

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

الجمهورية الجزائرية الديمقراطية الشعبية

MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

وزارة التعليم العالي والبحث العلمي

Université du 20 Août 1955-Skikda

Faculté des Sciences

Département des Sciences Agronomiques



Thèse

En vue de l'obtention du diplôme de

DOCTORAT LMD

Filière: Sciences Agronomiques

Spécialité: Aménagement Hydro-Agricole

Présentée par:

Mr. LEFOULA Bilal

Thème

**Gestion des Barrages Réservoirs En Algérie : Modélisation
Par Le Machine Learning**

Devant le jury

Président :	Mr. HEDDAM Salim	Professeur à l'Université 20 Août 1955, Skikda
Rapporteur:	Mr. HEBAL Aziz	M.C.A à l'Université 20 Août 1955, Skikda
Examineurs:	Mr. BOUHAYENE Salah	M.C.A à l'Université 20 Août 1955, Skikda
	Mr. LAOUACHERIA Fares	M.C.A à l'Université Badji Mokhtar, Annaba
	Mr. TOUMI Faycal	M.C.A à l'Université Badji Mokhtar, Annaba

Année Universitaire: 2023 / 2024

Dédicaces

Je dédie ce modeste travail :

A mes parents, qui ont toujours été mes piliers de soutien.

*A ma tendre épouse, **Imane**, dont le soutien indéfectible m'a encouragé tout au long de ce parcours.*

*A mes précieux enfants, **Djana** et **Aya**, qui sont ma plus grande source de motivation.*

A toute ma famille et belle-famille, pour leur amour et leur encouragement constants.

A Tous mes amis.

BILAL LEFOULA

Remerciements

Avant tout propos, nous remercions « Dieu » le tout puissant qui nous a donné la sagesse et la santé pour faire ce modeste travail.

*Je tiens à remercier tout d'abord mon promoteur Mr **HEBAL Aziz**, pour avoir bien voulu m'encadrer pour ce travail, et d'avoir mis à notre disposition les outils intellectuels et logistiques nécessaires, mais aussi pour ses suggestions et ses orientations ainsi que sa disponibilité.*

*Je tiens également à remercier Mr **Bengora Djamel**, pour son aide très fructueuse. Son expérience dans le domaine de l'optimisation de la gestion des barrages, m'a été d'une grande importance pour ma formation.*

*J'exprime également ma sincère reconnaissance aux membres du jury, pour l'honneur qu'ils m'ont fait en acceptant de juger ce travail : Mr **Heddoum Salim**, Mr **Bouhayene Salah**, Mr **Laouacheria Fares**, et Mr **Toumi Faycal**.*

*Cette thèse n'aurait pu voir le jour sans les données qui m'ont été gracieusement octroyées par l'Agence Nationale des Barrages et Transfert. Je tiens à exprimer ma gratitude à toute l'équipe de l'**ANBT** pour leur assistance précieuse.*

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

Enfin j'aimerais remercier et adresser ma reconnaissance à tous ceux qui m'ont soutenu, de loin ou de près, durant les moments difficiles.

ملخص

يعد تسيير السدود التخزينية مهمة أساسية لصانعي القرار الراغبين في تحسين استخدام الموارد المائية. لا يمكن للأساليب التقليدية أن تعالج بشكل كافٍ جميع القضايا التي يجب أخذها بعين الاعتبار من أجل تطوير نموذج يسمح بأفضل إدارة ممكنة لاحتياطات المياه التي تحشدها السدود. وبالفعل، فإن التنبؤ بكميات المياه المخصصة لإمدادات مياه الشرب والسقي (VTAL) هو أمر استراتيجي للتخطيط والإدارة الفعالة والناجعة للموارد المائية، لا سيما خلال مواسم الجفاف.

يتزايد استخدام نماذج التعلم الآلي (ML) للتنبؤ بمتغيرات تشغيل الخزانات. في هذه الدراسة، تم اختيار نماذج الشبكات العصبية متعددة الطبقات (MPLNN) و"انحدار الغابة العشوائية (RFR) و"انحدار متجه الدعم (SVR) للتنبؤ بمتغيرات تشغيل الخزان باستخدام قاعدة بيانات لثمانية متغيرات يومية على مدار ثماني سنوات (2009-2017) في سدي زيت إمبا والقنيطرة الواقعين في شمال شرق الجزائر. تم النظر في سبع تركيبات من المدخلات ومقارنتها للعثور على أفضل متغيرات المدخلات للتنبؤ بمتغير VTAL.

كشفت النتائج العددية التي تم الحصول عليها أنه في مرحلة المصادقة، يعتبر نموذج RFR أفضل نموذج من بين النماذج المستخدمة في هذه الدراسة، مع أعلى معامل ارتباط (R) وكفاءة ناش-ستكليف (NSE) من جهة، وأقل متوسط خطأ جذر متوسط مربع (RMSE) ومتوسط خطأ مطلق (MAE) من جهة أخرى، لكل من سدي زيت إمبا والقنيطرة. يليه نموذج MLPNN وفي المركز الأخير نموذج SVR. بالإضافة إلى ذلك، من المهم الإشارة إلى أن كفاءة النماذج ترتبط ارتباطاً وثيقاً بعدد المتغيرات المستخدمة كمدخلات، ويتم الحصول على النموذج الأمثل دائماً من خلال تضمين المتغيرات الخمسة المختارة (VOL، COTE، EVAP، VID، APP).

وأخيراً، تثبت دقة خوارزميات التعلم الآلي الثلاث (MPLNN، SVM، RFR) أنها جميعاً أدوات فعالة لمحاكاة المياه المتغيرة من السدود، وبالتالي يمكن أن تساعد المهنيين في تخطيط إدارة احتياطات المياه التي تعبئها السدود الخزانية.

كلمات مفتاحية: خزان السدود، السقي، AEP، التعلم الآلي، RFR، SVR، MLPNN

Résumé

L'exploitation des barrages-réservoirs est une tâche essentielle pour les décideurs qui souhaitent optimiser l'utilisation des ressources en eau. Les méthodes classiques ne peuvent pas répondre adéquatement à l'ensemble des problématiques, qui doivent être considérées pour élaborer un modèle permettant de gérer au mieux les réserves d'eau mobilisées par les barrages. En effet, la prévision des volumes d'eau alloués à l'AEP et l'irrigation (VTAL) est stratégique pour une planification et une gestion efficace et efficiente des ressources en eau particulièrement pendant les épisodes de sécheresse.

Les modèles de Machine Learning (ML) sont de plus en plus utilisés pour les prévisions des variables d'exploitation des réservoirs. Dans cette étude, le perceptron multicouche (MPLNN), la forêt aléatoire de régression (RFR) et la régression à vecteurs de support (SVR), ont été sélectionnés pour la prévision du VTAL en utilisant une base de données, de huit variables d'exploitation au pas de temps journalier, recueillies sur huit ans (2009- 2017) au barrage de Zit Emba et Guenitra, situés au Nord-Est algérien. Sept combinaisons d'entrées ont été considérées et comparées pour trouver les meilleures variables d'entrée pour prédire le VTAL.

Les résultats numériques obtenus, révèlent qu'en phase de validation, le modèle RFR est considéré comme le meilleur modèle parmi ceux utilisés dans cette étude, avec un coefficient de corrélation (R) et un Nash-Sutcliffe (NSE) les plus élevés d'une part, et d'autre part la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne (MAE) les plus faibles, tant pour le barrage Zit Emba que pour le barrage Guenitra. Suivi par le modèle MLPNN et en dernière position le modèle SVR. En outre, il est important de signaler que l'efficacité des modèles est étroitement liée au nombre de variables utilisées en tant qu'entrées, et le modèle optimal est toujours obtenu en incluant les cinq variables sélectionnées (COTE, VOL, APP, VID, EVAP).

Enfin, la précision des trois algorithmes de ML (RFR, SVM et MPLNN) prouve qu'ils sont tous des outils efficaces pour simuler les VTAL à partir des barrages, et peuvent ainsi aider les professionnels dans la planification de la gestion des réserves d'eau mobilisées par les barrages réservoirs.

Mots – Clés: Barrage reservoir; Irrigation; AEP; Machine Learning; RFR; SVR; MLPNN.

Abstract

The operation of reservoir dams is an essential task for decision-makers wishing to optimise the use of water resources. Classical methods cannot adequately address all the issues that need to be considered in order to develop a model that can best manage the water reserves mobilised by dams. Indeed, forecasting the volumes of water allocated to drinking water supply (DWS) and irrigation (VTAL) is strategic for efficient and effective planning and management of water resources, particularly during drought episodes.

Machine Learning (ML) models are increasingly used for forecasting reservoir exploitation variables. In this study, Multilayer Perceptron (MPLNN), Random Forest Regression (RFR) and Support Vector Regression (SVR) were selected for VTAL forecasting using a database of eight daily time-step operating variables collected over eight years (2009-2017) at the Zit Emba and Guenitra dams, located in north-eastern Algeria. Seven input combinations were considered and compared to find the best input variables to predict the VTAL.

The numerical results obtained reveal that, in the validation phase, the RFR model is considered to be the best model among those used in this study, with the best correlation coefficient (R) and Nash-Sutcliffe efficiency (NSE), on the one hand, and the lowest root mean square error (RMSE) and mean absolute error (MAE), on the other, for both the Zit Emba and Guenitra dams. Followed by the MLPNN model and in last position the SVR model. In addition, it is important to point out that the efficiency of the models is closely linked to the number of variables used as inputs, and the optimal model is always obtained by including the five selected variables (COTE, VOL, APP, VID, and EVAP).

Finally, the accuracy of the three ML algorithms (RFR, SVM and MPLNN) proves that they are all effective tools for simulating VTAL from dams, and can thus help professionals in planning the management of water reserves mobilised by reservoir dams.

Keywords: Reservoir dam; Irrigation; DWS; Machine Learning; RFR; SVR; MLPNN.

LISTE DES TABLEAUX

Tableau 2.1. Les barrages Algériens de première génération	26
Tableau 2.2. Les barrages Algériens de seconde génération.....	26
Tableau 2.3. Caractéristiques morpho-métriques du bassin versant d’oued El Hammam.....	34
Tableau 2.4. Caractéristiques du barrage Zit Emba	36
Tableau 2.5. Caractéristiques morpho-métriques du bassin versant d’oued Fessa	39
Tableau 2.6. Caractéristiques du barrage Guenitra	40
Tableau 3.1. Exemple d’application sur la base de données du barrage Zit Emba.....	51
Tableau 3.2. Exemple d’application sur la base de données du barrage Guenitra.....	52
Tableau 3.3. Exemples d’erreurs de volumes	68
Tableau 3.4. Exemples sur l’établissement de la balance des volumes	69
Tableau 3.5. Exemples sur la correction de volume stocké	70
Tableau 3.6. Statistiques descriptives des séries de données sélectionnées.....	80
Tableau 4.1. Fonctions de noyau couramment utilisées.....	86
Tableau 5.1. Différentes combinaisons d’entrée utilisées dans la modélisation.....	99
Tableau 5.2. Structure des modèles utilisés durant la modélisation de VTAL	100
Tableau 5.3. Résultats obtenus par les modèles ML au niveau du barrage Zit Emba.....	103
Tableau 5.4. Résultats obtenus par les modèles ML au niveau du barrage Guenitra.....	105
Tableau 5.5. Comparaison des performances des modèles	107

LISTE DES FIGURES

Figure 1.1. Tranche de fonctionnement du réservoir	12
Figure 1.2. Variation des tranches de fonctionnement au cours de l'année.....	13
Figure 1.3. Stratégie à adopter en fonction de VOL et APP	14
Figure 1.4. Représentation graphique de la règle de gestion empirique	15
Figure 1.5. Discrétisation des réservoirs par Moran	19
Figure 2.1. Répartition des barrages en Algérie.....	30
Figure 2.2. Situation des barrages choisis pour l'étude.....	32
Figure 2.3. Localisation du barrage Zit-Emba	33
Figure 2.4. Réseau hydrographique du bassin versant d'oued El Hammam.....	35
Figure 2.5. Coupe en travers du barrage de Zit-Emba	36
Figure 2.6. Localisation du barrage Guenitra.....	37
Figure 2.7. Réseau hydrographique du bassin versant d'oued Fessa	38
Figure 2.8. Coupe en travers du barrage de Guenitra.....	40
Figure 3.1. Schéma théorique du bilan d'eau d'un barrage	44
Figure 3.2. L'échelle limnimétrique sur la tour de prise du barrage Zit-Emba.....	44
Figure 3.3. Bac d'évaporation (classe A) au niveau du barrage de Zit Emba.....	45
Figure 3.4. Piézomètre de fuite sur la digue du barrage de Zit Emba	46
Figure 3.5. Evacuateur des crues de Zit Emba	47
Figure 3.6. Présentation schématique des termes du bilan d'eau d'un barrage	50
Figure 3.7. Variation des VOL dans les barrages : (a) Zit Emba, (b) Guenitra	71
Figure 3.8. Variation des APP dans les barrages : (a) Zit Emba, (b) Guenitra	73
Figure 3.9. Variation des VTAL dans les barrages : (a) Zit Emba, (b) Guenitra.....	74
Figure 3.10. Variation des EVAP dans les barrages : (a) Zit Emba, (b) Guenitra.....	75
Figure 3.11. Variation de la PLU au niveau du barrage : (a) Zit Emba, (b) Guenitra	76
Figure 3.12. Variation des VID du barrage : (a) Zit Emba, (b) Guenitra.....	77

Figure 3.13. Variation des EVAC à travers le barrage : (a) Zit Emba, (b) Guenitra	78
Figure 4.1. Exemple d'un modèle de SVR	84
Figure 4.2. Architecture du modèle SVR	86
Figure 4.3. Architecture du modèle RFR	88
Figure 4.4. Architecture du modèle MLPNN.....	90
Figure 4.5. Différentes fonctions d'activation	91
Figure 4.6. Processus de validation croisée.....	92
Figure 5.1. Organigramme de modélisation du VTAL	98
Figure 5.2. Evolution du VTAL mesurée et calculée par les modèles de ML durant la phase de validation, Barrage Zit Emba	108
Figure 5.3. Evolution du VTAL mesurée et calculée par les modèles de ML durant la phase de validation, Barrage Guenitra	109
Figure 5.4. Scatterplots des valeurs mesurée et calculée du VTAL durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra.....	110
Figure 5.5. Diagrammes Box-plots du VTAL mesurée et calculée durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra	111
Figure 5.6. Diagrammes Violin du VTAL mesurée et calculée durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra	111
Figure 5.7. Diagramme Taylor du VTAL mesurée et calculée durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra	112

LISTE DES ABREVIATIONS

ABH : Agence de Bassin Hydrographique
AEA : Alimentation en Eau Agriculture
AEI : Alimentation en Eau Industrielle
AEP : Alimentation en Eau Potable
ANBT : Agence Nationale des Barrages et des Transferts
ANFIS: Adaptive Neuro Fuzzy Inference System
ANN: Artificial Neural Networks
ANRH : Agence Nationale des Ressources Hydriques
APP: Apport
BF: Basis Function
CART: Classification And Regression Trees
COTE : Niveau d'eau dans le réservoir du barrage
CV : Cross Validation
DL: Deep Learning
DP: Programmation Dynamique
DRE : Direction des Ressources en Eau
DT: Desision Tree
DWS: Drinking Water Supply
EQM: Erreurs Quadratique Moyenne
EVAC: Volumes Evacuee
EVAP: Evaporation
FUI : Fuites
GA: Algorithmes Génétiques
GB: Gradient Boosting
GP: Genetic Programming
IRR: Irrigation
LSTM: Long-Short Term Memory
ML: Machine Learning
MLPNN: Multilayer Perceptron Neural Network
Moy: Moyenne
MRE: Ministère des Ressources en Eau

MSE: Mean Square Error
NNR : Niveau Normale de la Retenue
NSE: Nash-Sutcliffe Efficiency
ONID : Office National de l'Irrigation et du Drainage
OOB: Out Of Bag
PLU: Pluie
PNE : Plan National de l'Eau
R: Coefficient de Corrélation
R²: Coefficient de Détermination
RBFNN: Radial Basis Function Neural Network
RMSE: Root Mean Square Error
RNA: Réseaux de Neurones Artificiels
RT: Regression Tree
SVM: Support Vector Machine
SVR: Support Vector Regression
VID : Volumes Vidangé
VOL : Volume Stocké
VTAL: Volume Total Alloué
XGBoost: Extreme Gradient Boosting

Table des matières

Dédicaces	I
Remerciements	II
الملخص	III
Résumé	IV
Abstract.....	V
Liste des tableaux	VI
Liste des figures	VII
Liste des abréviations	IX
Sommaire	XI
Introduction Générale	2

Chapitre 1 : Etat de l'art sur la gestion des barrages-réservoirs

1.1 Introduction.....	6
1.2 Les objectifs d'un barrage.....	6
1.2.1 Régulation des débits d'apports.....	6
1.2.2 Alimentation en eau potable	6
1.2.3 Desserte en eau d'irrigation.....	7
1.2.4 Autres objectifs.....	7
1.3 Type de gestion des barrages - réservoirs	7
1.3.1 La gestion tactique.....	7
1.3.2 La gestion stratégique.....	8
1.3.3 La gestion interannuelle.....	8
1.4 Eléments cruciaux dans la gestion de barrages.....	9
1.5 Caractéristiques de gestion des barrages réservoirs.....	10
1.5.1 Les incertitudes stratégiques.....	10
1.5.2 Les incertitudes physiques.....	10
1.5.3 Les incertitudes technologiques.....	10
1.6 Règles de gestion des barrages	10

1.6.1 Règles empiriques par courbes «objectif» de remplissage	12
1.6.2 Règles linéaires de gestion	13
1.6.3 Règles empiriques paramétrées de gestion	14
1.7 Contraintes de la gestion des barrages	15
1.7.1 Conflits dû à l'espace du réservoir	15
1.7.2 Les conflits entre les objectifs	16
1.7.3 Les conflits temporels au sein d'un même objectif	16
1.8 La modélisation des paramètres de gestion des barrages	17
1.8.1 Modèle déterministe de gestion d'un barrage.....	18
1.8.2 Modèle stochastique de gestion d'un barrage.....	18
1.8.3 Modèles d'intelligence artificielle.....	20
1.9 Conclusion	23

Chapitre 2 : Historique des barrages en Algérie et présentation de la zone d'étude

2.1 Introduction.....	25
2.2 L'évolution des barrages en Algérie.....	25
2.2.1 Les premières implantations de 1850 à 1962	25
2.2.2 La période entre 1962-1980.....	27
2.2.3 La relance hydraulique à partir des années 1980-2000	27
2.2.4 La poursuite du rythme de réalisation de 2001 à 2020	28
2.3 Choix des barrages pour la modélisation du volume total alloué	31
2.4 Présentation des barrages sélectionnés	32
2.4.1 Barrage Zit-Emba	32
2.4.1.1 Localisation du site	32
2.4.1.2 Objectifs du barrage	33
2.4.1.3 Description du bassin versant d'oued El Hammam	33
2.4.1.4 Description du barrage	35
2.4.2 Barrage de Guenitra	37
2.4.2.1 Localisation du site	37
2.4.2.2 Objectifs du barrage	37
2.4.2.3 Description du bassin versant d'Oued Fessa	38

2.4.2.4 Description du barrage	39
2.5 Conclusion	40

Chapitre 3 : Collecte, critique et traitement de données

3.1 Introduction.....	43
3.2 Description des bases de données	43
3.2.1 Paramètres mesurés.....	44
3.2.1.1 La côte du plan d'eau.....	44
3.2.1.2 La pluie	44
3.2.1.3 L'évaporation.....	45
3.2.1.4 Les fuites de l'ouvrage récupérables	45
3.2.1.5 Les lâchers	46
3.2.1.6 Les volumes d'eau déversés	46
3.2.2 Paramètres estimés.....	47
3.2.2.1 Le volume stocké dans le réservoir et la surface du plan d'eau	47
3.2.2.2 L'évaporation au niveau du barrage	47
3.2.2.3 L'apport d'eau entrant dans le réservoir	48
3.2.3 Etablissement du bilan hydrique.....	48
3.3 Critique et traitement de données.....	67
3.3.1 Critique de données.....	67
3.3.2 Traitement de données	68
3.4 Sélection des séries de données à modéliser	70
3.4.1 Analyse de données d'exploitation	70
3.4.1.1 Les volumes stockés dans les barrages.....	71
3.4.1.2 Les apports entrant dans les barrages	72
3.4.1.3 Les volumes totaux alloués à l'AEP et l'irrigation.....	74
3.4.1.4 Les volumes évaporés.....	75
3.4.1.5 La pluie	76
3.4.1.6 Les volumes des vidanges	77
3.4.1.7 Les volumes évacués	78

3.4.2 Choix des séries de données à modéliser	78
3.4.3 Statistique des séries de données sélectionnées	79
3.5 Conclusion	80

Chapitre 4 : Matériels et méthodes

4.1 Introduction	82
4.2 Choix des modèles de Machine Learning.....	82
4.3 Présentation des modèles de Machine Learning utilisés.....	83
4.3.1 SVR	83
4.3.2 RFR.....	86
4.3.3 MLPNN	88
4.4 Technique de validation croisée.....	91
4.5 Critères de validation et de performances des modèles.....	93
4.5.1 Critères statistiques.....	93
4.5.2 Critères graphiques	94
4.6 Logiciels utilisés	95
4.7 Conclusion	95

Chapitre 5 : Modélisation des volumes totaux alloués par les barrages

5.1 Introduction	97
5.2 Développement des modèles.....	97
5.2.1 Stratégie de développement du meilleur modèle	97
5.2.2 Identification des combinaisons des variables d'entrée.....	98
5.2.3 Partitionnement des données	99
5.2.4 Structures des modèles.....	100
5.2.5 Paramétrage des modèles	101
5.3 Résultats de la modélisation	101
5.3.1 Influence des variables sur les performances des modèles.....	102
5.3.2 Résultats de la modélisation du VTAL par le Barrage Zit Emba	102
5.3.3 Résultats de la modélisation du VTAL par le Barrage Guenitra	104
5.3.4 Comparaison de performances des meilleurs modèles	105

5.4 Discussion	112
5.5 Conclusion	115
Conclusion générale.....	116
Références bibliographiques	119

Introduction Générale

Introduction Générale

Les barrages-réservoirs sont l'une des structures d'ingénierie les plus importantes, utilisées pour répondre à diverses fins tels que l'alimentation en eau potable, l'approvisionnement en eau industrielle et agricole, le contrôle des inondations, la production de l'énergie électrique, l'assainissement écologique et la navigation, et sont appelés réservoirs à usages multiples.

Ces dernières années, les sécheresses dans les zones arides et semi-arides se sont intensifiées, la satisfaction des besoins en eau est devenue de plus en plus difficile, ainsi les problèmes sociaux se sont accrus. A cet effet, pour atténuer la pénurie d'eau et répartir équitablement les ressources en eau disponibles entre les différents utilisateurs de l'eau au fil du temps, beaucoup de barrages qui étaient auparavant gérés de façon autonome ont été interconnectés. Ceci a augmenté la difficulté d'établir les consignes de gestion de ces derniers.

En outre, compte tenu de la complexité des paramètres d'entrée et de sortie du réservoir, de leur comportement non linéaire, des divers objectifs concurrents, des caractéristiques dynamiques et des incertitudes des paramètres hydrologiques tels que les apports, la pluie et l'évaporation, et des paramètres opérationnels tels que les niveaux d'eau dans les barrages, les volumes d'eau stockés, les volumes d'eau libérés et les volumes d'eau déchargés, ainsi que les volumes d'eau alloués, la gestion et l'exploitation de ces structures nécessitent une approche réaliste et intelligente. La complexité de la gestion de ces installations découle également, de la prise en compte par les exploitants de deux objectifs contradictoires qui sont ; la sécurisation de l'approvisionnement en eau des différents utilisateurs et la rentabilité de ces ouvrages.

Pour répondre à ces impératifs les gestionnaires des barrages-réservoirs ont toujours recherché des outils d'aide à la décision plus efficaces et plus précis. Toutefois, la gestion des volumes d'eau retenus par les barrages constitue un souci permanent aux chercheurs, qui se sont focalisé, en grande partie, sur l'amélioration des performances du système de mobilisation de la ressource en eau de surface.

Par ailleurs, les modèles utilisés pour la gestion des barrages réservoirs sont particulièrement basées sur l'équation de continuité. La capacité de stockage du barrage, l'apport d'eau, les pertes dans le réservoir et les volumes alloués sont les principaux paramètres de cette équation. En effet, la prévision des volumes d'eau alloués est stratégique

pour la planification et la gestion des ressources en eau ainsi que pour l'exploitation des barrages-réservoirs et particulièrement pendant les épisodes de sécheresse. Ainsi, la modélisation de la quantité journalière allouée aux différents utilisateurs d'eau (domestiques, agricoles et industriels) est essentielle pour planifier et gérer efficacement l'eau mobilisée par les barrages, en particulier pendant les périodes de sécheresse.

Les responsables du secteur de l'eau en Algérie évoquent de gros efforts pour répondre à l'augmentation de la demande, qui a quadruplé au cours des 40 dernières années.

En effet, l'Algérie compte actuellement 80 barrages d'une capacité totale de 7.6 milliards de m³ (MRE, 2022).

Toutefois, la gestion des volumes mobilisés par ces barrages ne repose pas sur des modèles, mais sur des décisions prises par une ou plusieurs personnes en fonction des volumes d'eau stockés.

Au cours des deux dernières décennies, de nombreux modèles ont été développés pour aider les gestionnaires à gérer les barrages. Ils peuvent être divisés en deux catégories : La première a étudié les paramètres hydrologiques tels que les apports et l'évaporation, tandis que la seconde s'est intéressée à quelques paramètres de gestion des barrages tels que les niveaux et les volumes d'eau stockés dans les barrages.

Cependant, les volumes d'eau alloués à l'alimentation en eau potable et à l'irrigation n'ont pas été suffisamment étudiés.

Le principal objectif de cette étude de recherche, est d'améliorer la gestion des barrages-réservoirs en Algérie par l'élaboration d'un modèle de gestion par l'intelligence artificielle. Ainsi, à partir des données historiques des paramètres d'exploitation des barrages-réservoirs, nous développerons des modèles de prévision des volumes d'eau à fournir pour l'approvisionnement en eau potable (AEP), en eau industrielle (AEI) et en eau agricole (AEA) en utilisant, le machine Learning et en déduire ceux les plus compétitifs qui serviront par la suite pour aider l'exploitant à élaborer des stratégies de gestion performante.

Cette thèse est structurée en cinq chapitres distincts.

Le premier chapitre, examine les différentes méthodes de gestion des barrages-réservoirs, en détaillant les techniques traditionnelles et modernes utilisées dans ce domaine.

Le deuxième chapitre aborde l'évolution de la construction des barrages en Algérie et le cadre de l'étude, mettant en lumière la répartition des barrages dans le pays et fournissant une description générale des deux barrages étudiés : le barrage Zit Emba et le barrage Guenitra, ainsi que leur état actuel d'exploitation

Le chapitre trois expose les données collectées auprès de l'opérateur du barrage, en décrivant minutieusement les étapes de leur acquisition. Ces bases de données, comprenant huit variables observées sur une période de 17 ans, ont été soumises à une critique et à un processus de correction.

Le quatrième chapitre se concentre sur les principes fondamentaux de la théorie des trois modèles de Machine Learning utilisés pour prédire les volumes totaux à allouer, incluant la technique de validation croisée.

Enfin, le cinquième chapitre, partie la plus importante du travail, est dédié à la présentation des résultats de modélisation des volumes totaux à allouer obtenus à l'aide des modèles de Machine Learning (RFR, MLPNN et SVR), suivie d'une comparaison de leurs performances.

Chapitre 1 : Etat de l'art sur la gestion des barrages-réservoirs

Chapitre 1 : Etat de l'art sur la gestion des barrages-réservoirs

1.1 Introduction

Les objectifs justifiant la construction d'un barrage peuvent être nombreux et variés. Ces différents objectifs peuvent, généralement, être regroupés en deux fonctions principales : réduire les impacts d'une inondation en aval et atténuer les conséquences d'une saison sèche sur les volumes d'eau (Dewals et al., 2011).

La gestion de ces infrastructures est une opération complexe qui doit prendre en compte un large éventail de facteurs et de contraintes, qu'ils soient techniques, économiques, sociaux, environnementaux ou même politiques. La gestion des volumes mobilisés par les barrages est un domaine vaste qui fait appel à plusieurs disciplines, dont la modélisation.

Le chapitre présent propose une revue générale de l'état de l'art en matière de gestion des barrages-réservoirs. Dans ce contexte, il expose les principaux objectifs de la construction des barrages-réservoirs, les règles de gestion associées, ainsi que les approches et les diverses techniques de modélisation qui ont été appliquées par le passé. Il donne un aperçu général de l'état de l'art en matière de gestion des barrages-réservoirs. Dans ce contexte, les principaux objectifs de la construction, les règles de gestion associées, les approches et ainsi que les approches et les diverses techniques de modélisation, qui ont été appliquées dans le passé sont présentés.

1.2 Les objectifs d'un barrage

Les barrages réservoirs ont été construits à travers le monde entier pour jouer un rôle important dans le développement de nombreuses régions du monde (WCD, 2000), les principaux objectifs des barrages sont :

1.2.1 Régulation des débits d'apports

Sous un climat de type méditerranéen, à fortes irrégularités, les barrages peuvent avoir un rôle de laminage des crues et inversement, de soutien d'étiage, l'objectif « *valorisation de l'eau* » devient alors secondaire, mais présent.

1.2.2 Alimentation en eau potable

C'est la demande la plus importante à partir d'un barrage réservoir, elle est considérée la plus prioritaire par rapport aux autres demandes ; elle est définie comme la somme des volumes à

mobiliser pour satisfaire les différents besoins en eau potable tel que l'alimentation en eau potable domestique et industrielle.

1.2.3 Desserte en eau d'irrigation

En Algérie, comme ailleurs, les apports pluviométriques ne correspondent pas aux besoins hydriques des plantes pour la plupart des années, l'essentiel des apports provient des pluies dites Automne/Hiver. Les apports au printemps sont non négligeables. En été, on peut considérer les apports au barrage et la réserve du sol comme quasi nuls malgré certains apports d'orage. Le barrage peut alors réguler la distribution d'eau en fonction des demandes. Généralement, avec de l'expérience, les agriculteurs essaient de fournir une quantité d'eau proche des besoins agronomiques. Ceci se vérifie surtout lors des périodes sensibles au déficit hydrique qui sont variables selon les plantes, par exemple ; le début de croissance végétative et la floraison sont les phases les plus sensibles pour les cultures annuelles.

1.2.4 Autres objectifs

On peut citer à titre indicatif et non exhaustif ; la production d'énergie électrique, le maintien d'un niveau écologique minimum, plans d'eau à vocation touristique ...etc. Ils sont tout aussi importants mais hors de notre cadre d'étude.

1.3 Type de gestion des barrages - réservoirs

La gestion efficace des barrages - réservoirs a été un sujet d'intérêt pour les chercheurs au cours des dernières décennies ([Gagne et al., 2015](#) ; [Allawi et al., 2019](#) ; [Bozorg Haddad et al., 2018](#)). Il s'agit d'un problème complexe à résoudre en raison des objectifs multiples et conflictuels des barrages – réservoirs ([Ehteram et al., 2017](#)), d'un modèle fortement non linéaire, discret et discontinu, d'un grand nombre de variables en jeu avec des degrés de sensibilité plus ou moins importants, et d'un horizon temporel de prévision court ([Valizadeh et El-Shafe, 2013](#)). La gestion des barrages-réservoirs est divisée en trois types :

1.3.1 La gestion tactique

La gestion tactique est la gestion à court terme du barrage, est un processus complexe visant à garantir un approvisionnement en eau fiable et durable, à minimiser les risques d'inondation, à optimiser la production hydroélectrique et à assurer la sécurité. Les gestionnaires de barrages utilisent diverses stratégies pour atteindre ces objectifs ([Ehteram et al., 2017](#)). En période de fortes pluies ou de fonte rapide de la neige, ils peuvent réduire les lâches pour éviter les inondations en aval. Pendant les sécheresses, la gestion tactique vise à

conserver l'eau dans le réservoir. De plus, elle peut optimiser la production d'énergie en ajustant les débits d'eau en fonction de la demande d'électricité et des fluctuations des prix de l'énergie sur le marché. Certains aspects, comme le maintien de l'écologie des rivières et la réponse aux urgences, sont également pris en compte. Les gestionnaires doivent être capables de prendre des décisions éclairées en temps réel en surveillant attentivement les conditions météorologiques, les niveaux d'eau et les besoins des utilisateurs finaux. Cela garantit la sécurité des personnes et des biens, ainsi qu'un approvisionnement en eau fiable pour les générations futures.

1.3.2 La gestion stratégique

La gestion stratégique est la gestion à long terme du barrage, elle a pour but de garantir une utilisation efficace et sécurisée des ressources hydriques tout en minimisant les risques associés à ces infrastructures (Wang et al., 2021).

Plusieurs éléments clés influent sur cette gestion stratégique. En premier lieu, la planification revêt une importance cruciale, impliquant une définition précise des objectifs de gestion tels que l'approvisionnement en eau pour l'irrigation ou la génération d'électricité. Ensuite, une évaluation des risques permet d'identifier les menaces potentielles telles que les crues ou les séismes (Ahn et Sheng, 2021), suivie de la mise en œuvre de mesures d'atténuation des risques. La surveillance continue des barrages est indispensable pour repérer les problèmes émergents, tandis qu'un programme de maintenance régulier assure leur bon fonctionnement (Chun et al., 2006). La gestion des débits d'eau est également cruciale pour répondre aux besoins des utilisateurs et prévenir les inondations (Chu et al., 2020), de même que la gestion des sédiments pour maintenir la performance des barrages (Charles, 2009 ; Hera et al., 2014 ; Wang et al., 2010). Une planification d'urgence est également essentielle pour faire face à des situations de crise. Par ailleurs, l'intégration de technologies telles que les systèmes d'information géographique et la modélisation hydraulique, joue un rôle déterminant dans l'amélioration de la gestion des barrages (Khayyun, et al., 2019). Enfin, l'engagement des parties prenantes, incluant les autorités locales et les communautés riveraines, est nécessaire pour une gestion efficace et équilibrée des barrages.

1.3.3 La gestion interannuelle

La gestion interannuelle des barrages consiste à gérer les réserves d'eau mobilisées sur plusieurs années. Elle s'efforce de planifier et d'optimiser l'utilisation de l'eau stockée dans les barrages (Mohamed, 2017), en tenant compte des variations saisonnières et interannuelles

des précipitations (Amnatsan et al., 2018), des débits de cours d'eau, et des besoins en eau pour différentes utilisations.

Les éléments clés de la gestion interannuelle des barrages incluent la planification à long terme pour assurer une utilisation durable de l'eau, la gestion des précipitations et des débits en fonction des besoins, l'utilisation des prévisions météorologiques pour orienter les décisions, l'équilibrage des besoins entre les différents usages de l'eau, l'optimisation des réserves pour faire face aux périodes de déficit, l'adaptation aux changements climatiques (Kim et al., 2019), l'évaluation des risques liés aux crues et aux sécheresses, ainsi que la collaboration avec les parties prenantes (Nazir et al., 2019).

En résumé, cette approche vise à garantir la durabilité de l'approvisionnement en eau sur plusieurs années, en tenant compte des facteurs environnementaux et climatiques.

1.4 Eléments cruciaux dans la gestion de barrages

Selon James et Lee (1971), les six points suivants doivent être résolus de façon optimale tout en développant une politique d'exploitation d'un réservoir :

- 1. Utilisation du volume de stockage pour la régulation des crue (Flood Storage) :** la question qui se pose est le maintien des volumes apportés par les crues ou bien de les lâcher afin de fournir un volume de stockage supplémentaire en cas de nouvelles pluies produisant des apports encore plus conséquents ;
- 2. Utilisation du stockage total :** Faut-il remplir le volume de stockage pour garantir l'approvisionnement en eau, pour une utilisation bénéfique, ou le vider pour éviter les crues potentielles ?
- 3. Lâchers d'eau stockée :** Doit-on allouer de l'eau stockée dans le réservoir à la disposition de la consommation ou la conserver pour pallier à d'éventuelles futures sécheresses ?
- 4. Lâchers par réservoir :** Combien de volume d'eau doit être lâché à partir de chaque réservoir pour une utilisation bénéfique de l'eau ?
- 5. Utilisation de l'eau disponible :** Quelle est la fraction d'eau prélevée à partir du réservoir à allouer à chaque usager ou objectif ?
- 6. Provenance du prélèvement des lâchers :** Doit-on capter l'eau à partir de la surface, ou à partir d'une certaine profondeur dans le réservoir ?

1.5 Caractéristiques de gestion des barrages réservoirs

Les grands objectifs de fonctionnement des barrages réservoirs vont permettre de définir la gestion d'un système. Il est donc important de bien connaître les réactions du système à son environnement afin de déterminer ses particularités. En effet, dans les pays arides et semi-arides, les gestionnaires et les agriculteurs doivent faire face à la conjonction de la rareté et de l'irrégularité de la ressource, ainsi qu'à la disjonction entre la période des apports en eau et celle où les besoins en eau se déclarent.

Dans la gestion des réserves d'eau, il existe de nombreuses incertitudes. Nous les classons en trois grands types (Lebdi, 1996) :

1.5.1 Les incertitudes stratégiques

Elles interviennent lors de la discussion sur l'opportunité d'un aménagement et par suite d'un investissement. Il arrive que nous soyons incapables de prédire les objectifs futurs de l'ouvrage hydraulique et d'élaborer une planification correcte qui prend en compte de cette vision dynamique de définition des objectifs.

1.5.2 Les incertitudes physiques

Les phénomènes hydrologiques varient dans le temps et dans l'espace. Pour cerner l'incertitude due à la variabilité des paramètres hydrologiques nous utilisons les outils statistiques dans les modèles mathématiques de gestion de l'eau.

1.5.3 Les incertitudes technologiques

A la méconnaissance des processus physiques (Relation entre la pluie et le débit qui ruisselle vers le barrage, évaluation correcte des besoins en eau, fonction de production reliant la quantité d'eau fournie à la plante et son rendement....etc.) et économiques (Comportement de l'agriculteur face au marché, choix de cultures moins consommatrices en eau et plus rémunératrices,.....etc.), s'ajoute la nature de l'information moins disponible (information incomplète et limitée dans le temps, entachée d'erreurs. . . etc.).

1.6 Règles de gestion des barrages

La procédure de "décision" est l'opération qui permet, pour des conditions hydrologiques et économiques fixées, de choisir un lâcher. Ce choix est fait parmi un ensemble de solutions alternatives, résultant d'une déduction d'informations et de faits (Wan et al, 2011).

Bohanec (2001) décrit la prise de décision comme un processus global qui commence par l'évaluation du problème, la collecte d'informations, l'identification de solutions de remplacement, la prévision des conséquences, et enfin l'action et l'évaluation des décisions. Les principales activités dans ce processus incluent l'identification du problème, la recherche d'informations, l'analyse du problème, l'évaluation des solutions, et enfin la décision. L'information, la connaissance, et l'expérience jouent un rôle crucial dans la prise de décision. L'information et la connaissance requises pour la prise de décision peuvent dépasser les capacités cognitives du décideur. Selon les travaux de Zack (2007), les défis majeurs pour les décideurs liés à l'utilisation de l'information et de la connaissance comprennent l'incertitude, la complexité, l'ambiguïté et l'équivocité.

L'incertitude résulte souvent d'un manque d'information, ce qui est un facteur majeur dans la prise de décision. La complexité émerge en raison d'une surcharge d'information, ce qui complique le traitement et l'interprétation de l'information. Le manque de connaissance peut entraîner l'ambiguïté, rendant difficile l'interprétation des informations. En revanche, un excès de connaissance peut créer de l'équivocité en raison de contradictions.

Dans la pratique, les gestionnaires doivent suivre des règles de gestion bien définies pour prendre des décisions appropriées en fonction de l'état du système. Ces règles de gestion sont basées sur une analyse séquentielle détaillée de diverses combinaisons critiques de conditions hydrologiques et de besoins en eau. Elles indiquent les niveaux d'eau dans le barrage et les lâchers pour différentes périodes de l'année, y compris les politiques opérationnelles.

Young (1967) a introduit la première méthode pour obtenir des règles d'exploitation générales à partir d'une optimisation déterministe. François (2013) mentionne que les règles de gestion peuvent se traduire par l'utilisation de courbes guides, qui varient en fonction des problèmes de gestion spécifiques.

Les courbes guides représentent le niveau de stockage prévu dans un réservoir en fonction de diverses conditions probabilistes d'apports et de demandes, pour différentes périodes de l'année. Elles visent à optimiser la satisfaction des objectifs du réservoir en maintenant le stockage spécifié par les courbes de règle à différentes périodes de l'année.

Il convient de noter que, malgré ces avancées, de nombreux systèmes de réservoirs continuent d'être exploités sur la base de courbes de règle fixes, comme l'a observé Yeh (1985).

Ces règles sont habituellement présentées sous forme de graphiques ou de tables et guident les lâchers du barrage selon le niveau courant de stockage, des conditions

hydrométéorologiques et de la période de l'année. Les exploiters, cependant, appliquent également le jugement personnel pour décider de la valeur à atteindre, cette dernière devient ainsi subjective.

Le travail réalisé par Parent (1991) expose des différentes étapes nécessaires à l'élaboration des consignes de gestion des barrages : de la discussion indispensable avec le gestionnaire pour déterminer ce que serait une bonne gestion à l'optimisation possible de cette gestion, en passant par la création des modèles hydrologique et hydraulique.

D'après Parent (1991), on distingue trois catégories de règles :

1.6.1 Règles empiriques par courbes «objectif» de remplissage

Cette méthode permet au gestionnaire de calculer, à chaque instant spécifique, les quantités de stock requises pour satisfaire les besoins à un niveau de satisfaction prédéfini. Une surveillance constante des niveaux d'eau dans le réservoir et les cours d'eau sera mise en place pour prendre des décisions en fonction de la situation actuelle.

L'ensemble de l'espace de stockage du réservoir peut être conceptuellement divisé en un certain nombre de zones en dessinant des plans horizontaux imaginaires à des altitudes différentes. La taille de ces zones n'est pas forcément constante et peut varier avec le temps (figure 1.1).




Figure 1.1. Tranche de fonctionnement du réservoir

La figure 1.1, montre les différentes zones contenants dans un barrage :

La Tranche de fonctionnement normal où se situe l'état idéal du réservoir et qui permet une marge due aux aléas hydrologiques.

La Tranche d'écrêtement qui permet de faire face à des crues. Au-delà de cette zone, il y a débordement.

La Tranche d'étiage où il faut réduire le plus sévèrement possible les lâchers.

La Tranche inactive, située sous le niveau de la prise d'eau. Cette partie délimite le volume mort destiné à accueillir les dépôts liquides tout au long de la durée de vie ou de fonctionnement du barrage.

L'épaisseur de la tranche de fonctionnement fluctue au cours de l'année, ce qui permet de modéliser des effets tampons plus faibles en périodes critiques (**figure 1.2**).

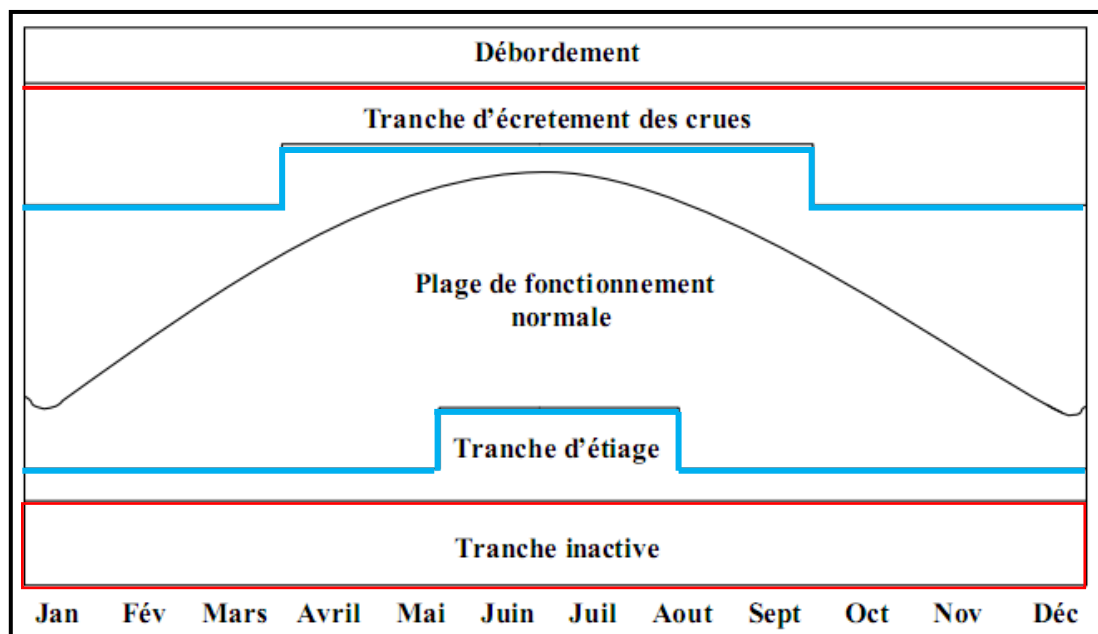


Figure 1.2. Variation des tranches de fonctionnement au cours de l'année

1.6.2 Règles linéaires de gestion

C'est une stratégie de gestion qui consiste à choisir la fonction linéaire pour modéliser un lâcher fonction linéaire du stock dans le réservoir (VOL) et des apports (APP) :

$$L(t) = a + b \times VOL_{(t)} + c \times APP_{(t)} \quad (1.1)$$

Où **a**, **b** et **c** représentent des constantes périodiques dans le cas de réservoir unique ou des matrices périodiques dans le cas d'un système multi-varié.

On peut déterminer sa stratégie en fonction de la position à l'instant (t) dans le plan (VOL, APP) (**figure 1.3**).

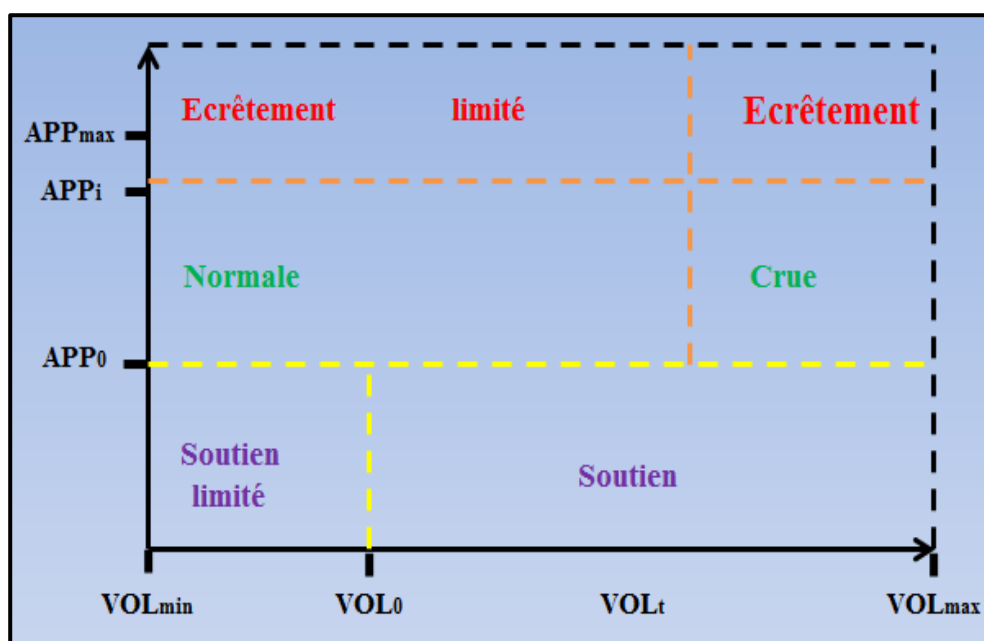


Figure 1.3. Stratégie à adopter en fonction de VOL et APP

Stratégie normale : on cherche alors à rejoindre le stock objectif en un faible nombre de pas de temps.

Stratégie d'écrêtement : l'apport est très élevé. On décide que $L_{(t)} = APP_1 =$ lâcher normal.

Stratégie d'écrêtement limité : l'apport est très élevé mais le stock est déjà grand, il faut alors trouver un compromis entre l'écrêtement et le lâcher maximal :

$$L(t) = a \times APP_t + (1 - a) \times APP_{\max} \quad (1.2)$$

Où : APP_{\max} correspondant aux potentialités de lâcher maximale de la retenue.

Stratégie de crue : on cherche un compromis entre rejoindre le stock objectif en un faible nombre de pas de temps et une stratégie d'écrêtement.

Stratégie de soutien : l'apport est faible mais le stock est suffisant. On décide que $L_{(t)} = APP$

Stratégie de soutien limité : l'apport et le stock sont faibles. On décide alors d'un compromis entre une politique de soutien et une politique de restriction afin de retarder le moment où l'on arrivera à VOL_{\min} en espérant qu'il y ait des apports futurs.

1.6.3 Règles empiriques paramétrées de gestion

Selon [Lebdi et al. \(1997\)](#), c'est la règle qui traduit le comportement du gestionnaire de la ressource avec la logique suivante :

1. Quand le niveau de stock est faible, le gestionnaire sera prudent pour augmenter ou diminuer l'allocation d'eau, selon un schéma par exemple linéaire.

2. Pour un stock d'eau variant dans les limites moyennes, le gestionnaire restera encore prudent en apportant un pourcentage de la satisfaction en eau, espérant des apports futurs.
3. Pour les stocks d'eau approchant la capacité maximale du barrage, le gestionnaire tend vers une satisfaction totale de la demande avec un souci d'écrêtement de crues. Le schéma est supposé linéaire (**figure 1.4**).




Figure 1.4. Représentation graphique de la règle de gestion empirique

Les paramètres de gestion (pente des droites et seuils de la figure ci-dessus) sont déterminés par simulation et/ou reconstitution historique. Ils peuvent être estimés pour différents scénarios (ex : années humides, sèches).

1.7 Contraintes de la gestion des barrages

L'exploitation d'un réservoir à objectifs multiples peut créer un certain nombre de conflits entre les demandes. Les conflits qui surviennent lors de l'exploitation d'un réservoir à objectif multiples peuvent être classés comme suit :

1.7.1 Conflits dû à l'espace du réservoir

Ces conflits se produisent quand un réservoir (de stockage limité) est destiné à satisfaire des objectifs variés, par exemple la conservation de l'eau et la régulation des inondations. Si les caractéristiques géologiques et topographiques du site du barrage ainsi que les fonds financiers du projet sont disponibles, alors un barrage d'une hauteur suffisante peut être construit et un volume de stockage peut être clairement attribué pour chaque objectif.

La satisfaction des objectifs de conservation exige un remplissage maximal du réservoir, alors que l'objectif de régulation des inondations exige un remplissage minimal du réservoir par la mise à disposition d'un certain volume. Par conséquent, l'exploitation d'un tel réservoir passe par la décision cruciale de remplir le réservoir ou de le garder vacant. Un réservoir plein permet de mieux répondre aux demandes consommatrices d'eau, en accomplissant des objectifs de conservation, mais en même temps, il y a un risque plus élevé de dommages dû aux inondations. D'autre part, un réservoir vide peut réguler les inondations de manière plus efficace, mais si les flux d'apport ne sont pas aux prévisions souhaitées, le réservoir peut rester vacant et par conséquent les objectifs de conservation risquent d'en pâtir.

1.7.2 Les conflits entre les objectifs

Des conflits peuvent aussi surgir pour les objectifs de conservation, lorsque le motif de l'utilisation de l'eau est différent et que le volume d'eau requis par un objectif peut nuire aux autres demandes. Par exemple, les demandes d'irrigation peuvent présenter un modèle de variation, en fonction des cultures, de la saison et des précipitations, tandis que la demande d'énergie hydroélectrique peut avoir une variation différente. L'eau nécessaire à des fins de consommation comme l'irrigation, l'approvisionnement en eau potable (AEP), ne peut être partagée avec d'autres usagers qu'après complète satisfaction de ces dernières. Les conflits pour les débits journaliers sont également monnaie courante pour un réservoir à objectifs multiple. Si un réservoir a pour objectif la consommation et la production d'énergie hydroélectrique, les lâchers pour les deux objectifs peuvent varier considérablement en l'espace d'une journée. De même, les avantages de l'utilisation d'un réservoir pour les loisirs récréatifs sont importants pendant l'été, mais les demandes d'irrigation peuvent aussi être les plus élevées pendant cette période nécessitant un prélèvement supplémentaire au niveau du réservoir.

1.7.3 Les conflits temporels au sein d'un même objectif

Un déficit d'eau peut être réparti de différentes façons dans le temps. Une décision typique est de savoir si l'offre doit être restreinte à un moment donné pour diminuer le déficit pour une période plus longue dans l'avenir ou de reporter au plus tard les restrictions, ce qui accroît le risque de pénurie dans un temps plus court. L'impact de ces deux décisions sera différent dans différentes situations et dépendra également de l'utilisation de l'eau, à savoir ; irrigation, AEP et ainsi de suite. Dans un système multi-réservoir, le décideur doit aussi allouer des lâchers ainsi qu'entreprendre des restrictions entre les réservoirs. Évidemment, les

utilisations courantes de l'eau ne sont pas compatibles les unes avec les autres. La politique de coopération doit guider l'opérateur dans la résolution de ces conflits de façon satisfaisante. On peut souligner ici que le mot clé dans la régulation d'un réservoir multi-objectif est le « compromis ».

1.8 La modélisation des paramètres de gestion des barrages

La gestion traditionnelle des barrages réservoirs est basée sur des courbes régulatrices, qui sont des programmes prédéterminés de lâchers et d'apports d'eau. Toutefois, ces courbes sont souvent basées sur des données historiques et ne tiennent pas compte des conditions actuelles ou des scénarios futurs, ce qui peut entraîner une performance sous-optimale et des dommages potentiels au barrage réservoir.

La modélisation pour la gestion des barrages réservoirs est une approche qui consiste à utiliser des modèles mathématiques, pour représenter le fonctionnement du système de gestion de l'eau (Gragne et al., 2015). Ces modèles permettent de simuler les différents scénarios possibles et d'évaluer les conséquences des décisions de gestion.

La gestion rationnelle d'un système peut être supportée par des outils d'aide à la décision. Le système peut alors être représenté d'un pas de temps à un autre. Selon deux évolutions : l'évolution déterministe, utilise des données d'entrées connues a priori tandis que l'évolution stochastique, utilise des données d'entrées définies par un aléa. La réalité hydrologique impose toujours une évolution stochastique du système.

En outre, la formulation d'un modèle, se définit par :

1. Les états du système, correspondant aux niveaux d'eau dans le réservoir, au niveau de l'apport, de l'évaporation et des pertes dans le réservoir.
2. Les commandes, sont des variables sur lesquelles le gestionnaire peut agir, comme les lâchers.
3. La fonction d'évolution du système qui dépend du temps en plus des deux paramètres précédents :

$$\mathbf{APP} = \mathbf{VOL}(t) + \mathbf{APP}(t) - \mathbf{EVAP}(t) - \mathbf{L}(t) - \mathbf{EVAC}(t) \quad (1.3)$$

Avec :

VOL(t) : Volume du réservoir à l'instant t ;

L (t) : lâcher à l'instant t ;

APP (t) : Apport au réservoir à l'instant t ;

EVAC (t) : déverse à l'instant t.

EVAP(t) : Évaporation du réservoir à l'instant t ;

Remarque :

1. Cette fonction d'évolution peut être plus complète en ajoutant d'autres termes telles que les infiltrations, les écoulements inféroflux . . . etc.
2. On qualifie le système de dynamique car on étudie ses états sur des pas de temps successifs.
3. Les contraintes du système. Elles peuvent être d'ordre physique (capacités de transfert et de stockage limitées) ou d'ordre institutionnel (seuil minimum dans les pays arides et semi-aride pour garantir un niveau écologique).

1.8.1 Modèle déterministe de gestion d'un barrage

Par définition, toutes les variables d'entrée pour chaque pas de temps APP (t) et EVAP (t) sont connues dans le cas d'un modèle déterministe. Alors, les différents niveaux d'eau ne dépendent que des décisions de lâchers. Compte tenu des problèmes de conditions aux limites (réservoir vide et déversement). Il est difficile de définir analytiquement la fonction décrivant l'évolution du système (Howard, 1969). Il faut donc trouver les relations entre la fonction d'évolution et ses contraintes pour pouvoir ensuite estimer chaque état du système.

Ainsi, la fonction d'évolution est vraie si les conditions aux limites sont respectées.

La fonction objective n'intervient qu'après l'évolution du système pour juger de la pertinence de la décision de lâcheur. Cette fonction doit exprimer la qualité du résultat par rapport aux objectifs. Par exemple, pour illustrer la satisfaction de la demande en eau elle pourra s'écrire comme le rapport de la fourniture sur la demande.

1.8.2 Modèle stochastique de gestion d'un barrage

Dans ce cas, les apports ne sont plus connus pour chaque pas de temps. Pour une décision de lâcher, la fonction d'évolution donnera plusieurs résultats possibles selon l'apport considéré (**figure 1.5**). La probabilité d'avoir le volume d'eau (VOL) à (t+1) est égal à la probabilité conditionnelle d'avoir l'apport APP(t) sachant que la fonction donnant l'évolution du système est réalisable. Ainsi, pour un niveau initial, le système évoluera vers au plus « n » états finaux : « n » étant le nombre d'apports possibles.

Il est donc nécessaire que l'ensemble des apports soit discrétisé en un nombre fini de valeurs. En parallèle, le réservoir est aussi discrétisé, ce qui permet d'envisager des lâchers d'eau par unités de discrétisation.

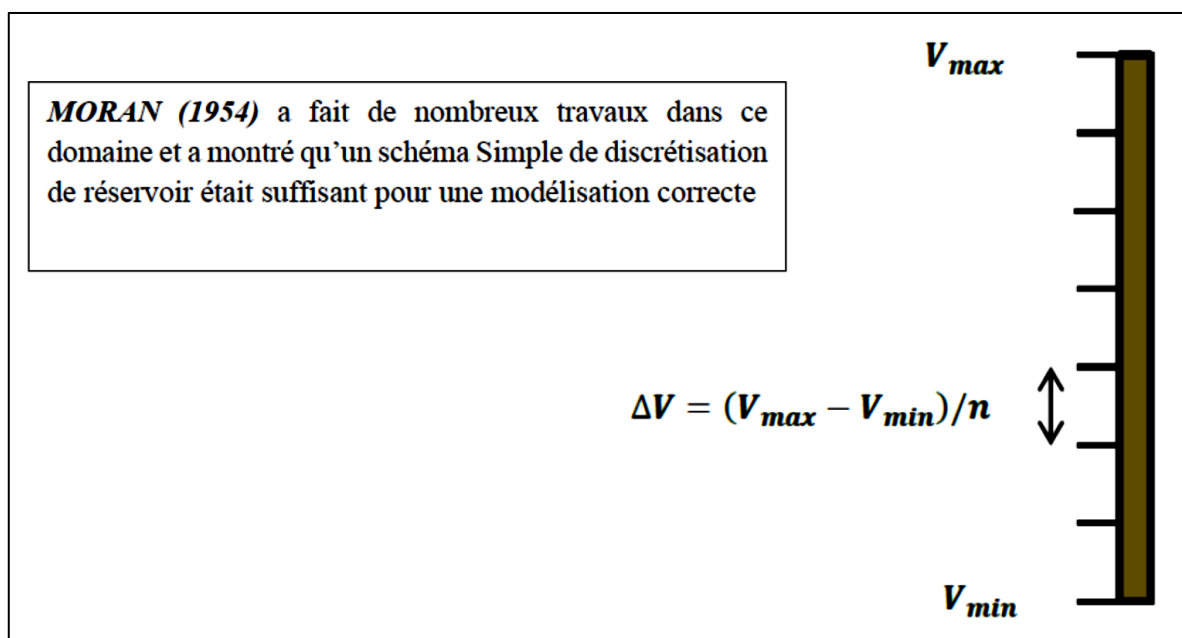


Figure 1.5. Discrétisation des réservoirs par Moran

Le problème est donc de déterminer les apports potentiels à chaque pas de temps. Il se présente alors deux cas possibles :

1. **Les apports sont indépendants les uns des autres** : dans ce cas, il est possible de trouver une variable aléatoire permettant de déterminer la probabilité d'apparition d'un apport. On raisonne alors d'après l'espérance mathématique de l'apport et non plus uniquement d'après l'apport. Cette loi de probabilité permet de définir une loi de probabilité sur l'état du système à l'instant (t +1). Si la série hydrologique est longue, on peut approcher à priori la probabilité d'occurrence de l'apport par sa probabilité empirique ;
2. **Les apports ne sont pas indépendants** : Les aléas dépendent alors de l'historique du processus. Il faut donc connaître l'évolution du niveau n entre 1 et t et des apports entre 1 et (t-1).

[Savarenskiy \(1940\)](#) a assimilé le problème d'apports-réservoir-lâchers à une file d'attente. Le réservoir est un guichet où la distribution des apports peut être approchée du taux d'arrivée, tandis que la répartition des lâchers peut être assimilée au taux de clients – afin d'assimiler le réservoir à un système MARITOVIEEN.

Le concept de la chaîne de Markov permet d'estimer la probabilité d'obtenir certains apports à (t+1) à partir de la fonction de distribution de probabilité qui dépend uniquement de la valeur d'apport à t. En d'autres termes, si on connaît l'histoire du système jusqu'à l'instant

actuel, son état présent résume toute l'information utile pour connaître son comportement futur.

$$\text{Prob}\{\text{APP}(t)/\text{APP}(t-1), \dots, \text{APP}(0)\} = \text{prob}\{\text{APP}(t)/\text{APP}(t-1)\} \quad (1.4)$$

Le lien d'un pas de temps à un autre est exprimé par la matrice de transition contenant toutes les informations concernant l'évolution du système (stocks, lâcheurs, apports). La probabilité pour que les apports à (t+1) soient $\text{APP}_j(t+1)$ sachant que les apports à (t) étaient $\text{APP}_i(t)$, est :

$$\text{APP}_j(t+1) = \text{APP}_i(t) \times P_{i,j} \quad (1.5)$$

Avec : $P_{i,j}$ probabilité de transition d'un apport APP_i , à un apport APP_j .

$$\sum_{j=1}^N P_{i,j} = 1 \quad (1.6)$$

Avec : $0 \leq P_{i,j} \leq 1$

1.8.3 Modèles d'intelligence artificielle

Au cours des dernières décennies, les modèles d'intelligence artificielle (IA) ont été admis comme un outil alternatif pour la modélisation des variables qualitatives et quantitatives des ressources en eau (Tabari et al., 2010a ; Tabari et al., 2011 ; Heddami et al., 2011 ; Marofi et al., 2011 ; Talaei et al., 2011). Quant au développement des règles d'exploitation des barrages, les réseaux de neurones artificiels (RNA) sont utilisés comme une alternative pour surmonter les difficultés liées à l'analyse par régression linéaire ou non linéaire. Ainsi, la plupart des problèmes traités avec les méthodes d'analyse par régression ont été résolus par les modèles RNA qui ont prouvé qu'ils représentent une meilleure alternative (Rossi et al., 1999).

Les modèles d'IA peuvent aider à prédire les niveaux d'eau, les débits d'eau et les risques de crues (Ismail et al., 2012), tout en offrant des opportunités de prise de décision en temps réel pour les gestionnaires des barrages.

L'approche de l'IA également été utilisée par (Babaei et al., 2019), pour fournir des informations précieuses sur les débits d'entrée dans les réservoirs qui aident les planificateurs à gérer et à allouer des ressources en eau optimales. Les valeurs optimales de la libération de l'eau du réservoir sont déterminées par différents paramètres, à savoir le débit entrant dans le réservoir, l'efficacité de l'exploitation des réservoirs et les demandes en aval (Gragne et al., 2015 ; Liu et al., 2015a ; Wu et al., 2020 ; Mohamadi et al., 2020 ; Ghorbani et al., 2017).

Les réseaux de neurones artificiels ont également été utilisés pour le développement des règles d'exploitation d'un barrage réservoir (Cancelliere et al., 2002 ; Li & Huang, 2013) et la gestion de systèmes à plusieurs barrages réservoirs (Chandramouli et Raman., 2001).

Plus récemment, les algorithmes de machine Learning (ML) ont été largement utilisés dans le domaine de la gestion des barrages pour prédire le débit des cours d'eau, les niveaux d'eau des réservoirs, les règles de fonctionnement et l'ordonnancement (Yang et al., 2020). Effectivement, l'utilisation de ML permet de développer des modèles plus robustes et précis pour la gestion des volumes d'eau stockés dans les barrages, ce qui peut répondre aux différentes demandes en eau et à gérer ainsi les limitations de la quantité d'eau, qu'elle soit excédentaire ou déficitaire (Seckin et al., 2013 ; Mokhtar et al., 2014). Pour cela une variété d'algorithmes de ML a été appliqués pour analyser les méga-données et les systèmes à grande échelle, en particulier pour la modélisation hydrologique et la gestion des ressources en eau (Wee et al., 2021 ; Uneş et al., 2019; Meng et al., 2018).

Les techniques d'apprentissage automatique ont été appliquées avec succès dans de nombreuses domaines hydrologiques (Le et al., 2019 ; Xiang et al., 2020 ; Kratzert et al., 2018 ; Rjeily et al., 2017 ; Guzman et al., 2017 ; Lee et Tuan Resdi, 2016 ; Sattari et al., 2012 ; Ghorbani et al., 2019 ; Emami et Parsa, 2020 ; Sammen et al., 2017)

Parmi les nombreux algorithmes d'apprentissage automatique, les forêts aléatoires (RFR), la machine à vecteurs de support (SVM) et les réseaux de neurones artificiels (ANN) sont trois des algorithmes les plus largement utilisés dans le domaine de la gestion des ressources en eau, afin d'améliorer la cohérence et la précision des modèles d'estimation à différentes échelles temporelles (Naghbi et Pourghasemi, 2015 ; Ahmadlou et al., 2019 ; Lee et al., 2020 ; Wee et al., 2021). En effet, plusieurs travaux de recherche ont exploré profondément la modélisation des paramètres hydrologiques ainsi que quelques paramètres de gestion des barrages. Néanmoins les volumes totaux alloués n'ont pas été suffisamment étudiés. Ainsi les modèles ML ont aidé à prédire les niveaux d'eau dans les barrages, les apports d'eau et l'évaporation en s'appuyant sur des données pertinentes plutôt que de simuler les processus hydrologiques impliqués (Allawi et al., 2019 a et b ; Hadiyan et al., 2020) et les risques d'inondation (Ke et al., 2020), tout en offrant des opportunités de prise de décision en temps réel pour les gestionnaires des barrages. Cela a permis aux gestionnaires de planifier et d'ajuster leurs activités en fonction des conditions actuelles, améliorant ainsi l'efficacité et la durabilité de la gestion des barrages. Les modèles ML ont également fourni des informations précieuses pour l'identification et la résolution des problèmes (Noori et al., 2010), permettant une gestion proactive des barrages plutôt qu'une réaction tardive aux problèmes émergents

[Bozorg Haddad et al. \(2018\)](#) ont utilisé les algorithmes génétiques (GA), les ANN, les SVM et la programmation dynamique (DP) pour établir les politiques de gestion optimales du barrage réservoir Karoon 3 en Iran, et ils ont constaté que les résultats du SVM étaient meilleurs que ceux des ANN. Dans une perspective, [Zhang et al., 2018](#) ont étudié trois modèles ML, à savoir le réseau de neurones à rétropropagation (BP), la technique de régression par vecteur de support (SVR) et le modèle de mémoire à long terme (LSTM), pour simuler le fonctionnement du réservoir à différentes échelles de temps (mensuelles, quotidiennes et horaires), en utilisant environ 30 ans d'enregistrements historiques d'exploitation du réservoir de Gezhouba en Chine. Les résultats ont montré que BP et SVR étaient bien adaptés pour apprendre les règles de fonctionnement du réservoir à partir d'un petit ensemble de données, tandis que le modèle LSTM a démontré une bonne capacité à simuler les faibles débits ainsi que la courbe de sortie pour la période de pointe de fonctionnement. Dans d'autres recherches, [Allawi et al. \(2019c\)](#) ont examiné la fiabilité et l'efficacité des modèles ANN et SVR pour prédire l'évaporation du réservoir. Deux scénarios différents pour les variables d'entrée ont été proposés pour vérifier l'applicabilité des modèles prédictifs. Les indices statistiques ont montré que les prédictions obtenues par le modèle ANN sont plus précises que celles fournies par le modèle SVR. Dans l'étude de [Zhang et al. \(2020\)](#), trois modèles différents axés sur les données, notamment ANN, les systèmes adaptatifs d'inférence neuro-floue (ANFIS) et SVM, ont été utilisés pour prévoir les apports des réservoirs. Plusieurs paramètres climatiques ont été utilisés comme variables d'entrée pour les modèles prédictifs. Les résultats ont indiqué que l'ensemble d'intrants est la principale source d'incertitude, la contribution du modèle axé sur les données est limitée et présente une forte variation saisonnière. De leur part, [Latif et al. \(2021\)](#) ont développé un modèle ANN avec fonction de base radiale (RBFNN) en utilisant comme entrée les apports, les volumes d'eau stockés par le barrage (initiaux et finaux), les volumes d'eau libérés par le réservoir, pour prédire les pertes d'eau du réservoir. Toutes les données recueillies sur 11 ans (1997-2007) d'exploitation du barrage de Klang Gate ont été utilisées pour développer et valider les résultats du modèle. Les résultats montrent que le modèle proposé peut fournir une prévision mensuelle avec une erreur quadratique moyenne maximale de ± 20.07 %. L'avantage de ce modèle ANN est qu'il fournit des informations sur la perte d'eau, le stock final et les changements de niveau d'eau pour un meilleur fonctionnement du réservoir. En outre, [Chiamsathit et al. \(2016\)](#) ont utilisés un modèle de type perceptron multicouche (MLPNN) pour prévoir l'apport du barrage d'Ubol-Ratana situé en Thaïlande. Ils ont examiné l'influence du niveau de précision des prévisions sur l'exploitation du réservoir. Le MLPNN a

été développé sur la base de différentes variables d'entrée. En général, le modèle proposé s'est avéré adéquat pour la prévision des débits entrants dans les réservoirs. Afin d'améliorer et éclairer les décisions à prendre pour quant à la prélibération de l'eau avant qu'une inondation ne se produise au moyen d'une méthode de prévision de l'apport des réservoirs (Zarei et al., 2021) ont appliqué des modèles de décalage temporel sur 1 et 2 mois avec plusieurs modèles ML, à savoir : SVM, ANN, arbre de régression (RT) et Genetic Programming (GP). Sur les données des réservoirs de Dez, Karkheh et Gotvand situés en Iran lors de l'inondation de 2019. Les résultats montrent que SVM et RT, présentent la meilleure précision de prévision des inondations que les autres algorithmes. En comparant, la capacité prédictive de RT et de SVM, pour simuler les débits d'eau sortant du réservoir de Bhakra en utilisant différentes combinaisons de données hydrologiques mesurées sur environ 30 ans, Kaushik et Awasthi, (2023) ont démontré que la SVM quadratique, pour un K-fold égale à 10 et sept paramètres d'entrée, peut être considéré comme le meilleur modèle.

1.9 Conclusion

La quantité optimale à allouer aux consommateurs peuvent être déduite soit à partir des courbes règles issues des modèles de simulation ou à partir des modèles de modélisation axés sur différentes techniques d'optimisation développées dans la recherche opérationnelle. Il est essentiel de souligner que la modélisation des lâchers occupe une place cruciale dans notre étude. À cet effet, nous maintenons l'utilisation de la technique de machine Learning pour résoudre le problème inhérent à la gestion des barrages. Cette approche se distingue par sa capacité à calculer les solutions optimales exactes (notamment les lâchers optimaux), permettant ainsi de déduire le modèle de gestion le plus adapté à la mobilisation des ressources du barrage.

Chapitre 2 : Historique des barrages en Algérie et présentation de la zone d'étude

Chapitre 2 : Historique des barrages en Algérie et présentation de la zone d'étude

2.1 Introduction

Au cours des dernières décennies, la demande en eau en Algérie a augmenté de manière significative en raison de divers facteurs tels que la croissance démographique, l'expansion des terres irriguées, le développement de l'industrie et du tourisme. Cette augmentation a entraîné une diminution notable du volume d'eau disponible par habitant, incitant ainsi les autorités locales à accroître la construction de barrages pour augmenter la disponibilité des ressources en eau, qui sont naturellement limitées, et pour faire face à l'irrégularité élevée des précipitations, tant saisonnières qu'interannuelles.

Dans cette optique, la première partie de ce chapitre se penchera sur l'évolution chronologique de la construction des barrages en Algérie, depuis la période coloniale jusqu'à l'année 2020. Dans la seconde partie, nous donnerons une description détaillée des deux barrages choisis dans cette étude, mettant en évidence leurs caractéristiques, leurs fonctions et leur importance dans le contexte hydraulique algérien.

2.2 L'évolution des barrages en Algérie

2.2.1 Les premières implantations de 1850 à 1962

Le début de la construction des barrages en Algérie remonte au 19^e siècle, marqué par la réalisation de quelques ouvrages de taille modeste dans la partie occidentale du pays. Il est important de noter que cette initiative ne s'est pas étendue à l'Est algérien à cette époque. Les premiers barrages érigés dans cette région datent du milieu du 20^e siècle, avec la mise en place de Foum El Gueiss (Khenchela) en 1939, suivi du K'sob (M'sila) en 1940 et du Zardezas (Skikda) en 1945. Toutefois, en raison des limitations des techniques de construction de l'époque, certains de ces barrages ont rapidement cédé face aux crues des oueds, tandis que d'autres ont été reconstruits à plusieurs reprises, tels que Cheurfas, Tlelat et Fergoug. Trois raisons principales, peuvent expliquer ces difficultés ([Boutouatou, 2020](#) ; [Touati, 2010](#)) :

1. La technologie des barrages n'était pas encore pleinement maîtrisée ;
2. La connaissance du régime des cours d'eau était lacunaire ;

3. Les moyens techniques déployés pour la construction de ces barrages étaient souvent insuffisants, ce qui a entraîné des retards significatifs sur les chantiers. À titre d'exemple, la construction du barrage de Djidiouia (0.7 hm³) s'est étendue sur vingt ans (1857-1877), tandis que celle du barrage de Hamiz (14 hm³) a nécessité 25 ans (**tableau 2.1**).

Tableau 2.1. Les barrages Algériens de première génération

Nom	Oued	Année de construction	Volume initial (hm³)
Meurad	Djabroun	1852-1859	0.8
Tlelat	Tlelat	1860	-
Tlelat	Tlelat	1869-1870	0,7
Fergoug	Habra	1865-71 puis 1882	30
Cheurfas	Sig	1880-1882	3
Cheurfas	Sig	1886-1892	18
Djidiouia	Djidiouia	1857-1877	0.7
Hamiz	Hamiz	1869-1894	14

(Perennes, 1979)

Entre 1932 et 1948, neuf (9) barrages ont été construits, comme indiqué dans le **tableau 2.2**. Ces ouvrages présentent des capacités variées, majoritairement de grande et moyenne envergure, à l'exception du barrage de Foug El Gueiss qui est de petite taille. De plus, durant cette période, les barrages de première génération Hamiz et Cheurfas ont été surélevés.

Tableau 2.2. Les barrages algériens de seconde génération

Nom	Oued	Année de mise en service	Volume initial (hm³)
Fodda	Fodda	1932	228
Boughzoul	Chelif	1934	55
Bakhadda	Mina	1936	56
Ghrib	Chelif	1939	280
Foug El Gueiss	Gueiss	1939	3.4
K'sob	K'sob	1940	12.4
Zardezas	Saf-saf	1946	14.9
Beni bahbel	Tafna	1946	63
Bouhanifia	Hammam	1948	73

(Perennes, 1993)

Le volume qu'ils régularisaient s'élevait à peine à 910 hm³ et se concentraient principalement à l'ouest du pays. Afin que l'est de l'Algérie puisse bénéficier de quelques infrastructures (Ksob, Zardezas, Foug El Gueiss, Foug El Gherza, Cheffia), de taille relativement modeste, à l'exception du barrage Cheffia qui n'a été achevé qu'après l'indépendance en 1965 et dont la capacité est plutôt importante (168 hm³).

2.2.2 La période entre 1962-1980

La situation héritée a persisté jusqu'au début des années 1980, et l'Algérie indépendante a ainsi, d'une certaine manière, perpétué la politique coloniale. Entre 1962 et 1980, au cours des vingt premières années, seuls trois nouveaux barrages ont été érigés à savoir : Cheffia en 1965, Djorf Torba en 1969, Sidi Mohamed Ben Aouda en 1970. Néanmoins, ces constructions ont contribué à augmenter la capacité de stockage de 910 à 1 660 hm³. Pendant cette période, l'héritage de l'époque coloniale a connu une diminution constante. L'envasement à lui seul entraînait une perte annuelle de 2 à 3 % de la capacité utile de ces barrages. Afin de préserver ce potentiel, il a été nécessaire soit de surélever la structure (Zardezas en 1974, Ksob en 1977), soit de procéder à leur dévasement, une opération extrêmement coûteuse qui immobilise également le barrage pendant les travaux, causant des préjudices aux utilisateurs. Enfin, dans certains cas, la reconstruction totale des barrages a été entreprise, notamment pour les ouvrages de Fergoug et Cheurfas.

2.2.3 La relance hydraulique à partir des années 1980-2000

Dès le début des années 1980, l'Algérie s'est engagée dans un ambitieux programme pour rattraper son retard hydraulique. Dix (10) barrages d'une capacité cumulée de 1585 hm³ furent mis en eau entre 1981 et 2000, leur capacité variant de 40 à 200 hm³.

Le barrage Guenitra, construit sur l'oued Fessa (un affluent de l'oued Guebli), a été officiellement inauguré le 14 octobre 1984 sa capacité est de 125 hm³. Son objectif principal était de renforcer l'approvisionnement en eau de la ville de Skikda, qui connaissait une urbanisation croissante et abritait un important pôle pétrochimique. De plus, il devait également permettre l'irrigation de la zone de Safsaf, qui s'étend sur une superficie de 5654 hectares. En 1985, le barrage Ain Zada a été mis en eau sur l'oued Bousselam (un affluent situé à l'est de l'oued Soummam). Sa capacité était de 125 hm³ et un volume régularisé de 50 hm³. Bien qu'il ait été initialement construit pour l'irrigation, il a finalement été utilisé pour l'approvisionnement en eau potable des agglomérations de Bord-Bou-Arréridj, Bougaa, El Eulma et Sétif. L'année suivante, en 1987, le barrage de Hammam Grouz a été achevé sur le haut Rhumel. Par la suite, en décembre de la même année, le barrage Hammam Debagh a été mis en service sur l'oued Bouhamdane (un affluent de la Seybouse). Il avait une capacité de 200 hm³ et un volume régularisé de 55 hm³ par an. Ce barrage a permis la création d'une zone irriguée dans la vallée de Guelma Bouchegouf, qui s'étend sur 13 000 hectares. À partir de 1993, une partie de l'eau régularisée par cet ouvrage a été utilisée pour l'approvisionnement en eau potable des petits centres proches du barrage ainsi que de l'agglomération de Guelma. En

1987, le barrage d'Ain Dalia a été mis en eau sur l'oued Medjerda, avec une capacité de 82 hm³ et un volume régularisé de 45 hm³/an. Ce volume est utilisé pour l'alimentation en eau potable et industrielle de la région de Souk-Ahras, ainsi que pour les transferts vers Ouenza et El Aouinet (ANBT, 2014). Le petit barrage de Béni Zid, d'une capacité de 40 hm³, a été construit sur l'oued Guergoura, à environ vingt kilomètres de la ville de Collo, en juin 1993 pour stocker les eaux de l'oued Béni Zid sous-affluent d'oued Rekane, afin de répondre aux besoins en eau de la région de Collo et d'irriguer le périmètre de Béni Zid. Le barrage Foum El Khanga, situé à vingt kilomètres de Sedrata et à quinze kilomètres de la confluence de l'oued Cherf avec l'oued Nil, a été construit sur l'oued Cherf (un affluent de la Seybouse) et a été réceptionné en novembre 1995. En 1990, les travaux de construction du barrage Babar sur l'oued Arab (capacité : 41 hm³, volume régularisé : 12 hm³/an) ont été entrepris. Les eaux captées par ce barrage sont principalement destinées à l'irrigation des terres en aval du barrage, ainsi qu'à l'approvisionnement en eau potable. Le barrage de Mexa, construit sur l'oued Kébir-Est, a été réceptionné au cours de l'année 1998. Enfin, le barrage Fontaines des Gazelles, d'une capacité de 55.5 hm³ et d'un volume régularisé de 14 hm³/an, a été mis en eau au cours de l'année 2000 dans le but d'irriguer la plaine d'Outaya.

2.2.4 La poursuite du rythme de réalisation de 2001 à 2020

La poursuite du rythme de réalisation de barrages s'est traduite par la mise en service de 8 ouvrages dont le volume régularisé théorique s'élève à 982.7 hm³/an.

Le barrage de Zit Emba a été construit sur l'oued El Hammam et a une capacité de 120.00 hm³ avec un volume régularisé de 43,4 hm³ par an. Sa construction s'est déroulée de 1989 à la fin de l'année 2002, date à laquelle il a été mis en eau. En plus de son utilisation pour l'irrigation, ce barrage contribue également à renforcer l'approvisionnement en eau potable de la ville de Skikda. Le barrage El Agrem, situé sur l'oued du même nom dans les Côtiers de Jijel, a été inauguré en 2002. Il est principalement destiné à l'irrigation de 5 000 hectares de terres agricoles dans les plaines de Jijel-Taher, ainsi qu'à l'approvisionnement en eau potable de la ville de Jijel et des localités environnantes. Quant au barrage Koudiat Medouar, sa construction a débuté en 1995 sur l'oued El Reboa et sa mise en eau a été réalisée en 2003. Ce barrage a été conçu avec une capacité de stockage et de régularisation supérieure afin de recevoir les transferts en provenance du grand barrage de Beni Haroun (via le réservoir d'Oued Athmania). Il a pour objectif d'assurer l'approvisionnement en eau potable des villes des wilayas Batna et Khenchela, ainsi que l'irrigation des terres agricoles. En 2003, le plus grand barrage d'Algérie, Béni Haroun, a été achevé. Il a une capacité de 963 hm³ et

régularise un volume de 435 hm³ par an. Situé sur l'oued Kébir-Rhumel, à environ 40 km au Nord-Ouest de la ville de Constantine, il fait partie d'un vaste système de transfert hydraulique comprenant une immense station de pompage qui permet de refouler un débit de 21 m³/s sur une dénivelée de 700 m (Boulahbal et al, 2013). Cet ouvrage a un impact sur six wilayas de l'Est, à savoir Batna, Khenchela, Mila, Oum El Bouaghi, Constantine et Jijel. Le barrage Kissir, quant à lui, a été construit sur l'oued Kissir, dans la wilaya de Jijel, entre juin 2006 et octobre 2009 (date de mise en eau). Sa capacité est de 68 hm³ et il régularise un volume de 68 hm³/an. Il est destiné à l'alimentation en eau potable de la ville de Jijel et des localités avoisinantes, ainsi qu'à l'irrigation des plaines côtières. Le barrage Tichy Haf, construit sur l'aval de l'oued Boussellam, a été achevé en 2007. Il a une capacité de régulation de 150 hm³/an et s'inscrit dans la planification des ressources en eau du bassin hydrographique la Soummam (approvisionnement en eau potable des agglomérations situées le long du couloir Akbou-Béjaia, irrigation du périmètre du Sahel et de la basse Soummam, ainsi que la prévention des inondations de l'oued Boussellam). Le barrage Boussiaba, situé à proximité de la ville d'El Milia, a été mis en eau à la fin de l'année 2010. Son objectif est d'utiliser les eaux de l'Oued Boussiaba pour répondre aux besoins en eau potable de la région d'El Milia et de transférer une partie de ces eaux vers le réservoir de Beni Haroun via une station de pompage installée près d'El Milia. Le barrage Bougous, quant à lui, a été réceptionné en 2010. Son bassin couvre une superficie de 235 km² et a une capacité utile de 65 hm³, permettant de réguler 49 hm³/an pour approvisionner en eau potable Mexa, le couloir El Tarf-Bouteldja-Annaba, ainsi que l'agglomération d'El Kala. L'irrigation de la vallée du Kébir-Est est un autre objectif majeur du système Mexa-Bougous.

La **figure 2.1** illustre l'implantation des projets de barrages abandonnés, les barrages en exploitation, les barrages livrés en 2015 et 2020 ainsi que ceux livrables à 2030.

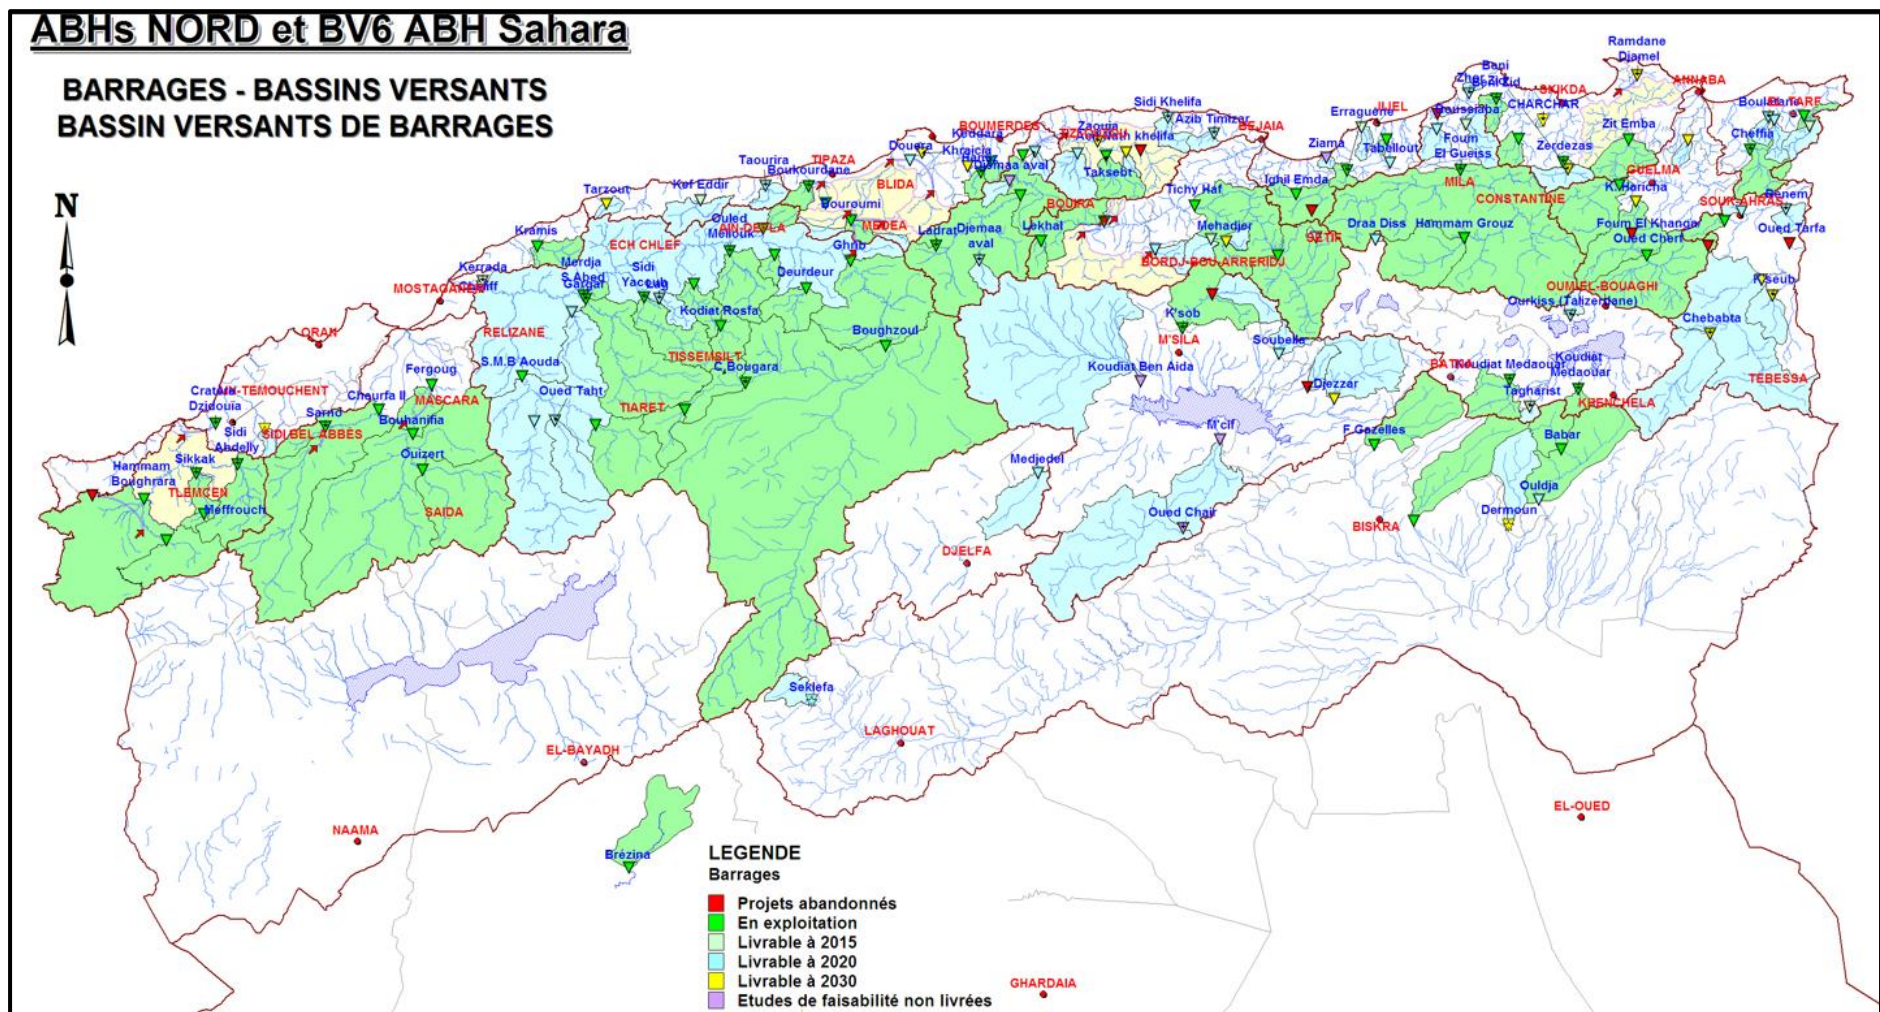


Figure 2.1. Répartition des barrages en Algérie (PNE, 2010)

2.3 Choix des barrages pour la modélisation du volume total alloué

Plusieurs facteurs essentiels influencent la sélection des barrages à étudier pour la modélisation du volume total alloué. Parmi ceux-ci figurent l'approvisionnement en eau potable, assurant l'accès à une ressource vitale pour les habitants locaux, ainsi que l'irrigation des terres agricoles, garantissant la sécurité alimentaire étant donné que ces aspects représentent le volume total à modéliser.

Dans ce contexte, après avoir analysé les données de plusieurs barrages du Nord de l'Algérie récupérées auprès de l'ANBT, nous avons constaté que les barrages de Zit Emba et Guenitra, localisés dans la wilaya de Skikda au Nord-Est de l'Algérie (**figure 2.2**), se distinguent comme des choix privilégiés en raison de leur capacité à répondre aux besoins croissants en eau potable et en irrigation de la wilaya. De plus, ils jouent des rôles pratiquement similaires et disposent de bases de données exhaustives et de longue durée d'exploitation.

En effet, ces deux barrages desservent en eau potable les communes avoisinantes et renforcent l'AEP du chef-lieu de la wilaya, tout en permettant une irrigation intensive des terres agricoles environnantes, respectivement sur une superficie de 6500 ha et 5650 ha (presque identique). De plus, ils se situent dans les mêmes étages bioclimatiques, possèdent quasiment le même volume utile, à savoir respectivement 120 et 125 hm³, et sont exploités sur des périodes presque identiques, soit de 2004 à 2021 et de 2005 à 2020 respectivement, ce qui facilite la comparaison des résultats de la modélisation.

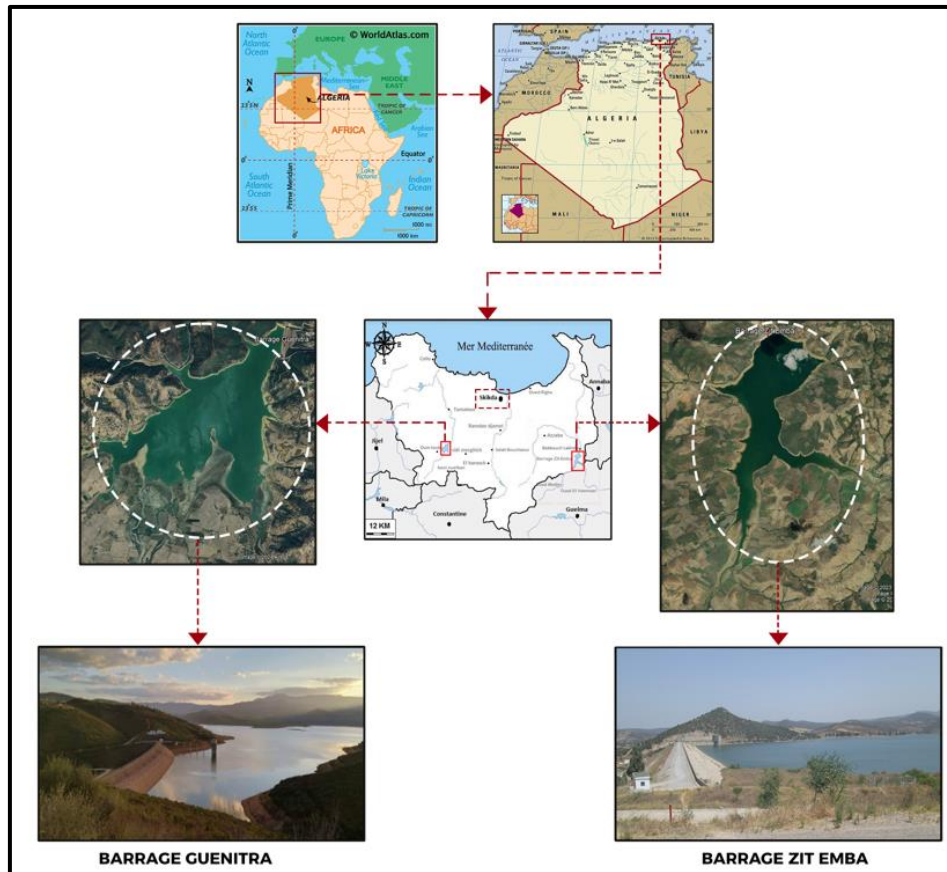


Figure 2.2. Situation des barrages choisis pour l'étude

2.4 Présentation des barrages sélectionnés

Cette section est dédiée à la présentation des deux barrages étudiés ainsi qu'à leur caractérisation.

2.4.1 Barrage Zit-Emba

2.4.1.1 Localisation du site

Le barrage Zit Emba est situé à deux kilomètres en amont de la localité de Bekkouche Lakhdar sur l'oued El-Hammam dans la wilaya de Skikda (**figure 2.3**), il est délimité : au Nord par la commune de Ben-Azzouz (wilaya de Skikda), au Sud par la commune de Berknia et Bouati-Mahmoud (wilaya de Guelma), à l'Est par la commune de Berrahal et Eulma (wilaya d'Annaba) et à l'Ouest par la commune d'Ain Charchar et Es-Sebt (wilaya de Skikda).

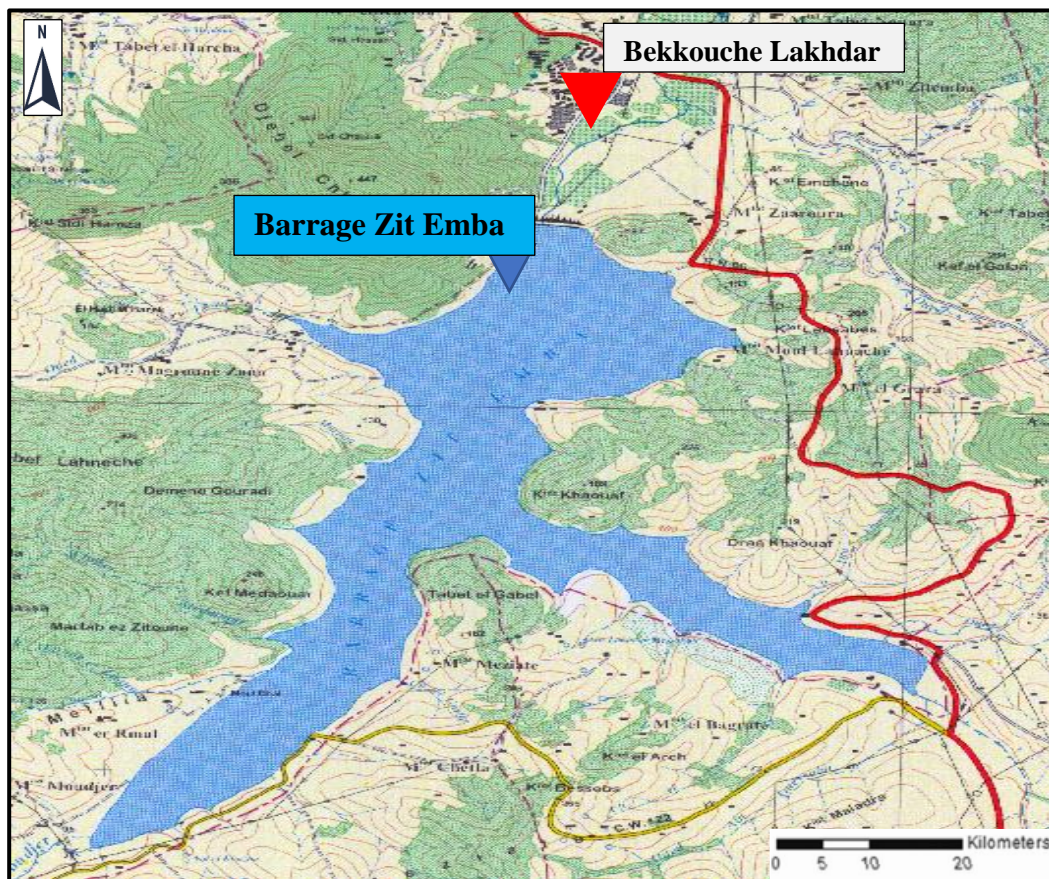


Figure 2.3. Localisation du barrage Zit-Emba

2.4.1.2 Objectifs du barrage

Les principaux objectifs du barrage sont :

- ◆ Assurer la régulation des débits sur plusieurs années ;
- ◆ Satisfaire les besoins d'approvisionnement en eau potable des communes : Azzaba, Djendel, Ain Cherchar, tout en renforçant l'AEP de la ville de Skikda, avec un débit global de 40 000 m³/jour.
- ◆ Garantir l'approvisionnement en eau pour l'irrigation des terres agricoles de Bekkouche Lakhdar et Ben-Azzouz, qui couvrent 6500 ha et nécessitent un volume annuel de 3.5 hm³, tout en facilitant l'irrigation des zones avoisinantes de l'oued El Kebir telles que Ben Azzouz, Marsa, Boumaiza et El Hamma, avec un volume total annuel de 6.0 hm³.

2.4.1.3 Description du bassin versant d'oued El Hammam

Le bassin versant du barrage Zit-Emba, qui s'étend sur une superficie de 485 km², est principalement drainé par l'oued El Hammam. L'oued prend sa source aux sources thermales d'Ouled Ali, situées sur le versant Nord tellien (ANRH, 2015). La superficie totale de ce bassin versant, qui présente une forme compacte et presque triangulaire, est scindée en deux

parties bien distinctes. Plus précisément, 2/5 de cette surface est drainée par l'Oued Hammam, tandis que les 3/5 restants sont acheminés par l'Oued Mouguer. La digue est située dans la wilaya de Skikda et la majorité des eaux sont stockées dans la wilaya de Guelma. Les altitudes varient de 1200 m en amont à 50 m sur le site de l'aménagement. Bien que la majeure partie du bassin (68%) se trouve entre les altitudes de 600 à 200 m, l'altitude moyenne du bassin est de 376 m. Les caractéristiques morpho-métriques du bassin versant Zit-Emba sont présentées dans le **tableau 2.3**.

Tableau 2.3. Caractéristiques morpho-métriques du bassin versant d'oued El Hammam

Paramètre	Symbole	Unité	Valeur
La Surface du bassin	S	km ²	485
Périmètre	P	km	107.6
Coefficient de compacité	Kc		1.2
Longueur du rectangle équivalent	Le	km	31.7
Longueur du Talweg	le	km	35.0
Densité de drainage	Dd	km/km ²	2.8
La pente de l'oued	I	%	0.0064
Altitude maximale	H max	m	1220
Altitude minimale	H min	m	50
Attitude moyenne	H moy	m	376
Indices de pente de Roche		%	0.17

(ANRH, 2015)

L'hydrographie du bassin versant est très dense avec un coefficient de densité de drainage de 2.8 Km/Km², principalement caractérisée par l'Oued EL-Hammam. Au départ orienté vers l'ouest en suivant l'anticlinal en altitude, il change ensuite de direction vers le nord pour rejoindre l'Oued Emchekel en aval de la digue du barrage Zit-Emba, près de la localité d'Ain Charchar, formant ainsi l'Oued Kebir. Les deux oueds suivent une direction nord-sud et le site du barrage se trouve à 5 km en amont du confluent de ces deux cours d'eau **(figure 2.4)**.

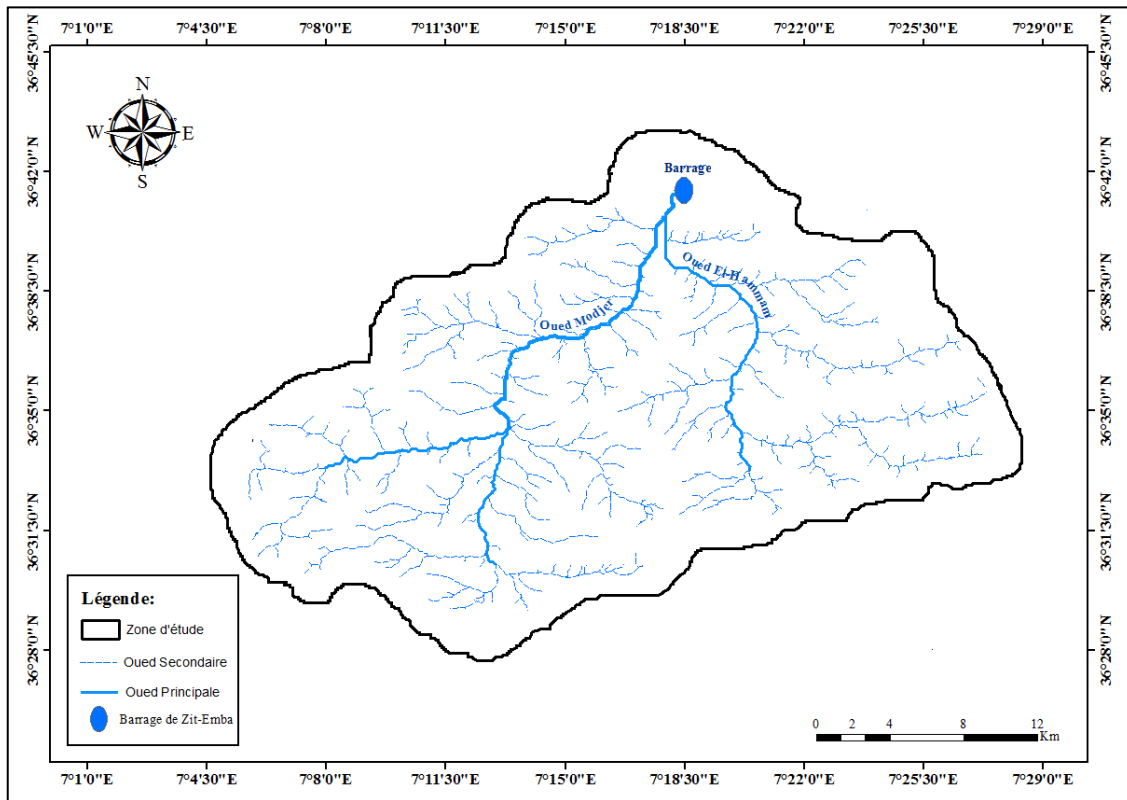


Figure 2.24. Réseau hydrographique du bassin versant d'oued El Hammam

De plus, le bassin d'Oued El Hammam se trouve dans une zone au climat subtropical, qui se distingue par un été chaud et sec ainsi qu'un hiver relativement doux et pluvieux. La température moyenne annuelle dans le bassin versant varie entre 17° et 18°C. Les précipitations dans la région étudiée sont réparties de manière inégale et atteignent une moyenne annuelle d'environ 700 mm, dont 80% sont enregistrés pendant la période la plus froide. Les vents dominants dans le bassin versant proviennent du nord et du sud, avec une moyenne maximale de 27 m/s et pouvant atteindre, dans certains cas, les 40 m/s. La vitesse la plus élevée est enregistrée en hiver, tandis que la plus faible est observée en été. Par ailleurs, la zone d'étude se caractérise par une végétation dense, principalement composée de forêts boisées, tandis que les vastes plaines sont occupées par l'arboriculture et les cultures maraîchères (telles que la culture de légumes) ainsi que des prairies.

2.4.1.4 Description du barrage

La digue du barrage Zit Emba, est en terre hétérogène. La hauteur au-dessus des fondations et le terrain naturel est respectivement de 52 m et 47.5 m. Le corps du barrage, est construit par deux principaux matériaux : les argiles et les galets graviers. Le niveau normal de la retenue (NNR) du barrage est de 86 m, ce qui correspond à un volume utile d'environ 120 millions de m³ et une superficie de la cuvette de 810 ha. Le niveau des plus hautes eaux

(PHE) correspondant à la cote de la retenue lors des crues exceptionnelles est de 91 m. La cote du niveau d'eau mort de la retenue est de 62 m ce qui correspond à un volume mort de 8.4 Millions m³ (figure 2.5). L'ensemble de l'ouvrage de la prise d'eau du barrage comprend les ouvrages suivants : Canal d'amenée ; La tour de prise ; Le tunnel ; L'ouvrage de raccordement avec la risberme et chambres de vannes. ; Canal de fuite (canal de restitution). La structure et les dimensions de l'ouvrage de prise d'eau permettent d'assurer la prise d'eau à partir de la retenue, la dérivation provisoire et la vidange et le lavage de la retenue.

Tableau 2.4. Caractéristiques du barrage Zit Emba

Type	Valeur
Hauteur	47 m
Longueur en crête	640 m
Largeur de la crête	10 m
Vidange de fond	68 m³/s
Capacité initiale	120.00 hm ³
Capacité au dernier levé topo-bathymétrique (2003)	116.59 hm³
Envasement moyen annuel	0.24 hm ³ /an

(ANBT, 2010)

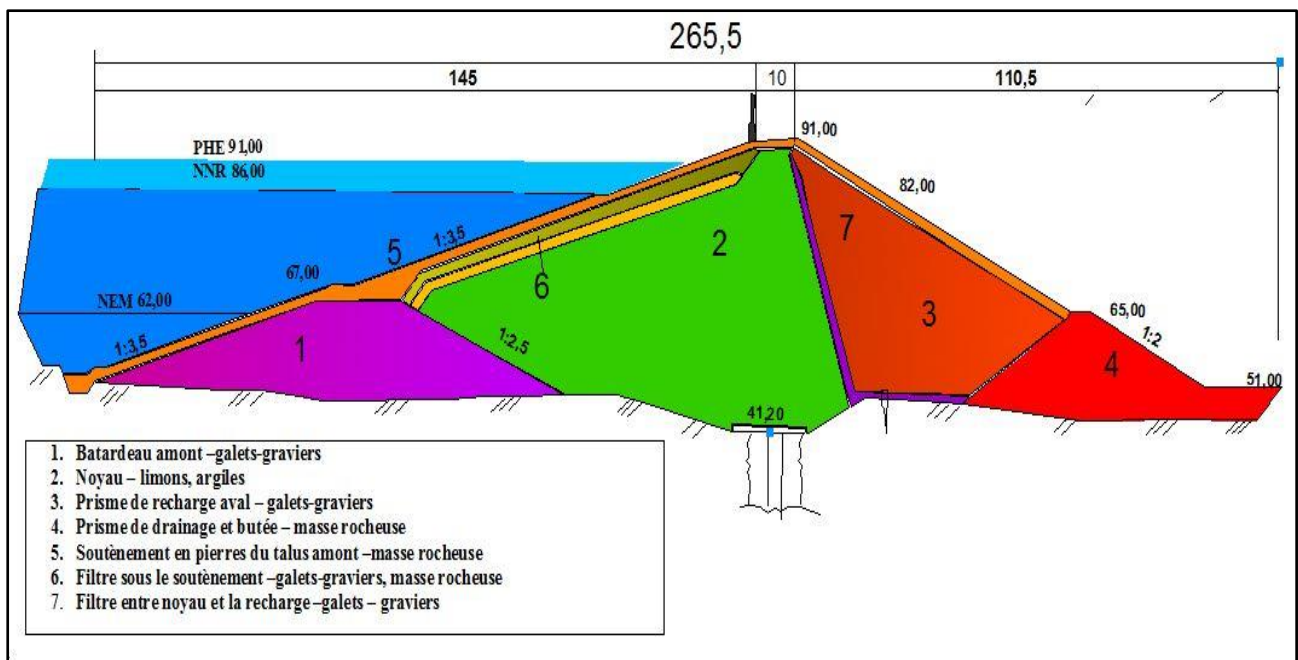


Figure 2.5. Coupe en travers du barrage de Zit-Emba (ANBT, 2010)

2.4.2 Barrage de Guenitra

2.4.2.1 Localisation du site

Le barrage est implanté dans la commune d'Oum Toub (figure 2.6), à une cinquantaine de kilomètre au sud-Ouest de chef-lieu de wilaya Skikda. Il se trouve sur l'oued Fessa, il est limité au nord par la commune de Tamalous, à l'est la commune de Sidi Mezghiche, au sud la commune de Béni Ouelbane et à l'ouest par la commune Ain Kechera.

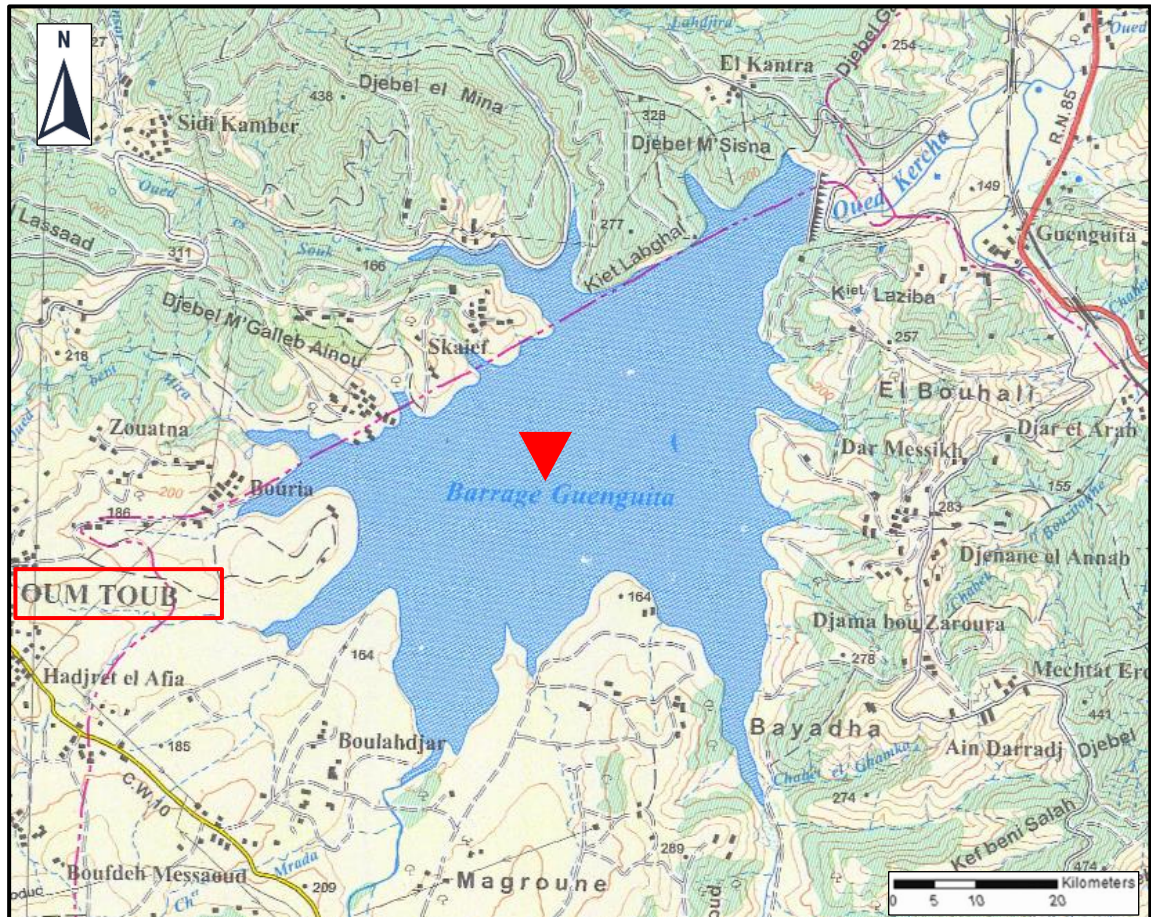


Figure 2.6. Localisation du barrage Guenitra

2.4.2.2 Objectifs du barrage

Les objectifs principaux du barrage sont les suivants :

- ◆ Garantir la régulation des débits sur une période de plusieurs années ;
- ◆ Répondre aux besoins d'approvisionnement en eau potable du couloir Tamalous - Aïn Kechera-Béni Ouelbane-Oum Toub, et de la ville de Skikda.
- ◆ Assurer l'irrigation de 5650 ha de terres agricoles dans la vallée du Saf-Saf et dans la plaine de Medjez Edchich

- ◆ Assurer la couverture en eau industrielle de la ville de Skikda et son complexe industrielle.

2.4.2.3 Description du bassin versant d'Oued Fessa

Le bassin versant de Guenitra se trouve dans la partie Sud-Ouest du bassin hydrographique d'Oued Guebli. Il est localisé à une trentaine de kilomètres au Sud-Ouest de la wilaya de Skikda, avec une superficie d'environ 202 km² et une altitude maximale de 1364 m. Il reçoit une précipitation moyenne de 729.25 mm et se distingue par un réseau hydrographique important, avec une densité de drainage de 4.04 km/km². Parmi les cours d'eau principaux qui alimentent le barrage, nous trouvons l'Oued Fessa, ainsi que ses affluents, à savoir (figure. 2.7) : l'Oued Charfa, qui longe la limite est du sous-bassin versant au pied d'un relief escarpé, l'Oued Mégramne et l'Oued Mellouh, entre lesquels se situe le village d'Oum Toub et l'Oued Essouk, qui traverse la zone minière de Sidi Kamber et présente la pente la plus élevée.




Figure 2.7. Réseau hydrographique du bassin versant d'oued Fessa

Les caractéristiques morpho-métriques du bassin versant du barrage Guenitra sont illustrées dans le **tableau 2.5**

Tableau 2.5. Caractéristiques morpho-métriques du bassin versant d'oued Fessa

Paramètre	Symbole	Unité	Valeur
Superficie	S	km ²	202.6
Périmètre	P	km	62.2
Coefficient de compacité	Kc	-	1.22
Longueur du rectangle équivalent	Le	km	21.25
Longueur du Talweg	le	km	15.25
Densité de drainage	Dd	km/km ²	4.04
Altitude maximale	H max	m	1364
Altitude minimale	H min	m	110
Attitude moyenne	H moy	m	492.54
Indices de pente de Roche		m/Km	7.15

(ANRH, 2015)

En outre, la région de la plaine d'Oum Toub est caractérisée par un climat méditerranéen avec deux saisons bien distinctes. L'hiver est froid et pluvieux, tandis que l'été est chaud et sec. Les précipitations annuelles s'élèvent à environ 729.25 mm, avec une température moyenne annuelle de 17.9 °C. En ce qui concerne la végétation, la région est principalement couverte de deux types de formations végétales, à savoir les forêts et les maquis, qui occupent la majeure partie de son territoire.

2.4.2.4 Description du barrage

Le barrage Guenitra est construit à partir d'une digue en terre zonée avec un noyau argileux central. Sa hauteur est de 60 m et sa longueur en crête est de 515 m. Il s'agit d'un barrage de type remblai compacté en silts et graves argileuses avec des recharges amont et aval tabulatrices. La hauteur au-dessus des fondations et du terrain naturel est de 69 m. La retenue créée par le barrage a une capacité de 125 hm³, permettant de régulariser annuellement 48 hm³. Le niveau normal de la retenue (NNR) est de 164 m, ce qui correspond à une superficie de 694 ha. Le niveau des plus hautes eaux (PHE) lors des crues exceptionnelles est de 167.70 m. La cote du niveau d'eau mort de la retenue est de 133 m, correspondant à un volume mort de 8 hm³ (**figure 2.8**).

La tour de prise du barrage de Guenitra mesure 71.85 m de hauteur et a un diamètre de 9.60 /11.20 m. Les prises d'eau, d'un diamètre de 1000 mm, sont situées respectivement à trois niveaux : 134.15 m, 144.6 m et 154.5 m. Le déversoir du barrage, conçu pour évacuer un débit maximum de 757 m³/s, se trouve sur la rive gauche de la digue. Il est équipé d'un seuil

déversant d'une largeur de 47.5 m, arasé à la cote de 164 m, et est prolongé par un coursier raccordé à un saut de ski. Les autres caractéristiques sont données dans le **tableau 2.6**.

Tableau 2.6. Caractéristiques du barrage Guenitra

Type	Valeur
Hauteur	169.7 m
Longueur en crête	515 m
Largeur de la crête	9 m
Vidange de fond	211 m ³ /s
Capacité initiale	125,00 hm ³
Capacité au dernier levé topo-bathymétrique (2014)	113.12 hm ³
Envasement moyen annuel	0.4 hm ³ /an

(ANBT, 2020)




Figure 2.8. Coupe en travers du barrage de Guenitra (ANBT, 2020)

2.5 Conclusion

Le présent chapitre a d'abord exposé l'évolution de la construction des barrages en Algérie. Cette évolution a été divisée en quatre grandes périodes, selon une chronologie précise : 1938-1962, 1963-1980, 1981-2000 et 2001 à nos jours. Les deux barrages Zit Emba et Guenitra ont été choisis sur la base de leur volume quasiment identique et même période d'exploitation. Par la suite, ces barrages ainsi que leurs bassins versants, ont été décrits d'un point de vue historique et technique. Ces barrages, construits respectivement en terre hétérogène et en terre zonée avec un noyau central argileux, mobilisent conjointement 245 hm³ d'eau. Les réservoirs de ces barrages reçoivent respectivement les eaux de l'oued El

Hammam et de l'oued Fessa, qui drainent deux bassins versants d'une superficie totale de 686 km². Enfin, les différentes utilisations des eaux mobilisées ont été identifiées. Il s'agit notamment de l'AEP de certaines agglomérations avoisinantes, du renforcement de l'AEP du chef-lieu de la wilaya de Skikda, ainsi que de l'irrigation de 12 000 ha de terres agricoles.

Chapitre 3 : Collecte, critique et traitement de données

Chapitre 3 : Collecte, critique et traitement de données

3.1 Introduction

Afin de comprendre l’historique de la gestion et par conséquent le fonctionnement des deux barrages Zit-Emba et Guenitra, nous allons présenter et critiquer la totalité de données recueillies. En effet, l’analyse de ces dernières, collectées au niveau des barrages, est primordiale avant de se lancer dans la mise en place de procédures permettant de mieux contrôler les processus d’allocation d’eau et d’assurer ainsi la meilleure réponse en cas de perturbations importantes (fortes variations de la demande, ressources momentanément insuffisantes, etc.).

Ce chapitre s’intéresse à l’acquisition, le contrôle de la fiabilité et le traitement de données utilisées pour l’élaboration du modèle de prévision du volume total affecté à l’alimentation en eau potable et agricole.

Les données obtenues auprès de l’Agence Nationale des Barrages et Transferts (ANBT) constituent la principale source pour l’élaboration des travaux de cette thèse. Cette base de données comprend les données d’exploitation du barrage Zit Emba pour une période de 17 ans (2004-2021), et le barrage Guenitra pour une période de 15 ans (2005-2020).

3.2 Description des bases de données

Dans le but d’établir le bilan hydraulique du réservoir et de mettre en place un outil de suivi de la disponibilité de l’eau, l’exploitant des barrages (ANBT) effectue une série de mesures à intervalles journalier (tous les matins à 8 heures). Ces données sont consignées sur une fiche préétablie intitulée "ETAT DE LA RESERVE", puis saisies sous format numérique (Excel) pour être exploitées ultérieurement. Il s’agit des mesures des apports, des réserves (ou des volumes de remplissage), des précipitations, des pertes (évaporation et fuites), des volumes évacués (déversements de crue et vidanges de fond), ainsi que des volumes régularisés pour les besoins de consommation (AEP, AEI et AEA). Ces données sont considérées comme les paramètres d’entrée et de sortie qui composent l’équation du bilan hydrique d’un barrage.

Tel qu’illustré dans la **figure 3.1**, l’estimation des principaux termes du bilan hydrique d’un barrage (apports ou entrées, défluent ou sorties, stock ou réserve) permet de surveiller les variations de la capacité de retenue (évolution des gains et des pertes). De plus, cela permet d’évaluer les déficits de régularisation, qui sont à la fois liés au régime irrégulier des apports et à l’importance des pertes (évaporation et fuites).

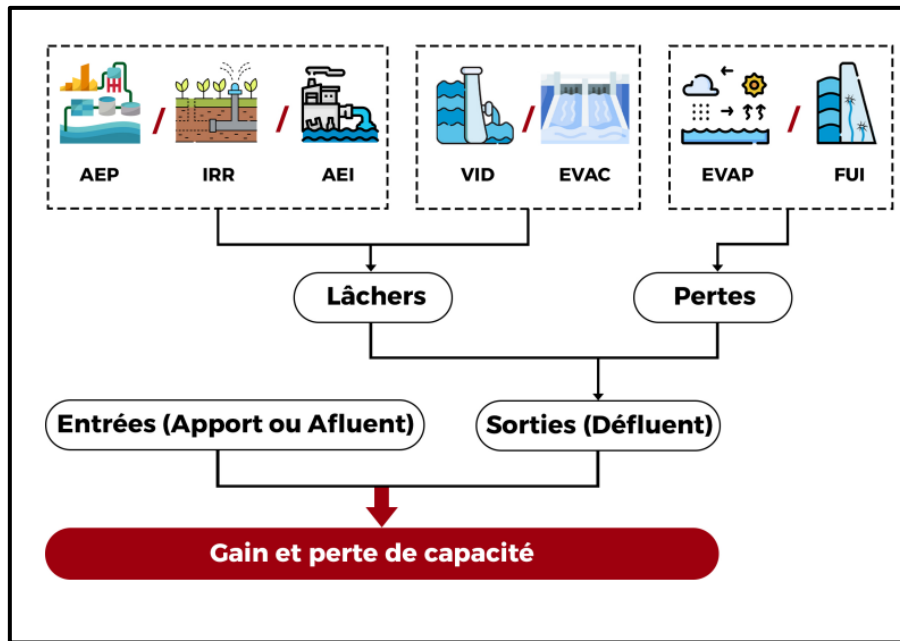


Figure 3.1. Schéma théorique du bilan d'eau d'un barrage

3.2.1 Paramètres mesurés

3.2.1.1 La côte du plan d'eau

Sa mesure peut être réalisée par levé direct en utilisant une échelle limnimétrique positionnée sur la tour de prise d'eau du barrage ou en utilisant un appareil topographique qui sera installé sur le point de référence situé sur la dalle en béton de la tour de prise d'eau (figure 3.2).




Figure 3.2. L'échelle limnimétrique sur la tour de prise du barrage Zit-Emba

3.2.1.2 La pluie

Les précipitations sur l'ensemble des cuvettes des barrages Zit Emba et Guenitra sont jaugées en se basant sur les relevés pluviométriques effectués dans la station située au niveau de

la retenue du barrage. Cette méthode repose sur l'hypothèse selon laquelle les précipitations enregistrées dans une station sont représentatives de celles qui sont tombées aux alentours de la station, sur une zone plus étendue en fonction de la densité du réseau pluviométrique. Ces mesures sont obtenues grâce à une lecture quotidienne du pluviomètre.

3.2.1.3 L'évaporation

L'évaporation des lacs des barrages est une composante essentielle du bilan hydrique d'une retenue. Il est crucial de quantifier avec précision cette évaporation et de comprendre son évolution au fil de l'année. Pour ce faire, différents types de bacs d'évaporation peuvent être utilisés. Ces bacs, de dimensions variées, sont placés sur le sol avec le niveau de l'eau maintenu à une faible distance en dessous du bac. Les variations du niveau d'eau dans le bac, mesurées à intervalles réguliers, reflètent l'intensité de l'évaporation.

Dans les barrages de Zit Emba et Guenitra, on retrouve un bac d'évaporation de type Colorado classe A. Ce bac circulaire a un diamètre de 1.20 m et une profondeur de 0.25 m. Il est fabriqué en tôle galvanisée non peinte et est posé sur un socle permettant une circulation d'air libre. Ce type de bac est le plus couramment utilisé (figure 3.3).



Figure 3.3. Bac d'évaporation (classe A) au niveau du barrage de Zit Emba

3.2.1.4 Les fuites de l'ouvrage récupérables

Les fuites d'eau sont inévitables, peu importe l'emplacement du barrage. Elles se produisent non pas seulement à travers le corps de l'ouvrage, mais aussi à travers les rives et les fondations. En raison de la pression hydrostatique exercée par l'eau retenue sur le fond et les berges du barrage, une certaine quantité d'eau s'infiltré et s'évacue. Actuellement, les fuites dans

nos barrages ne posent pas de problème, mais des fuites sont détectées sur le canal principal de collecte des fuites grâce à un déversoir triangulaire (figure 3.4).




Figure 3.4. Piézomètre de fuite sur la digue du barrage de Zit Emba

3.2.1.5 Les lâchers

Les lâchers représentent les eaux desservies et/ou déchargées à l'aval du barrage. Nous avons : les eaux destinées à l'AEP, l'AEI, l'AEA et les eaux évacuées par vidange (VID) pour des raisons d'inspection et d'entretien du barrage, ainsi que pour réduire le volume des sédiments en début de crue.

Les lâchers pour l'irrigation et la VID sont déterminés en fonction de la loi régissant l'ouverture de la vanne de vidange de fond, tandis que les lâchers pour l'approvisionnement en eau potable sont déterminés en fonction de la loi régissant l'ouverture de la vanne de prise.

3.2.1.6 Les volumes d'eau déversés

Le déversoir de crue, également connu sous le nom d'évacuateur, est l'un des éléments essentiels d'un barrage. Son rôle est de permettre l'évacuation d'un volume d'eau depuis le réservoir amont vers un canal de décharge. Son utilisation est particulièrement importante en cas de crue, qui pourrait mettre en danger le barrage en provoquant une augmentation excessive du niveau amont. Il est donc primordial de veiller à la bonne conception et au bon fonctionnement de l'évacuateur de crue, afin de garantir la sécurité du barrage et de prévenir tout risque lié aux crues.

Les quantités d'eau déversées sont calculées en fonction du temps de déversement et de la courbe des côtes. Ainsi, la formule utilisée pour déterminer le volume d'eau déversé est la suivante : $Q \text{ déversé} = f(\text{côtes})$.



Figure 3.5. Evacuateur des crues de Zit Emba

3.2.2 Paramètres estimés

3.2.2.1 Le volume stocké dans le réservoir et la surface du plan d'eau

Chaque barrage possède sa propre courbe hauteur-surface-volume. Connaissant le niveau d'eau dans la retenue, il est possible d'estimer le volume correspondant en se référant à cette courbe. La connaissance du stock d'eau dans le barrage est essentielle pour une gestion efficace de la retenue, permettant de surveiller en continu les volumes d'eau disponibles, d'effectuer des inspections du barrage en analysant l'impact du niveau de la retenue sur les mesures des instruments (comme les débits et la piézométrie), et d'enrichir les données hydrologiques en mesurant les débits de crue.

3.2.2.2 L'évaporation au niveau du barrage

La mesure de l'évaporation par le bac (E en mm), prend en compte la pluie tombant sur le bac (P en mm) ainsi que la différence de côte du plan d'eau dans le bac entre deux mesures (ΔH en mm). Ainsi la valeur de l'évaporation est donnée par la relation suivante (Boutoutaou et al, 1995 et 2012) :

$$E = \Delta H \pm P \quad (3.1)$$

Afin de convertir l'évaporation du bac en évaporation du plan d'eau de la retenue, il convient de multiplier les mesures effectuées sur le bac par un coefficient spécifique au bac (k). Ce coefficient est déterminé en fonction du type de bac, de son environnement et du climat (Roche, 1963).

3.2.2.3 L'apport d'eau entrant dans le réservoir

Les apports jouent un rôle essentiel dans le comportement hydrique de la retenue d'eau du barrage. Ils sont influencés par :

- Les précipitations annuelles, saisonnières, mensuelles ou journalières, ainsi que leur répartition sur l'ensemble du bassin versant ;
- La surface du bassin versant ;
- La perméabilité du bassin versant ;
- L'humidité du sol.

Dans notre cas, nous intéressons aux apports qui parviennent au barrage après sa mise en service, ce qui constitue la première inconnue du bilan car il n'existe pas de station de jaugeage contrôlant les entrées au barrage. Cette donnée est déduite du bilan hydrique.

3.2.3 Etablissement du bilan hydrique

Les études sur les bilans hydrique des réservoirs se sont multipliées au cours de ces trois dernières décennies dans les domaines de l'hydrologie et de l'hydraulique (Kingumbi, 1999 ; Mihoubi, 2009 ; Amirèche, 2009 ; Abdellaoui et al, 2002 ; Mebarki, 2009, Touati, 2010 ; Mebarki, 2010 ; Boulahbal et al, 2013; Louamri, 2013 ; Benfetta et al, 2016 ; Bengora, 2020).

Dans la pratique, le bilan hydrique consiste à surveiller toutes les entrées (Apports) et sorties (Pertes) d'un lac ou un réservoir. Il est établi en comparant les apports et les pertes en eau pour un site et une période donnée. En outre, il prend en compte les réserves et les prélèvements ultérieurs sur ces réserves. Le bilan est considéré comme positif lorsque la différence entre les apports et les pertes est positive, ou lorsque le rapport est supérieur à 1.

Les apports d'eau correspondent aux flux d'eau sur le bassin versant, tandis que les pertes d'eau englobent l'évaporation, les demandes en eau et les divers lâchers.

Les données de mesure, collectées par l'Agence Nationale des Barrages et des Transferts (ANBT), permettent de surveiller l'évolution journalière mensuelle et interannuelle du bilan hydrique du réservoir depuis sa mise en service. Dans le cas des barrages de Zit Emba et Guenitra, le bilan se compose d'un équilibre hydrique quotidien, comprenant les débits entrants (apports), les débits sortants (pertes par évaporation, prélèvements pour AEP, AEI et AEA) et les variations du stock du réservoir.

Sur un intervalle de temps donné, l'équation générale du bilan hydrique d'une retenue découle de l'application du principe de la conservation des volumes d'eau (Lebdi, 2002). Elle peut s'écrire :

$$VOL_{FINAL} = VOL_{INITIAL} + (VOL_{AFFLUENT}) - (VOL_{DEFFLUENT}) \quad (3.2)$$

$$VOL_{AFFLUENT} = (V_{RUI} + V_{AS} + V_{AP}) \quad (3.3)$$

$$VOL_{DEFFLUENT} = (V_{EVAP} + V_{EVAC} + V_{VID} + V_{FUI} + V_{TAL}) \quad (3.4)$$

Avec :

- V_{RUI} : Le volume ruisselé ;
- V_{AS} : Le volume des apports souterrains ;
- V_{AP} : Le volume des apports pluviométriques ;
- V_{EVAP} : Le volume évaporé ;
- V_{EVAC} : Le volume évacué ou déversé par l'évacuateur des crues ;
- V_{VID} : Le volume vidangé ;
- V_{FUI} : Le volume des fuites ou infiltré ;
- V_{TAL} : Le volume total alloué à l'AEP, l'AEI et l'AEA.

Il est à noter que les volumes ruisselés, les apports souterrains et les apports pluviométriques sur la retenue contribuent à l'apport global (APP) entrant dans le barrage.

En d'autres termes, le volume des apports d'eau (V_{APP}) ou « Entrée » est réparti entre les besoins en eau (V_{TAL}), les pertes globales (V_{EVAP} , V_{FUI}), les lâchers (V_{VID} , V_{EVAC}). Ces trois éléments représentent les « Sorties », et enfin l'excédent éventuel ΔV reste stocké dans la cuvette. La représentation schématique des différentes variations de la capacité du réservoir d'un barrage est illustrée par la **figure 3.6**, en se basant sur les données d'observation.

En outre, l'équation du bilan peut aussi s'écrire comme suit :

$$\text{Apport hydrologique ou affluent (hm}^3\text{)} = \text{défluent (hm}^3\text{)} + \Delta V \text{ (hm}^3\text{)} \quad (3.5)$$

Avec :

Défluent : La somme de toutes les sorties du barrage (évaporation, fuite, évacuation des crues, vidange de fond et allocations).

ΔV (variation de stock) : Le volume stocké dans la cuvette (réserve finale – réserve initiale).

Étant donné que la capacité de stockage des réservoirs des barrages diminue progressivement au fil du temps en raison de l'envasement accéléré, les volumes réels mobilisés dans le réservoir, les surfaces réelles correspondantes et les volumes évaporés sont déduits à

partir des nouvelles courbes hauteur-surface-volume du barrage établies en tenant compte des résultats du levé bathymétrique et cela, en fonction de la cote du plan d'eau mesurée.

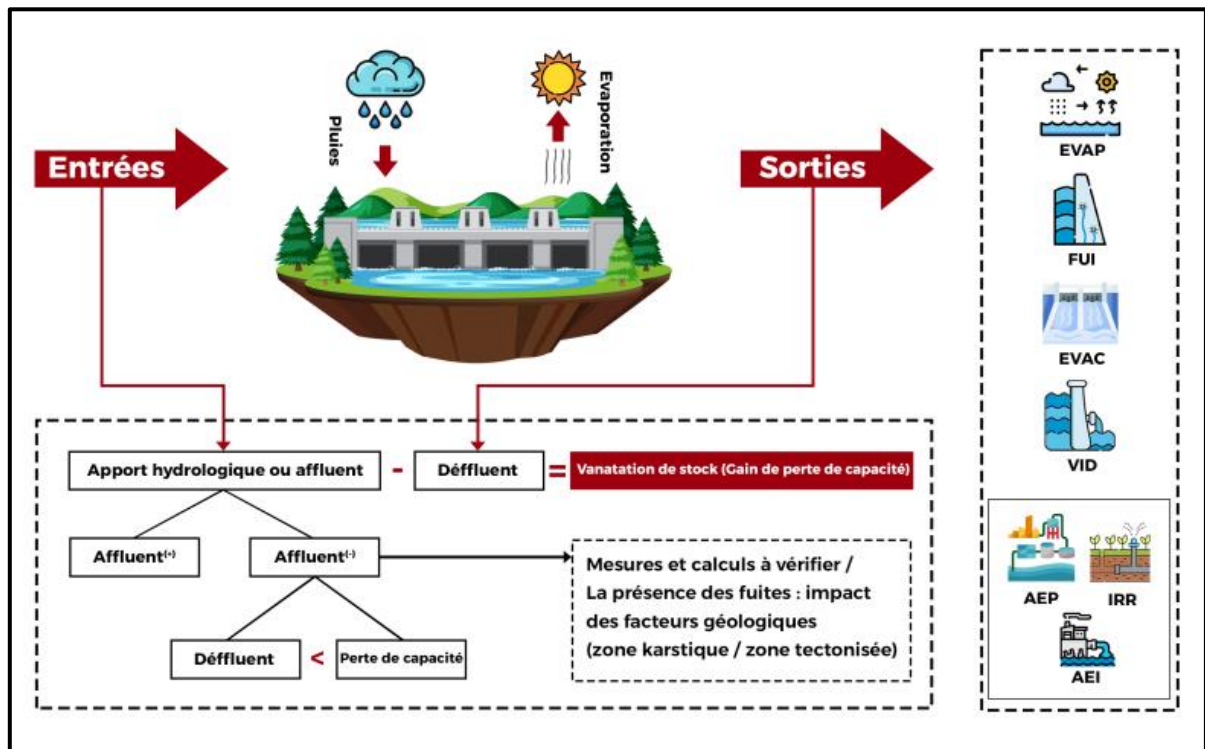


Figure 3.6. Présentation schématique des termes du bilan d'eau d'un barrage

Les **tableaux 3.1** et **3.2** fournissent un exemple de calcul du bilan hydrique pour les deux barrages examinés, Zit Emba et Guenitra.

Avec :

Gain de capacité = Augmentation du volume de la retenue au début du jour « j+1 » où du mois « m+1 » ;

Perte de capacité = Diminution du volume de la retenue au début du jour « j+1 » où du mois « m+1 » ;

Défluent = Somme des sorties du barrage au jour « j+1 » où au mois « m+1 » ;
= Consommation + évaporation + fuites + vidange + déversement ;

Affluent = Somme des entrées = Apport du jour « j+1 » où du mois « m+1 »).

Tableau 3.1. Exemple d'application sur la base de données du barrage Zit Emba

DATE (J)	COTE (m)	VOL (hm ³)	APP (hm ³)	AEP (hm ³)	IRR (hm ³)	PLU (mm)	EVAP (hm ³)	FUI (hm ³)	VID (hm ³)	EVAC (hm ³)	GAIN (hm ³)	PERTE (hm ³)	LACHERS (hm ³)	DEFFL (hm ³)	AFFL+ (hm ³)
01/02/2005	86.42	120.079	3.140	0.033	0.000	11.000	0.001	0.001	0.587	2.518		0.000	3.138	3.140	3.140
02/02/2005	86.41	119.995	2.964	0.031	0.000	6.800	0.000	0.001	0.587	2.429		0.084	3.047	3.048	2.964
03/02/2005	86.37	119.659	2.369	0.031	0.000	1.700	0.004	0.001	0.587	2.082		0.336	2.700	2.705	2.369
04/02/2005	86.33	119.324	2.039	0.030	0.000	2.400	0.002	0.001	0.587	1.754		0.335	2.371	2.374	2.039
05/02/2005	86.29	118.990	1.733	0.031	0.000	1.500	0.003	0.001	0.587	1.445		0.334	2.063	2.067	1.733
06/02/2005	86.26	118.740	1.601	0.030	0.000	0.000	0.007	0.001	0.587	1.226		0.250	1.843	1.851	1.601
07/02/2005	86.16	117.909	0.399	0.030	0.000	0.000	0.020	0.001	0.587	0.592		0.831	1.209	1.230	0.399
08/02/2005	86.14	117.744	0.362	0.031	0.000	0.600	0.010	0.001	0.000	0.485		0.165	0.516	0.527	0.362
09/02/2005	86.26	118.740	2.258	0.032	0.000	15.500	0.003	0.001	0.000	1.226	0.996		1.258	1.262	2.258
10/02/2005	86.56	120.258	5.431	0.031	0.000	0.000	0.004	0.001	0.000	3.877	1.518		3.908	3.913	5.431
11/02/2005	86.38	119.743	2.286	0.031	0.000	0.000	0.015	0.001	0.587	2.167		0.515	2.785	2.801	2.286
12/02/2005	86.24	118.574	0.554	0.030	0.000	0.000	0.017	0.001	0.587	1.088		1.169	1.705	1.723	0.554
13/02/2005	86.22	118.407	0.838	0.031	0.000	0.000	0.019	0.001	0.000	0.954		0.167	0.985	1.005	0.838
14/02/2005	86.22	118.407	0.992	0.030	0.000	10.800	0.007	0.001	0.000	0.954	0.000	0.000	0.984	0.992	0.992
15/02/2005	86.38	119.743	3.539	0.030	0.000	20.900	0.005	0.001	0.000	2.167	1.336		2.197	2.203	3.539
16/02/2005	86.42	120.079	3.476	0.031	0.000	31.900	0.003	0.001	0.587	2.518	0.336		3.136	3.140	3.476
17/02/2005	86.49	120.667	4.383	0.031	0.000	15.500	0.003	0.001	0.587	3.173	0.588		3.791	3.795	4.383
18/02/2005	86.56	120.258	4.086	0.030	0.000	10.100	0.001	0.001	0.587	3.876		0.409	4.493	4.495	4.086
19/02/2005	86.50	120.752	4.387	0.031	0.000	10.700	0.004	0.001	0.587	3.270	0.494		3.888	3.893	4.387
20/02/2005	86.36	119.575	1.447	0.031	0.000	4.100	0.006	0.001	0.587	1.999		1.177	2.617	2.624	1.447
21/02/2005	86.28	118.907	1.330	0.030	0.000	0.400	0.010	0.001	0.587	1.370		0.668	1.987	1.998	1.330
22/02/2005	86.24	118.574	1.381	0.031	0.000	4.200	0.007	0.001	0.587	1.088		0.333	1.706	1.714	1.381

Tableau 3.2. Exemple d'application sur la base de données du barrage Guenitra

DATE (J)	COTE (m)	VOL (hm ³)	APP (hm ³)	AEP (hm ³)	IRR (hm ³)	PLU (mm)	EVAP (hm ³)	FUI (hm ³)	VID (hm ³)	EVAC (hm ³)	GAIN (hm ³)	PERTE (hm ³)	LACHERS (hm ³)	DEFFL (hm ³)	AFFL+ (hm ³)
01/02/2005	164.24	119.494	0.871	0.063	0.000	2.3	0.003	0.004	1.081	0.000		0.280	1.144	1.151	0.871
02/02/2005	164.38	120.475	3.205	0.064	0.000	12.6	0.002	0.004	2.154	0.000	0.981		2.218	2.224	3.205
03/02/2005	164.33	120.124	1.472	0.070	0.000	3.5	0.005	0.004	1.744	0.000		0.351	1.814	1.823	1.472
04/02/2005	164.23	119.424	0.516	0.066	0.000	2.3	0.006	0.004	1.014	0.126		0.700	1.206	1.216	0.516
05/02/2005	164.16	118.935	0.471	0.004	0.000	1.1	0.004	0.004	0.588	0.360		0.489	0.952	0.960	0.471
06/02/2005	164.09	118.447	0.189	0.008	0.000	0.0	0.005	0.004	0.249	0.411		0.488	0.668	0.677	0.189
07/02/2005	164.10	118.517	0.376	0.006	0.000	0.0	0.005	0.004	0.291	0.000	0.070		0.297	0.306	0.376
08/02/2005	164.10	118.517	0.313	0.009	0.000	10.6	0.009	0.004	0.291	0.000	0.000		0.300	0.313	0.313
09/02/2005	164.14	118.796	0.777	0.008	0.000	17.8	0.005	0.004	0.481	0.000	0.279		0.489	0.498	0.777
10/02/2005	164.19	119.145	2.405	0.009	0.000	0.0	0.004	0.004	0.883	1.156	0.349		2.048	2.056	2.405
11/02/2005	164.08	118.378	0.285	0.009	0.000	0.0	0.009	0.004	0.208	0.822		0.767	1.039	1.052	0.285
12/02/2005	164.00	117.821	0.078	0.005	0.000	0.0	0.010	0.004	0.000	0.616		0.557	0.621	0.635	0.078
13/02/2005	164.00	117.821	0.231	0.055	0.000	0.7	0.008	0.004	0.000	0.164		0.000	0.219	0.231	0.231
14/02/2005	164.01	117.891	0.156	0.061	0.000	17.6	0.008	0.004	0.013	0.000	0.070		0.074	0.086	0.156
15/02/2005	164.20	119.214	2.167	0.007	0.000	1.5	0.010	0.004	0.823	0.000	1.323		0.830	0.844	2.167
16/02/2005	164.20	119.214	0.844	0.009	0.000	24.4	0.008	0.004	0.823	0.000	0.000		0.832	0.844	0.844
17/02/2005	164.23	119.424	3.737	0.008	0.000	17.6	0.007	0.004	1.015	2.493	0.210		3.516	3.527	3.737
18/02/2005	164.17	119.005	3.016	0.009	0.000	4.7	0.004	0.004	0.759	2.659		0.419	3.427	3.435	3.016
19/02/2005	164.05	118.169	1.942	0.008	0.000	6.8	0.003	0.004	0.104	2.659		0.836	2.771	2.778	1.942
20/02/2005	164.17	119.005	1.606	0.002	0.000	0.0	0.005	0.004	0.759	0.000	0.836		0.761	0.770	1.606
21/02/2005	164.20	119.214	1.045	0.004	0.000	8.7	0.005	0.004	0.823	0.000	0.209		0.827	0.836	1.045
22/02/2005	164.24	119.49	1.38	0.01	0.00	0.00	0.00	0.00	1.08	0.00	0.280		1.090	1.098	1.378

3.3 Critique et traitement de données

3.3.1 Critique de données

L'étape de critique de données de gestion d'un barrage revêt une importance cruciale dans le processus global de gestion des ressources hydriques. Cette phase initiale vise à examiner attentivement l'ensemble des données collectées, qu'elles soient observées sur le terrain ou estimées, afin d'identifier toute anomalie, lacune ou incohérence. Les critères d'évaluation portent sur divers paramètres, allant de la précision des mesures métrologiques à la fiabilité des méthodes de collecte et de stockage de données. La qualité de données est scrutée avec rigueur, en tenant compte notamment des variations saisonnières, des phénomènes météorologiques perturbateurs, et des éventuelles interférences environnementales éventuelles.

Les volumes stockés dans la retenue sont calculés à partir des mesures des niveaux d'eau, en utilisant la courbe hauteur-capacité. Les erreurs principales dans ces données proviennent de l'imprécision des mesures des niveaux d'eau, comme l'effet du vent sur la surface de la retenue. Dans les retenues de grande taille, une petite erreur de mesure peut avoir un impact significatif sur l'estimation du volume stocké. De plus, la précision de la mesure du volume dépend de la mise à jour de la courbe hauteur-capacité.

La mesure de la pluie est délicate, puisqu'elle peut être perturbée par l'influence du vent et de l'implantation du pluviomètre qui, dans certains cas affecte fortement la mesure.

Les apports en eau ne sont pas directement mesurés, mais sont déduits du bilan hydrique, ce qui peut entraîner des incertitudes, notamment en raison de problèmes de précision dans la mesure des débits d'eau, des vidanges et des déversements. Il est donc essentiel d'analyser attentivement les données recueillies pour s'assurer de leur fiabilité. Cette analyse consiste à détecter d'éventuelles anomalies dans les paramètres mesurés et estimés, à combler les lacunes des données collectées, et à ajuster les paramètres déduits des courbes hauteur-capacité en fonction des résultats des mesures topo-bathymétriques.

Les bases de données que nous avons reçues présentent de nombreuses erreurs et anomalies, qu'elles soient systématiques ou accidentelles. Par exemple, les mêmes côtes du plan d'eau correspondent à des volumes différents, ou vice versa (**tableau 3.3**). Il y a aussi des omissions des volumes de vidange et/ou de déversement, etc.

Tableau 3.3. Exemples d'erreurs de volumes

Barrage	Date	COTE (m)	VOL (hm ³)	APP (hm ³)	AEP (hm ³)	IRR (hm ³)	EVAP (hm ³)	PLU (mm)	VID (hm ³)	FUI (hm ³)
Zit Emba	20/06/2011	85.77	114.719	0.026	0.03	0.107	0.050	0.0	8.9	0.001
	21/06/2011	85.77	114.719	0.085	0.027	0.015	0.042	0.0	7.6	0.001
	22/06/2011	85.77	114.558	0.028	0.029	0.107	0.052	0.0	9.4	0.001
	23/06/2011	85.77	114.558	0.099	0.030	0.015	0.053	0.0	9.5	0.001
	12/09/2013	83.19	95.374	0.000	0.000	0.008	0.025	5.5	0.028	0.001
	13/09/2013	83.19	95.304	0.000	0.000	0.006	0.025	0.0	0.020	0.001
Guenitra	29/05/2006	162.14	105.263	0.000	0.050	0.064	0.029	0.0	0.050	0.004
	30/11/2009	162.14	105.328	0.082	0.057	0.000	0.021	0.0	0.000	0.004
	07/02/2015	162.14	105.263	0.373	0.106	0.000	0.000	0.0	0.000	0.004
	23/09/2007	159.32	87.585	0.012	0.069	0.049	0.009	15.0	0.000	0.004
	28/10/2013	159.32	87.585	0.000	0.102	0.000	0.013	0.0	0.000	0.004
	28/10/2014	159.32	87.050	0.000	0.104	0.048	0.014	0.0	0.008	0.004

Avec :

COTE : Le niveau de l'eau dans le barrage ;

VOL : Le volume stocké dans le barrage ;

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

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

IRR : Le volume alloué à l'irrigation ;

EVAP : Le volume évaporé ;

PLU : La pluie mesurée au niveau du barrage ;

VID : Le volume de vidange ;

FUI : volume des fuites.

3.3.2 Traitement de données

Le principal souci de ces bases de données réside dans le fait que les données journalières d'exploitation ne sont pas cohérentes. En effet, en se basant sur les paramètres disponibles, il est difficile de balancer les entrées, les sorties et les volumes restants dans la cuvette (**tableau 3.4**).

Tableau 3.4. Exemples sur l'établissement de la balance des volumes

DATE	COTE (m)	VOL Mesurés (hm ³)	APP (hm ³)	AEP (hm ³)	IRR (hm ³)	EVAP (hm ³)	PLU (hm ³)	VID (hm ³)	FUI (hm ³)	VOL Calculés (hm ³)	Ecart VOL (hm ³)
31/07/2019	84.14	102.184	0	0.025	0.050	0.037	0	0	0.001	102.291	0.107
01/08/2019	84.12	102.037	0	0.021	0.070	0.045	0	0	0.001	102.047	0.010
02/08/2019	84.10	101.890	0	0.028	0.070	0.048	0	0	0.001	101.890	0.000
03/08/2019	84.08	101.744	0	0.022	0.070	0.053	0	0	0.001	101.744	0.000
04/08/2019	84.06	101.597	0	0.025	0.070	0.051	0	0	0.001	101.597	0.000
05/08/2019	84.04	101.451	0	0.022	0.070	0.053	0	0	0.001	101.451	0.000
06/08/2019	84.02	101.305	0	0.027	0.070	0.048	0	0	0.001	101.305	0.000
07/08/2019	84.00	101.159	0	0.025	0.060	0.043	0	0	0.001	101.176	0.017
08/08/2019	83.98	101.014	0	0.026	0.055	0.041	0	0	0.001	101.036	0.022
09/08/2019	83.96	100.868	0	0.027	0.055	0.040	0	0	0.001	100.891	0.023
10/08/2019	83.94	100.723	0	0.026	0.055	0.038	0	0	0.001	100.748	0.025
11/08/2019	83.92	100.578	0	0.029	0.055	0.039	0	0	0.001	100.599	0.021
12/08/2019	83.90	100.433	0	0.028	0.053	0.040	0	0	0.001	100.456	0.023
13/08/2019	83.88	100.288	0	0.027	0.052	0.038	0	0	0.001	100.315	0.027
14/08/2019	83.86	100.143	0	0.029	0.052	0.038	0	0	0.001	100.168	0.025
15/08/2019	83.84	99.998	0	0.027	0.054	0.038	0	0	0.001	100.023	0.025
16/08/2019	83.82	99.854	0	0.018	0.050	0.040	0	0	0.001	99.889	0.035
17/08/2019	83.80	99.709	0	0.017	0.050	0.040	0	0	0.001	99.746	0.037
18/08/2019	83.79	99.637	0	0.014	0.020	0.037	0	0	0.001	99.637	0.000
19/08/2019	83.78	99.565	0	0.012	0.020	0.039	0	0	0.001	99.565	0.000
20/08/2019	83.77	99.493	0	0.013	0.020	0.038	0	0	0.001	99.493	0.000

Il est évident qu'il y a une grande différence entre les volumes mesurés chaque jour et ceux calculés selon l'expression (3.2) (§ section 3.2). Ainsi, la balance des volumes n'est pas équilibrée, ce qui nous amène à conclure qu'il y a :

- ✓ Soit des erreurs de mesure où de transcription ;
- ✓ Soit des erreurs de calcul des apports ;
- ✓ Soit des oublis de saisie des volumes vidangés.

Le **tableau 3.5** présente un exemple de rectification apportée au bilan hydrique du barrage Zit Emba. Il est observé que les agents responsables de la surveillance ont omis d'enregistrer le volume de vidange ou ne l'ont pas pris en compte pour ces jours.

Tableau 3.5. Exemples sur la correction de volume stocké

DATE	COTE (m)	VOL Mesurés (hm ³)	APP (hm ³)	AEP (hm ³)	IRR (hm ³)	EVAP (hm ³)	PLU (hm ³)	VID (hm ³)	FUI (hm ³)	VOL Calculés (hm ³)	Ecart VOL (hm ³)
31/07/2019	84.14	102.184	0	0.025	0.050	0.037	0	0.107	0.001	102.184	0
01/08/2019	84.12	102.037	0	0.021	0.070	0.045	0	0.010	0.001	102.037	0
02/08/2019	84.10	101.890	0	0.028	0.070	0.048	0	0	0.001	101.890	0
03/08/2019	84.08	101.744	0	0.022	0.070	0.053	0	0	0.001	101.744	0
04/08/2019	84.06	101.597	0	0.025	0.070	0.051	0	0	0.001	101.597	0
05/08/2019	84.04	101.451	0	0.022	0.070	0.053	0	0	0.001	101.451	0
06/08/2019	84.02	101.305	0	0.027	0.070	0.048	0	0	0.001	101.305	0
07/08/2019	84.00	101.159	0	0.025	0.060	0.043	0	0.017	0.001	101.159	0
08/08/2019	83.98	101.014	0	0.026	0.055	0.041	0	0.022	0.001	101.014	0
09/08/2019	83.96	100.868	0	0.027	0.055	0.040	0	0.023	0.001	100.868	0
10/08/2019	83.94	100.723	0	0.026	0.055	0.038	0	0.025	0.001	100.723	0
11/08/2019	83.92	100.578	0	0.029	0.055	0.039	0	0.021	0.001	100.578	0
12/08/2019	83.90	100.433	0	0.028	0.053	0.040	0	0.023	0.001	100.433	0
13/08/2019	83.88	100.288	0	0.027	0.052	0.038	0	0.027	0.001	100.288	0
14/08/2019	83.86	100.143	0	0.029	0.052	0.038	0	0.025	0.001	100.143	0
15/08/2019	83.84	99.998	0	0.027	0.054	0.038	0	0.025	0.001	99.998	0
16/08/2019	83.82	99.854	0	0.018	0.050	0.040	0	0.035	0.001	99.854	0
17/08/2019	83.80	99.709	0	0.017	0.050	0.040	0	0.037	0.001	99.709	0
18/08/2019	83.79	99.637	0	0.014	0.020	0.037	0	0	0.001	99.637	0
19/08/2019	83.78	99.565	0	0.012	0.020	0.039	0	0	0.001	99.565	0
20/08/2019	83.77	99.493	0	0.013	0.020	0.038	0	0	0.001	99.493	0

3.4 Sélection des séries de données à modéliser

Après avoir effectué le nettoyage et le prétraitement de données afin d'éliminer les valeurs aberrantes, les valeurs manquantes et autres anomalies susceptibles d'influencer les résultats des tests, nous procédons à l'analyse des caractéristiques de données. Nous examinons les tendances, les saisons et les événements spéciaux pour identifier les séries temporelles pertinentes à tester.

3.4.1 Analyse de données d'exploitation

Dans cette étape, nous cherchons à examiner les données d'exploitation des barrages Zit Emba et Guenitra pour évaluer leur fiabilité et repérer la période adéquate pour modéliser les volumes alloués. L'analyse portera sur les différents paramètres du bilan hydrique des barrages, à savoir:

VOL : Le volume stocké dans le barrage ;

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

VTAL : volumes totaux alloués à l'AEP, AEI et AEA ;

EVAP : Le volume évaporé ;

PLU : La pluie mesurée au niveau du barrage ;

VID : Le volume de vidange ;

L'analyse statistique et la visualisation graphique de ces données permettront de :

- ✓ Comprendre les variations temporelles des différents paramètres ;
- ✓ Identifier les tendances et les anomalies ;
- ✓ Comparer les performances des deux barrages ;
- ✓ Déterminer les facteurs qui influencent le bilan hydrique des barrages ;

L'analyse s'appuiera sur des données journalières s'étalant sur une période minimale de 17 ans pour le barrage Zit Emba (2004 -2021) et d'au moins 15 ans pour le barrage Guenitra (2005-2020).

L'évolution temporelle des différents paramètres d'exploitation est visualisée par les graphiques suivants :

3.4.1.1 Les volumes stockés dans les barrages

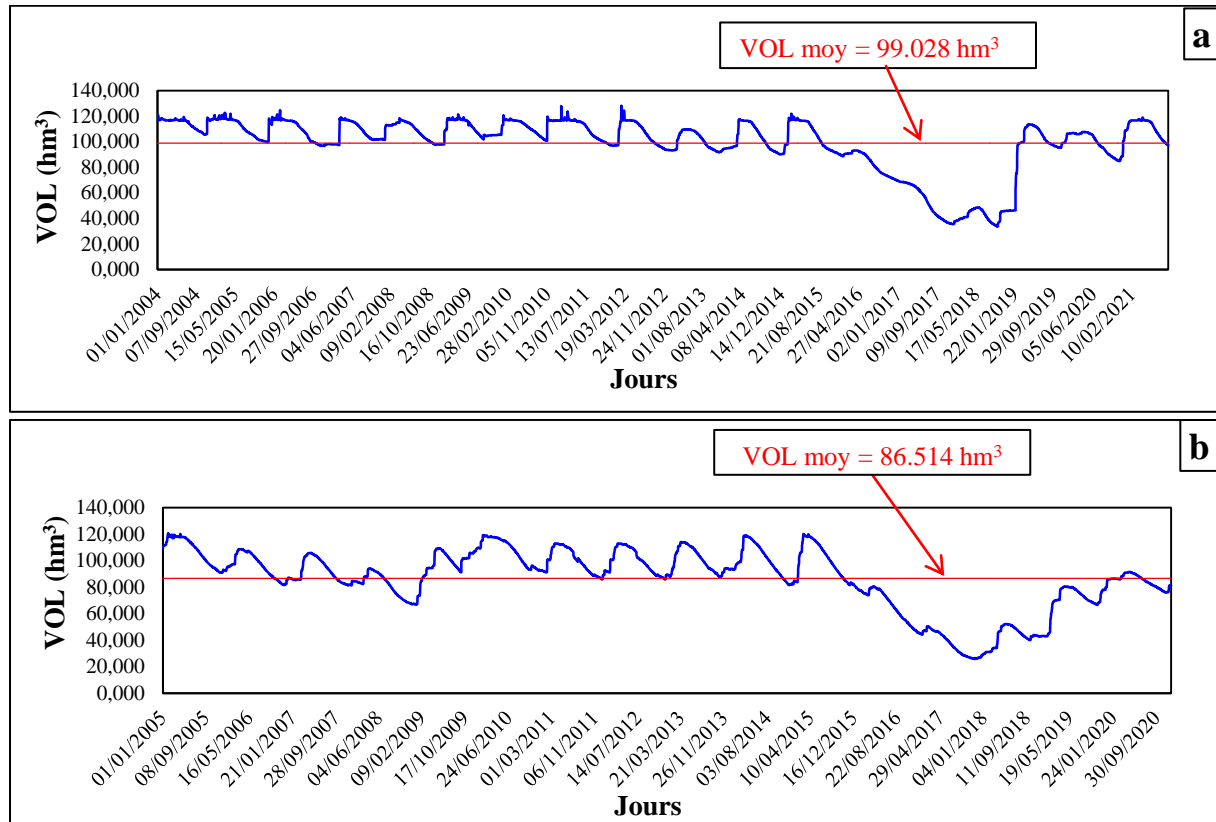


Figure 3.7. Variation des VOL dans les barrages : (a) Zit Emba, (b) Guenitra

La **figure 3.7** montre que les volumes d'eau stockés dans les barrages Zit Emba et Guenitra varient de manière significative au cours de l'année. Cette variation est influencée par plusieurs facteurs, dont les précipitations, l'évaporation, la consommation d'eau et les lâchers d'eau.

Nous remarquons que le barrage Zit Emba a enregistré le plus grand volume stocké, soit 128.144 hm^3 le 23/02/2012, dépassant ainsi sa capacité utile de 120.00 hm^3 . Cette situation est attribuée, à notre avis, à des événements ponctuels tels que de fortes pluies, ainsi qu'à une diminution des volumes alloués pour répondre aux besoins en eau potable et en irrigation, étant donné que la saison d'irrigation est terminée. Dans l'ensemble, le marnage du réservoir est régulier. Cela se traduit par un équilibre des jours où les volumes stockés sont supérieurs à la moyenne de 99.028 hm^3 . Cependant, au cours de la période d'exploitation de 2015 à 2019, le volume stocké dans le barrage a considérablement diminué pour atteindre son niveau le plus bas de 33.576 hm^3 le 03/10/2018, en raison en partie de la sécheresse dans la région et de l'augmentation des volumes alloués pour répondre aux besoins en eau potable et en irrigation. Ensuite, le volume a progressivement augmenté jusqu'en octobre 2019, pour ensuite rester relativement stable, alternant entre des valeurs supérieures et inférieures à la moyenne.

En ce qui concerne le barrage Guenitra, les volumes d'eau stockés n'ont jamais dépassé les 125.00 hm^3 . Cette situation peut être expliquée par une augmentation des allocations pour répondre aux besoins en eau potable et en irrigation, ainsi qu'une gestion prudente des volumes d'eau mobilisés par le barrage. Le volume le plus bas était de 27.755 hm^3 enregistré le 13/11/2017. Par la suite, le stock a augmenté mais est toujours resté en dessous de la moyenne.

3.4.1.2 Les apports entrant dans les barrages

Les variations saisonnières des débits des cours d'eau sont tributaires d'une multitude de facteurs climatiques et physiques du bassin versant (le régime de précipitations, la nature lithologique des bassins versants, les conditions climatiques, l'équipement des bassins en ouvrages hydrauliques, etc.).

La connaissance de ces variations sont indéniablement d'une grande importance pour une gestion rationnelle des ressources en eau.

La variation journalière des apports entrant pour les deux barrages étudiés est représentée dans la **figure 3.8**

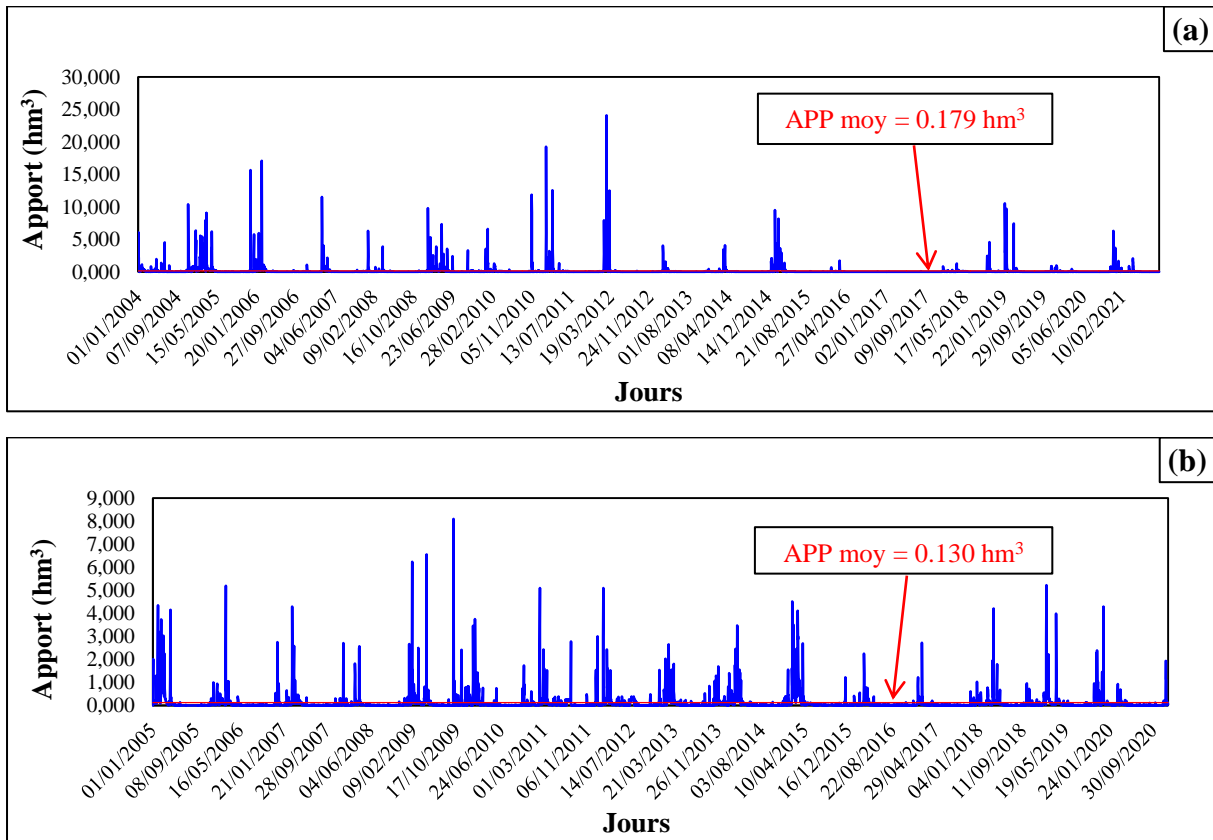


Figure 3.8. Variation des APP dans les barrages : (a) Zit Emba, (b) Guenitra

Pendant les périodes d'exploitation des deux barrages, nous pouvons observer une irrégularité notable dans la variation des apports journaliers, comme le montre la **figure 3.8**. Les apports peuvent fluctuer de manière significative d'un jour à l'autre. De plus, nous remarquons que les apports vers le barrage Zit Emba sont généralement plus élevés que ceux vers le barrage Guenitra en raison des différences entre les caractéristiques morphométriques des bassins versants qui alimentent les réservoirs respectifs des barrages

Concernant le barrage Guenitra, la moyenne des apports journaliers est de 0.130 hm^3 , avec un pic atteignant 8.094 hm^3 . Cette variation reflète les fluctuations quotidiennes dans les volumes d'eau entrant dans le barrage Guenitra. Une moyenne de 0.130 hm^3 indique une faible variation quotidienne des apports, tandis qu'un pic de 8.094 hm^3 suggère une journée où les apports ont été exceptionnellement élevés. En revanche, pour le barrage Zit Emba, un pic d'apport maximal de 24.111 hm^3 a été enregistré le 23/02/2012. Il est ainsi remarqué que la période d'exploitation entre 2015 et 2018 a été marquée par une pénurie d'eau due, comme nous l'avons mentionnée plus haut, à la sécheresse qu'a connue la région.

3.4.1.3 Les volumes totaux alloués à l'AEP et l'irrigation

Les barrages Zit Emba et Guenitra jouent un rôle essentiel dans l'approvisionnement en eau potable des habitants de la wilaya de Skikda et répondent également aux besoins spécifiques de l'agriculture dans la wilaya. La **figure 3.9** illustre une répartition très fluctuante des VTAL par les deux barrages au cours des périodes d'exploitation.




Figure 3.9. Variation des VTAL dans les barrages : (a) Zit Emba, (b) Guenitra

Ces fluctuations sont dues principalement au raccordement progressif des agglomérations aux réseaux d'adduction à partir de la station de traitement des eaux et par la mise en service des périmètres d'irrigation à partir de chaque barrage.

La **figure 3.9 (a)** montre que 25% des volumes attribués à l'AEP et à l'irrigation par le barrage Zit Emba dépassent la moyenne qui s'élève à 0,054 hm³. Cette observation peut s'expliquer par le fait que les allocations en eau pour l'irrigation sont réduites pendant les mois de décembre, janvier et février.

De plus, nous observons des variations assez significatives en ce qui concerne le barrage Guenitra. En effet, la **figure 3.9 (b)** révèle que 48,25 % de l'ensemble des jours de la

période d'exploitation ont enregistré une dotation en eau inférieure à la moyenne (0.084 hm^3) et que 52.75 % des allocations dépassent cette moyenne.

3.4.1.4 Les volumes évaporés

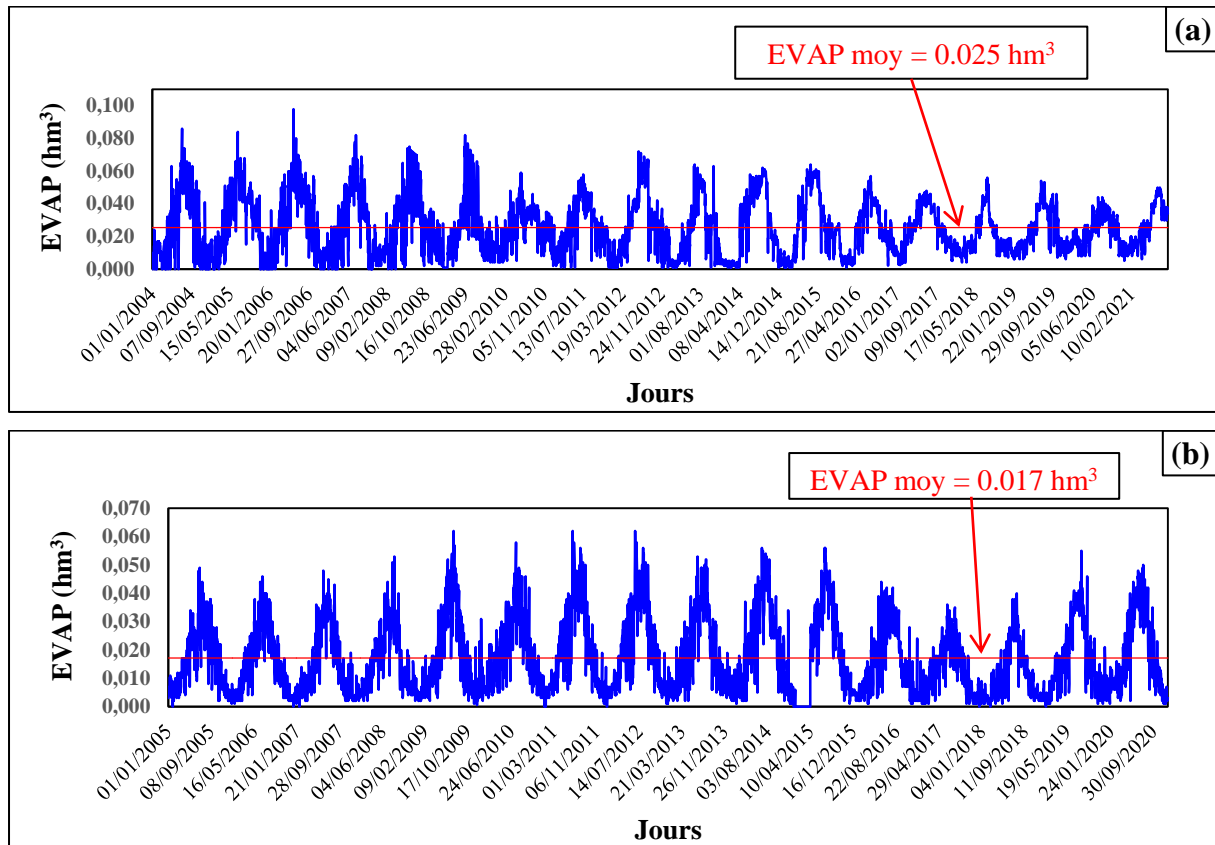


Figure 3.10. Variation des EVAP dans les barrages : (a) Zit Emba, (b) Guenitra

La **figure 3.10** met en évidence une cyclicité marquée dans l'évolution des volumes évaporés dans les barrages étudiés. Cette cyclicité se manifeste par l'enregistrement de deux pics distincts. Le premier pic, qui se caractérise par un volume maximal évaporé de 0.098 hm^3 , est observé dans le barrage de Zit Emba, tandis que le second pic est relevé dans le barrage de Guenitra et présente un volume maximal évaporé de 0.062 hm^3 . Cette régularité cyclique semble être intrinsèquement liée à l'augmentation du niveau d'eau, résultant des apports hydriques substantiels et des températures élevées observées au cours de ces phases d'exploitation.

3.4.1.5 La pluie




Figure 3.11. Variation de la PLU au niveau du barrage : (a) Zit Emba, (b) Guenitra

La **figure 3.11** illustre une variation presque identique des précipitations mesurées à la station pluviométrique des deux barrages pendant la période d'exploitation, avec une moyenne de 11 mm pour chaque barrage. Cette représentation met en évidence deux événements exceptionnels avec des valeurs remarquables par rapport aux autres jours. L'un d'entre eux concerne le premier barrage, Zit Emba, avec un pic de 127 mm enregistré le 04/02/2011, tandis que l'autre concerne le deuxième barrage avec un maximum de 62 mm enregistré le 21/03/2019.

De plus, une analyse de la variation des quantités de pluie journalière, par analogie à la variation des apports, révèle qu'environ 75 % des jours de la période d'exploitation ont enregistré une quantité de pluie inférieure à la moyenne pour Zit Emba, et environ 76 % pour l'autre barrage.

Finalement, en comparant les quantités totales de pluie enregistrées au niveau des deux barrages, nous constatons qu'ils sont presque équivalents (total pour le premier barrage = 12 848.30 mm et total pour le deuxième barrage = 10 359.90 mm).

3.4.1.6 Les volumes des vidanges

En général, les lâchers (vidanges) sont effectués après la crue c'est-à-dire lors des ruissellements importants. La représentation graphique des volumes vidangés de la période considérée est illustrée par la **figure 3.12**. Les vidanges sont très éparées dans le temps du fait de la variation des apports, de la spécificité des opérations de vidange et de l'état de la sédimentation de la retenue.

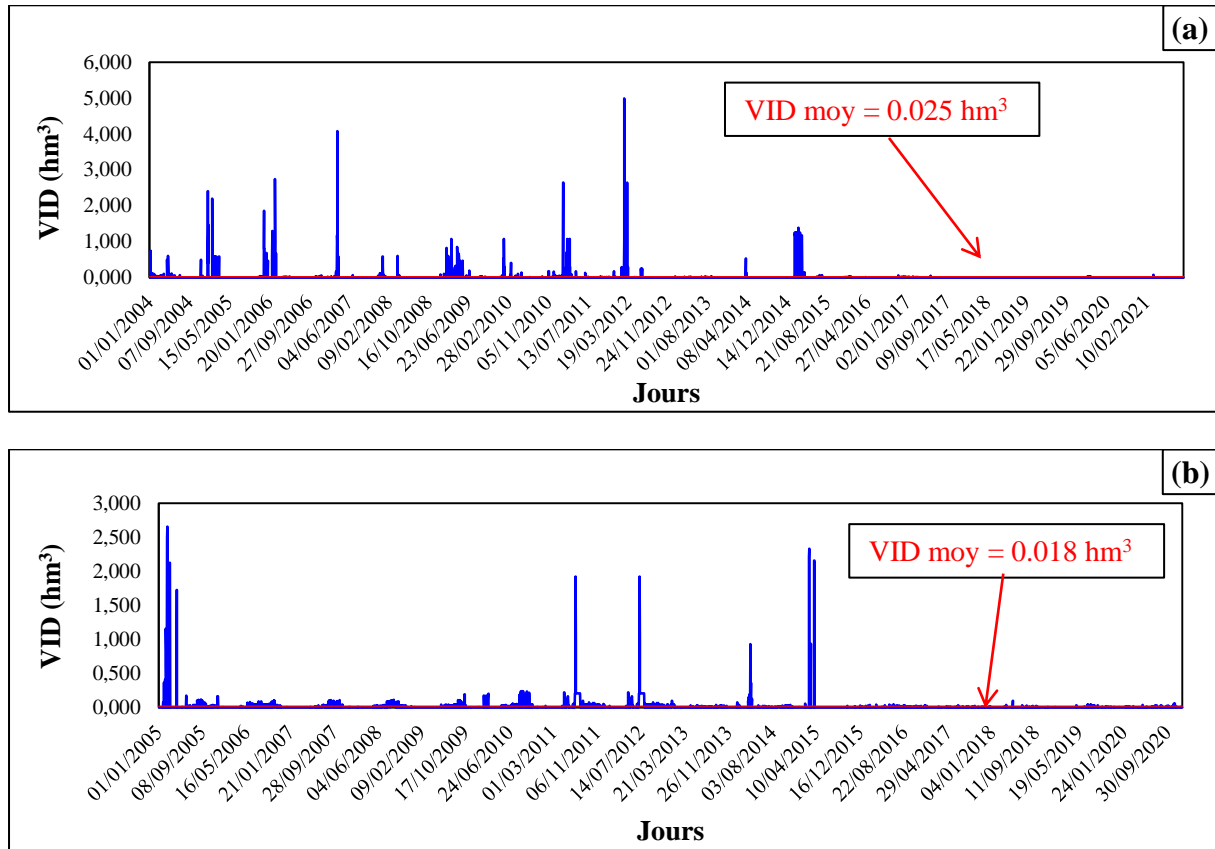


Figure 3.12. Variation des VID du barrage : (a) Zit Emba, (b) Guenitra

En analysant la **figure 3.12**, nous remarquons que les volumes importants vidangés sont très éparés dans le temps du fait qu'ils sont liés d'une part à la variation des apports entrant dans le barrage et d'autre part à la spécificité des consignes de gestion (programmation des opérations de vidange et état de l'envasement de la retenue).

3.4.1.7 Les volumes évacués




Figure 3.13. Variation des EVAC à travers le barrage : (a) Zit Emba, (b) Guenitra

Au cours de la période d'exploitation des barrages étudiés (**figure 3.13**), on constate une fréquence notablement élevée de déversements au niveau du barrage Zit Emba, en particulier entre 2004 et 2012 (**figure 3.13a**), mais une diminution significative est observée de 2012 à 2021. En revanche, pour le barrage Guenitra, le nombre de déversements est relativement faible (**figure 3.13b**). Ces déversements semblent être étroitement liés aux niveaux de remplissage élevés des barrages.

3.4.2 Choix des séries de données à modéliser

Les séries de données requises pour simuler les volumes totaux alloués (VTAL) par les barrages Zit Emba et Guenitra ont été sélectionnées après avoir prétraité et analysé les données initiales fournies gracieusement par l'exploitant des barrages ANBT. En effet, l'analyse de données journalières initiales des huit variables liées à l'exploitation des barrages, dont trois variables hydrologiques (APP, PLU et EVAP) et cinq variables d'exploitation (COTE, VOL, VID, EVAC et VTAL), sur une période de 17 ans (2004-2021) pour le barrage

de Zit Emba et une période de 15 ans (2005-2020) pour le barrage Guenitra, nous a permis d'identifier trois périodes d'exploitation distinctes :

1. La première période s'étale de 2004 à 2009 pour le barrage Zit Emba et de 2005 à 2009 pour le barrage Guenitra. Elle se caractérise par le remplissage des réservoirs.
2. La deuxième période est commune aux deux barrages et s'étend de 2009 à 2017. Elle se caractérise par un marnage régulier du niveau d'eau dans les réservoirs, grâce à des précipitations régulières, ce qui témoigne d'une exploitation des barrages sans contraintes.
3. La troisième période s'étend de 2017 à 2021 pour le barrage Zit Emba et de 2017 à 2020 pour le barrage Guenitra. Elle se caractérise par une diminution des volumes d'eau stockés en raison d'une sécheresse sévère et d'une forte demande en eau.

Etant donné qu'il est recommandé de partitionner les données de manière à ce que les ensembles d'apprentissage et de validation aient des caractéristiques statistiques similaires, nous choisissons les données de la deuxième période couvrant huit années d'exploitation, allant du 01/01/2009 au 01/01/2017, ce qui équivaut à un total de 2923 ensembles de données historiques pour chaque barrage.

3.4.3 Statistique des séries de données sélectionnées

Dans cette recherche, les paramètres statistiques ont été calculés pour les séries de données sélectionnées après le traitement et l'analyse des bases de données initiales. Les résultats pour la période allant de 2009 à 2017 sont synthétisés dans le **tableau 3.6**, incluant :

- ✓ La moyenne (**Xmean**), définie comme la somme des valeurs divisée par leur nombre ;
- ✓ La valeur maximale (**Xmax**), représentant le point culminant de la série et correspondant à la borne supérieure ;
- ✓ La valeur minimale (**Xmin**), indiquant le point le plus bas de la série et constituant la borne inférieure ;
- ✓ L'écart-type (**Sd**), reflétant la dispersion des données ;
- ✓ Le coefficient de variation (**CV**), défini comme le rapport entre l'écart-type et la moyenne. Une valeur plus élevée du coefficient de variation suggère une dispersion accrue autour de la moyenne ;
- ✓ Le coefficient de corrélation linéaire (**R**), permettant de visualiser la relation entre la variable d'exploitation et le volume total alloué.

Tableau 3.6. Statistiques descriptives des séries de données sélectionnées

Barrages	Variables	Unité	X_{mean}	X_{max}	X_{min}	S_d	C_v	R
Zit Emba	COTE	m	84.29	87.36	79.09	1.65	0.020	-0.006
	VOL	hm ³	103.78	128.14	69.49	11.84	0.114	-0.06
	APP	hm ³	0.17	24.11	0.00	0.91	5.308	-0.13
	VID	hm ³	0.05	4.99	0.00	0.22	4.384	-0.06
	PLU	mm	2.04	127.00	0.00	6.82	3.346	-0.19
	EVAP	hm ³	0.02	0.08	0.00	0.02	0.697	0.73
	EVAC	hm ³	0.07	11.60	0.00	0.44	6.602	-0.10
	VTAL	hm ³	0.04	0.10	0.00	0.02	0.419	1
Guenitra	COTE	m	159.25	164.32	144.74	4.72	0.03	0.23
	VOL	hm ³	89.76	120.05	25.755	23.99	0.27	0.23
	APP	hm ³	0.19	8.09	0.00	0.50	2.64	-0.06
	VID	hm ³	0.02	2.33	0.00	0.10	6.08	0.09
	PLU	mm	8.08	61.7	0.00	5.68	0.70	-0.12
	EVAP	hm ³	0.02	0.06	0.00	0.01	0.75	0.36
	EVAC	hm ³	0.01	1.67	0.00	0.08	7.93	0.05
	VTAL	hm ³	0.10	0.18	0.00	0.04	0.39	1

Les coefficients de variation consignés au **tableau 3.6**, révèlent que les données des séries sélectionnées sont remarquablement irrégulières et montrent des fluctuations significatives pour les paramètres d’exploitation, EVAC, APP, VID et PLU. Ces fluctuations sont moins prononcées pour COTE, VOL, VTAL et EVAP. De plus, les valeurs maximales de VOL, APP, PLU, VID et EVAC par rapport aux valeurs moyennes indiquent l’existence de valeurs extrêmes (outliers).

3.5 Conclusion

Les bases de données d’exploitation des barrages Zit Emba et Guenitra qui nous ont été fournies par l’ANBT comportent des erreurs à la fois systématiques et accidentelles. Ces données ont été soumises à un traitement afin de les rendre plus fiables et plus exploitables.

En outre, après avoir traité les données d’exploitation, nous avons procédé à une visualisation graphique de l’évolution temporelle de différents paramètres de gestion. Ainsi, toutes les figures reproduisent les fluctuations remarquables des différents paramètres tels que les apports, les volumes totaux alloués, les volumes de vidange et les volumes évacués. Ces fluctuations sont moins accentuées pour le volume stocké, la pluie et l’évaporation.

Par ailleurs, ces illustrations, en particulier celles des volumes stockés, nous ont permis de sélectionner les séries de données à modéliser pour une période de huit ans, allant du 01/01/2009 au 01/01/2017. Les statistiques descriptives établies pour les séries de données sélectionnées ont approuvé les observations suscitées.

Chapitre 4 : Matériels et méthodes

Chapitre 4 : Matériels et méthodes

4.1 Introduction

Dans les ressources en eau, en général, les phénomènes sont régis par des lois physiques et impliquent des relations qui ont des limites amorphes et des variables latentes complexes (Karpadne et al., 2018). En outre, les données utilisées pour la modélisation des ressources en eau comprennent un grand nombre de variables potentielles, générées à partir d'une variété de sources et présentant des résolutions spatio-temporelles, avec différents niveaux d'asymétrie et d'incertitude. Afin de résoudre ce problème, et dans le but d'extraire des informations à partir de données brutes, les chercheurs ont étudié l'application de techniques de Machine Learning telles que ; ANN, SVR, et la famille des arbres de décision (DT). Dans cette perspective, cette étude a utilisé trois techniques de ML pour modéliser la VTAL. Ces techniques sont RFR, MLPNN et SVR.

4.2 Choix des modèles de Machine Learning

Les modèles ont été choisis pour la complexité de la tâche de modélisation de la gestion des réservoirs, la nature spécifique des données et la nécessité de prendre en compte les relations non linéaires entre les variables.

Tout d'abord, le modèle RFR a été choisi en raison de son utilisation d'algorithmes itératifs multiples, de sa capacité à traiter des ensembles de données complexes et à prendre en compte des valeurs extrêmes sans qu'elles aient un effet disproportionné sur le modèle, et des relations non linéaires entre les variables indépendantes et dépendantes (Ahmadi et al., 2022). Les arbres de décision réduisent l'impact des valeurs extrêmes sur le modèle dans son ensemble en divisant les données en sous-ensembles. En outre, le regroupement des arbres de décision permet de prendre en compte simultanément plusieurs variables. En outre, le modèle RFR peut surmonter efficacement les problèmes de bruit et de surapprentissage et atteindre une grande précision de prédiction (Wang et al., 2015).

Deuxièmement, le SVR a été choisi en raison de sa capacité à traiter des ensembles de données de taille moyenne à petite. En fait, la flexibilité du modèle SVR se reflète dans l'utilisation de la fonction noyau, qui sert à mettre en correspondance des données de faible dimension avec des données de haute dimension (Hussain et Khan, 2020). En se concentrant sur la détermination d'une marge d'erreur acceptable, les valeurs extrêmes sont exclues de la modélisation.

Enfin, le MLPNN a été inclus pour sa flexibilité dans la modélisation des relations non linéaires entre les données. En effet, il peut établir des relations entrées-sorties complexes avec une connaissance limitée du domaine (Cinkus et al., 2023). En outre, la rétropropagation de l'erreur peut contribuer à réduire l'impact des valeurs extrêmes sur le poids du réseau pendant l'apprentissage.

4.3 Présentation des modèles de Machine Learning utilisés

4.3.1 SVR

La machine à vecteur de support (SVM) est un modèle intelligent basé sur la théorie de l'apprentissage automatique (Machine Learning). En général, il s'agit d'une méthode bien adaptée à la régression, à la classification et à la prédiction de séries temporelles. Les performances de ce modèle ont été jugées acceptables dans les études hydrologiques (Vapnik 1995, Vapnik 1998).

L'algorithme SVR a été développé pour générer une fonction de régression à partir d'un ensemble de vecteurs de support choisis dans un groupe de données d'entraînement (Essam et al., 2022), en général, ce modèle crée la fonction d'apprentissage pour les entrées et les sorties $((x_1, y_1), \dots, (x_l, y_l))$. En d'autres termes, dans le modèle SVR, il est nécessaire d'estimer la fonction de dépendance de la variable dépendante (y) en fonction de la variable indépendante (x). Dans ce modèle, la fonction linéaire a été définie pour résoudre un problème de régression linéaire et, par conséquent, un problème d'optimisation convexe peut être défini (Smola et Scholkopf, 1998). En d'autres termes, la fonction approximative $f(x)$ peut être calculée en utilisant toutes les paires (x_i, y_i) avec la précision minimale (ϵ) et la fonction de perte de Vapnik, appelée fonction de perte insensible à l' ϵ (Vapnik, 1995). La **figure 4.1** donne la configuration structurelle du modèle SVR.

La fonction de régression du SVR est exprimée sous la forme :

$$\mathbf{f}(\mathbf{x}) = \mathbf{w} \times \phi(\mathbf{x}) + \mathbf{b} \quad (4.1)$$

Où ; f est la fonction de régression, ϕ est la fonction de transfert, w et b sont respectivement le poids et le biais. Le problème de régression peut être déclaré comme ;

$$\text{Minimiser} = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (4.2)$$

$$\text{En fonction de : } \begin{cases} y_i - f(x) \leq \epsilon + \xi_i \\ f(x) - y_i \leq \epsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, 3, \dots, N \end{cases} \quad (4.3)$$

Où : C est le paramètre de pénalité, ξ_i et ξ_i^* correspondent aux variables de relâchement et ε est la valeur limite.




Figure 4.1. Exemple d'un modèle de SVR (Keshtegar et al., 2019)

La formulation proposée est résolue à l'aide de la méthode de Lagrange et le vecteur de poids (w) peut être défini comme une combinaison de données d'apprentissage pondérées de x_i . Enfin, la valeur des multiplicateurs peut être déterminée en résolvant le problème d'optimisation et la fonction estimée peut donc être définie comme suit :

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (4.4)$$

Où, $K(x_i, x)$ représente le produit point des deux vecteurs, x est le vecteur des variables du problème, b est le bruit additif (biais), α_i et α_i^* sont des variables duales.

Cette équation est ce que l'on appelle l'expansion du vecteur de support qui est utilisée pour la régression linéaire. Dans ce modèle, la méthode proposée est entièrement définie par la multiplication interne des vecteurs d'entrée. Par conséquent, le calcul de la fonction $f(x)$ ne nécessite pas le calcul explicite de W .

En général, la plupart des problèmes d'ingénierie sont non linéaires et l'utilisation de la régression linéaire n'est donc pas adaptée à la résolution de ces problèmes. Par conséquent, la méthode proposée doit être étendue pour résoudre les problèmes non linéaires à l'aide de fonctions de noyau. En outre, différentes fonctions de noyau, telles que le noyau linéaire, le noyau polynomial, le noyau tangent hyperbolique et la fonction de base radiale gaussienne

(RBF) ont été proposées et utilisées dans les études de modélisation non linéaire du SVR (Lin et al., 2006 ; Dibike et al., 2001 ; Yu et al., 2006). Les fonctions de noyau couramment utilisées sont énumérées dans le **tableau 4.1**.

En effet, le choix d'une fonction noyau appropriée est une question importante pour résoudre un problème à l'aide d'un modèle SVR (Dibike et al., 2001 ; Asefa et al., 2004 ; Liong et Sivapragasam, 2002 ; Yu et al., 2006 ; Kisi et Cimen, 2011). En raison de la meilleure performance de la fonction de noyau RBF par rapport à d'autres fonctions de noyau pour les prévisions hydrologiques (Yu et al., 2006 ; Kisi et Cimen, 2011), cette fonction a été utilisée dans cette recherche et est définie comme suit :

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (4.5)$$

Où, γ est le paramètre de la fonction de noyau gaussien et les autres paramètres ont été définis précédemment. Il convient de noter que la modification de γ a un effet significatif sur l'apprentissage du modèle et le taux d'erreur du problème et que, par conséquent, la valeur de ce paramètre doit être déterminée avec soin pour différentes conditions du problème.

La précision de l'estimation des paramètres C , ε et γ est très importante et a un effet significatif sur la réduction de l'erreur d'estimation du problème (Smola et Scholkopf, 1998). Par conséquent, la détermination des paramètres optimaux pour le modèle SVR est une étape importante de la conception de ce modèle qui affecte de manière significative les performances du modèle et qui est donc essentielle pour prédire les résultats de sortie du modèle.

Selon le type de fonction de noyau utilisé dans cette recherche, les valeurs appropriées de C , ε et γ ont été déterminées à l'aide d'une méthode d'essai et d'erreur. Cette procédure a permis de trouver les meilleures valeurs de C , ε et γ , à savoir 15, 0.039 et 0.05, respectivement.

Tableau 4.1. Fonctions de noyau couramment utilisées

Type de noyau	Fonction	Paramètres
Linéaire	$\langle x, x_i \rangle$	-
Polynomial	$(\langle x, x_i \rangle + 1)^d$	d
Fonction gaussienne à base radiale	$\exp(-\ x - x_i\ ^2/2\sigma^2)$	σ
Tangente hyperbolique	$\tan h(b\langle x, x_i \rangle + C)$	b, c

L'architecture du modèle SVR est représentée dans la **figure 4.2**.

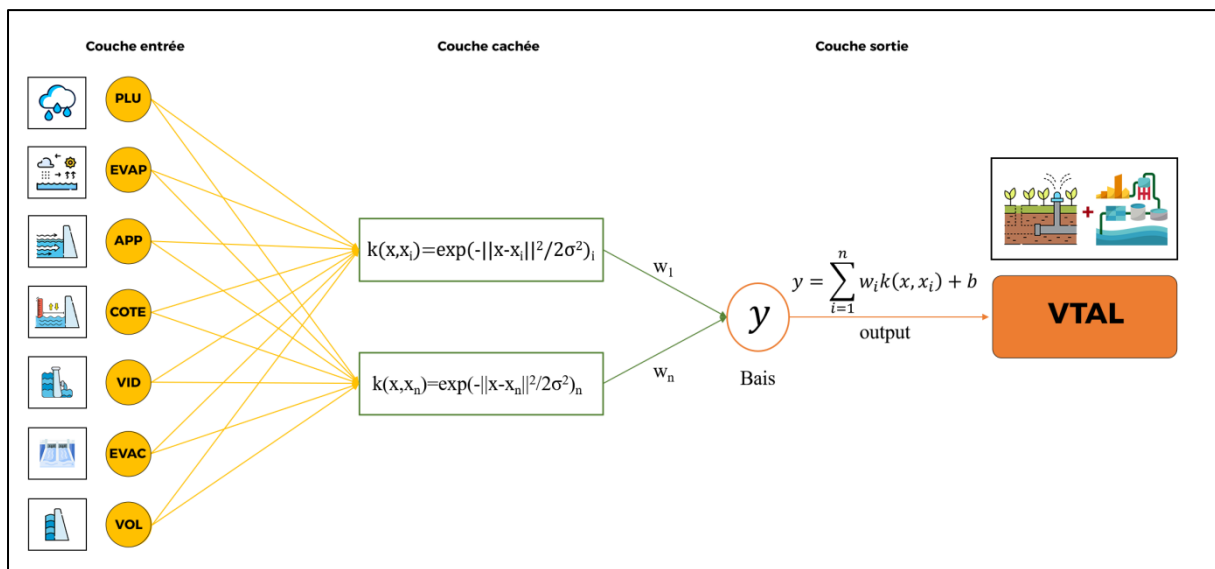


Figure 4.2. Architecture du modèle SVR

4.3.2 RFR

La forêt aléatoire est une approche d'apprentissage automatique d'ensemble proposée par [Breiman \(2001\)](#), pour surmonter les inconvénients de l'ajustement excessif et de l'instabilité lors de l'utilisation d'un seul arbre de décision. Le concept de base d'une forêt aléatoire consiste à construire indépendamment plusieurs arbres de décision sur des sous-ensembles aléatoires de l'ensemble de données d'apprentissage initial. Les moyennes des prédictions de ces arbres uniques sont utilisées pour améliorer la généralisation robuste du modèle ([Tyralis et al., 2019](#) ; [Wu et al., 2020b](#) ; [Heddam et al., 2020](#)).

Deux étapes aléatoires sont nécessaires pour construire un modèle RFR, la première étape implique une randomisation de l'échantillon à l'aide de la méthode bootstrap avec

remplacement. La seconde étape consiste à sélectionner aléatoirement un nombre déterminé de critères parmi l'ensemble de critères d'origine (Guo et al., 2023b).

Le RFR crée un ensemble des arbres de classification et de régression (CART) randomisés en utilisant la méthode de l'indice de Gini des impuretés comme mesure de la meilleure sélection de division (Breiman, 2001), où chaque arbre contribue avec un seul vote à l'affectation de la classe la plus fréquente aux données d'entrée (Deng et al., 2020). RFR possède la capacité de sélection aléatoire des caractéristiques à chaque nœud et aucune règle d'élagage ou d'arrêt pendant le processus d'apprentissage (Tan et al., 2020). Chaque CART est formé sur un échantillon bootstrap des données de formation originales en sélectionnant de nombreuses observations bootstrap à partir des données originales (Tao et al., 2020). La RFR utilise un sous-ensemble aléatoire de variables prédictives dans la division de chaque nœud, ce qui réduit l'erreur de généralisation (Chen et al., 2020), et après qu'un grand nombre d'arbres de régression ont été générés, ils sont utilisés pour prédire la classe de nouvelles données, la meilleure division à chaque nœud de l'arbre est recherchée uniquement parmi un sous-ensemble de prédicteurs sélectionnés au hasard, en utilisant les données dites hors sac (OOB) (Hanna et al., 2020).

La construction d'un modèle RFR nécessite trois paramètres : le nombre d'arbres dans la forêt, le nombre minimum de points de données dans chaque nœud terminal et le nombre de caractéristiques testées à chaque nœud (Breiman, 2001).

Le principe structurel de la forêt aléatoire de régression (RFR) susmentionnée est représenté sur la **figure 4.3**.

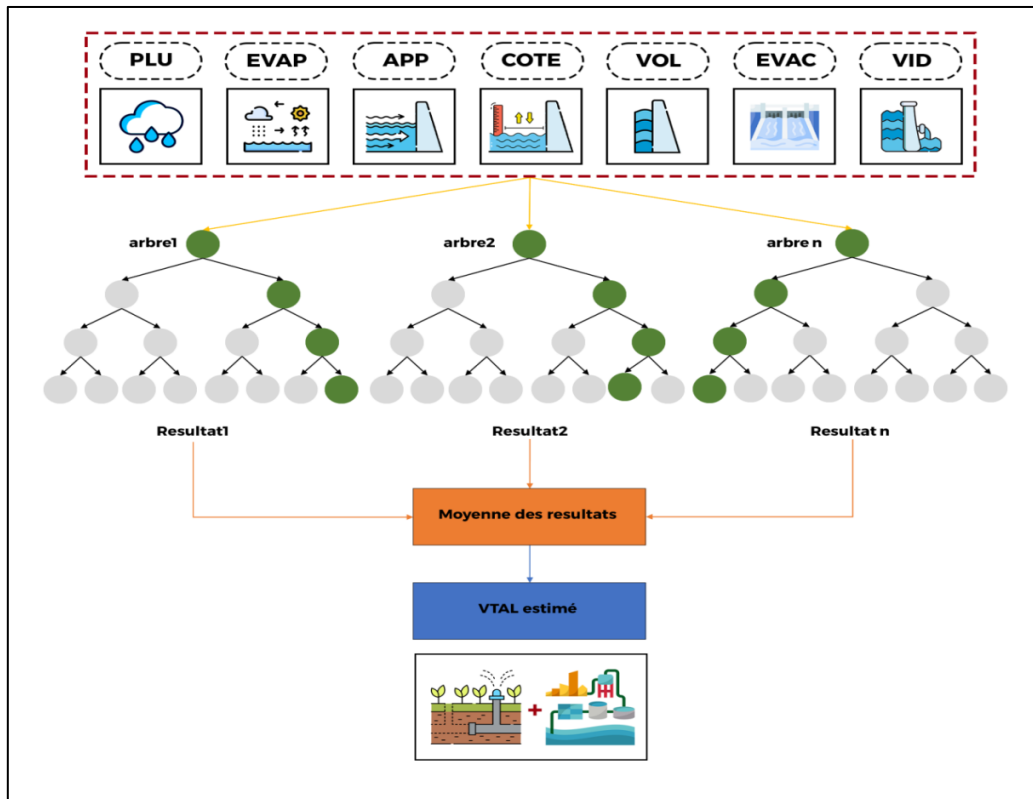


Figure 4.3. Architecture du modèle RFR

4.3.3 MLPNN

Le perceptron multicouche (MLPNN) est le type de réseaux de neurones le plus utilisé et le plus reporté dans la littérature (Zamanisabzi et al., 2018 ; Khishe et Mosavi, 2020). Ce type de réseaux de neurones est largement utilisé dans le domaine des ressources en eau, d'hydrologie et de l'environnement. Le modèle MLPNN se compose de trois types de couches (Kassem et al., 2020) : la couche d'entrée, la couche cachée et la couche de sortie (figure 4.4). La première couche contient un nombre de neurones équivalent au nombre de variables explicatives, tandis que la dernière ne compte qu'un seul neurone qui correspond à la variable à expliquer. Les paramètres du modèle MLPNN sont les poids et les biais. Ces derniers sont optimisés par un algorithme d'apprentissage généralement la rétro-propagation du gradient en utilisant la partie apprentissage de la base de données.

L'algorithme d'apprentissage est répété plusieurs fois pour déterminer le meilleur modèle qui possède la plus petite erreur entre les valeurs observées et les valeurs calculées.

Le modèle utilisé dans le cadre de la présente thèse possède une fonction d'activation sigmoïde pour les neurones de la couche cachée et une fonction d'activation linéaire pour les neurones de la couche de sortie.

Il a été démontré qu'un perceptron multicouche (MLPNN) ayant une seule couche cachée à fonction d'activation sigmoïde est un approximateur universel (Hornik et al., 1990 ; Jang et Xing, 2020). Du point de vue mathématique, un MLPNN peut être présenté comme suit :

$$I_j = \sum_{i=1}^m x_i w_{ij} + \delta_j \quad (i = 1, 2, \dots, n) \quad (4.6)$$

$$E_j = f_1(I_j) \quad (j = 1, 2, \dots, m) \quad (4.7)$$

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad (4.8)$$

$$O = \sum_{j=1}^m E_j w_{jk} + \delta_0 \quad (k = 1, 2, \dots, p) \quad (4.9)$$

$$Y = f_2(O) \quad (4.10)$$

Avec :

x_i : l'entrée i ;

I_j : Etat du neurone j de la couche cachée (égale à la somme pondérée de toutes les entrées x_i plus un biais) ;

W_{ij} : Poids de la connexion entre les neurones i et j (entre la couche d'entrée et la couche cachée) ;

W_{jk} : Poids de la connexion entre les neurones j et k (entre la couche cachée et la couche de sortie) ;

f_j : Fonction d'activation du neurone j appartenant à la couche cachée (généralement la sigmoïde) ;

δ_j : Le biais associé au neurone j de la couche cachée ;

δ_k : Le biais associé au neurone k de la couche de sortie ;

m : Nombre de neurone dans la couche cachée ;

O_k : Etat du neurone k de la couche de sortie.

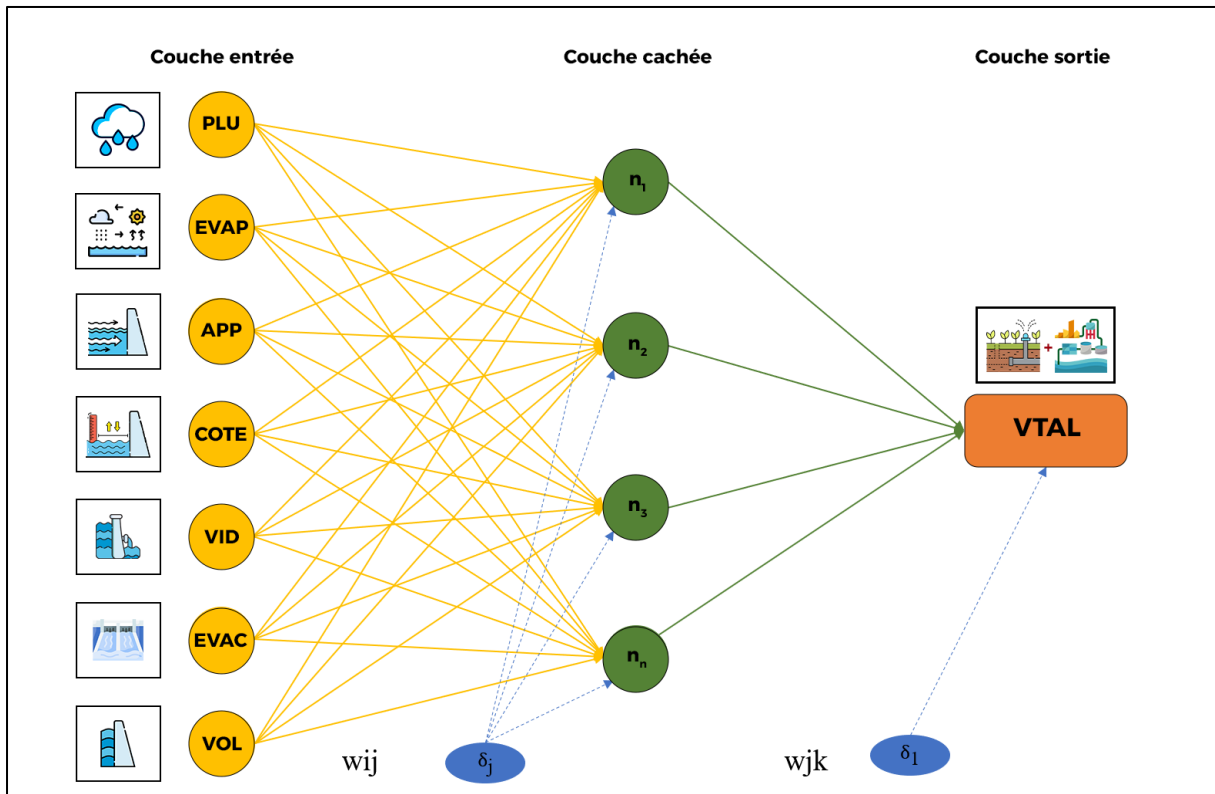


Figure 4.4. Architecture du modèle MLPNN

Il existe plusieurs types de fonctions d'activation (figure 4.5), parmi lesquelles :

a- La fonction identité :

$$f(A) = A \tag{4.11}$$

b- La fonction sigmoïde :

$$f(A) = \frac{1}{1 + e^{-A}} \tag{4.12}$$

c- La fonction Tangente hyperbolique :

$$f(A) = \frac{e^A - e^{-A}}{e^A + e^{-A}} \tag{4.13}$$

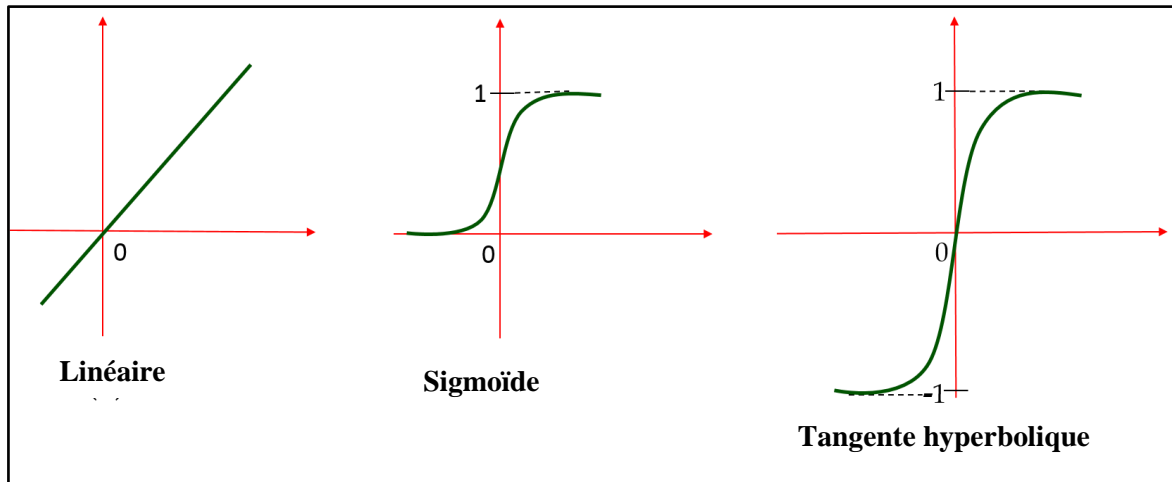


Figure 4.5. Différentes fonctions d'activation

Le problème de l'apprentissage se résume à minimiser une fonction coût, cette minimisation s'effectue à l'aide de méthodes de gradient descendant. L'algorithme le plus connu c'est l'algorithme de rétropropagation du gradient (Rumelhart et al., 1986a ; 1986b). La fonction coût la plus fréquemment utilisée est la moyenne de l'erreur quadratique (MSE), cette dernière mesure l'écart entre les sorties effectives du réseau de neurones (s) et les sorties désirées ou cibles (d).

$$E_p = \frac{1}{2} \sum_{k=1}^P (d_k - s_k)^2 \quad (\text{Erreur sur l'exemple } p) \quad (4.14)$$

$$E = \sum_{p=1}^P E_p \quad (\text{Erreur totale sur la base d'apprentissage}) \quad (4.15)$$

4.4 Technique de validation croisée

Les modèles d'apprentissage automatique appliqués dans cette étude utilisent plusieurs hyperparamètres. Pour cela, nous avons utilisé dans cette étude la validation croisée (CV) k-fold, qui est une technique populaire pour le réglage des hyperparamètres (Sathishkumar et Yongyun, 2020 ; Hagenauer et al., 2019 ; Thanh Noi et al., 2017). La validation croisée k-fold sépare les données d'apprentissage en k sous-ensembles et teste séparément chaque sous-ensemble pour ajuster le modèle. En raison des dépendances temporelles entre les données, la CV k-fold est conçue pour définir les premiers k comme l'ensemble d'apprentissage et les données après les plis comme l'ensemble de test (Jung, 2018). Cela garantit que les données futures ne sont pas utilisées pour tester les données passées, puisque le modèle de prévision doit exclure toutes les données relatives à des événements qui se produisent

chronologiquement après les événements utilisés pour ajuster le modèle (Tashman, 2000). Dans cette étude, conformément à la littérature antérieure, tel que Molinaro et al. (2005), k est fixé à 10, et les données d'apprentissage sont fixées à 10 sous-ensembles pour l'apprentissage et l'ajustement du modèle. La **figure 4.6** illustre le concept qui sous-tend le processus de CV utilisé dans cette étude.

Le processus de CV est conçu pour sélectionner un ensemble optimal d'hyperparamètres qui produit les erreurs quadratiques moyennes (EQM) les plus faibles sur la base des tests de 10 sous-ensembles. En d'autres termes, l'ensemble d'hyperparamètres suggéré par le processus de CV sera utilisé pour établir des prévisions sur la base de l'ensemble de données de test. La stratégie de réglage des hyperparamètres utilisée dans cette étude est la recherche en grille, dans laquelle toutes les combinaisons possibles des hyperparamètres donnés sont testées (Probst et al., 2019). En ce qui concerne le nombre de prédicteurs, tous les prédicteurs sont pris en compte, et la profondeur des arbres est contrôlée avec le nombre de divisions pour le modèle de gradient boosting et le modèle de forêt aléatoire. La validation croisée est conçue pour trouver une combinaison d'hyperparamètres qui minimise la moyenne de l'EQM.

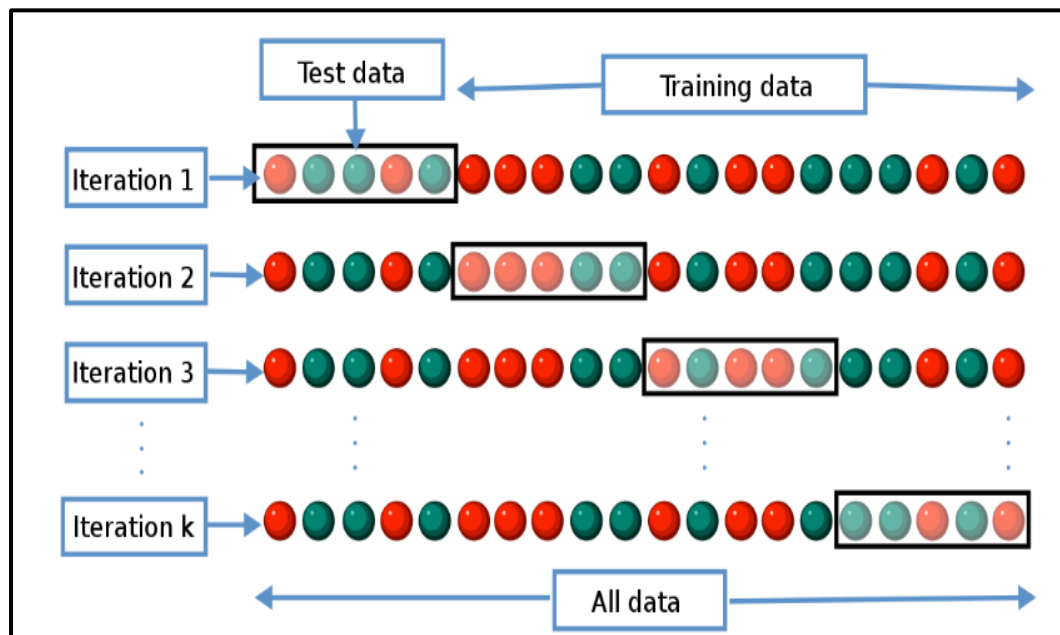


Figure 4.6. Processus de validation croisée

Sur cette la **figure 4.6**, on peut remarquer que le dataset ayant 20 points a été divisé en 4 folds, chaque fold contenant 5 points ou observations. Lors de la première itération, le premier fold sert de données de Test, pendant qu'un modèle est entraîné sur le reste des folds.

A la seconde itération, le modèle est de nouveau entraîné, mais cette fois-ci, sur les données des folds 1, 3 et 4, le second fold servant de données de test, et ainsi de suite.

Avec cette méthode, on s'assure que chaque point de notre dataset a servi une fois au moins au Test et à l'entraînement, tout en respectant le principe selon lequel on ne fait pas de Test que des données qui ont servi à l'entraînement.

4.5 Critères de validation et de performances des modèles

Il existe de nombreux critères de validation des modèles utilisés dans les simulations et/ou dans les prévisions, ces critères sont classés en deux groupes : les mesures statistiques ou numériques et les indicateurs graphiques.

4.5.1 Critères statistiques

Suit a plusieurs travaux mentionnés dans la littérature, les performances des modèles utilisés pour estimer les volumes totaux alloués à l'AEP et l'irrigation, ont été évaluées moyennant les quatre critères statistiques couramment utilisés (Khosravi et al., 2018 ; Kisi et Yaseen, 2019), à savoir : l'erreur quadratique moyenne (RMSE), le coefficient de corrélation (R), l'erreur absolue moyenne (MAE) et l'efficacité de Nash-Sutcliffe (NSE), ont été calculés en utilisant l'ensemble des données, en phase apprentissage et validation.

Le coefficient de corrélation de Pearson (R) est habituellement le plus utilisé pour évaluer les performances des modèles hydrologiques (Legates et McCabe, 1999). Il est obtenu en calculant la régression linéaire entre les valeurs (VTAL) calculées et les valeurs (VTAL) observées ou mesurées. Sa formulation est donnée par l'équation (Eq. 4.16), Le coefficient de corrélation est compris toujours entre -1 et 1.

$$R = \frac{\frac{1}{N} \sum_{i=1}^N ((VTAL_o)_i - (VTAL_o)_m) ((VTAL_p)_i - (VTAL_p)_m)}{\sqrt{\frac{1}{N} \sum_{i=1}^N ((VTAL_o)_i - (VTAL_o)_m)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N ((VTAL_p)_i - (VTAL_p)_m)^2}} \quad (-1 < R \leq +1) \quad (4.16)$$

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

La racine carrée de l'erreur quadratique moyenne (RMSE) (Eq. 4.17) est l'un des critères d'évaluation les plus utilisés dans les travaux de recherche de modélisation (Adnan et al., 2023 ; Kim et al., 2023). Elle donne une indication quantitative sur l'erreur des calculs obtenue par le modèle de prévision. Il détermine la déviation de la prévision et de la simulation par rapport à la valeur observée.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N ((\text{VTAL}_0)_i - (\text{VTAL}_p)_i)^2} \quad (0 \leq \text{RMSE} < +\infty) \quad (4.17)$$

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

L'Erreur moyenne absolue (MAE) définit la valeur moyenne de la différence absolue entre les valeurs calculées et mesurées. Un MAE bas signifie une bonne performance de modèle. Une parfaite concordance entre les valeurs observées et celles simulées produit un MAE=0. Le MAE est calculée par (Eq. 4.18):

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |((\text{VTAL}_0)_i - (\text{VTAL}_p)_i)| \quad (0 \leq \text{MAE} < +\infty) \quad (4.18)$$

Le coefficient d'efficacité de Nash-Sutcliffe (NSE) fournit une mesure de la performance des modèles de prévision ou de simulation en comparant les valeurs observées aux valeurs prédites. Il est largement utilisé dans divers domaines scientifiques pour évaluer la qualité des modèles et guider leur amélioration (Merabet et Heddam, 2023; Alizamir et al., 2023). Le NSE est calculée par (Eq. 4.19)

$$\text{NSE} = 1 - \frac{\sum_{i=1}^N ((\text{VTAL}_0)_i - (\text{VTAL}_p)_i)^2}{\sum_{i=1}^N ((\text{VTAL}_0)_i - (\text{VTAL}_p)_m)^2} \quad (-\infty < \text{NSE} \leq 1) \quad (4.19)$$

Plus NSE tend vers 1, meilleure sera l'adéquation entre les valeurs calculées et observées.

Dans lesquelles, N est le nombre de données, $(\text{VTAL}_0)_i$, $(\text{VTAL}_p)_i$, $(\text{VTAL}_0)_m$, $(\text{VTAL}_p)_m$ sont les valeurs mesurées, et estimées, ainsi que les valeurs moyennes mesurées et estimées des VTAL (hm^3), respectivement.

4.5.2 Critères graphiques

Pour obtenir une compréhension visuelle de la performance des modèles, nous avons tracé les courbes de variations des valeurs des VTAL mesurées et calculées, des scatterplots, des diagrammes en boîte (Williamson et al., 1989), des diagrammes de Taylor (Taylor, 2001), des diagrammes de violon (Hintze et Nelson, 1998).

Le diagramme en boîte ou boîte moustaches fourni un aperçu des capacités des modèles en utilisant les valeurs extrêmes, les médianes et les prédictions du premier et du troisième quartile.

Le diagramme de Taylor est un graphique polaire comportant trois statistiques : le coefficient de corrélation, l'écart-type normalisé (variance) et l'erreur quadratique moyenne. Plus les valeurs du modèle sont proches des observations dans le diagramme de Taylor, meilleure est la performance (Sigaroodi et al., 2014).

Le diagramme de violon est un diagramme en boîte incorporé à des diagrammes de densité de noyau, pour indiquer la distribution de probabilité des données (Choubin et Malekian, 2017 ; Choubin et al., 2017a).

4.6 Logiciels utilisés

Les modèles précédemment mentionnés ont été implémentés à l'aide de deux principaux codes de calculs distincts, à savoir ; Matlab et R.

Matlab (MATrix LABoratory) version 2020b, utilisé pour MLPNN, est un logiciel de calcul numérique et de programmation développé par MathWorks. Il est largement employé dans le domaine de l'ingénierie, offrant des fonctionnalités avancées de calcul, d'analyse de données et de modélisation mathématique.

R (version 4.1.3Rb), utilisé pour les deux autres modèles RFR et SVR, est un langage de programmation ainsi qu'il est un logiciel open-source. Il propose des outils pour la modélisation statistique et la prévision, incluant des packages pour modèles de séries chronologiques, des réseaux de neurones, des arbres de décision, ainsi que des méthodes de Machine Learning.

En outre, les logiciels Excel 2010 et Origin 2021 ont été utilisés pour fournir des outils de visualisation permettant de créer des graphiques, des diagrammes et des tableaux. Ceci vise à présenter les données de manière visuelle et compréhensible, facilitant ainsi l'analyse et la prise de décision.

4.7 Conclusion

Dans ce chapitre, nous avons tenté de fournir une brève description des modèles de Machine Learning utilisés dans cette étude, à savoir : le SVR, le RFR et le MLPNN, en mettant en lumière leurs applications, leurs catégories et leurs caractéristiques, ainsi que leurs diverses architectures. Nous avons également introduit la technique de validation croisée, suivie d'une vue d'ensemble sur les critères de performance.

Enfin, nous avons donné une brève description de différents codes de calculs et logiciels utilisés pour le bon aboutissement de cette étude.

Chapitre 5 : Modélisation des volumes totaux alloués par les barrages

Chapitre 5 : Modélisation des volumes totaux alloués par les barrages

5.1 Introduction

En pratique, le fonctionnement des barrages-réservoirs est extrêmement complexe car il implique des paramètres hydrologiques tels que les apports (APP) et l'évaporation (EVAP), et des paramètres opérationnels tels que les niveaux d'eau (COTE) dans les barrages, les volumes d'eau stockés (VOL), les volumes d'eau vidés (VID) et les volumes déchargés (EVAC), ainsi que le VTAL. Cependant, le VTAL est essentiel à la gestion efficace et efficiente des barrages-réservoirs, car il fait partie intégrante de leurs règles d'exploitation. Par conséquent, l'estimation du VTAL est particulièrement importante pour l'exploitation à court et à long terme des barrages. En effet, il permet l'amélioration du niveau de vie de l'homme en facilitant l'accès à l'eau domestique et d'irrigation.

Avec les progrès de l'informatique au cours des dernières décennies, plusieurs chercheurs se sont concentrés sur l'application des algorithmes de ML dans le domaine de l'hydrologie et de la gestion des ressources en eau (Di Nunno et al., 2023).

Dans ce chapitre, nous procédons à une comparaison des résultats obtenus par les modèles de ML, à savoir MLPNN, RFR et SVR, lorsqu'ils sont appliqués directement aux données historiques des paramètres d'exploitation de deux barrages réservoirs situés dans le nord-est de l'Algérie sur une période de huit ans (2009-2017). Cette analyse diagnostique vise à évaluer l'efficacité de ces algorithmes dans l'estimation du VTAL. Pour ce faire, nous avons optimisé le nombre de variables d'entrée et sélectionné les meilleures combinaisons de ces variables. Enfin, nous avons développé et étudié vingt et un (21) modèles de ML afin d'atteindre notre objectif.

5.2 Développement des modèles

5.2.1 Stratégie de développement du meilleur modèle

L'organigramme présenté dans la **figure 5.1** expose le processus engagé pour développer le modèle le plus performant en matière de prévision des volumes totaux alloués pour l'alimentation en eau potable et l'irrigation.

Le processus de développement et de validation des modèles d'estimation du VTAL se déroule en trois étapes principales. La première étape consiste à collecter, traiter et mettre à jour la base de données. La deuxième étape se focalise sur la sélection de la combinaison optimale de variables d'entrée afin de construire le modèle basé sur l'intelligence artificielle,

en identifiant les relations entre les variables à l'aide de techniques de corrélation. La troisième étape implique le développement des modèles de machine Learning (MLPNN, RFR et SVR) en utilisant les vecteurs déterminés lors de la deuxième étape. Enfin, en se basant sur des critères de performance prédéfinis, le modèle le plus adéquat est sélectionné.

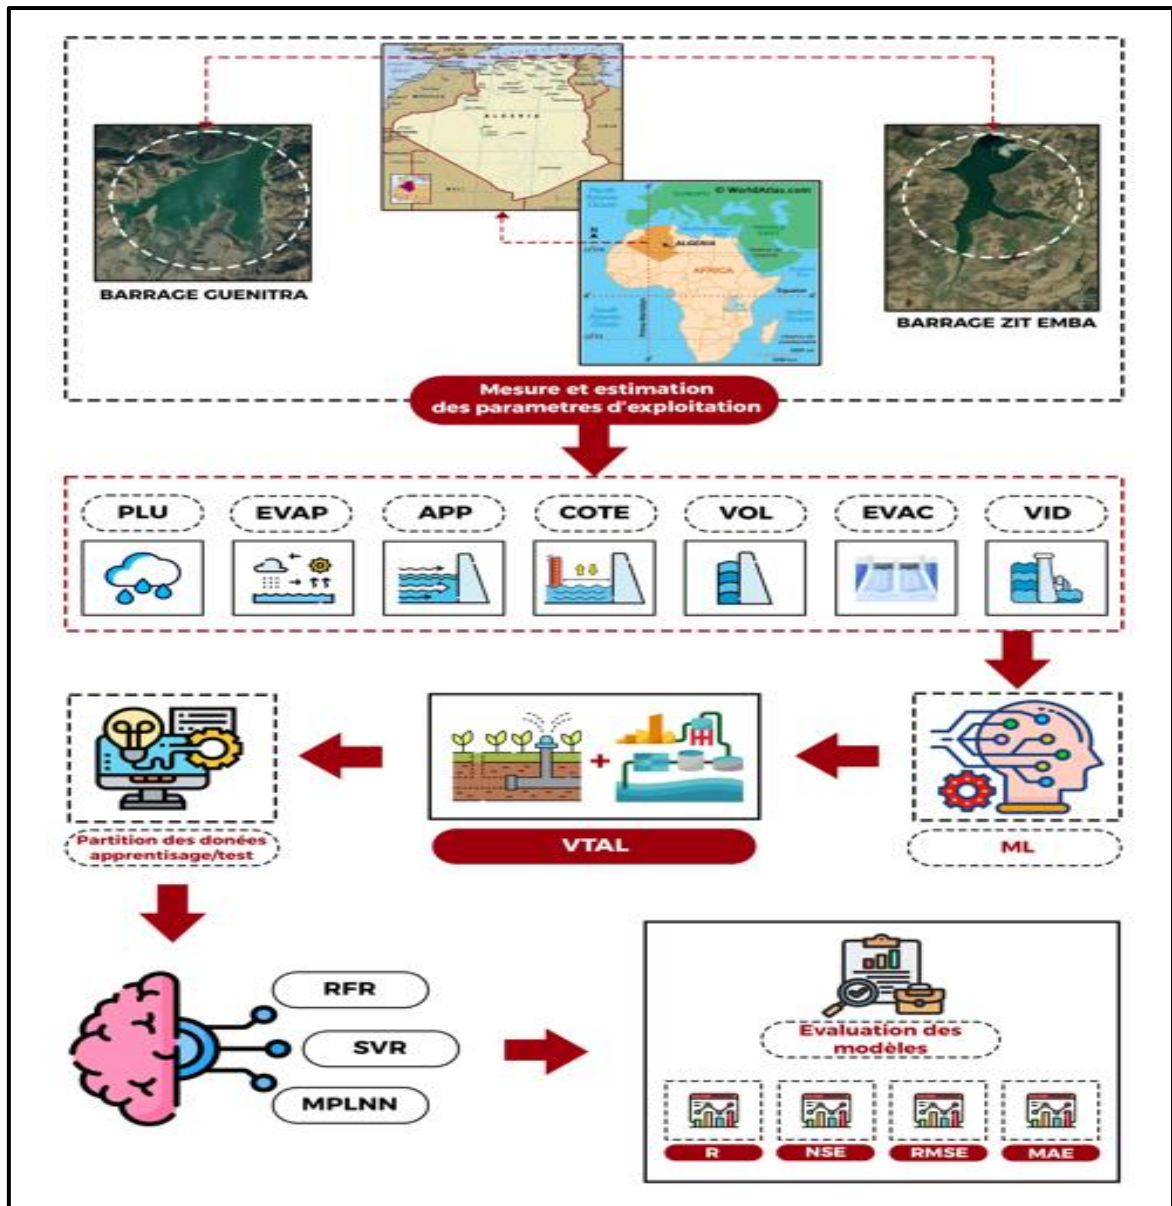


Figure 5.1. Organigramme de modélisation du VTAL

5.2.2 Identification des combinaisons des variables d'entrée

La modélisation consiste, en premier lieu, à sélectionner les variables explicatives les plus appropriées parmi l'ensemble des variables d'entrée acquises (Hu et Wan., 2009 ; Bahrami et Wigand., 2018). Cette étape est considérée comme un défi pour les modélisateurs (Afan et al., 2020). Il est donc crucial de développer une méthode capable de déterminer les combinaisons d'entrée optimales.

On calcule la matrice des corrélations lorsque l'on souhaite appréhender plusieurs variables simultanément. Elle retranscrit les corrélations entre les variables prises deux à deux. Elle est symétrique, et la diagonale de la corrélation d'une variable avec elle-même est égale à 1. Le coefficient de corrélation sert avant tout à caractériser une relation linéaire positive ou négative entre la variable à expliquer et les variables explicatives, plus il est proche de 1 (en valeur absolue), plus la relation est forte. Si le coefficient de corrélation est proche de 0, la relation indique l'absence de corrélation.

Sur la base des coefficients de corrélation entre les variables explicatives et le VTAL (**tableau 5.1**) et de l'analyse du bilan hydrique du barrage, sept combinaisons de variables d'entrée ont été générées. La corrélation entre l'EVAP et le VTAL a été démontrée avec une forte relation linéaire ($R \approx 0,73$) pour le barrage Zit Emba et une bonne relation linéaire ($R \approx 0,36$) pour le barrage Guenitra. De ce fait la variable EVAP a été incluse dans les sept combinaisons d'intrants conçues dont trois hydrologiques à savoir les apports (APP), la pluie (PLU) et l'évaporation (EVAP), et quatre d'exploitation tels que les niveaux d'eau dans les barrages (COTE), les volumes d'eau stockés (VOL), les volumes d'eau vidangés (VID), les volumes d'eau déversés (EVAC). Les différentes combinaisons d'entrées utilisées dans la modélisation des volumes totaux alloués à l'AEP et l'irrigation (VTAL) sont synthétisées dans le **tableau 5.1**.

Tableau 5.1. Différentes combinaisons d'entrée utilisées dans la modélisation

N°	Différentes combinaisons entrée
1	EVAP
2	VOL, EVAP
3	APP, EVAC, EVAP
4	APP, PLU, EVAC, EVAP
5	COTE, VOL, APP, VID, EVAP
6	COTE, VOL, APP, VID, EVAC, EVAP
7	COTE, VOL, APP, PLU, VID, EVAC, EVAP

5.2.3 Partitionnement des données

Les séries de données sélectionnées dans le [chapitre3](#), (§ [section 3.4.2](#)), sont fractionnées en deux sous-ensembles, à savoir l'ensemble d'apprentissage et l'ensemble de validation. L'ensemble d'apprentissage est utilisé pour ajuster les modèles d'apprentissage automatique, tandis que l'ensemble de validation est utilisé pour évaluer la capacité prédictive de ces modèles à l'aide de critères de performance prédéfinis. Il est essentiel de signaler que

la valeur de l'ensemble d'apprentissage soit supérieure à celle de l'ensemble de validation, car il est nécessaire d'entraîner le modèle de données avant de le tester.

Les chercheurs ont sélectionnés un taux d'entraînement compris entre 70 % et 95 % (Ahmed, et al., 2019 ; Soleymani et al., 2016 ; Muslim, et al., 2020). Ainsi, le rapport optimal entre le nombre de données d'apprentissage et de données de validation est de 70 % et 30 %, (dans notre cas 2046 données et 876 données). Cette approche de division 70 : 30 est largement adoptée pour l'apprentissage et la validation des modèles, bien qu'il n'existe pas de ligne directrice officielle à ce sujet (Ayele et al., 2017). Il est généralement recommandé que le partitionnement des données soit effectué de manière à assurer que les ensembles d'apprentissage et de validation possèdent des caractéristiques statistiques similaires.

5.2.4 Structures des modèles

Dans cette étude, trois techniques de Machine Learning ont été employées afin de modéliser les volumes totaux alloués pour l'alimentation en eau potable et l'irrigation, à savoir la forêt aléatoire (RFR), le perceptron multicouche (MLPNN) et la machine à vecteurs de support (SVR). L'implémentation de ces modèles a été réalisée à l'aide de deux logiciels distincts : Matlab 2020b pour le MLPNN et R4.1.3Rb pour le RFR et le SVR. Les structures de ces modèles sont détaillées dans le **tableau 5.2**.

Tableau 5.2. Structure des modèles utilisés durant la modélisation de VTAL

Modèles		Variables entrées (Inputs)		Output
RFR1	MLPNN1	SVR1	EVAP	VTAL
RFR2	MLPNN2	SVR2	VOL, EVAP	VTAL
RFR3	MLPNN3	SVR3	APP, EVAC, EVAP	VTAL
RFR4	MLPNN4	SVR4	APP, PLU, EVAC, EVAP	VTAL
RFR5	MLPNN5	SVR5	COTE, VOL, APP, VID, EVAP	VTAL
RFR6	MLPNN6	SVR6	COTE, VOL, APP, VID, EVAC, EVAP	VTAL
RFR7	MLPNN7	SVR7	COTE, VOL, APP, PLU, VID, EVAC, EVAP	VTAL

Avec :

COTE : Niveau d'eau dans le réservoir du barrage (m), **VOL** : Volume stocké (hm^3), **APP** : Apport (hm^3), **EVAP** : Evaporation (hm^3), **VID** : Volumes vidangé (hm^3), **PLU** : Pluie (mm), **EVAC** : Volumes déchargé (hm^3), **VTAL** : Volume total allouer (hm^3).

5.2.5 Paramétrage des modèles

Les différents modèles utilisés possèdent différent type de paramètres à optimiser durant la phase d'apprentissage. Pour le modèle MLPNN, nous avons utilisés un modèle à trois couches : couche d'entrée, couche cachée et couche de sortie. Pour les fonctions d'activation, nous avons choisi la fonction sigmoïde pour les neurones de la couche cachée et la fonction linéaire pour le neurone de sortie. L'apprentissage du réseau s'est fait en utilisant l'algorithme de Rétropropagation du gradient. Le nombre de neurones dans la couche d'entrée est égale au nombre de variables du bilan hydrique du barrage selon la combinaison choisie (de 1 à 7). Nous avons fait varier le nombre de neurones de la couche cachée de 1 à 20, et le nombre optimal varie d'un barrage à l'autre et d'un modèle à l'autre. Pour le modèle RFR, la valeur de "ntree" a été fixée à 50, avec une nodosité de 5, tout en utilisant K-fold égal 10. Enfin, le modèle SVR utilise la fonction kernel (RBF), avec un gamma optimal déterminé en utilisant une fonction d'acquisition qui choisit la prochaine valeur de gamma à tester en fonction des résultats précédents du SVR, pour éviter le sur-apprentissage ou le sous-apprentissage. Ce modèle a également été exécuté avec une K-fold égal 10.

5.3 Résultats de la modélisation

L'objectif principal de cette étude consiste à élaborer un modèle permettant d'estimer les volumes d'eau alloués à l'approvisionnement en eau potable (AEP) et à l'irrigation en utilisant des modèles d'apprentissage automatique (ML). Pour ce faire, les données historiques quotidiennes de la gestion de deux barrages, à savoir Zit Emba et Guenitra, sur une période de huit ans (2009-2017), ont été utilisées. Huit variables d'exploitation du barrage ont été identifiées et combinées de sept manières différentes. Quatre critères statistiques, à savoir R, NSE, RMSE et MAE, ont été calculés pendant la phase d'apprentissage et de validation afin de déterminer la meilleure combinaison d'entrées.

Les résultats sont présentés séparément pour chaque barrage dans les **tableaux 5.3 & 5.4**. En complément des résultats numériques, nous exposerons des résultats graphiques pour les modèles les plus performants de chaque barrage à travers des illustrations Scatterplots, Boxplots, Violin plots, et diagramme de Taylor (**figures 5.2 à 5.9**). Étant donné que la phase de validation revêt une importance capitale, notre analyse se focalisera sur les résultats obtenus par les divers modèles au cours de cette étape.

5.3.1 Influence des variables sur les performances des modèles

Les résultats obtenus démontrent que la combinaison d'entrée C5 a une influence plus significative sur les performances des modèles RFR, MLPNN et SVR, malgré le fait que les variables COTE, VOL, APP et VID ne soient pas fortement corrélées avec VTAL. [Khosravi et al. \(2018\)](#) l'ont également signalé dans leur travail de recherche sur la quantification de la charge horaire de sédiments en suspension au niveau du bassin versant andin glaciaire au Chili. La combinaison d'entrée C1, qui se concentre uniquement sur l'évaporation de l'eau du barrage, s'avère plus efficace que les combinaisons C2, C3 et C4 pour le modèle RFR. Elle présente le même impact que la combinaison C7 et est compétitive en matière d'efficacité par rapport aux combinaisons C5 et C6. Par ailleurs, les données des [tableaux 5.3 et 5.4](#) indiquent que la combinaison C2 a un impact majeur sur les performances des trois modèles pour l'estimation de VTAL, par rapport aux combinaisons C1, C3 et C4 qui ont tendance à le sous-estimer. Les résultats révèlent également que l'influence des combinaisons C5, C6 et C7 sur les performances des modèles RFR et SVR est similaire, tandis qu'elle est compétitive pour les modèles MLPNN. Il convient de noter que ces conclusions sont spécifiques à cette étude et que d'autres variables pourraient influencer les performances des modèles. En résumé, il est recommandé d'analyser la meilleure combinaison de variables d'entrées pour chaque ensemble de données, sans se limiter aux variables fortement corrélées ([Melesse et al., 2020](#)).

5.3.2 Résultats de la modélisation du VTAL par le Barrage Zit Emba

Les résultats obtenus pour le barrage Zit Emba sont consignés au [tableau 5.3](#). Ce tableau permet de comparer les différentes valeurs des critères de performance (R, NSE, RMSE, MAE). En effet, nous pouvons s'apercevoir que ces résultats varient d'un modèle à un autre lors des phases d'apprentissage et de validation. Les moyennes des valeurs de R et NSE pour les trois modèles, en phase validation, varient respectivement de 0.887 à 0.787 pour le meilleur modèle qui est le RFR. En revanche pour le modèle le moins performant, qui est le SVR, elles varient respectivement de 0.767 à 0.583. Les meilleurs résultats sont obtenus par le modèle RFR5 avec des indices de performance de l'ordre de ($R \approx 0.920$, $NSE \approx 0.846$, $RMSE \approx 0.006$, $MAE \approx 0.008$), par contre les performances les plus faibles sont obtenues par le modèle RFR3 avec des critères de performance de l'ordre de ($R \approx 0.837$, $NSE \approx 0.700$, $RMSE \approx 0.008$, $MAE \approx 0.006$). Les modèles SVR1 et SVR3 obtiennent les résultats les plus faibles au niveau du barrage Zit Emba, avec des indices similaires en termes de R, NSE, RMSE, MAE, à savoir respectivement 0.719, 0.505, 0.012 et 0.009. Cependant, le modèle

SVR5 a obtenu des résultats satisfaisants avec des valeurs de R et NSE de 0.795 et 0.628 respectivement. En ce qui concerne les modèles MPLNN, le modèle MLPNN5 a donné les meilleurs résultats avec des coefficients R et NSE de 0.863 et 0.742, tandis que le modèle MLPNN4 a obtenu des résultats plus faibles avec des coefficients R et NSE de 0.760 et 0.576 respectivement. Enfin, en analysant les résultats des différents modèles pour le barrage Zit Emba, nous pouvons conclure ce qui suit :

1. Les modèles RFR5, MLPNN5 et SVR5 ont obtenu les meilleurs résultats par rapport aux autres modèles lors de la phase de validation, avec des valeurs respectives de R de 0.920, 0.863 et 0.795.
2. Le modèle RFR5 s'est révélé être le plus performant par rapport aux autres modèles, avec des valeurs de (R=0.920, NSE=0.864, RMSE=0.006, MAE=0.003).

Tableau 5.3. Résultats obtenus par les modèles ML au niveau du barrage Zit Emba

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN1	0.752	0.566	0.010	0.007	0.762	0.580	0.011	0.008
MLPNN2	0.86	0.739	0.009	0.006	0.855	0.730	0.009	0.006
MLPNN3	0.761	0.580	0.011	0.008	0.763	0.416	0.013	0.009
MLPNN4	0.751	0.563	0.011	0.008	0.76	0.576	0.011	0.008
MLPNN5	0.884	0.781	0.008	0.005	0.863	0.742	0.008	0.006
MLPNN6	0.857	0.735	0.009	0.006	0.83	0.688	0.009	0.007
MLPNN7	0.876	0.767	0.008	0.006	0.846	0.689	0.009	0.007
RFR1	0.986	0.971	0.003	0.001	0.918	0.843	0.006	0.003
RFR2	0.941	0.881	0.005	0.004	0.853	0.728	0.008	0.006
RFR3	0.896	0.801	0.007	0.004	0.837	0.700	0.008	0.006
RFR4	0.898	0.804	0.007	0.004	0.843	0.707	0.008	0.006
RFR5	0.986	0.971	0.003	0.001	0.92	0.846	0.006	0.003
RFR6	0.986	0.971	0.003	0.001	0.919	0.844	0.006	0.003
RFR7	0.986	0.971	0.002	0.001	0.918	0.843	0.006	0.003
SVR1	0.746	0.547	0.011	0.008	0.719	0.505	0.012	0.009
SVR2	0.753	0.557	0.010	0.007	0.758	0.562	0.010	0.007
SVR3	0.755	0.56	0.011	0.008	0.719	0.505	0.012	0.009
SVR4	0.809	0.652	0.010	0.007	0.794	0.626	0.011	0.008
SVR5	0.811	0.654	0.010	0.007	0.795	0.628	0.011	0.008
SVR6	0.812	0.656	0.010	0.007	0.793	0.626	0.011	0.008
SVR7	0.816	0.663	0.010	0.007	0.793	0.628	0.011	0.008

5.3.3 Résultats de la modélisation du VTAL par le Barrage Guenitra

Les résultats obtenus au niveau du barrage Guenitra sont reportés au niveau du **tableau 5.4**. Les divers modèles démontrent de bonnes performances tant en phase d'apprentissage, qu'en phase de validation, et révèlent les mêmes ordres de grandeur de performance lors de la simulation du VTAL. Nous remarquons que les modèles RFR se distinguent par leur performance en produisant des valeurs de VTAL qui sont proches des valeurs mesurées avec de faibles erreurs et légèrement supérieures à celles des modèles MLPNN et SVR. Nous pouvons observer que le modèle RFR5 donne les meilleures valeurs pour R (≈ 0.886), NSE (≈ 0.784), RMSE (≈ 0.020) et MAE (≈ 0.013). Les modèles MLPNN5, et SVR5 ont donné des performances légèrement inférieures au RFR5 avec des valeurs de R et NSE de (0.876, 0.750) et (0.867, 0.744) respectivement. En termes de valeurs moyennes, les modèles RFR donnent des valeurs moyennes les plus élevées pour R (≈ 0.870) et NSE (≈ 0.754) ainsi que les valeurs moyennes les plus faibles pour RMSE (≈ 0.022) et MAE (≈ 0.015), suivis par les modèles MLPNN et SVR, respectivement. Les modèles RFR2, MLPNN2 et SVR2 ont montré de faibles performances par rapport aux autres modèles. Les coefficients R et NSE sont respectivement de (0.790, 0.621), (0.771, 0.572) et (0.743, 0.544). En analysant les résultats obtenus par les différents modèles au niveau du barrage Guenitra, nous résumons que :

1. Les modèles RFR5, MLPNN5 et SVR5 se distinguent en produisant les meilleurs résultats par rapport aux autres modèles en phase de validation avec des valeurs de R respectives de 0.886, 0.876 et 0.867. Cela indique qu'ils possèdent une capacité de modélisation supérieure aux autres modèles.
2. La plupart des modèles RFR présentent des performances très similaires en phase de validation, avec des valeurs de R comprises entre 0.881 et 0.886. Cependant, le modèle RFR2 montre une légère dégradation, avec un R de 0.790.

Tableau 5.4. Résultats obtenus par les modèles ML au niveau du barrage Guenitra

Modèles	Apprentissage				Validation			
	R	NSE	RMSE	MAE	R	NSE	RMSE	MAE
MLPNN1	0.873	0.762	0.017	0.010	0.872	0.739	0.022	0.014
MLPNN2	0.800	0.635	0.021	0.012	0.771	0.572	0.028	0.019
MLPNN3	0.874	0.762	0.017	0.009	0.866	0.734	0.022	0.014
MLPNN4	0.868	0.751	0.017	0.01	0.864	0.736	0.022	0.015
MLPNN5	0.928	0.86	0.013	0.008	0.876	0.75	0.022	0.014
MLPNN6	0.868	0.751	0.017	0.010	0.754	0.559	0.029	0.020
MLPNN7	0.890	0.793	0.016	0.009	0.845	0.701	0.024	0.017
RFR1	0.881	0.774	0.016	0.009	0.884	0.773	0.021	0.014
RFR2	0.790	0.627	0.021	0.014	0.79	0.621	0.027	0.019
RFR3	0.863	0.748	0.017	0.011	0.881	0.772	0.021	0.014
RFR4	0.869	0.757	0.017	0.011	0.884	0.777	0.021	0.014
RFR5	0.871	0.760	0.017	0.011	0.886	0.784	0.020	0.013
RFR6	0.868	0.756	0.017	0.011	0.886	0.782	0.020	0.014
RFR7	0.865	0.75	0.017	0.011	0.881	0.772	0.021	0.014
SVR1	0.926	0.852	0.013	0.008	0.860	0.725	0.023	0.016
SVR2	0.893	0.789	0.016	0.01	0.743	0.544	0.029	0.021
SVR3	0.924	0.851	0.013	0.008	0.860	0.723	0.023	0.016
SVR4	0.916	0.839	0.014	0.009	0.854	0.718	0.023	0.016
SVR5	0.881	0.774	0.016	0.009	0.867	0.744	0.022	0.014
SVR6	0.786	0.603	0.022	0.013	0.754	0.559	0.029	0.020
SVR7	0.779	0.604	0.022	0.013	0.781	0.609	0.027	0.018

5.3.4 Comparaison de performances des meilleurs modèles

Après avoir identifié la combinaison d'entrée la plus appropriée pour chaque modèle, les performances des trois modèles utilisés pour modéliser le VTAL ont été évaluées à l'aide de quatre mesures statistiques différentes (**tableau 5.5**). Par la suite, le modèle le plus performant parmi ceux-ci a été identifié. Les graphiques de corrélation entre les données de VTAL estimées et observées, la dispersion des points autour de la droite de régression, les boîtes à moustaches, le diagramme de Violin et le diagramme de Taylor en phase de validation ont été établis et examinés) afin de comparer les meilleurs modèles sélectionnés.

Nous remarquons que les modèles appliqués ont produit des résultats satisfaisants en termes d'estimation du VTAL, tel qu'illustré dans le **tableau 5.5**. Cependant, tous les indicateurs de performance étudiés ont indiqué que le modèle RFR a une précision

d'estimation supérieure à celle des autres modèles. Cette observation s'explique par le fait que, dans une forêt aléatoire, le meilleur estimateur choisi aléatoirement dans un nœud est utilisé pour diviser le nœud, ce qui rend le modèle plus efficace que d'autres modèles tels que le SVR et MPLNN (Khozani et al., 2019).

Le coefficient de corrélation R entre les valeurs simulées par les modèles et les valeurs mesurées du VTAL (**tableau 5.5**) révèle que bien que tous les modèles soient aptes à la modélisation pour les deux barrages Zit Emba et Guenitra, le modèle RFR a une très bonne performance ($R \approx 0.920$ et $R \approx 0.886$) respectivement pour le Zit Emba et Guenitra, tandis que ceux du MLPNN ($R \approx 0.863$ et $R \approx 0.876$) et du SVR ($R \approx 0.794$ et $R \approx 0.867$) sont respectivement bons et satisfaisants (Hinkle et al., 2003 ; Ayele et al., 2017). Toutefois, le coefficient de corrélation R (coefficient de détermination R^2) est vulnérable aux valeurs extrêmes (valeurs aberrantes) et ne prend pas en compte les variations additives et proportionnelles entre les estimations du modèle et les observations. Par conséquent, il ne devrait pas être utilisé seul pour évaluer la performance du modèle (Legates et McCabe., 1999 ; Yaseen et al., 2016).

En ce qui concerne RMSE, le modèle RFR affiche aussi une excellente efficacité de modélisation ($RMSE \approx 0.006$ et $RMSE \approx 0.020$) respectivement pour le Zit Emba et Guenitra, suivi de MPLNN, avec $RMSE \approx 0.008$ et $RMSE \approx 0.022$ et de SVR, avec $RMSE \approx 0.011$ et $RMSE \approx 0.022$. Le modèle RFR démontre également la plus faible valeur MAE ≈ 0.003 et $MAE \approx 0.013$ respectivement pour le Zit Emba et Guenitra, suivi de MLPNN ($MAE \approx 0.006$ et $MAE \approx 0.014$) et de SVR ($MAE \approx 0.008$ et $MAE \approx 0.014$).

En conformité avec le coefficient R, les valeurs du NSE révèlent que tous les modèles donnent de bons résultats. Néanmoins, les performances du modèle RFR sont très bonnes ($NSE \approx 0.847$ et $NSE \approx 0.784$) respectivement pour le Zit Emba et Guenitra, alors que celles du MLPNN ($NSE \approx 0.746$ et $NSE \approx 0.750$) et du SVR ($NSE \approx 0.626$ et $NSE \approx 0.744$) sont respectivement bonne et satisfaisante (Moriasi et al., 2007).

Tableau 5.5. Comparaison des performances des modèles

Barrage	Modèles	R	NSE	RMSE	MAE
Zit EMBA	RFR5	0.920	0.847	0.006	0.003
	MLPNN5	0.863	0.746	0.008	0.006
	SVR5	0.794	0.626	0.011	0.008
Guenitra	RFR5	0.886	0.784	0.020	0,013
	MLPNN5	0.876	0,750	0.022	0.014
	SVR5	0.867	0.744	0.022	0.014

Les **figures 5.2 & 5.3** illustre la corrélation des VTAL estimés par les trois modèles avec ceux mesurés en phase de validation. Cette représentation graphique démontre que tous les modèles ont prédit le VTAL avec une grande précision, ce qui confirme les résultats obtenus en utilisant les critères d'évaluation des modèles mentionnés dans le **tableau 5.5**. En outre, le modèle RFR reflète adéquatement les valeurs extrêmes de VTAL, ce qui témoigne de sa grande capacité d'estimation.

Les résultats présentés par le graphique de dispersion (**figure 5.4**) sont conformes aux résultats consignés au **tableau 5.5** et illustrés par la **figure 5.2 & 5.3**, étant donné que les valeurs estimées sont concentrées autour de la ligne de régression de 45°. Cela justifie le niveau de précision d'estimation des modèles. Néanmoins, les valeurs de VTAL élevées n'ont pas été correctement estimées par les modèles MLPNN et SVR, seul le modèle RFR a réussi à reproduire ces valeurs avec précision.

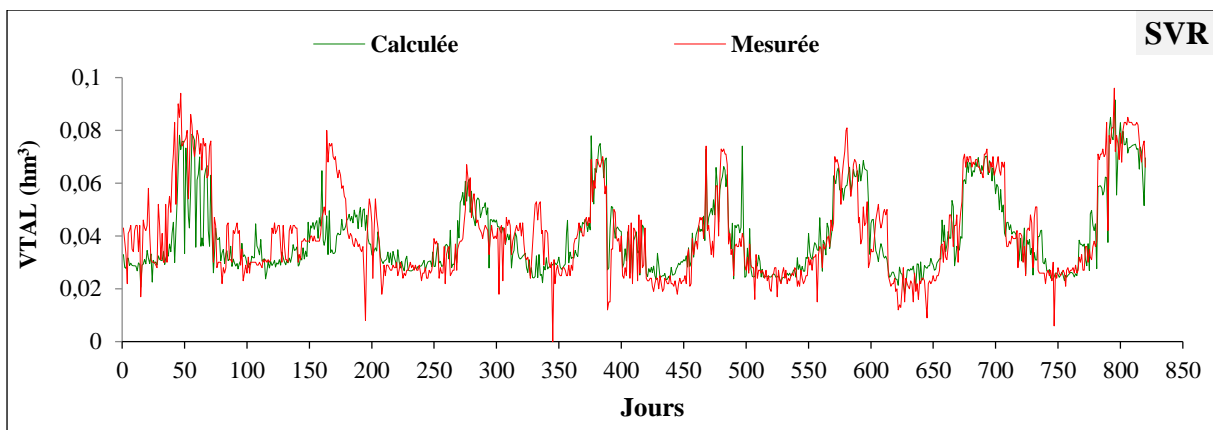
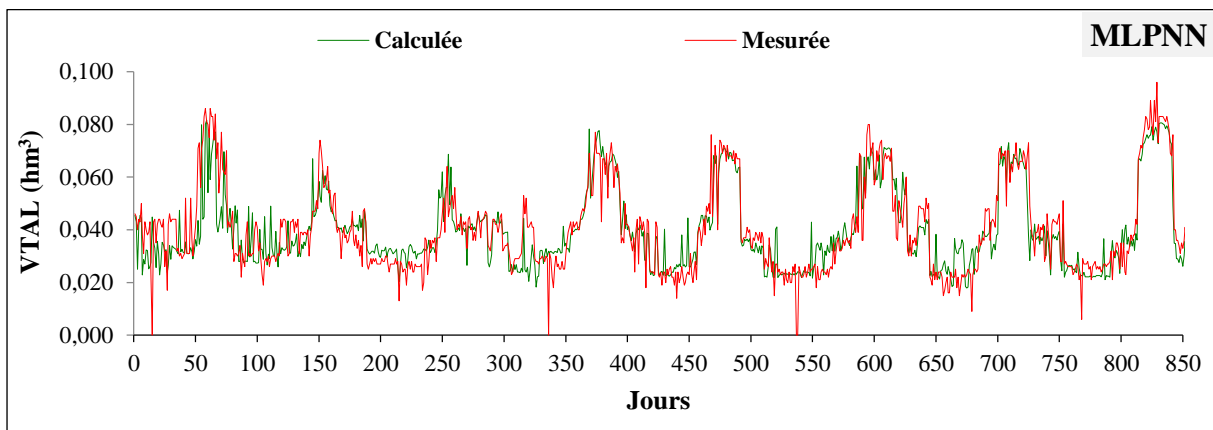



Figure 5.2. Evolution du VTAL mesurée et calculée par les modèles de ML durant la phase de validation, Barrage Zit Emba

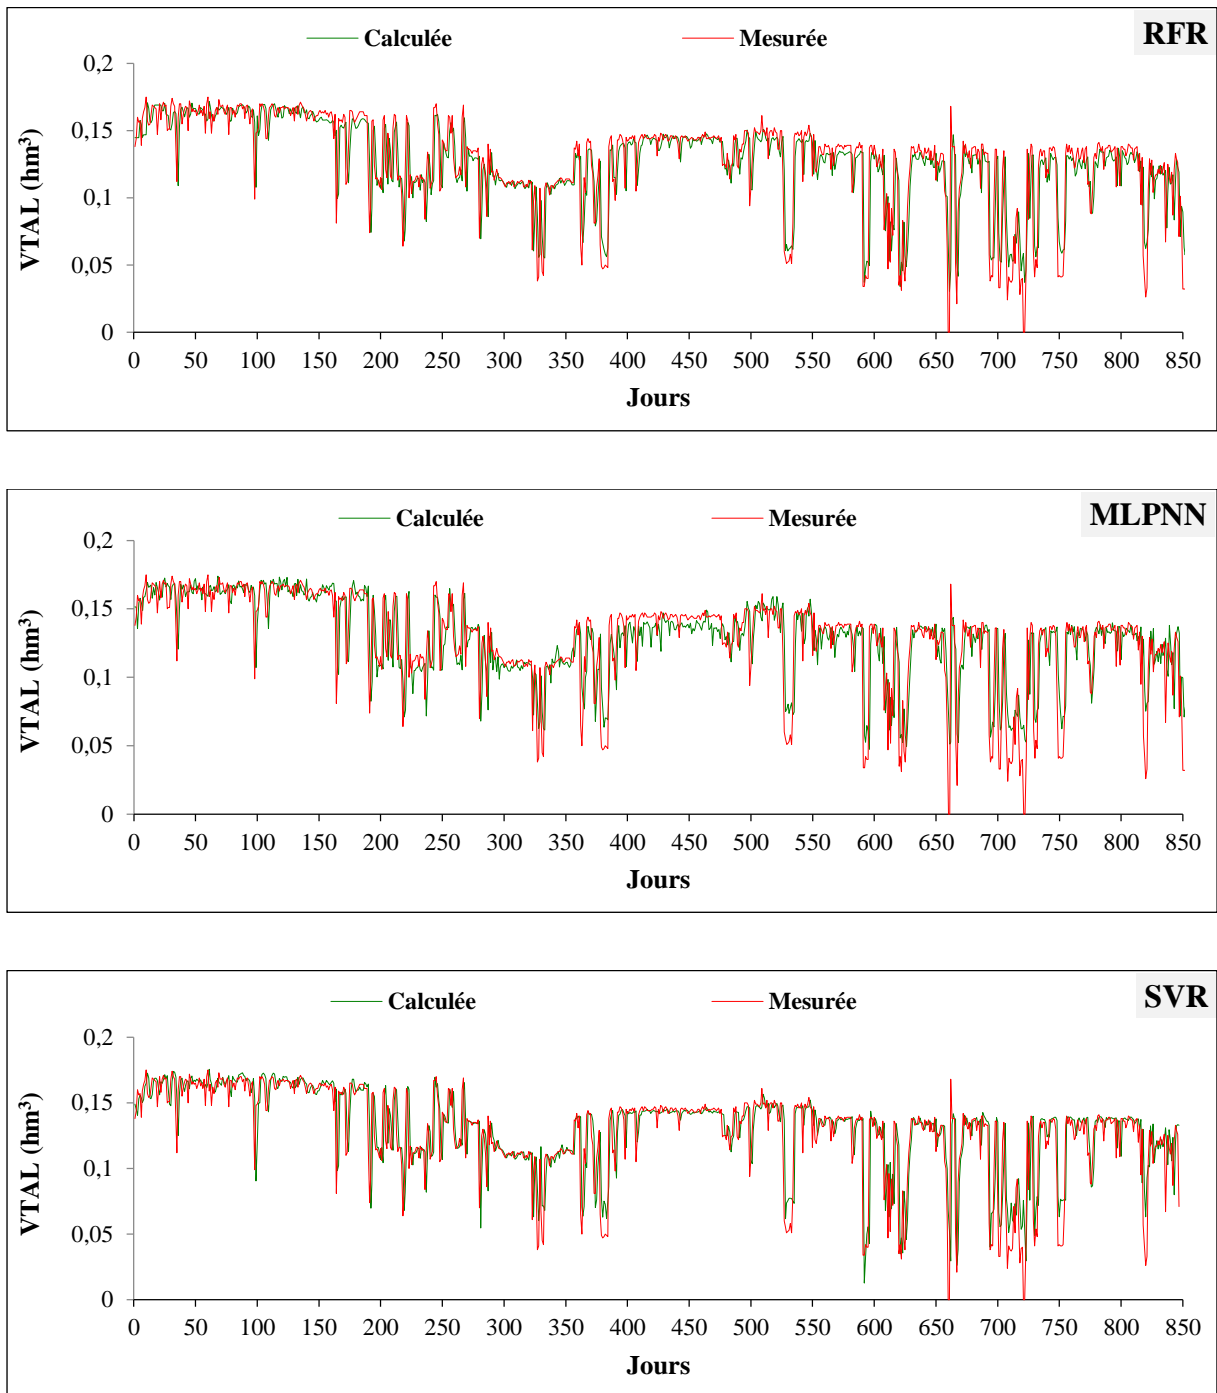


Figure 5.3. Evolution du VTAL mesurée et calculée par les modèles de ML durant la phase de validation, Barrage Guenitra

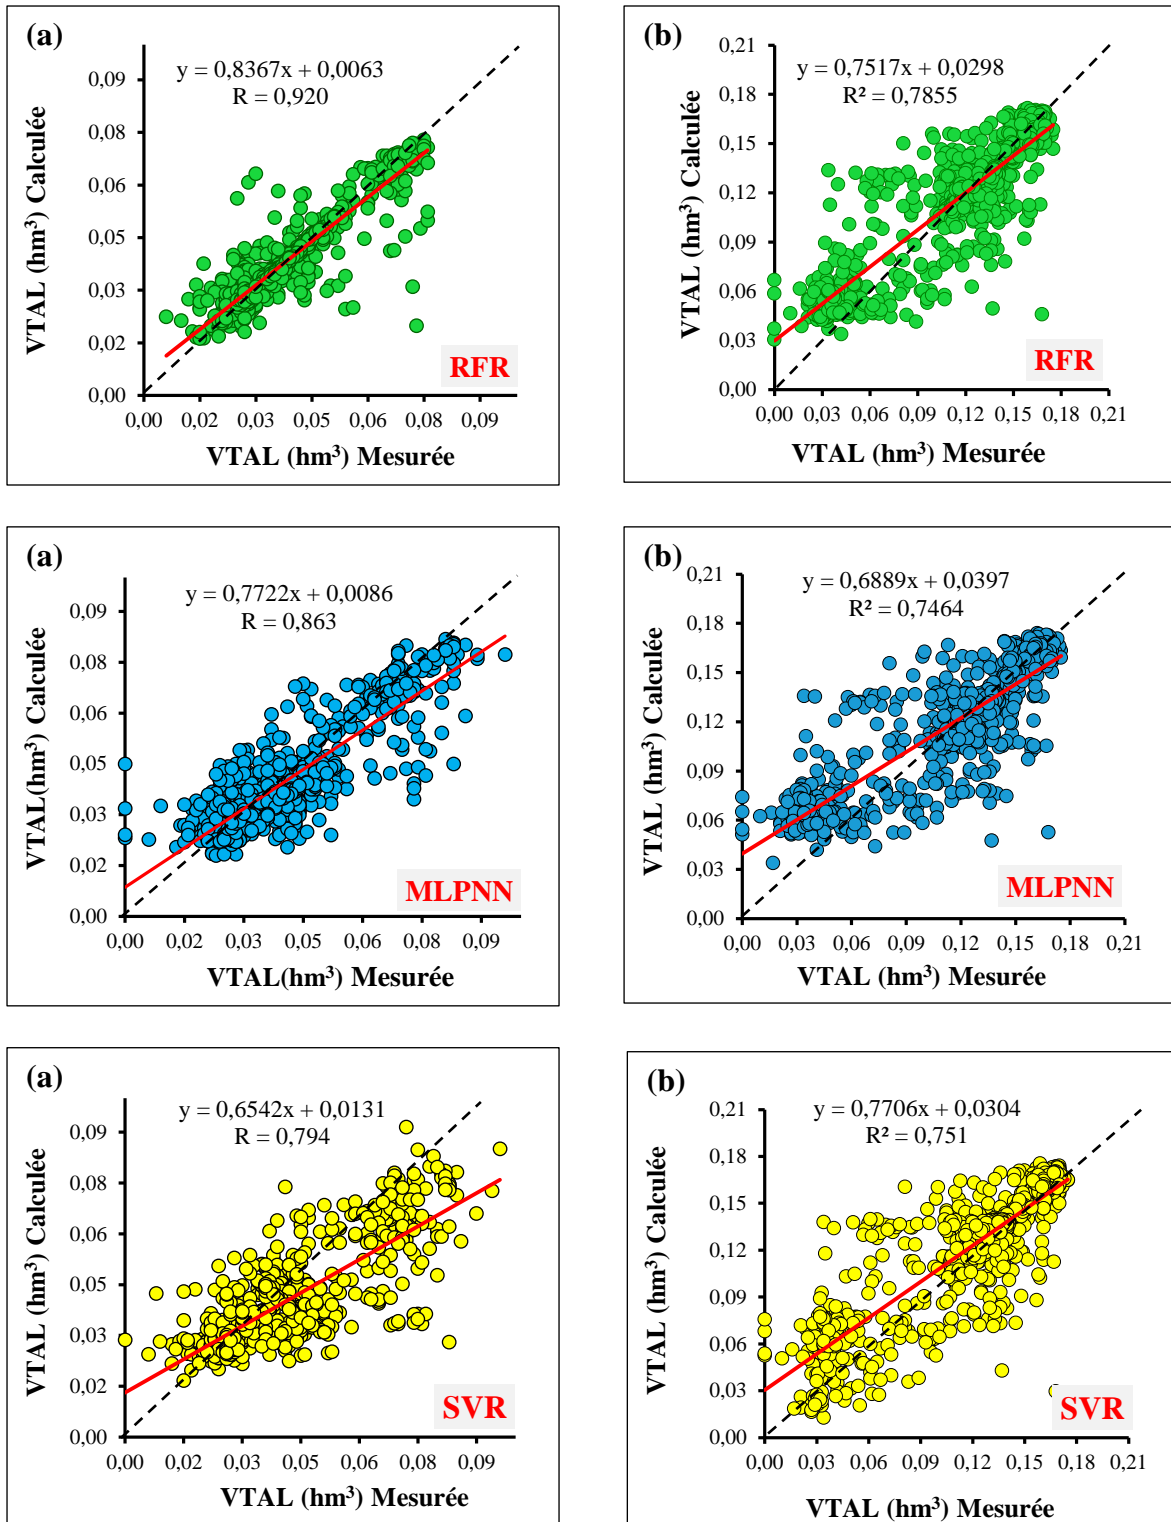


Figure 5.4. Scatterplots des valeurs mesurée et calculée du VTAL durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra

Afin de mieux évaluer la précision des modèles examinés, les diagrammes en boîtes à moustaches (figure 5.5) et les diagrammes en Violin (figure 5.6) des valeurs estimées par rapport aux valeurs mesurées sont générées pour la phase validation. Sur la base de la présentation statistique affichée par la figure 5.5, concernant les médianes, les quartiles et les plages de données, le modèle RFR a obtenu la meilleure performance d'évaluation des données observées, aux barrage Zit Emba et Guenitra, avec une légère erreur, suivi par les modèles MLPNN et SVR. De même que le graphique en boîte à moustaches, le graphique en violon (figure 5.6) montre que les distributions du VTAL obtenues par les modèles employés (RFR, MLPNN et SVR) sont cohérentes avec celles des valeurs observées. En effet, les moyennes des valeurs estimées par les trois modèles sont semblables, bien que pour les médianes, nous remarquons une légère différence pour celle du modèle SVR que ce soit pour le barrage Zit Emba ou le barrage Guenitra.

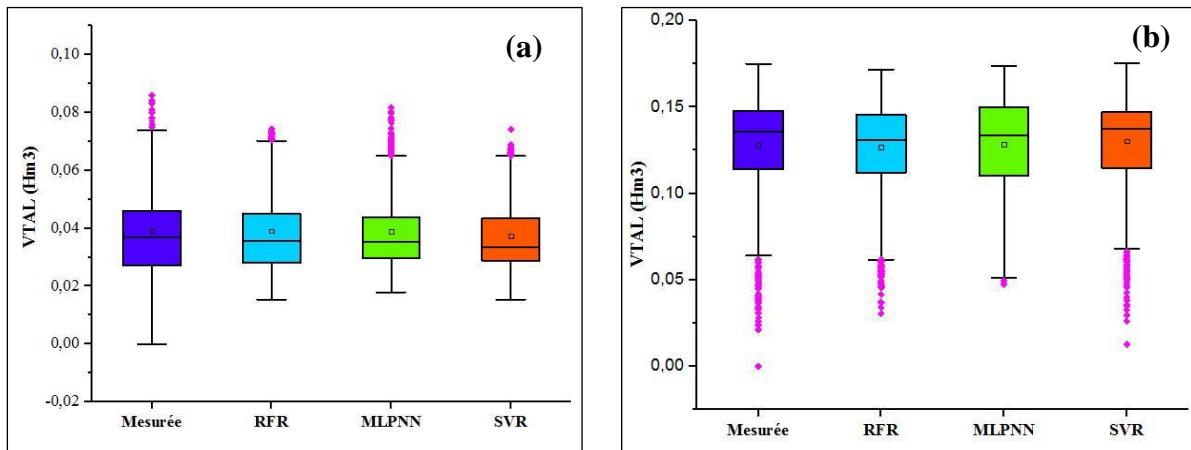


Figure 5.5. Diagrammes Box-plots du VTAL mesurée et calculée durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra

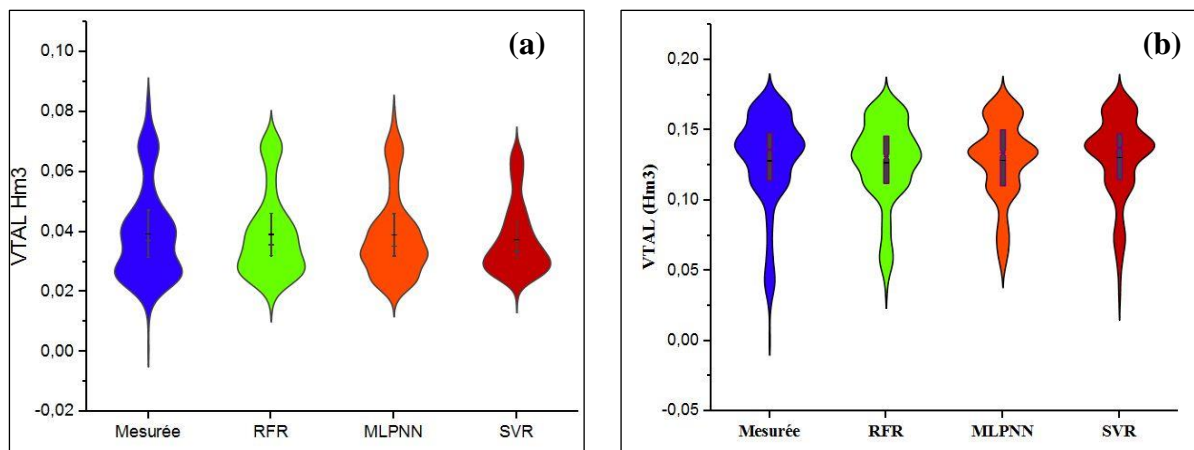


Figure 5.6. Diagrammes Violin du VTAL mesurée et calculée durant la phase de validation : (a) Barrage Zit Emba, (b) Barrage Guenitra

Pour analyser plus en détail l'efficacité des modèles, un diagramme de Taylor représentant à la fois l'écart type et le coefficient de corrélation (R) a été construit (**figure 5.7**). Sur ce diagramme, nous constatons que les valeurs VTAL estimées par les trois modèles (RFR, MLPNN et SVR) sont systématiquement comparables aux valeurs mesurées. Le graphique montre également que le modèle RFR s'ajuste mieux aux observations. Il présente la corrélation la plus élevée avec les données observées et le RMSE le plus faible, tandis que l'écart type normalisé des estimations présente une certaine variabilité. Bien que les modèles MLPNN et SVR aient une corrélation bonne ou satisfaisante avec les observations, le modèle MLPNN simule bien mieux l'amplitude des variations (c'est-à-dire l'écart type) que le modèle SVR, ce qui entraîne une erreur RMSE plus petite.

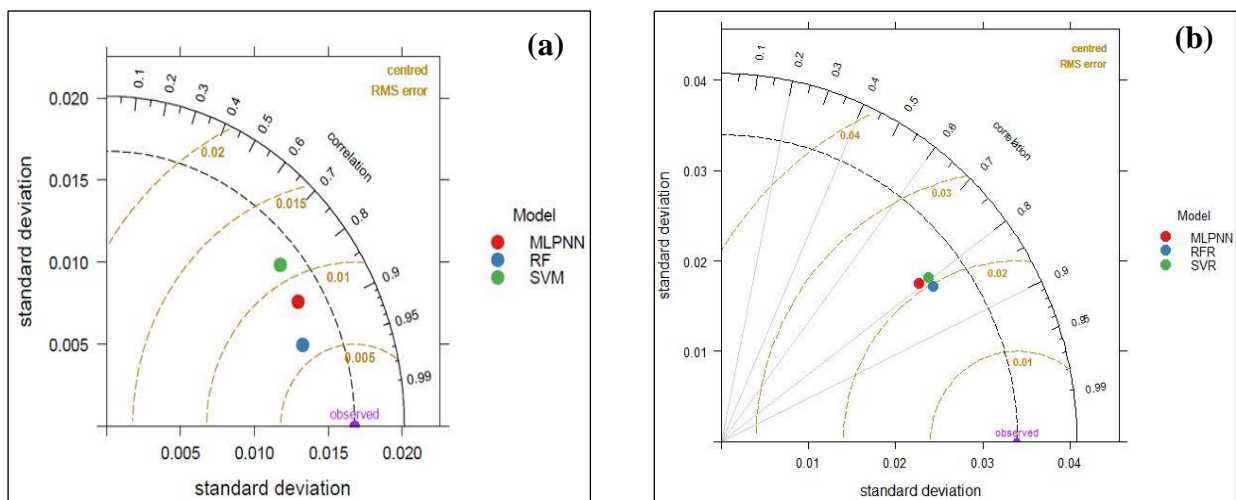


Figure 5.7. Diagramme de Taylor du VTAL durant la phase de validation :
(a) Barrage Zit Emba, (b) Barrage Guenitra

5.4 Discussion

Actuellement, l'utilisation d'algorithmes d'apprentissage automatique en tant qu'outil pratique dans les domaines de l'hydrologie et de la gestion des ressources en eau a connu une croissance rapide (Chang et Guo., 2020), en particulier dans la prévision des inondations (Chang et al., 2019), l'évaluation précise des pertes d'eau par évaporation, surtout dans les régions tropicales et semi-arides, qui est cruciale pour la surveillance et l'affectation adéquate des ressources en eau (Ghorbani et al., 2017 ; Allawi et al., 2021), l'estimation des apports d'eau vers les réservoirs qui est d'une importance majeure pour la planification de l'approvisionnement en aval (Babaei et al., 2019), ainsi que la prévision des autres paramètres hydrologiques et d'exploitation des barrages-réservoirs.

Dans cette étude, trois techniques de ML largement utilisées, RFR, MLPNN et SVR, ont été examinées et comparées pour estimer le VTAL à partir des barrages Zit Emba et Guenitra. Compte tenu du fait que les données observées ont été collectées dans les mêmes conditions expérimentales et durant les mêmes périodes d'observation, la distinction constatée dans les performances des trois modèles d'apprentissage automatique (ML) peut être attribuée à la structure de chaque modèle notamment sa flexibilité, sa capacité d'estimation et sa tendance au surajustement. Les aptitudes de calcul et la complexité de chaque algorithme ont une influence sur leurs performances (Kisi et al., 2019). Des recherches antérieures ont utilisé divers modèles de ML en hydrologie et pour estimer les paramètres de gestion et d'exploitation des barrages. Nos résultats semblent être plus précis ou tout aussi précis que ces études. Toutes ces recherches, y compris la nôtre, ont conclu que les trois algorithmes de ML (RFR, MLPNN et SVR) sont des outils prometteurs pour évaluer les paramètres hydrologiques et d'exploitation des barrages réservoirs (Yang et al., 2017 ; Ahmed et al., 2019 ; Kim et al., 2019 ; Lange et Sippel., 2020). La précision et l'efficacité des trois algorithmes de ML permettent de conclure que ces modèles peuvent aider les professionnels à planifier la gestion des ressources en eau. En effet, Cheng et al. (2015) ont appliqués les réseaux de neurones (ANN), la technique SVR et des modèles hybrides de SVR basés sur un algorithme génétique (SVR-GA) pour prévoir l'apport vers le réservoir de Xinfengjiang. Les algorithmes hybrides de cette étude ont donné les meilleurs résultats ($R \approx 0.91$), par contre les algorithmes individuels ANN ($R \approx 0.87$) et SVM ($R \approx 0.89$) ont affichés des pouvoirs de prédiction moins élevés. Cependant, le modèle SVM-GA est moins précis que le modèle RFR5 ($R \approx 0.92$) développé dans notre étude pour le barrage Zit Emba. De même (Tezel et al., 2016) ont utilisés le MLPNN, le réseau de fonctions à base radiale (RBFNN) et le SVR pour estimer l'évaporation mensuelle du réservoir à partir des données de température, d'humidité relative, de vitesse du vent et de précipitations de la station météorologique de Beysehir pour la période 1972-2005. Les modèles ont été conçus par validation croisée (CV) 10 fois. Selon les critères de performance, les algorithmes RBFNN et SVR ont atteint une bonne précision de prédiction, cependant la technique SVR était un peu meilleure que le modèle RBFNN. La meilleure performance en phase de validation est $R \approx 0.951$, dépassant ainsi la meilleure valeur de nos résultats ($R \approx 0.920$ pour le barrage Zit Emba). Aussi Hong et al. (2020) ont utilisés six modèles ML, notamment MLPNN, arbre de décision (DT), réseau neuronal récurrent RNN, RFR et Gradient Boosting (GB), pour prédire les apports au barrage de la rivière Soyang en Corée du Sud. Parmi ces modèles, le MLPNN a produit les meilleurs résultats dans la

prédiction des apports au barrage, avec une valeur de NSE de 0.812, une RMSE de 77.218 m³/s, une MAE de 29.034 m³/s et un R de 0.924. Cependant, pour les débits inférieurs à 100 m³/s, les modèles d'ensemble (RFR et GB) ont donné de meilleurs résultats que MLPNN pour la prédiction de l'apport au barrage. Ces résultats diffèrent de ceux obtenus dans notre étude, qui indiquent que le modèle d'ensemble (RFR) est plus efficace que le MLPNN. En outre, [Latif et al. \(2021\)](#) ont suggéré une architecture de ANN pour prédire les pertes en eau dans le réservoir Klang Gate en Malaisie. Le modèle s'appuie sur des données hydrologiques historiques telles que l'apport, le volume libéré par le barrage, ainsi que le stockage initial et final du réservoir. Les résultats ont montré que le modèle proposé a permis d'obtenir des prévisions mensuelles avec une RMSE de 26.15 % et une MAE de 23.47 %. Toutefois, ces résultats sont significativement moins précis que les valeurs obtenues dans notre étude, à savoir MAE qui varie entre 0,3 % et 1.4 %, et RMSE qui varie entre 0.6 % et 2.2 %.

Finalement, [Qie et al. \(2022\)](#) ont examinés et comparés trois algorithmes de ML, (RFR, SVM et ANN), pour modéliser le débit libéré à partir de deux réservoirs dans l'Illinois, États-Unis. Les résultats ont démontré que les trois modèles permettent de simuler avec fiabilité et précision le débit libéré journalièrement du réservoir. Pour le réservoir Carlyle, les valeurs de R et de NSE sont toutes proches de 1 pour les trois modèles. Le SVM s'est avéré plus performant que le RFR et l'ANN, comme en témoignent les valeurs de R élevée (0.986) et de RMSE faible (104.9). Pour le réservoir Shelbyville, le modèle ANN a été le plus efficace, avec des valeurs de R (0.995), de RMSE (25.8) et de NSE très proches de 1, surpassant ainsi le RFR et le SVM, ce qui diffère entièrement de nos résultats.

Enfin, les résultats obtenus montrent que les modèles (RFR, MLPNN, et SVR) peuvent être utilisés pour estimer les volumes totaux alloués à l'alimentation en eau potable et à l'irrigation. Le modèle RFR se distingue particulièrement par sa précision élevée, qui s'explique par le fait que les algorithmes basés sur les arbres de décision ne requièrent aucune hypothèse concernant la distribution des données et sont capables de s'adapter aux valeurs extrêmes ([Loh, 2011](#)). Par conséquent, ils sont plus efficaces que les autres algorithmes d'apprentissage automatique. Cette conclusion concorde avec les résultats des études antérieures, qui ont également démontré la supériorité des modèles fondés sur les arbres de décision en matière de prédiction. Ces résultats sont incontestablement utiles pour la gestion et la planification de l'allocation de l'eau pour les différents usagés.

5.5 Conclusion

A la lumière des résultats obtenus par les trois modèles à base de l'apprentissage automatique à savoir : RFR, MLPNN et SVR nous pouvons conclure ce qui suit :

1. Les trois modèles peuvent être considérés comme un outil performant pour la simulation des volumes totaux alloués.
2. Les résultats numériques obtenus, démontrent que les performances des modèles dépendent du nombre des variables utilisées comment entrées (inputs) et le meilleur modèle est toujours obtenu en incluant les cinq variables sélectionnées (COTE, VOL, APP, VID, EVAP).
3. Les résultats obtenus par le barrage Zit Emba en phase de validation montrent que le modèle RFR5 est le meilleur avec ($R \approx 0.920$ et $NSE \approx 0.847$) les plus élevées et ($RMSE \approx 0.006$ et $MAE \approx 0.003$) les plus faibles, suivi par le modèle MLPNN5 et enfin le modèle SVR5.
4. En phase de validation, les résultats pour le barrage Guenitra montrent que le modèle RFR5 affiche les valeurs les plus élevées pour les coefficients de corrélation ($R \approx 0.886$) et d'efficacité du modèle ($NSE \approx 0.784$), ainsi que les valeurs les plus faibles pour la racine moyenne des carrés des erreurs ($RMSE \approx 0.020$) et l'erreur moyenne absolue ($MAE \approx 0.013$). Ce modèle est suivi par le modèle MLPNN5, puis par le modèle SVR5.
5. Les résultats obtenus confirment l'efficacité des modèles évalués, et la méthode des réseaux de neurones semble être une solution alternative prometteuse pour la prédiction des volumes totaux à allouer.

Conclusion générale

Conclusion générale

La rareté grandissante des ressources en eau qui résulte de la diminution des quantités disponibles par habitant, la dégradation de la quantité et les objectifs de développement économique et social, imposent donc l'élaboration et la définition d'une stratégie de gestion de l'eau à moyen et à long terme. Le problème de l'eau est aggravé ces dernières années de sécheresse qui ont touché l'ensemble du territoire, ont montré combien il était nécessaire d'accorder la plus grande attention à l'eau. Dans la présente thèse, l'idée de développer un modèle de prédiction du volume total à allouer à l'alimentation en eau potable et à l'irrigation (VTAL) à partir des barrages réservoirs a été motivée par l'indisponibilité de l'eau, particulièrement dans les zones à forte demande des régions à vocation agricole.

L'utilisation des techniques de Machines Learning pour la gestion des barrages est en effet bien adaptée, spécialement pour la prévision du volume total à allouer, grâce à leur robustesse, leur capacité à traiter des données de différentes natures et surtout leurs capacités d'apprentissage. Dans un premier temps, nous avons présenté les trois modèles de Machine Learning utilisées dans ce travail, à savoir ; le perceptron multicouche (MPLNN), la forêt aléatoire de régression (RFR) et la régression à vecteurs de support (SVR). Ces derniers ont été sélectionnés pour la prévision du VTAL en utilisant une base de données, de huit variables d'exploitation au pas de temps journalier, recueillies sur huit ans (2009- 2017) aux barrages de Zit Emba et Guenitra, situés dans le Nord-Est de l'Algérie exactement, dans la wilaya de Skikda.

Dans une seconde étape pour élaborer un modèle facile à utiliser comportant un nombre optimal de variables d'entrée, les variables prépondérantes retenues sont APP, PLU, EVAP, COTE, VID, VOL et EVAC, pour la modélisation de VTAL. Afin d'obtenir les variables d'entrée les plus efficaces, cette étude a évalué vingt et un (21) différents modèles. Le cinquième modèle comprenant COTE, VOL, APP, VID et EVAP s'est révélé la plus optimale et la plus performante.

Les performances obtenues par les trois modèles fluctuent d'un barrage à l'autre. Généralement, ces résultats étaient encourageants, surtout au niveau du barrage Zit Emba, avec un coefficient de corrélation qui atteint ($R \approx 0.92$). De plus, le modèle RFR était le plus performant que les autres modèles, suivi par le modèle MLPNN. Par contre, le modèle SVR garantit le moyen résultat pour les deux barrages.

Perspectives :

La recherche menée dans le cadre de cette thèse a mis en évidence plusieurs axes d'amélioration qui méritent une attention particulière :

- L'exploration d'autres méthodes de sélection des variables d'entrée comme le Gamma test, XGBoost, etc., pour améliorer la pertinence des variables utilisées dans les modèles ;
- L'utilisation de variables endogènes (VTAL) en combinaison avec des variables exogènes en tant que variable d'entrée pour étudier leur impact sur les performances des modèles ;
- La modélisation du VTAL en utilisant uniquement les variables endogènes en tant que variables d'entrée pour évaluer leur impact sur les performances des modèles ;
- Il serait opportun d'explorer la possibilité d'adapter les modèles testés à d'autres barrages en conservant les mêmes variables d'entrée ;
- Il serait pertinent d'approfondir l'évaluation d'autres techniques d'intelligence artificielle, telles que le Deep Learning, les modèles de logique floue, ainsi que différentes approches d'hybridation impliquant des algorithmes d'optimisation.

Références bibliographiques

-
- Abdellaoui, B., Merzouk, A., Aberkan, M., & Albergel, J. (2002). Bilan hydrologique et envasement du barrage Saboun (Maroc). *Revue des sciences de l'eau*, 15(4), 737-748. <https://doi.org/10.7202/705478ar>
- Adnan, R. M., Mostafa, R. R., Dai, H. L., Heddami, S., Kuriqi, A., & Kisi, O. (2023). Pan evaporation estimation by relevance vector machine tuned with new metaheuristic algorithms using limited climatic data. *Engineering Applications of Computational Fluid Mechanics*, 17(1), 2192258. <https://doi.org/10.1080/19942060.2023.2192258>
- Ahmadi, F., Mehdizadeh, S., & Nourani, V. (2022). Improving the performance of random forest for estimating monthly reservoir inflow via complete ensemble empirical mode decomposition and wavelet analysis. *Stochastic Environmental Research and Risk Assessment*, 36(9), 2753-2768. <https://doi.org/10.1007/s00477-021-02159-x>
- Ahmadi, M., Karimi, M., Alizadeh, S., Shirzadi, A., Parvinnejhad, D., Shahabi, H., & Panahi, M. (2019). Flood susceptibility assessment using integration of adaptive network-based fuzzy inference system (ANFIS) and biogeography-based optimization (BBO) and BAT algorithms (BA). *Geocarto International*, 34(11), 1252-1272. <https://doi.org/10.1080/10106049.2018.1474276>
- Ahmed, A. N., Othman, F. B., Afan, H. A., Ibrahim, R. K., Fai, C. M., Hossain, M. S., Ethteram, M., Elshafie, A. (2019). Machine learning methods for better water quality prediction. *Journal of Hydrology*, 578, 124084. <https://doi.org/10.1016/j.jhydrol.2019.124084>
- Ahn, S., & Sheng, Z. (2021). Assessment of water availability and scarcity based on hydrologic components in an irrigated agricultural watershed using SWAT. *JAWRA Journal of the American Water Resources Association*, 57(1), 186-203. <https://doi.org/10.1111/1752-1688.12888>
- Alizamir, M., Shiri, J., Fard, A. F., Kim, S., Gorgij, A. D., Heddami, S., & Singh, V. P. (2023). Improving the accuracy of daily solar radiation prediction by climatic data using an efficient hybrid deep learning model: Long short-term memory (LSTM) network coupled with wavelet transform. *Engineering Applications of Artificial Intelligence*, 123, 106199. <https://doi.org/10.1016/j.engappai.2023.106199>
-

- Allawi, M. F., Ahmed, M. Z., Aidan, I. A., Liu, B., & El-Shafie, A. (2021). Developing reservoir evaporation predictive model for successful dam management. *Stochastic Environmental Research and Risk Assessment*, 35(2), 499–514.
<https://doi.org/10.1007/s00477-020-01918-6>
- Allawi, M. F., Jaafar, O., Hamzah, F. M., & El-Shafie, A. (2019). Novel reservoir system simulation procedure for gap minimization between water supply and demand. *Journal of Cleaner Production*, 206, 928–943.
<https://doi.org/10.1016/j.jclepro.2018.09.237>
- Allawi, M. F., Jaafar, O., Hamzah, F. M., Koting, S., Mohd, N. S., & El-Shafie, A. (2019). Forecasting hydrological parameters for reservoir system utilizing artificial intelligent models and exploring their influence on operation performance. *Knowledge Based Systems*, 163, 907–926.
<https://doi.org/10.1016/j.knosys.2018.10.013>
- Allawi, M. F., Othman, F., Afan, H. A., Ahmed, A., Hossain, S., Chow, M. F., & El-Shafie, A. (2019). Reservoir evaporation prediction modeling based on artificial intelligence methods. *Water*, 11(6), 1226. <https://doi.org/10.3390/w11061226>
- Amireche, H. (2009). Dégradation dans les bassins versants de l'Algérie orientale, effets et stratégies d'aménagement cas du bassin versant des Zardezas. *Revue science et technologie*. 33-40p.
- Amnatsan, S., Yoshikawa, S., & Kanae, S. (2018). Improved forecasting of extreme monthly reservoir inflow using an analogue-based forecasting method: a case study of the sirikit dam in Thailand. *Water*, 10(11), 1614. <https://doi.org/10.3390/w10111614>
- ANBT, Agence Nationale des Barrages et Transferts. (2003). Fiche technique du barrage Guenitra. Agence National des barrages et de transfert – Skikda. Doc internes.
- ANBT, Agence Nationale des Barrages et Transferts. (2014). Fiche technique des 25 barrages. Agence National des barrages et de transfert – Alger. Doc internes.
- ANBT, Agence Nationale des Barrages et Transferts. (2020). Fiche technique du barrage Zit Emba. Agence National des barrages et de transfert – Skikda. Doc internes.

- Andrew Charles, J. (2009). The engineering behaviour of fill materials and its influence on the performance of embankment dams. *Dams and Reservoirs*, 19(1), 21-33.
<https://doi.org/10.1680/dare.2009.19.1.21>.
- ANRH. Agence Nationale Des Ressources Hydriques, (2015). Etude hydrologique de l'oued Hammam et oued fessa . Doc internes.
- Asefa, T., Kemblowski, M., McKee, M., & Khalil, A. (2006). Multi-time scale stream flow predictions: The support vector machines approach. *Journal of hydrology*, 318(1-4), 7-16. <https://doi.org/10.1016/j.jhydrol.2005.06.001>
- Ayele, G. T., Teshale, E. Z., Yu, B., Rutherford, I., & Jeong, J. (2017). Streamflow and sediment yield prediction for watershed prioritization in the Upper Blue Nile River Basin, Ethiopia. *Water*, 9(10), 782. <https://doi.org/10.3390/w9100782>
- 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. <https://doi.org/10.1007/s11269-019-02252-5>
- Bahrami, S., & Wigand, E. (2018). Daily streamflow forecasting using nonlinear echo state network. *International Journal of Advanced Research in Science, Engineering and Technology*, Vol. 5, Issue 9, 2350-0328.
- Benfetta, H., Ouadja, B., Achour, B., Remini, B. (2016). Perte de capacité dans les barrages situés dans les zones arides et semi arides. Cas des barrages de gargar, bouhanifia, ouizert et foug el gherza. *Larhyss journal*, issn 1112-3680, n°25. 183-201p.
- Bengora, D. (2020). Optimisation de la gestion du barrage hammam debagh (guelma) dans la seyboise - algérie, Thèse de doctorat en sciences, Ecole Nationale Polytechnique, département d'hydraulique, 52p.
- Bohanec M, (2001). What is Decision Support. *Proc. Information Society : Data Mining and Decision Support in Action*, pp : 86-89, 2001.
- Boulahbel, S., Mebarki, A. (2013). Fonctionnement hydrologique du barrage de béni haroun (oued kébir-rhumel, algérie orientale), ciredd alger. 749-754 p.

- Boutoutaou, D. (1995). Évaporation des surfaces des plans d'eau des retenues et barrages en Algérie. Thèse de doctorat en Sciences Techniques, Institut d'hydraulique, Moscou. 200p.
- Boutoutaou, D., Saker, M., Daddi Bouhoun, M., Saggai, S., Ould El Hadj, M. (2012). Détermination de l'évaporation des surfaces des plans d'eau pour les conditions climatiques de l'Algérie. Algerian journal of arid environment, vol. 2, n° 2. 94-101p.
- Bozorg-Haddad, O., Aboutalebi, M., Ashofteh, P. S., & Loáiciga, H. A. (2018). Real-time reservoir operation using data mining techniques. Environmental Monitoring and Assessment, 190, 1-22. <https://doi.org/10.1007/s10661-018-6970-2>
- Breiman, L., 2001. Random forest. Mach. Learn. 45, 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Cancelliere, A., Giuliano, G., Ancarani, A., & Rossi, G. (2002). A neural networks approach for deriving irrigation reservoir operating rules. Water resources management, 16, 71-88. <https://doi.org/10.1023/A:1015563820136>.
- Chandramouli, V. And Raman, H., (2001). Multireservoir modeling with dynamic programming and neural networks. Water Resources Planning and Management ASCE, April, 2001, Vol.127, n° 2, p. 89–98. <https://doi.org/10.10610733-9496127:2>.
- Chang, F. J., & Guo, S. (2020). Advances in hydrologic forecasts and water resources management. Water, 12(6), 1819. <https://doi.org/10.3390/w12061819>
- Chang, F. J., Hsu, K., & Chang, L. C.. (2019). Flood forecasting using machine learning methods. MDPI. <https://doi.org/10.3390/books978-3-03897-549-6>
- Chen, L., Su, W., Feng, Y., Wu, M., She, J., Hirota, K. (2020) Two-layer fuzzy multiple random forest for speech emotion recognition in human-robot interaction. Inf Sci 509:150–163. <https://doi.org/10.1016/j.ins.2019.09.005>

- Cheng, C., Feng, Z., Niu, W., & Liao, S. (2015). Heuristic Methods for reservoir monthly inflow Forecasting: A case study of Xinfengjiang reservoir in Pearl River, China. *Water*, 7(12), 4477– 4495. <https://doi.org/10.3390/w7084477>
- Chiamsathit, C., Adeloje, A. J., & Bankaru-Swamy, S. (2016). Inflow forecasting using Artificial Neural Networks for reservoir operation. *Proceedings of the International Association of Hydrological Sciences*, 373, 209-214. <https://doi.org/10.5194/piahs-373-209-2016>
- Choubin, B., Malekian, A., (2017). Combined gamma and M-test-based ANN and ARIMA models for groundwater fluctuation forecasting in semiarid regions. *Environ. Earth Sci.* 76_ <https://doi.org/10.1007/s12665-017-6870-8>
- Choubin, B., Malekian, A., Samadi, S., Khalighi-Sigaroodi, S., Sajedi-Hosseini, F., (2017a). An ensemble forecast of semi-arid rainfall using large-scale climate predictors. *Meteorol. Appl.* <https://doi.org/10.1002/met.1635>
- Chu, H., Wu, W., Wang, Q. J., Nathan, R., & Wei, J. (2020). An ANN-based emulation modelling framework for flood inundation modelling: Application, challenges and future directions. *Environmental Modelling & Software*, 124, 104587. <https://doi.org/10.1016/j.envsoft.2019.104587>
- Chun, B. S., Lee, Y. J., & Chung, H. I. (2006). Effectiveness of leakage control after application of permeation grouting to earth fill dam. *KSCE Journal of Civil Engineering*, 10, 405-414. <https://doi.org/10.1007/BF02823979>
- Cinkus, G., Wunsch, A., Mazzilli, N., Liesch, T., Chen, Z., Ravbar, N., ... & Jourde, H. (2023). Comparison of artificial neural networks and reservoir models for simulating karst spring discharge on five test sites in the Alpine and Mediterranean regions. *Hydrology and Earth System Sciences*, 27(10), 1961-1985. <https://doi.org/10.5194/hess-27-1961-2023>, 2023
- Deng, X., Liu, Z., Zhan, Y., Ni, K., Zhang, Y., Ma, W., ... & Rogers, K. M. (2020). Predictive geographical authentication of green tea with protected designation of origin using a random forest model. *Food Control*, 107, 106807. <https://doi.org/10.1016/j.foodcont.2019.106807>

- Dewals, B., Erpicum, S., Detrembleur, S., Archambeau, P., & Piroton, M. (2011). Failure of dams arranged in series or in complex. *Natural Hazards*, 56, 917-939.
<https://doi.org/10.1007/s11069-010-9600-z>.
- Di Nunno, F., Zhu, S., Ptak, M., Sojka, M., & Granata, F. (2023). A stacked machine learning model for multi-step ahead prediction of lake surface water temperature. *Science of the Total Environment*, 890, 164323.
<https://doi.org/10.1016/j.scitotenv.2023.164323>
- Dibike, Y. B., Velickov, S., Solomatine, D., & Abbott, M. B. (2001). Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering*, 15(3), 208-216
[https://doi.org/10.1061/\(ASCE\)0887-3801\(2001\)15:3\(208\)](https://doi.org/10.1061/(ASCE)0887-3801(2001)15:3(208)).
- Ehteram, M., Karami, H., Mousavi, S. F., El-Shafie, A., & Amini, Z. (2017). Optimizing dam and reservoirs operation based model utilizing shark algorithm approach. *Knowledge-Based Systems*, 122, 26-38.
<https://doi.org/10.1016/j.knosys.2017.01.026>
- Emami, S., & Parsa, J. (2020). Comparative evaluation of imperialist competitive algorithm and artificial neural networks for estimation of reservoirs storage capacity. *Applied Water Science*, 10(7), 1-13. <https://doi.org/10.1007/s13201-020-01259-3>
- Essam, Y., Huang, Y. F., Ng, J. L., Birima, A. H., Ahmed, A., & El-Shafie, A. (2022). Predicting streamflow in Peninsular Malaysia using support vector machine and deep learning algorithms. *Scientific Reports*, 12(1).
<https://doi.org/10.1038/s41598-022-07693-4>
- Boutouatou, F. (2020). Les barrages en exploitation dans l'est Algérien : fonctionnement hydrologique et aménagement. Etude de cas. Thèse de Doctorat. Université Mentouri – Constantine.pp57.
- François, B. (2013). Gestion optimale d'un réservoir hydraulique multiusages et changement climatique. Modèles, projections et incertitudes Application à la réserve de Serre-Ponçon. Thèse de Doctorat de l'Université de Grenoble.

-
- Ghorbani, M. A., Deo, R. C., Karimi, V., Kashani, M. H., and Ghorbani, S. (2019). Design and implementation of a hybrid MLP-GSA model with multi-layer perceptron-gravitational search algorithm for monthly lake water level forecasting, *Stoch. Environ. Res. Risk A.*, 33, 125–147, <https://doi.org/10.1007/s00477-018-1630-1>
- Ghorbani, M. A., Deo, R. C., Yaseen, Z. M., H. Kashani, M., & Mohammadi, B. (2017). Pan evaporation prediction using a hybrid multilayer perceptron-firefly algorithm (MLP-FFA) model: case study in North Iran. *Theoretical and applied climatology*, 133, 1119-1131. <https://doi.org/10.1007/s00704-017-2244-0>
- Gragne, A. S., Alfredsen, K., Sharma, A., & Mehrotra, R. (2015). Recursively updating the error forecasting scheme of a complementary modelling framework for improved reservoir inflow forecasts. *Journal of Hydrology*, 527, 967-977. <https://doi.org/10.1016/j.jhydrol.2015.05.039>
- Guo, J., Zan, X., Wang, L., Lei, L., Ou, C., & Bai, S. (2023b). A random forest regression with Bayesian optimization-based method for fatigue strength prediction of ferrous alloys. *Engineering Fracture Mechanics*, 109714. <https://doi.org/10.1016/j.engfracmech.2023.109714>
- Guzman, S. M., Paz, J. O., and Tagert, M. L. M., (2017). The Use of NARX Neural Networks to Forecast Daily Groundwater Levels, *Water Resour. Manage.*, 31, 1591–1603, <https://doi.org/10.1007/s11269-017-1598-5>.
- Hadiyan, P. P., Moeini, R., & Ehsanzadeh, E. (2020). Application of static and dynamic Artificial neural networks for forecasting inflow discharges, case study: Sefidroud Dam reservoir. *Sustainable Computing: Informatics and Systems*, 27, 100401. <https://doi.org/10.1016/j.suscom.2020.100401>
- 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. <https://doi.org/10.1080/13658816.2019.1579333>
-

- Hanna, B. N., Dinh, N. T., Youngblood, R. W., & Bolotnov, I. A. (2020). Machine-learning based error prediction approach for coarse-grid Computational Fluid Dynamics (CG-CFD). *Progress in Nuclear Energy*, 118, 103140.
<https://doi.org/10.1016/j.pnucene.2019.103140>
- Heddam, S., Bermad, A., Dechemi, N. Applications of Radial-Basis Function and Generalized Regression Neural Networks for Modeling of Coagulant Dosage in a Drinking Water-Treatment Plant: Comparative Study. *Journal of Environmental Engineering*, December, 2011, Vol. 137, n° 12, p. 1209-1214.
[https://doi.org/10.1061/\(ASCE\)EE.1943-7870.0000435](https://doi.org/10.1061/(ASCE)EE.1943-7870.0000435).
- Heddam, S., Ptak, M., & Zhu, S. (2020). Modelling of daily lake surface water temperature from air temperature: Extremely randomized trees (ERT) versus Air2Water, MARS, M5Tree, RF and MLPNN. *Journal of Hydrology*, 588, 125130.
<https://doi.org/10.1016/j.jhydrol.2020.125130>.
- Hera, Á., López-Pamo, E., Santofimia, E., Gallego, G., Morales, R., Durán, J. J., & Murillo-Díaz, J. M. (2014). A case study of geometric modelling via 3-d point interpolation for the bathymetry of the Rabasa lakes (Alicante, Spain). In *Mathematics of Planet Earth: Proceedings of the 15th Annual Conference of the International Association for Mathematical Geosciences* (pp. 503-506). Springer Berlin Heidelberg.
https://doi.org/10.1007/978-3-642-32408-6_110.
- Hinkle, D. E., Wiersma, W., & Jurs, S. G. (2003). *Applied Statistics for the Behavioral Sciences*. 5e éd.; Houghton Mifflin: Boston, MA, États-Unis.
- Hintze, J.L., Nelson, R.D., 1998. Violin plots: a box plot-density trace synergism. *Am. Stat.* 52:181–184. <https://doi.org/10.1080/00031305.1998.10480559>.
- Hong, J., Lee, S., Bae, J. Y., Lee, J., Park, W., Lee, D., Kim, J., & Lim, K. J. (2020). Development and evaluation of the combined machine learning models for the prediction of dam inflow. *Water*, 12(10), 2927. <https://doi.org/10.3390/w12102927>
- Hornik, K., Stinchcombe, M., & White, H. (1990). Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. *Neural networks*, 3(5), 551-560. [https://doi.org/10.1016/0893-6080\(90\)90005-6](https://doi.org/10.1016/0893-6080(90)90005-6)

- Howard H.A., (1969). Dynamic programming and Markov processes. MIT Press.
- Hu, C., & Wan, F. (2009). Input selection in learning systems: a brief review of some important issues and recent developments. In 2009 IEEE International Conference on Fuzzy Systems (pp. 530-535). IEEE.
<https://doi.org/10.1109/FUZZY.2009.5277050>
- Hussain, D., & Khan, A. A. (2020). Machine learning techniques for monthly river flow forecasting of Hunza River, Pakistan. *Earth Science Informatics*, 13, 939-949.
<https://doi.org/10.1007/s12145-020-00450-z>
- Jain, S. K., Das, A., & Srivastava, D. K. (1999). Application of ANN for reservoir inflow prediction and operation. *Journal of water resources planning and management*, 125(5), 263-271.
[https://doi.org/10.1061/\(ASCE\)0733-9496\(1999\)125:5\(263\)](https://doi.org/10.1061/(ASCE)0733-9496(1999)125:5(263)).
- James, L. D., & Lee, R. R. (1971). *Economics of Water Resources Planning*, McGraw-Hill Book Co, New York.
- Jang, H. S., & Xing, S. (2020). A model to predict ammonia emission using a modified genetic artificial neural network: Analyzing cement mixed with fly ash from a coal-fired power plant. *Construction and Building Materials*, 230, 117025.
<https://doi.org/10.1016/j.conbuildmat.2019.117025>
- Jung, Y. (2018). Multiple predicting K-fold cross-validation for model selection. *Journal of Nonparametric Statistics*, 30(1), 197-215.
<https://doi.org/10.1080/10485252.2017.1404598>.
- Karpatne, A., Ebert-Uphoff, I., Ravela, S., Babaie, H. A., & Kumar, V. (2018). Machine learning for the geosciences: Challenges and opportunities. *IEEE Transactions on Knowledge and Data Engineering*, 31(8), 1544-1554.
<http://dx.doi.org/10.1109/TKDE.2018.2861006>
- Kassem, A. A., Raheem, A. M., & Khidir, K. M. (2020). Daily streamflow prediction for khazir river basin using ARIMA and ANN models. *Zanco Journal of Pure and Applied Sciences*, 32(3), 30-39. <http://dx.doi.org/10.21271/ZJPAS.32.3.4>

- Kaushik, V., & Awasthi, N. (2023). Simulation of reservoir outflows using regression tree and support vector machine. *AI in Civil Engineering*, 2(1), 2.
<https://doi.org/10.1007/s43503-023-00012-4>
- Ke, Q., Tian, X., Bricker, J. D., Tian, Z., Guan, G., Cai, H., Huang, X., Yang, H., & Liu, J. (2020). Urban pluvial flooding prediction by machine learning approaches – a case study of Shenzhen City, China. *Advances in Water Resources*, 145, 103719.
<https://doi.org/10.1016/j.advwatres.2020.103719>
- Keshtegar, B., Heddami, S., Sebban, A., Zhu, S.-P., Trung, N.-T., 2019. SVR-RSM: a hybrid heuristic method for modeling monthly pan evaporation. *Environ Sci Pollut Res*.
<https://doi.org/10.1007/s11356-019-06596-8>
- Khayyun, T. S., Alwan, I. A., & Hayder, A. M. (2019). Hydrological model for Hemren dam reservoir catchment area at the middle River Diyala reach in Iraq using ArcSWAT model. *Applied water science*, 9(5), 133.
<https://doi.org/10.1007/s13201-019-1010-0>
- Khishe, M., & Mosavi, M. R. (2020). Classification of underwater acoustical dataset using neural network trained by Chimp Optimization Algorithm. *Applied Acoustics*, 157, 107005. <https://doi.org/10.1016/j.apacoust.2019.107005>
- Khosravi, K., Mao, L., Kisi, O., Yaseen, Z. M., & Shahid, S. (2018). Quantifying hourly suspended sediment load using data mining models: case study of a glacierized Andean catchment in Chile. *Journal of Hydrology*, 567, 165-179.
<https://doi.org/10.1016/j.jhydrol.2018.10.015>
- Khozani, Z. S., Khosravi, K., Pham, B. T., Kløve, B., Wan Mohtar, W. H. M., & Yaseen, Z. M. (2019). Determination of compound channel apparent shear stress: application of novel data mining models. *Journal of Hydroinformatics*, 21(5), 798-811.
<https://doi.org/10.2166/hydro.2019.037>
- Kilinç, I., & Ciğizoğlu, K. (2012). Reservoir management using artificial neural networks. 14th. Reg. Directorate of DSI (State Hydraulic Works), Istanbul, Turkey.

- Kim, S., Seo, Y., Malik, A., Heddami, S., Yaseen, Z. M., ... & Singh, V. P. (2023). Quantification of river total phosphorus using integrative artificial intelligence models. *Ecological Indicators*, 153, 110437. <https://doi.org/10.1016/j.ecolind.2023.110437>
- Kim, T., Shin, J. Y., Kim, H., Kim, S., & Heo, J. H. (2019). The use of large-scale climate indices in monthly reservoir inflow forecasting and its application on time series and artificial intelligence models. *Water*, 11(2), 374. <https://doi.org/10.3390/w11020374>
- Kingumbi, A. (1999). Bilan et modélisation de la retenue du barrage de El Houareb .Mémoire de diplôme d'études approfondies à l'école nationale d'ingénieurs de Tunis, 148 p.
- Kisi, O., & Yaseen, Z. M. (2019). The potential of hybrid evolutionary fuzzy intelligence model for suspended sediment concentration prediction. *Catena*, 174, 11-23. <https://doi.org/10.1016/j.catena.2018.10.047>
- Kisi, O., & Cimen, M. (2010b). A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *Journal of Hydrology*, 399(1-2), 132-140. <https://doi.org/10.1016/j.jhydrol.2010.12.041>
- Kisi, O., Heddami, S., & Yaseen, Z. M. (2019). The implementation of univariable scheme-based air temperature for solar radiation prediction: New development of dynamic evolving neural-fuzzy inference system model. *Applied Energy*, 241, 184-195. <https://doi.org/10.1016/j.apenergy.2019.03.089>
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall–runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, 22(11), 6005-6022. <https://doi.org/10.5194/hess-22-6005-2018>.
- Lange, H., & Sippel, S. (2020). Machine learning applications in hydrology. *Forest-water interactions*, 233-257. https://doi.org/10.1007/978-3-030-26086-6_10
- Latif, S. D., Ahmed, A., Sherif, M., Sefelnasr, A., & El-Shafie, A. (2021). Reservoir water balance simulation model utilizing machine learning algorithm. *Alexandria Engineering Journal*, 60(1), 1365–1378. <https://doi.org/10.1016/j.aej.2020.10.057>

- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Water*, 11(7), 1387. <https://doi.org/10.3390/w11071387>, 2019.
- Lebdi., (1996). Gestion des ressources en eau et optimisation des règles de réservoirs. Cours optionnel GREF, à l'Institut National Agronomique de Tunis.
- Lee, D., Kim, H., Jung, I., & Yoon, J. (2020). Monthly reservoir inflow forecasting for dry Period using teleconnection Indices: A Statistical ensemble approach. *Applied Sciences*, 10(10), 3470. <https://doi.org/10.3390/app10103470>
- Lee, W. K., & Tuan Resdi, T. A. (2016). Simultaneous hydrological prediction at multiple gauging stations using the NARX network for Kemaman catchment, Terengganu, Malaysia. *Hydrological Sciences Journal*, 61(16), 2930-2945. <https://doi.org/10.1080/02626667.2016.1174333>
- Legates, D. R., & McCabe, G. J. (1999). Evaluating the use of “goodness-of-fit” Measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1), 233–241. <https://doi.org/10.1029/1998wr900018>
- Legates, D.R., McCabe Jr, G.J. (1999). Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), 233-241. <https://doi.org/10.1029/1998WR900018>.
- Li, Y. P., & Huang, G. H. (2013). Risk analysis and management for water resources systems. *Stochastic Environmental Research and Risk Assessment*, 27, 593-597. <https://doi.org/10.1007/s00477-012-0625-6>.
- Lin, J. Y., Cheng, C. T., & Chau, K. W. (2006). Using support vector machines for long-term discharge prediction. *Hydrological sciences journal*, 51(4), 599-612. <https://doi.org/10.1623/hysj.51.4.599>.
- Liong, S. Y., & Sivapragasam, C. (2002). Flood stage forecasting with support vector machines 1. *JAWRA Journal of the American Water Resources Association*, 38(1), 173-186. <https://doi.org/10.1111/j.1752-1688.2002.tb01544.x>

- Liu, P., Lin, K., & Wei, X. (2015). A two-stage method of quantitative flood risk analysis for reservoir real-time operation using ensemble-based hydrologic forecasts. *Stochastic Environmental Research and Risk Assessment*, 29, 803-813.
<https://doi.org/10.1007/s00477-014-0986-0>
- Loh, W. Y. (2011). Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1), 14-23. <https://doi.org/10.1002/widm.8>
- Louamri, A. (2013). le bassin versant de la Seybouse (Algérie orientale) : hydrologie et aménagement des eaux, thèse de doctorat en sciences (géographie et aménagement du territoire, option hydrologie), Université de Constantine, Faculté des Sciences de la Terre.315 p.
- Marofi, S., Tabari, H., & Abyaneh, H. Z. (2011). Predicting spatial distribution of snow water equivalent using multivariate non-linear regression and computational intelligence methods. *Water resources management*, 25, 1417-1435.
<https://doi.org/10.1007/s11269-010-9751-4>.
- Mebarki A, 2010. Apport des cours d'eau et cartographie du bilan hydrologique : cas des bassins de l'Algérie orientale, *Sécheresse* vol. 21, n° 4,301-308p.
- Melesse, A. M., Shahabi, H., Pourghasemi, H. R., Heddami, S., Kim, D. Y., Mosavi, A., & Pham, B. T. (2020). River Water Salinity Prediction Using Hybrid Machine Learning Models. *Water*, 12(10), 2951. <https://doi.org/10.3390/w12102951>
- Meng, E., Huang, S., Huang, Q., Fang, W., Wu, L., & Wang, L. (2019). A robust method for non-stationary streamflow prediction based on improved EMD-SVM model. *Journal of hydrology*, 568, 462-478.
<https://doi.org/10.1016/j.jhydrol.2018.11.015>
- Merabet, K., & Heddami, S., (2023). Improving the accuracy of air relative humidity prediction using hybrid machine learning based on empirical mode decomposition: a comparative study. *Environmental Science and Pollution Research*, 1- 22.
<https://doi.org/10.1007/s11356-023-26779-8>

- Mihoubi, N., (2009). Fonctionnement et gestion hydrogéologique et hydrologique des ressources en eau du bassin de Hammam Grouz, Mémoire de magister, Faculté des sciences de la terre, de la géographie et de l'aménagement du territoire, Département de la géologie, 244 p.
- Mohamadi, S., Ehteram M, El-Shafie A., (2020) Accuracy enhancement for monthly evaporation predicting model utilizing evolutionary machine learning methods. *Int J Environ Sci Technol* 17:3373–3396. <https://doi.org/10.1007/s13762-019-02619-6>
- Mohamed, H. I., (2017). Grand Ethiopian Renaissance Dam impact on long term operation of high Aswan Dam reservoir. *Int J Water Resour Arid Environ*, 6(1), 89-95.
- Mokhtar, S. A., Ishak, W. H. W., & Norwawi, N. M., (2014). Modelling of reservoir water release decision using neural network and temporal pattern of reservoir water level. In 2014 5th International Conference on Intelligent Systems, Modelling and Simulation (pp. 127-130). IEEE. <https://doi.org/10.1109/ISMS.2014.27>
- Molinaro, A. M., Simon, R., & Pfeiffer, R. M., (2005). Prediction error estimation: A comparison of resampling methods. *Bioinformatics*, 21(15), 3301–3307.
- Moriasi, D. N., Arnold, J. R., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L., (2007). Model Evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885–900. <https://doi.org/10.13031/2013.23153>
- MRE .(2022). Le secteur de l'eau en Algérie, Alger, Ministère des Ressources en Eau .31 p.
- Muslim, T. O., Ahmed, A. N., Malek, M. A., Abdulmohsin Afan, H., Khaleel Ibrahim, R., El-Shafie, A., ... & El-Shafie, A., (2020). Investigating the influence of meteorological parameters on the accuracy of sea-level prediction models in Sabah, Malaysia. *Sustainability*, 12(3), 1193. <https://doi.org/10.3390/su12031193>
- Naghibi, S. A., & Pourghasemi, H. R., (2015). A comparative assessment between three machine learning models and their performance comparison by bivariate and multivariate statistical methods in groundwater potential mapping. *Water resources management*, 29, 5217-5236. <https://doi.org/10.1007/s11269-015-1114-8>

- 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. <https://doi.org/10.7717/peerj.8043>
- Noi, P. T., 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 sensing*, 9(5), 398. <https://doi.org/10.3390/rs9050398>.
- Noori, R., Karbassi, A., & Sabahi, M. S., (2010). Evaluation of PCA and Gamma test techniques on ANN operation for weekly solid waste prediction. *Journal of Environmental Management*, 91(3), 767-771. <https://doi.org/10.1016/j.jenvman.2009.10.007>
- Parent, E., (1991). *Elaboration des consignes de gestion des barrages-réservoirs*. Thèse de Doctorat, Ecole Nationale Des Ponts Et Chaussées.
- Perennes, J.J., (1993). *L'eau et les hommes au Maghreb. Contribution à une politique de l'eau en Méditerranée*, Publié avec le concours du CNRS, Edition Khartala, Paris. 646 p.
- Perennes, J.J., (1979). *Structures agraires et décolonisation. Les oasis de l'Oued Righ (Algérie)*, OPU, Alger, 374 p.
- PNE (Plan National de l'Eau). (2010). *Réalisation de l'étude d'actualisation du plan national de l'eau*. Programme MEDA de l'Union Européenne, Alger, Algérie, 86-102.
- Probst, P., Wright, M. N., & Boulesteix, A. L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(3), e1301. <https://doi.org/10.1002/widm.1301>
- Qie, G., Zhang, Z., Getahun, E., & Allen Mamer, E. (2022). Comparison of machine learning models performance on simulating reservoir outflow: A case study of two reservoirs in Illinois, USA. *JAWRA Journal of the American Water Resources Association*, 59(3), 554-570. <https://doi.org/10.1111/1752-1688.13040>.

- Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P., & Green, R. (2019). Artificial intelligence and machine learning in pathology: the present landscape of supervised methods. *Academic pathology*, 6, 2374289519873088.
<https://doi.org/10.1177/2374289519873088>, 2019.
- Abou Rjeily, Y., Abbas, O., Sadek, M., Shahrour, I., & Hage Chehade, F. (2017). Flood forecasting within urban drainage systems using NARX neural network. *Water Science and Technology*, 76(9), 2401-2412.
<https://doi.org/10.2166/wst.2017.409>, 2017.
- Roche, M. (1963). *Hydrologie de surface*. Paris (ORSTOM).
- Rossi, G., Ancarani, A., & Cancelliere, A. (1999). A comparison between neural network approach and multiple regression procedures for deriving reservoir operation policies. *Proceedings of water resources planning and management*. Water Resources Publications, Fort Collins, 148-161.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986b). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>.
- Sammen, S. S., Mohamed, T. A., Ghazali, A. H., El-Shafie, A. H., & Sidek, L. M. (2017). Generalized regression neural network for prediction of peak outflow from dam breach. *Water Resources Management*, 31, 549-562.
<https://doi.org/10.1007/s11269-016-1547-8>, 2017.
- Sathishkumar, V. E., Park, J. et Cho, Y. (2020). Using Data Mining Techniques for Bike Sharing Demand Prediction in Metropolitan City. *Computer Communications*, 153, 353-366. <https://doi.org/10.1016/j.comcom.2020.02.00>
- Sattari, M. T., Yurekli, K., & Pal, M. (2012). Performance evaluation of artificial neural network approaches in forecasting reservoir inflow. *Applied Mathematical Modelling*, 36(6), 2649-2657. <https://doi.org/10.1016/j.apm.2011.09.048>
- Savarenskiy, A. D. (1940). A method for streamflow control computation. *Gidrotekh. stroit*, 2, 24-28.

-
- Seckin, N., Cobaner, M., Yurtal, R., & Haktanir, T. (2013). Comparison of artificial neural network methods with L-moments for estimating flood flow at ungauged sites: the case of East Mediterranean River Basin, Turkey. *Water resources management*, 27(7), 2103-2124. <https://doi.org/10.1007/s11269-013-0278-3>
- Sigaroodi, S. K., Chen, Q., Ebrahimi, S., Nazari, A., & Choobin, B. (2014). Long-term precipitation forecast for drought relief using atmospheric circulation factors: a study on the Maharloo Basin in Iran. *Hydrology and Earth System Sciences*, 18(5), 1995-2006. <https://doi.org/10.5194/hess-18-1995-2014>.
- Smola, A. J. (1996). Regression estimation with support vector learning machines. A note on the Gamma test. *Neural Comput & Applic* 5, 131–133. <https://doi.org/10.1007/BF01413858>
- Soleymani, S. A., Goudarzi, S., Anisi, M. H., Hassan, W. H., Idris, M. Y. I., Shamshirband, S., ... & Ahmady, I. (2016). A novel method to water level prediction using RBF and FFA. *Water Resources Management*, 30, 3265-3283. <https://doi.org/10.1007/s11269-016-1347-1>
- Tabari, H., Marofi, S., Abyaneh, H. Z., & Sharifi, M. R. (2010b). Comparison of artificial neural network and combined models in estimating spatial distribution of snow depth and snow water equivalent in Samsami basin of Iran. *Neural Computing and Applications*, 19, 625-635. <https://doi.org/10.1007/s00521-009-0320-9>
- Tabari, H., Marofi, S., & Sabziparvar, A. A. (2010a). Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrigation Science*, 28, 399-406. <https://doi.org/10.1007/s00271-009-0201-0>
- Talaei, P. H., Heydari, M., Fathi, P., Marofi, S., & Tabari, H. (2012). Numerical model and computational intelligence approaches for estimating flow through rockfill dam. *Journal of Hydrologic Engineering*, 17(4), 528-536. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000446](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000446).
- Tan, K., Wang, H., Chen, L., Du, Q., Du, P., & Pan, C. (2020). Estimation of the spatial distribution of heavy metal in agricultural soils using airborne hyperspectral imaging and random forest. *Journal of hazardous materials*, 382, 120987. <https://doi.org/10.1016/j.jhazmat.2019.120987>
-

-
- Tao, H., Chen, R., Xuan, J., Xia, Q., Yang, Z., Zhang, X., ... & Shi, T. (2020). Prioritization analysis and compensation of geometric errors for ultra-precision lathe based on the random forest methodology. *Precision Engineering*, 61, 23-40.
<https://doi.org/10.1016/j.precisioneng.2019.09.012>
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International journal of forecasting*, 16(4), 437-450.
[https://doi.org/10.1016/S0169-2070\(00\)00065-0](https://doi.org/10.1016/S0169-2070(00)00065-0)
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of geophysical research: atmospheres*, 106(D7), 7183-7192.
<https://doi.org/10.1029/2000JD900719>
- Tezel, G., & Buyukyildiz, M. (2015). Monthly evaporation forecasting using artificial neural networks and support vector machines. *Theoretical and applied climatology*, 124, 69-80. <https://doi.org/10.1007/s00704-015-1392-3>
- Touati, B. (2010). Les barrages et la politique hydraulique en Algérie : état, diagnostic et perspectives d'un aménagement durable, Thèse de doctorat d'Etat, Université Mentouri de Constantine, Faculté des sciences de la terre, de la géographie et de l'aménagement du territoire, pp277-288.
- Tyralis, H., Papacharalampous, G., & Langousis, A. (2019). A brief review of random forests for water scientists and practitioners and their recent history in water resources. *Water*, 11(5), 910. <https://doi.org/10.3390/w11050910>
- Üneş, F., Demirci, M., Taşar, B., Kaya, Y. Z., & Varçin, H. (2019). Estimating dam reservoir level fluctuations using data-driven techniques.
<https://doi.org/10.15244/pjoes/93923>
- Valizadeh, N., & El-Shafie, A. (2013). Forecasting the level of reservoirs using multiple input fuzzification in ANFIS. *Water resources management*, 27, 3319-3331.
<https://doi.org/10.1007/s11269-013-0349-5>
- Vapnik, V. (1995) *The nature of statistical learning theory*. Springer-Verlag, New York
- Vapnik, V. (1998) *Statistical learning theory*. Wiley, New York
-

- Ishak, W. H. W., Ku-Mahamud, K. R., & Morwawi, N. M. (2011). Conceptual model of intelligent decision support system based on naturalistic decision theory for reservoir operation during emergency situation. *International Journal of Civil & Environmental Engineering*, 11(2), 6-11.
- Wang, C., Zhao, J., & Tian, B. (2021). Assessment of water footprint for crop production: a case study in North China. In *IOP Conference Series: Earth and Environmental Science* (Vol. 831, No. 1, p. 012047). IOP Publishing. <https://doi.org/10.1088/1755-1315/831/1/012047>
- Wang, J., Yang, R., & Bai, Z. (2015). Spatial variability and sampling optimization of soil organic carbon and total nitrogen for Minesoils of the Loess Plateau using geostatistics. *Ecological Engineering*, 82, 159-164. <https://doi.org/10.1016/j.ecoleng.2015.04.103>.
- Wang, Y. M., Chang, J. X., & Huang, Q. (2010). Simulation with RBF neural network model for reservoir operation rules. *Water resources management*, 24, 2597-2610. <https://doi.org/10.1007/s11269-009-9569-0>.
- Wang, Z., Lai, C., Chen, X., Yang, B., Zhao, S., & Bai, X. (2015). Flood hazard risk assessment model based on random forest. *Journal of Hydrology*, 527, 1130-1141. <https://doi.org/10.1016/j.jhydrol.2015.06.008>
- Wee, W. J., Zaini, N. A. B., Ahmed, A. N., & El-Shafie, A. (2021). A review of models for water level forecasting based on machine learning. *Earth Science Informatics*, 14, 1707-1728. <https://doi.org/10.1007/s12145-021-00664-9>
- Williamson, D. F., Parker, R. A., & Kendrick, J. S. (1989). The box plot: a simple visual method to interpret data. *Annals of internal medicine*, 110(11), 916-921. <https://doi.org/10.7326/0003-4819-110-11-9163>
- World Commission On Dams. *Dams and development: A new framework for decision-making*. Report of WCD. London: Earthscan Publications, 2000, 404p. Disponible sur: https://www.internationalrivers.org/sites/default/files/attached-files/world_commission_on_dams_final_report.pdf.

- Wu L, Huang G, Fan J et al (2020a) Hybrid extreme learning machine with meta-heuristic algorithms for monthly pan evaporation prediction. *Comput Electron Agric* 168:105115. <https://doi.org/10.1016/j.compag.2019.105115>
- Wu, C., Fang, C., Wu, X., Zhu, G., (2020b). Health-risk assessment of arsenic and groundwater quality classification using random forest in the yanchi region of northwest China. *Expo. Health* 12, 761–774.
<https://doi.org/10.1007/s12403-019-00335-7>.
- Xiang, Z., Yan, J., & Demir, I. (2020). A Rainfall-Runoff Model With LSTM-Based Sequence-to-Sequence Learning, *Water resources research*, 56(1), e2019WR02532. <https://doi.org/10.1029/2019WR025326>.
- Yang, T., Asanjan, A. A., Welles, E., Gao, X., Sorooshian, S., & Liu, X. (2017). Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information. *Water Resources Research*, 53(4), 2786-2812. <https://doi.org/10.1002/2017WR020482>
- Yang, X., Zhang, M., He, X., Ren, L., Pan, M., Yu, X., ... & Sheffield, J. (2020). Contrasting influences of human activities on hydrological drought regimes over China based on high-resolution simulations. *Water Resources Research*, 56(6), e2019WR025843. <https://doi.org/10.1029/2019WR025843>
- Yaseen, Z. M., Jaafar, O., Deo, R. C., Kisi, O., Adamowski, J., Quilty, J., & El-Shafie, A. (2016). Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. *Journal of Hydrology*, 542, 603-614.
<https://doi.org/10.1016/j.jhydrol.2016.09.035>
- Yeh, W. G. (1985). Reservoir management and operations models: A state-of-the-art review. *Water resources research*, 21(12), 1797-1818.
- Young GK (1967) Techniques for finding reservoir operating rules. Harvard University, Div Am. Soc. Civ. Eng., 93(HY6), 297-321, 1967.
- Yu, P. S., Chen, S. T., & Chang, I. F. (2006). Support vector regression for real-time flood stage forecasting. *Journal of hydrology*, 328(3-4), 704-716.
<https://doi.org/10.1016/j.jhydrol.2006.01.021>

- Zack, M. H. (2007). The role of decision support systems in an indeterminate world. *Decision Support Systems*, 43(4), 1664-1674. <https://doi.org/10.1016/j.dss.2006.09.003>
- Zamanisabzi, H., King, J. A., Dilekli, N., Shoghli, B., & Abudu, S. (2018). Developing an ANN based streamflow forecast model utilizing Data-Mining techniques to improve reservoir streamflow prediction accuracy: a case study. *Civil Engineering Journal*, 4(5), 1135. <https://doi.org/10.28991/cej-0309163>
- Zarei, M., Bozorg-Haddad, O., Baghban, S., Delpasand, M., Goharian, E., & Loáiciga, H. A. (2021). Machine-learning algorithms for forecast-informed reservoir operation (FIRO) to reduce flood damages. *Scientific reports*, 11(1), 24295. <https://doi.org/10.1038/s41598-021-03699-6>
- Zhang, D., Lin, J., Peng, Q., Wang, D., Yang, T., Sorooshian, S., ... & Zhuang, J. (2018). Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm. *Journal of Hydrology*, 565, 720-736. <https://doi.org/10.1016/j.jhydrol.2018.08.050>
- Zhang, X., Wang, H., Peng, A., Wang, W., Li, B., & Huang, X. (2020). Quantifying the uncertainties in data-driven models for reservoir inflow prediction. *Water Resources Management*, 34, 1479-1493. <https://doi.org/10.1007/s11269-020-02514-7>