- Jung, Y. (2018). Multiple predicting k-fold cross-validation for model selection, *Journal of Nonparametric Statistics*, 30:1, 197-215.

- Karimi-Googhari, S., Feng, H. Y., Ghazali, A. H. B., & Shui, L. T. (2010). Neural Networks for Forecasting Daily Reservoir Inflows. *Pertanika J. Sci. and Technol*, 18(1), 33-41.
- Karunanayake, C., Gunathilake, M. B., & Rathnayake, U. (2020). Inflow forecast of iranamadu reservoir, Sri Lanka, under projected climate scenarios using artificial neural networks. *Applied Computational Intelligence and Soft Computing*, 2020. Article ID 8821627, 11 pages.
- Kasabov, N. K. (1996). Foundations of neural networks, fuzzy systems, and knowledge engineering. Marcel Alencar.
- Kassoul, M., Abdelgader, A., & Belorgey, M. (1997). Caractérisation de la sédimentation des barrages en Algérie. *Revue des sciences de l'eau/Journal of Water Science*, 10(3), 339-358.
- Kecman, V. (2001). *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*. Cambridge: MIT Press.
- Khosravi, K., Miraki, S., Saco, P. M., & Farmani, R. (2021). Short-term River streamflow modeling using Ensemble-based additive learner approach. *Journal of Hydro-environment Research*, 39, 81-91.
- Kling, H., Fuchs, M., & Paulin, M. (2012). Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios. *Journal of Hydrology*, 424, 264-277.
- Knoben, W. J., Freer, J. E., & Woods, R. A. (2019). Inherent benchmark or not? Comparing Nash–Sutcliffe and Kling–Gupta efficiency scores. *Hydrology and Earth System Sciences*, 23(10), 4323-4331.
- Kuhn, M., Johnson, K. (2013). *Applied predictive modeling*. New York: Springer. ISBN 978-1-4614-6848-6.
- Kumar, P., Singh, R., Sharma, A., Singh, G., Kumar, D., & Singh, A. K. (2021). Comparison of Different Interpolation Techniques for Mean Areal Rainfall Estimation of Uttarakhand using Geographical Information System. *Journal of the New England Water Works Association*, 135(3), 43-50.

- Laboratoire d'études maritimes (LEM). (2013). Levés bathymétriques de onze barrages en exploitation : campagne de mesures Béni Haroun. Rapport décembre 2013. Lieu-dit Djenane El Malik Hydra - Alger.
- Lan, Y. (2014). Forecasting performance of support vector machine for the Poyang Lake's water level. *Water Science & Technology*, 70(9), 1488-1495.
- Latif, S. D., Ahmed, A. N., Sathiamurthy, E., Huang, Y. F., & El-Shafie, A. (2021). Evaluation of deep learning algorithm for inflow forecasting: a case study of Durian Tunggal Reservoir, Peninsular Malaysia. *Natural Hazards*, 109(1), 351-369.
- Lewis, C.D. (1982). Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting. Butterworth-Heinemann.
- Liaw, A., & Wiener, M. (2003). Classification and regression by randomForest. *R News*, 2(3), 18-22.
- Lin, J., Cheng, C., & Chau, K. (2006). Using support vector machines for long-term discharge prediction. *Hydrological Sciences Journal*, 51(4), 599-612.
- Machekposhti, K. H., Sedghi, H., Telavari, A., & Babazadeh, H. (2017). Forecasting by Stochastic models to inflow of Karkheh dam at Iran. *Civil Engineering Journal*, 3(5), 340-350.
- Matrenin, P., Safaraliev, M., Dmitriev, S., Kokin, S., Eshchanov, B., & Rusina, A. (2022). Adaptive ensemble models for medium-term forecasting of water inflow when planning electricity generation under climate change. *Energy Reports*, 8, 439-447.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Mizukami, N., Rakovec, O., Newman, A. J., Clark, M. P., Wood, A. W., Gupta, H. V., & Kumar, R. (2019). On the choice of calibration metrics for "high-flow" estimation using hydrologic models. *Hydrology and Earth System Sciences*, 23(6), 2601-2614.
- Moeeni, H., Bonakdari, H., Fatemi, S. E., & Zaji, A. H. (2017a). Assessment of stochastic models and a hybrid artificial neural network-genetic algorithm method in forecasting monthly reservoir inflow. *INAE Letters*, 2(1), 13-23.

- Moeeni, H., Hossien, B., Fatemi, S.E. (2017b). Stochastic model stationarization by eliminating the periodic term and its effect on time series prediction. *Journal of Hydrology*. Vol. 547 pp. 348-364.
- Moeini, R., & Babaei, M. (2020). Hybrid SVM-CIPSO methods for optimal operation of reservoir considering unknown future condition. *Applied Soft Computing*, 95, 106572.
- More, D., Magar, R. B., & Jothiprakash, V. (2019). Intermittent reservoir daily inflow prediction using stochastic and model tree techniques. *Journal of The Institution of Engineers (India): Series A*, 100(3), 439-446.
- Nash, J. E., Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology*, 10 (3), 282-290.
- Nazir, H. M., Hussain, I., Faisal, M., Elashkar, E. E., & Shoukry, A. M. (2019). Improving the prediction accuracy of river inflow using two data pre-processing techniques coupled with data-driven model. *PeerJ*, 7, e8043.
- Ouedraogo, I., Defourny, P., & Vanclooster, M. (2019). Application of random forest regression and comparison of its performance to multiple linear regression in modeling groundwater nitrate concentration at the African continent scale. *Hydrogeology Journal*, 27(3), 1081-1098.
- Papacharalampous, G. A., & Tyrallis, H. (2018). Evaluation of random forests and Prophet for daily streamflow forecasting. *Advances in Geosciences*, 45, 201-208.
- Perin, C. (2000). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative. Thèse de doctorat de l'institut national polytechnique de Grenoble. France.
- Pool, S., Vis, M., & Seibert, J. (2018). Evaluating model performance: towards a non-parametric variant of the Kling-Gupta efficiency. *Hydrological Sciences Journal*, 63(13-14), 1941-1953.
- Rasouli, K., Hsieh, W. W., & Cannon, A. J. (2012). Daily streamflow forecasting by machine learning methods with weather and climate inputs. *Journal of Hydrology*, 414, 284-293.

- R Core Team. (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>
- Rodriguez, J.D., Perez, A., Lozano, J.A. (2010). Sensitivity analysis of K-fold cross validation in prediction error estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32, 569-575.
- Sathishkumar, V. E., Yongyun, Cho. (2020). A rule-based model for Seoul Bike sharing demand prediction using weather data. *European Journal of Remote Sensing*, 53:sup1, 166-183.
- Siddiqi, T. A., Ashraf, S., Khan, S. A., & Iqbal, M. J. (2021). Estimation of data-driven streamflow predicting models using machine learning methods. *Arabian Journal of Geosciences*, 14(11), 1-9.
- Smadi, A., Abrika, B. (2018). La résilience territoriale comme facteur d'émergence d'une destination touristique durable. Cas du barrage de Taksebt (Tizi-Ouzou, Algérie). *Études caribéennes*.
- Solomatine, D., See, L. M., & Abrahart, R. J. (2008). Data-driven modelling: concepts, approaches and experiences. In *Practical hydroinformatics* (pp. 17-30).
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183-7192.
- Taylor, J. W., Snyder, R. D. (2009). Forecasting intraday time series with multiple seasonal cycles using parsimonious seasonal exponential smoothing. (9/09).
- Termite, L. F., Todisco, F., Vergni, L., & Mannocchi, F. (2013). A neuro-fuzzy model to predict the inflow to the guardialfiera multipurpose dam (Southern Italy) at medium-long time scales. *Journal of Agricultural Engineering*, 44(s2).
- Thanh Noi, P., Degener, J., Kappas, M. (2017). Comparison of Multiple Linear Regression, Cubist Regression, and Random Forest Algorithms to Estimate Daily Air Surface temperature from Dynamic Combinations of MODIS LST Data. *Remote Sens*, 9, 398.
- Vapnik, V. (1995). *The nature of statistical learning theory*. Berlin: Springer Science & Business Media.

- Wang, W., Van Gelder, P. H., Vrijling, J. K., & Ma, J. (2006). Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*, 324(1-4), 383-399.
- Werbos, P. (1990). Backpropagation Through Time: What It Does and How to Do It. *Proceedings of the IEEE*. 78 (10): 1550-1560.
- Werbos, P. J. (1994). The roots of backpropagation: from ordered derivatives to neural networks and political forecasting (Vol. 1). John Wiley & Sons.
- West, M., Harrison, J. (1997). Bayesian forecasting and Dynamic models. Springer Series in Statistics, 2nd ed. Springer, New York. Whittle, P., 1951. Hypothesis Testing in Time.
- Willmott CJ., Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30, 79-82.
- Winters, P.R. (1976). Forecasting sales by exponentially weighted moving averages. *Mathematical Models in Marketing, Lecture Notes in Economics and Mathematical Systems*. Springer, Berlin, Heidelberg, pp. 384-386.
- Wurbs, R. A. (2012). Water Rights Analysis Package (WRAP) Modeling System - Reference Manual, Technical Report No. 255, Texas Water Resources Institute, The Texas A&M, University System, College Station, Texas.
- Yang, T., Gao, X., Sorooshian, S., & Li, X. (2016). Simulating California reservoir operation using the classification and regression-tree algorithm combined with a shuffled cross-validation scheme. *Water Resources Research*, 52(3), 1626-1651.
- Yin, Z., Feng, Q., Wen, X., Deo, R. C., Yang, L., Si, J., & He, Z. (2018). Design and evaluation of SVR, MARS and M5Tree models for 1, 2 and 3-day lead time forecasting of river flow data in a semiarid mountainous catchment. *Stochastic Environmental Research and Risk Assessment*, 32(9), 2457-2476.
- Zambrano-Bigiarini, M. (2020). Package 'hydroGOF'. *Goodness-of-fit Functions for Comparison of Simulated and Observed*.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

- Zhang, J., Cheng, C. T., Liao, S. L., Wu, X. Y., & Shen, J. J. (2009). Daily reservoir inflow forecasting combining QPF into ANNs model. *Hydrology and Earth System Sciences Discussions*, 6(1), 121-150.
- Zhang, Y., Yang, Y. (2015). Cross-validation for selecting a model selection procedure. *J Econom.* 187(1): 95-112.
- Zounemat-Kermani, M., Mahdavi-Meymand, A., & Hinkelmann, R. (2021). A comprehensive survey on conventional and modern neural networks: application to river flow forecasting. *Earth Science Informatics*, 14(2), 893-911.