

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



Université 20 Août 1955 Skikda

Faculté des Sciences

Département des Sciences Agronomiques



Filière : Sciences Agronomiques

THESE:

Présentée pour l'obtention du diplôme de DOCTORAT 3^{ème}Cycle (LMD)

SPÉCIALITÉ : AMÉNAGEMENT HYDRO-AGRICOLE

Thème :

Test de plusieurs modèles pluie-débit à différents pas de temps cas du Nord algérien

Présenté par :

- DAIF NOUREDDINE

Membres de Jury:

Mr : HEDDAM Salim	(prof)	Président	Université du 20 Août 1955 – Skikda
Mr : TOUMI Faycal	(MCA)	Examineur	Université Badji Mokhtar – Annaba
Mr : HOUICHI Larbi	(prof)	Examineur	Université Hadj Lakhdar – Batna 2
Mr : LAOUACHERIA Fares	(MCA)	Examineur	Université Badji Mokhtar – Annaba
Mr : HEBAL Aziz	(MCA)	Promoteur	Université du 20 Août 1955 – Skikda

Année universitaire : 2024-2025

DÉDICACES

Je tiens à dédier ce travail :

*A ma chère mère, mon cher père et mes frères
A mes amis et collègues de
l'Université de Skikda, à tous ceux qui
m'ont souhaité plein succès et
attendaient l'achèvement de ce travail*

REMERCIEMENT

Mes remerciements s'adressent en premier lieu à Allah le tout puissant pour la volonté, la santé et la patience qu'il m'a donné durant toutes ces longues années.

Ainsi, je tiens également à exprimer mes vifs remerciements à mon encadreur Mr. HEBAL Aziz qui m'a apporté une aide précieuse. je lui exprime mes gratitude pour sa grande disponibilité ainsi que pour sa compréhension et les encouragements qu'il m'a apportés...

Un remerciement spécial à monsieur le professeur HEDDAM SALIM pour son aide.

Je tient à exprimer ma profonde gratitude aux Membres du Jury pour avoir accepté de juger ce modeste travail, Votre disponibilité et votre engagement sont grandement appréciés.

Je suis convaincu que vos conseils et vos remarques seront précieux pour enrichir mon travail de recherche. Votre expertise et vos perspectives critiques me permettra d'améliorer la qualité et la rigueur de ma thèse.

Enfin, je tiens à exprimer mes reconnaissances à tous mes amis et collègues pour le soutien moral et matériel...

Résumé

La disponibilité en eau dans le Nord de l'Algérie revêt une importance capitale pour divers secteurs tels que l'agriculture, l'approvisionnement en eau potable et la gestion des ressources hydriques. Toutefois, cette région est confrontée à des défis majeurs en raison de la variabilité des précipitations et des changements climatiques. C'est dans ce contexte que s'inscrit cette étude, qui se concentre sur la modélisation pluie-débit à différentes échelles de temps : journalière, mensuelle et annuelle.

Cette thèse emploie tout d'abord des modèles conceptuels ; Génie Rural (GR5J, GR2M) et Hydrologiska Byråns Vattenbalansavdelning (HBV), pour leur capacité à représenter de manière simplifiée les processus hydrologiques. Ensuite, elle utilise des modèles d'intelligence artificielle autonomes ; Réseaux de Neurones Artificiels (MLPNN), Extreme Learning Machine (ELM), Random Forest Regression (RFR) et Modèle M5 (M5Tree) pour leur capacité à apprendre à partir des données et à s'adapter aux conditions évolutives. Enfin, des modèles d'intelligence artificielle hybrides sont développés en combinant les forces des modèles autonomes. Elle explore également l'utilisation de décompositions de signal (VMD et MODWT) pour améliorer la précision des modèles, ainsi que l'intégration d'algorithmes d'optimisation ; The Artificial Rabbits Optimization (ARO), l'algorithme d'optimisation Mayfly (MAO) et Particle Swarm Optimization (PSO)-Grey Wolf Optimizer (GWO) pour ajuster les modèles hybrides à différents pas de temps. Notre étude a été menée sur huit stations situées dans le Nord de l'Algérie.

Les résultats indiquent que les modèles hybrides avec décompositions de signal se révèlent être des choix judicieux pour le pas de temps journalier, démontrant une capacité remarquable à capturer la complexité des interactions pluie-débit à cette échelle fine. Pour le pas de temps mensuel, l'étude souligne l'efficacité des modèles simples d'intelligence artificielle ainsi que des modèles hybrides avec des algorithmes d'optimisation, suggérant une adaptation de la modélisation à cette échelle temporelle. Enfin, En ce qui concerne la modélisation du débit annuel, nous avons été limités dans l'application de nombreux modèles en raison du nombre restreint de données collectées, les modèles conceptuels sont recommandés, offrant une approche globale et simplifiée adaptée à cette échelle temporelle. Ces résultats mettent en évidence l'importance de choisir le modèle approprié en fonction du pas de temps pour garantir des estimations précises et fiables du débit dans cette région spécifique.

Les mots clé ; le Nord algérien, les modèles conceptuels, intelligence artificielle, les algorithmes .d'optimisation, décomposition de signal, modélisation pluie-débit

الملخص

تعد وفرة المياه في شمال الجزائر ذات أهمية كبيرة للقطاعات الحيوية، مثل الزراعة وتوفير المياه الصالحة للشرب وإدارة الموارد المائية. إلا أن هذه المنطقة تواجه تحديات ملحوظة بسبب التغيرات في معدلات الهطول المطري والتقلبات المناخية. وضمن هذا السياق، تهدف هذه الدراسة إلى نمذجة تدفق المياه الناتج عن الأمطار عبر فترات زمنية مختلفة تشمل المقياس اليومي، الشهري، والسنوي.

تستخدم هذه الرسالة في البداية نماذج مفهومية مثل نموذج GR2M،GR5J ونموذج إدارة التوازن المائي للمكتب الهيدرولوجي (HBV) ، لقدرتها على تمثيل العمليات الهيدرولوجية بشكل مبسط. ثم تستخدم نماذج الذكاء الاصطناعي المستقلة مثل الشبكات العصبية الاصطناعية (MLPNN) وآلة التعلم الشديدي (ELM) والانحدار الغابي العشوائي (RFR) ونموذج M5 (M5Tree) ، لقدرتها على التعلم من البيانات والتكيف مع التغيرات. وأخيراً، يتم تطوير نماذج ذكاء اصطناعي مختلطة من خلال توحيد قوى النماذج المفهومية والنماذج المستقلة. تستكشف الدراسة أيضاً استخدام فك تشفير الإشارة VMD و MODWT لتحسين دقة النماذج، بالإضافة إلى دمج خوارزميات ARO، MAO، PSO-GWO لضبط النماذج المختلطة على مختلف مقاييس الزمن، تم إجراء دراستنا على ثماني محطات تقع في شمال الجزائر.

تشير النتائج إلى أن النماذج المختلطة مع فك تشفير الإشارة تثبت أنها خيارات حكيمة لمقياس الزمن اليومي، حيث تظهر قدرة ملحوظة على التقاط تعقيد تفاعلات الهطول والتصريف على هذا المقياس الدقيق. بالنسبة للمقياس الشهري، تؤكد الدراسة فعالية النماذج البسيطة للذكاء الاصطناعي بالإضافة إلى النماذج المهجنة مع خوارزميات ، مما يقترح تكييف النمذجة بناءً على الفترة الزمنية المدروسة. أخيراً، فيما يتعلق بنمذجة التدفق السنوي، كنا محدودين في تطبيق النماذج بسبب العدد المحدود للبيانات المجمعة. يوصى بالنماذج المفاهيمية، لأنها توفر نهجاً شاملاً ومبسطاً يتناسب مع هذا المقياس الزمني. تبرز هذه النتائج أهمية اختيار النموذج المناسب بناءً على مقياس الزمن لضمان تقديرات دقيقة وموثوقة لتدفق المياه في هذه المنطقة الخاصة.

الكلمات المفتاحية: شمال الجزائر، النماذج المفهومية، الذكاء الاصطناعي، خوارزميات الأمثلية، فك تشفير الإشارة، نمذجة تدفق المياه.

Abstract

Water availability in northern Algeria is of paramount importance for various sectors such as agriculture, drinking water supply, and water resources management. However, this region faces major challenges due to the variability of precipitation and climate change. It is in this context that this study focuses on rainfall-runoff modeling at different time scales: daily, monthly, and annual.

This thesis first employs conceptual models such as Génie Rural (GR5J, GR2M) and Hydrologiska Byråns Vattenbalansavdelning (HBV), for their ability to represent hydrological processes in a simplified manner. It then uses autonomous artificial intelligence models such as Artificial Neural Networks (MLPNN), Extreme Learning Machine (ELM), Random Forest Regression (RFR), Model M5 (M5Tree) for their ability to learn from data and adapt to changing conditions. Finally, hybrid artificial intelligence models are developed by combining the strengths of conceptual and autonomous models. It also explores the use of signal decompositions (VMD and MODWT) to improve model accuracy, as well as the integration of optimization algorithms; The Artificial Rabbits Optimization (ARO), the Mayfly Optimization Algorithm (MAO), and Particle Swarm Optimization (PSO)-Grey Wolf Optimizer (GWO) to adjust hybrid models to different time steps, Our study was conducted on eight stations located in northern Algeria.

The results indicate that hybrid models with signal decompositions are wise choices for the daily time step, demonstrating remarkable ability to capture the complexity of rainfall-runoff interactions at this fine scale. For the monthly time step, the study highlights the effectiveness of simple artificial intelligence models as well as hybrid models with optimization algorithms, suggesting an adaptation of modeling based on the studied temporal periodicity. Finally, regarding the modeling of annual flow, we were limited in applying many models due to the restricted amount of collected data. Conceptual models are recommended, offering a comprehensive and simplified approach suitable for this temporal scale. These results emphasize the importance of choosing the appropriate model based on the time step to ensure accurate and reliable flow estimates in this specific region.

Keywords: northern Algeria, conceptual models, artificial intelligence, optimization algorithms, signal decomposition, rainfall-runoff modeling.

SOMMAIRE

Dédicace	I
Remerciements	II
Résumé	III
Sommaire	VI
Liste des figures	XI
Liste des tableaux	XIV
Liste des abréviations	XVI
Introduction générale	1

CHAPITRE I : RECHERCHE BIBLIOGRAPHIQUE ET ETAT DE L'ART

I.1 Introduction	4
I.2 Cycle hydrologique	4
I.3 La modélisation hydrologique	5
I.3.1 Eléments d'un modèle hydrologique.....	6
I.3.2 Etapes de la modélisation hydrologique	7
I.3.3 La modélisation pluie-débit.....	7
I.3.4 Intérêt de la modélisation pluie-débit.....	8
I.4 Classification des modèles pluie-débit.....	9
I.4.1 Selon la nature de la variable.....	9
I.4.1.1 Modèles stochastiques	9
I.4.1.2 Modèles déterministes.....	10
I.4.2 Selon le traitement de l'espace (Homogénéité du bassin).....	10
I.4.2.1 Modèles globaux.....	10
I.4.2.2 Modèles semi-distribués	10
I.4.2.3 Modèles distribués	11
I.4.3 Selon le fondement théorique et approche de développement.....	11
I.4.3.1 Modèles à base physique	11
I.4.3.2 Modèles empirique.....	12
I.4.3.3 Modèles conceptuels.....	12
I.5 Etat de l'art de la modélisation pluie-débit.....	13

I.5.1 Les modèles conceptuels.....	13
I.5.2 Les modèles à base d'intelligence artificielle.....	14
I.6 Conclusion	17

CHAPITRE II : PRÉSENTATION DE LA RÉGION D'ÉTUDE

II.1 Introduction	18
II.2 Situation géographique	18
II.3 Le relief	19
II.4 Climat	20
II.5 Couverture végétale	21
II.6 Sol.....	22
II.7 Hydrographie et hydrométrie	22
II.8 Caractéristiques des bassins versant étudiés	24
II.8.1 Bassin versant du Cheliff	24
II.8.2 Bassin versant des Côtiers Algérois	24
II.8.3 Bassin versant des Côtiers Constantinois	25
II.8.4 Bassin versant de la Seybouse	25
II.8.5 Bassin versant de la Soummam	26
II.9 Caractéristiques morphométriques des bassins versants étudiés	26
II.10. Conclusion.....	29

CHAPITRE III : DONNEES UTILISEES ET SELECTION DES VARIABLES

III.1 Introduction	30
III.2 La collecte de données	30
III.3 Les stations sélectionnées.....	31
III.4 Estimation de l'évapotranspiration	31
III.5 L'analyse statistique de données utilisées.....	33
III.6 L'analyse des séries des débits	37
III.7 La sélection des variables d'entrée	41
III.7.1 Les modèles conceptuels	41
III.7.2 Les modèles de l'intelligence artificielle.....	41
III.8 Conclusion.....	44

CHAPITRE IV : MATÉRIELS ET MÉTHODES

IV.1 Introduction	45
IV.2 Les modèles conceptuels.....	45
IV.2.1 Le modèle HBV	45
IV.2.2 Les modèles GR (génie rural)	50
IV.2.2.1 Modèle du Génie Rural à 1 paramètres annuels GR1A	50
IV.2.2.2 Modèle du Génie Rural à 2 paramètres mensuel GR2M.....	51
IV.2.2.3 Modèle du Génie Rural à 5 paramètres Journalier GR5J	53
IV.3 Modèles basés sur l'intelligence artificielle	56
IV.3.1 Les réseaux de neurones artificiels	56
IV.3.1.1 Définition.....	57
IV.3.1.2 Principe de fonctionnement.....	57
IV.3.2 Les forêts aléatoires	58
IV.3.2.1 Définition.....	58
IV.3.2.2 Principe de fonctionnement.....	59
IV.3.3 Apprentissage automatique extrême (ELM).....	60
IV.3.3.1 Définition.....	60
IV.3.3.2 Principe de fonctionnement.....	61
IV.3.4 Modèle de M5tres régression.....	62
IV.3.4 Définition	62
IV.3.4.2 Principe de fonctionnement.....	63
IV.4 Les modèles de l'intelligence artificielle hybrides	64
IV.4.1 Les transformations en ondelettes	64
IV.4.1.1 Maximum overlap discrete wavelet transform (MODWT).....	64
IV.4.1.1 Variational mode decomposition (VMD).....	65
IV.4.2 Les algorithmes d'Optimisation	65
IV.4.2.1 Particle Swarm Optimization (PSO)-Grey Wolf Optimizer (GWO).....	66
IV.4.2.2 l'algorithme d'optimisation Mayfly	66
IV.4.2.3 the Artificial Rabbits Optimization (ARO).....	67
IV.5 Critères d'évaluation de la qualité de modèles	67
IV.6 Les logiciels utilisés	68
IV.7 Conclusion	70

CHAPITRE V : RÉSULTATS ET DISCUSSIONS

V.1 Introduction	71
V.2 Les modèles conceptuels.....	71
V.2.1 Pas de temps journalier	72
V.2.2 Pas de temps mensuel et annuel.....	75
V.3 Les modèles à base d'intelligence artificielle	77
V.3.1 Pas de temps journalier	78
V.3.2 Pas de temps mensuel.....	81
V.4 Les modèles à base de l'intelligence artificielle hybrides	84
V.4.1 Les transformations en ondelettes.....	84
V.4.1.1 Pas de temps journalier	85
V.4.1.2 Pas de temps mensuel.....	91
V.4.2. Les algorithmes d'optimisation.....	91
V.4.2.1 Pas de temps journalier	92
V.4.2.2 Pas de temps mensuel.....	94
V.4.2.3 pas de temps annuel.....	97
V.5 Conclusion.....	98

CHAPITRE VI : ANALYSE COMPARATIVE DES MODELES DE PREDICTION DU DEBIT "Inter-Comparaison Des Modèles"

VI.1 Introduction	99
VI.2 Comparaison et évaluation des modèles	99
VI.2.1 Pas de temps journalier	100
VI.2.2 Pas de temps mensuel et annuels.....	107
VI.3 Performances des Modèles Testés aux pas de Temps Journalier et Mensuel.....	113
VI.4 Conclusion	116
Conclusion générale.....	117
Références bibliographiques.....	120
Annexe A.....	136
Annexe B.....	140
Annexe C.....	144

Annexe D.....	148
Annexe E.....	152
Annexe F.....	157
Annexe G.....	161

LISTE DES FIGURES

CHAPITRE I : RECHERCHE BIBLIOGRAPHIQUE ET ETAT DE L'ART

Figure I.1. Le cycle hydrologique (www.amareo.com , 2023).....	5
Figure I.2. Composants d'un modèle hydrologique (Singh, 1995)	7
Figure I.2. Classification des modèles hydrologiques (Berthier, 2005).....	12

CHAPITRE II : PRÉSENTATION DE LA RÉGION D'ÉTUDE

Figure II.1. Situation géographique de la zone d'étude (Benslimane et al., 2008).....	19
Figure II.2. Carte pluviométrique du Nord de l'Algérie (Source ANRH, 1993)	21
Figure II.3. Cartographie de l'indice de végétation en 2004 (Benslimane et al., 2008).....	22
Figure II.4. Organisation des grands bassins versants du Nord de l'Algérie	23
Figure II.5. Situation géographique des bassins étudiés	24
Figure II.6. Caractéristiques des bassins versants étudiés.....	28

CHAPITRE III : DONNEES UTILISEES ET SELECTION DES VARIABLE

Figure III.1. Intervalle plot pour les stations hydrométriques ou pas de temps a) journalière, b) mensuel, c) annuel.....	38
Figure III.2. Variation des débits journaliers pour quelques stations étudiées.....	39
Figure III.3. Variation des débits mensuels pour quelques stations étudiées.....	40
Figure III.4. Matrice de corrélation pour quelques stations étudiées ou pas de temps a) journalière, b) mensuel, c) annuel.....	43

CHAPITRE IV : MATÉRIELS ET MÉTHODES

Figure IV.1. Schéma simplifié du modèle HBV (Abadie, 2006).....	46
Figure IV.2. Structure Schématique du model HBV(Seibert et Vis, 2012)	49
Figure IV.3. Schéma de la structure du modèle GR2M (Mouelhi, 2006).....	51
Figure IV.4. Schéma du GR5J (Moine, 2008).....	55

Figure IV.5. Architecture du modèle Le réseaux de neurone multicouche	58
Figure IV.6. Architecture du modèle de régression de la forêt aléatoire (RFR)	60
Figure IV.7. Organigramme de l'architecture du modèle ELM	61
Figure IV.8. Organigramme de l'architecture du modèle M5tres	63
Figure IV.9. Schéma descriptif de l'outil utilisé pour les tests	70

CHAPITRE V : RÉSULTATS ET DISCUSSIONS

Figure.V.1. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles dans la phase validation.....	74
Figure.V.2. Nuage de points entre les débits mensuel mesurés et calculés pour les meilleurs modèles dans la phase de validation	76
Figure.V.3. Organigramme du cadre de modélisation pluie-débit $Q(t)$	77
Figure.V.4. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles de l'intelligence artificielle dans la phase validation.....	80
Figure.V.5. Nuage de points entre les débits mensuels mesurés et calculés pour les meilleurs modèles de l'intelligence artificielle hybridée dans la phase de validation	83
Figure.V.6. Organigramme du cadre de modélisation pluie-débit $Q(t)$	84
Figure.V.7. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur MODWT et VMD dans la phase validation	90
Figure.V.8. Organigramme du cadre de modélisation pluie-débit $Q(t)$ en utilisant les algorithmes d'optimisation.....	92
Figure.V.9. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur algorithmes dans la phase validation	94
Figure.V.10. Nuage de points entre les débits mensuel mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur algorithmes dans la phase validation	97

CHAPITRES VI : ANALYSE COMPARATIVE DES METHODES DE PREDICTION DU DEBIT " Inter-Comparaison Des Modèles"

Figure.VI.1. Performances des meilleurs modèles en phase validation à la station RN25 : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor	103
---	-----

Figure.VI.2. Performances des meilleurs modèles en phase validation à la station AIN ASSEL : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor.....	104
Figure.VI.3. Performances des meilleurs modèles en phase validation à la station BOUCHEGOUF : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor	105
Figure.VI.4. Performance des meilleurs modèles en phase validation à la station RN25 : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor	109
Figure.VI.3. Performances des meilleurs modèles en phase validation à la station BOUCHEGOUF : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor	110
Figure.VI.3. Performances des meilleurs modèles en phase validation à la station BOUCHEGOUF : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor	111

LISTE DES TABLEAUX

CHAPITRE I : RECHERCHE BIBLIOGRAPHIQUE ET ETAT DE L'ART

Tableau 1. 1. Exemple de caractéristiques des modèles pluie-débit (Berthier, 2005).....	9
---	---

CHAPITRE II : PRÉSENTATION DE LA RÉGION D'ÉTUDE

Tableau II.1. Caractéristiques des bassins versants étudiés (Source ANRH, 2021)	27
---	----

CHAPITRE III : DONNEES UTILISEES ET SELECTION DES VARIABLE

Tableau III.1. Les stations choisies dans cette étude (Source ANRH, 2021 ; ONM, 2021)..	31
Tableau III.2. Les paramètres statistiques des données utilisées au pas de temps journalier.....	33
Tableau III.3. Les paramètres statistiques des données utilisées au pas de temps mensuel.....	35
Tableau III.4. Les paramètres statistiques des données utilisées ou pas de temps annuel	36
Tableau III.5. Les combinaisons entrées pour différents modèles.....	44

CHAPITRE V : RÉSULTATS ET DISCUSSIONS

Tableau V.1. Durées de calibrage et validation.....	72
Tableau V.2. Paramètres de calibration du modèle GR5J	72
Tableau V.3. Paramètres de calibration du modèle HBV.....	72
Tableau V.4. Valeurs des critères d'évaluation des modèles conceptuels au pas de temps journalier	73
Tableau V.5. Résultats obtenus par le modèle GR2M.....	75
Tableau V.6. Résultats obtenus par le modèle GR1A	76
Tableau.V.7. Performances des différents modèles autonomes pour la station RN25 au pas de temps journalier	78
Tableau.V.8. Performances des différents modèles autonomes pour la station AIN ASSEL au pas de temps journalier	79
Tableau.V.9. Performances des différents modèles autonomes pour la station RN25 au pas de temps mensuel	80

Tableau.V.10. Performances des différents modèles autonomes pour la station AIN ASSEL au pas de temps mensuel	81
Tableau.V.11. Performance des modèles hybrides basés sur le MODWT pour la station RN 2584	
Tableau.V.12. Performance des modèles hybrides à base de MODWT pour la station de BOUCHEGOUF	86
Tableau.V.13. Performance des modèles hybrides à base de VMD pour la station de FREHA ..	88
Tableau.V.14. Performance des modèles hybrides à base de VMD pour la station d'AIN BERDA	89
Tableau.V.15. Performance des modèles hybrides à base des algorithmes d'optimisation de pour la station de FREHA.....	93
Tableau.V.16. Performance des modèles hybrides à base des algorithmes d'optimisation de pour la station de RN25.....	93
Tableau.V.17. Les performances des modèles hybrides à la base des algorithmes d'optimisation pour la station FERMATOU	95
Tableau.V.18. Les performances des modèles hybrides à la base des algorithmes d'optimisation pour la station BOUBRIK.....	95

CHAPITRES VI : ANALYSE COMPARATIVE DES METHODES DE PREDICTION

DU DEBIT " Inter-Comparaison Des Modèles"

Tableau.VI.1. Récapitule des résultats de tous les modèles pour RN25 au pas de temps journalier.....	101
Tableau.VI.2. Récapitule des résultats de tous les modèles pour AIN ASSEL au pas de temps journalier.....	101
Tableau.VI.3. Récapitule des résultats de tous les modèles pour BOUCHEGOUF au pas de temps journalier	102
Tableau.VI.4. Récapitule des résultats de tous les modèles pour RN25 au pas de temps mensuel.....	108
Tableau.VI.5. Récapitule des résultats de tous les modèles pour AIN ASSEL au pas de temps mensuel.....	108
Tableau.VI.6. Récapitule des résultats de tous les modèles pour BOUCHEGOUF au pas de temps mensuel.....	108

LISTE DES ABREVIATIONS

ACF = Autocorrelation Function = Fonction d'autocorrélation

PCA = Principal Component Analysis = Analyse en composantes principales

AI = Artificial Intelligence = Intelligence artificielle

ANFIS = Adaptive Neuro-Fuzzy Inference System = Système adaptatif d'inférence neuro floue

ANN = Artificial Neural Networks = Réseaux de neurones artificiels

ANRH = Agence Nationale des Ressources Hydraulique

ARIMA = Autoregressive Integrated Moving Average models = Modèles autorégressifs intégrés et de moyenne mobile

ARMA = Auto Regressive Moving Average models = Modèles autorégressifs et de moyenne mobile

ARO = Artificial Rabbits Optimization = Optimisation des lapins artificiels

BA = Bat Algorithm = algorithme de chauve-souris

BP = Back Propagation = Rétro-propagation

BR = Bayesian Regularization = Régularisation bayésienne

CWT = Continuous Wavelet Transform = Transformée continue en ondelettes

DWT = Discrete Wavelet Transform = Ondelettes de type transformation discrète

ELM = Extreme Learning Machine = Machine d'apprentissage extrême

EMD = Empirical Mode Decomposition = Décomposition en mode empirique

FFA = Fruit Fly Algorithms = Algorithme de la mouche des fruits

FFBP = Feed Forward Back Propagation = algorithme de rétro-propagation du gradient

GA = Genetic Algorithm = Algorithme génétique

GEP = Gene Expression Programming = programmation d'expression génique

GP = Genetic Programming = Programmation génétique

GR2m = Modèle conceptuel Génie rural à 2 paramètres Mensuel

GR4J = Modèle conceptuel Génie rural à 4 paramètres journalier

GR5J = Modèle conceptuel Génie rural à 5 paramètres journalier

GR6J = Modèle conceptuel Génie rural à 6 paramètres journalier

GRNN= Generalized Regression Neural Networks= Réseaux de neurones de régression généralisée

GSA = Gravitational Search Algorithm = Algorithme de recherche gravitationnelle

GWO = Grey Wolf Optimizer = Algorithme d'optimisation du loup gris

LSSVM = Least-Squares Support Vector Machines = Machines à vecteurs de support en moindres carrés

M5Tree = Model Tree = Modèles d'arbres

MAE = Mean Absolute Error = Erreur moyenne absolue

MARS = Multivariate Adaptive Regression Splines = spline de régression adaptative multivariée

MAO = Mayfly Optimization Algorithm = Algorithme d'optimisation Mayfly

MLP = Multi-Layer Perceptron = Perceptron multicouche

MLR = multiple linear regression = Régression linéaire multiple

MODWT= Maximum Overlap Discrete Wavelet Transform = Transformée en Ondelette Discrète à Chevauchement Maximum

NSE = Nash Sutcliffe criterion = Critère de Nash Sutcliffe

ONM = Office Nationale de la Météorologie

PACF = Partial Autocorrelation Function = Fonction d'autocorrélation partielle PSO = Particle swarm optimization = Optimisation par essais des particules Q = Débits

QPSO = Quantum Particle Swarm Optimization = Optimisation quantique par essais de particules

R = Coefficient de corrélation

R² = Coefficient de détermination

RBF = Radial Basis Function = Fonction de base radiale

RF = Random Forest = Forêt aléatoire

RMR = Régression Multiple Récursive

RMSE = Root Mean Square Error = Erreur moyenne quadratique

SFLA = Shuffled Frog-Leaping Algorithm = Algorithme du saut de grenouille traînante SOM= Self organisation maps = Cartes auto-organisées

SHA = Spotted Hyena Algorithm = Hyène tachetée algorithme

SVM = Support Vector Machine = Machines à vecteurs de support

SVR = Support Vector Regression = Régression à vecteurs de support

WANN = Wavelet-Artificial Neural Networks models = Modèles ondelettes-réseaux de neurones artificiels

WT = wavelet Transform = transformation en ondelettes

WSVR = Wavelet Support Vector Regression models = Modèles Ondelettes- régression à vecteurs de support

VMD = Variational Mode Decomposition = La décomposition en modes variationnels

INTRODUCTION

INTRODUCTION

Les ressources en eau revêtent une importance vitale pour la subsistance de la vie. Elle est essentielle à la production d'énergie, à l'industrie, à l'agriculture et bien sûr à la consommation en eaux humaine. Cependant, la croissance démographique rapide, les changements climatiques et les pratiques non durables mettent ces ressources essentielles sous pression. Les débits des cours d'eau se révèlent indispensables dans la gestion des ressources en eau, étant un élément clé pour assurer la durabilité et planifier judicieusement les activités humaines. En tant que mesure du flux d'eau au sein d'un cours d'eau, le débit offre des informations cruciales sur la disponibilité et la répartition de cette ressource précieuse. Son importance a motivé de nombreux scientifiques à entreprendre des recherches approfondies en vue d'une meilleure compréhension, contrôle et modélisation de ce dernier (Vörösmarty et al., 2000 ; Gleick, 1993).

La pertinence de la connaissance et de l'étude des régimes d'écoulement est manifeste dans la planification et la concrétisation de projets d'ouvrages hydrauliques tels que barrages, périmètres irrigués, prises d'eau le long des cours d'eau pour l'irrigation, zones industrielles, etc. La mesure du débit des cours d'eau au fil du temps se positionne comme une donnée fondamentale, indispensable à toutes les études et planifications relatives aux projets hydrauliques (Seo et al., 2018 ; Linsley et al., 1975 ; Dingman, 2015).

La mesure précise des débits des cours d'eau est souvent complexe, en raison des variations naturelles et des influences météorologiques, hydrologiques et topographiques. Les méthodes de mesure directe peuvent être coûteuses, difficiles à maintenir sur le long terme et parfois impossibles dans des conditions extrêmes. C'est là que la modélisation pluie-débit intervient. En utilisant des données météorologiques, physiologiques et topographiques, ces modèles peuvent estimer les débits avec une précision raisonnable. Ils jouent un rôle crucial dans la compréhension et la prédiction des régimes hydrologiques, essentiels pour la gestion des ressources en eau et la prévention des catastrophes telles que les inondations (Singh, 1995). Bien qu'ils ne remplacent pas les mesures directes, les modèles pluie-débit offrent une solution efficace pour combler les lacunes des méthodes traditionnelles de mesure (Moradkhani et al., 2004).

Les modèles pluie-débit peuvent être classés en plusieurs types, chacune apportant une perspective unique pour appréhender la dynamique hydrologique des bassins versants. A titre indicatif, les modèles conceptuels, qui sont souvent simples et basés sur des concepts

simplifiés du cycle hydrologique, offrent une compréhension globale des processus clés (Beven, 2012). Les modèles empiriques fournissent des outils pragmatiques mais dépendants des données historiques, en se basant sur les relations statistiques entre les précipitations et les débits observés (Wittenberg, 1999). Les modèles physiques, quant à eux, intègrent des équations détaillées du mouvement de l'eau, capturant ainsi les interactions complexes du système hydrologique (Freeze et Harlan, 1969)

Récemment, le domaine de l'intelligence artificielle (IA) a connu des avancées transformatrices, en particulier dans la prédiction de séries temporelles complexes et non stationnaires telles que les variables de débit. Des techniques non conventionnelles ont émergé, ce qui a entraîné un accroissement notable de l'utilisation d'IA dans ce domaine (Modaresi et al., 2018 ; Kisi et al., 2018). Bien que les approximations simplifiées limitent souvent les modèles hydrologiques traditionnels, l'utilisation de techniques d'IA telles que les réseaux de neurones permettent d'exploiter pleinement la richesse des données hydrologiques. Les relations non linéaires entre les variables hydrologiques telles que les précipitations, l'évapotranspiration et les débits peuvent être capturées par ces modèles à partir d'énormes ensembles de données complexes (Coulibaly et al., 2000).

Cette thèse s'inscrit dans le domaine de la modélisation de la transformation de la pluie en débit l'étude a été menée sur huit stations situées dans le nord de l'Algérie. L'objectif principal de ce travail de thèse, est d'explorer et de présenter une approche avancée de la modélisation pluie-débit en utilisant plusieurs techniques, c'est-à-dire, nous allons tenter de tester plusieurs modèles pluie-débit à différentes pas de temps et formulations mathématiques, pour pouvoir en choisir le meilleur parmi ceux-ci, qui peut améliorer la précision des prévisions hydrologiques en capturant les relations complexes entre les données pluviométriques et les débits des cours d'eaux. Nous nous essayerons de dresser une comparaison approfondie entre les approches avancées utilisées par rapport aux autres méthodes traditionnelles de modélisation hydrologique.

Les objectifs et les tâches de recherche abordés dans cette étude sont les suivants :

- Ajuster les modèles conceptuels choisis et tester leur efficacité.
- Analyser les résultats des modèles conceptuels pour évaluer leur capacité à prédire les variations de débit

- Étudier l'efficacité des modèles d'intelligence artificielle pour obtenir de meilleures performances de prévision en utilisant uniquement les données de débit et pluie en entrée.
- Comparer les résultats obtenus par les modèles autonomes ; le réseau de neurone artificiels (MLPNN) les forêts aléatoires (RFR), le modèle M5Tree et machine d'apprentissage extrême (ELM).
- Analyser l'influence de la transformation des données d'entrée par les ondelettes (MODWT et VMD) sur les performances de divers modèles d'intelligence artificielle.
- Optimiser la capacité opérationnelle des réseaux de neurone artificiels en intégrant trois nouvel algorithme métaheuristique appelé Artificial Rabbits Optimization (ARO), Mayfly Optimisation Algorithm (MOA), loup gris (GWO) avec particle swarm optimization (PSO) (GWO-PSO).
- Comparer les nouveaux modèles hybrides à la base de la transformation en ondelettes et l'algorithme d'optimisation avec les modèles autonomes.
- Examiner l'influence du choix des variables d'entrée sur la qualité des prévisions afin de mieux comprendre cet impact.
- Choisissez le modèle le plus adapté à chaque pas de temps.

Pour ce faire, nous avons subdivisé notre travail en six chapitres avec une introduction et une conclusion générale.

Le premier chapitre, intitulé « Recherche bibliographique et état de l'art », fournit un aperçu des connaissances de base et des notions essentielles pour réaliser une étude hydrologique. Le deuxième chapitre est consacré à la présentation de la région d'étude, en décrivant ses caractéristiques ainsi que les stations retenues. Dans le troisième chapitre, « Données utilisées et sélection des variables », nous présentons les caractéristiques statistiques des séries de données étudiées et proposons une sélection préliminaire des variables d'entrée pour les différents modèles. Le quatrième chapitre, « Matériels et méthodes », décrit les modèles et les logiciels utilisés dans cette étude. Le cinquième chapitre est dédié aux résultats obtenus et à leur discussion, où nous exposons les résultats des différents modèles. Enfin, le sixième chapitre compare tous les modèles afin de choisir celui qui est le plus approprié pour chaque pas de temps.

Et nous terminerons ce travail par une conclusion générale.

CHAPITRE I
RECHERCHE
BIBLIOGRAPHIQUE ET
ETAT DE L'ART

CHAPITRE I : RECHERCHE BIBLIOGRAPHIQUE ET ETAT DE L'ART

I.1 Introduction

La gestion des ressources en eau est devenue l'un des défis majeurs du 21^{ème} siècle, en raison de la croissance démographique, de l'urbanisation rapide, des changements climatiques et de l'exploitation anarchique des ressources hydriques. Ces facteurs, ont exacerbé les problèmes existants liés à l'eau, tels que la rareté, la pollution, la surexploitation des aquifères et les conflits pour l'accès à l'eau.

L'hydrologie intervient dans la gestion de ces problèmes en utilisant des méthodes scientifiques pour comprendre et quantifier les processus hydrologiques. Donc, l'hydrologie est la science qui nous donne la faculté de prédire et de gérer les ressources en eau, puis le bon dimensionnement et l'aménagement des ouvrages grâce à la modélisation, qui elle-même est un vaste champ exigeant de précieuses compétences hydrologiques et informatiques pour transformer la pluie en débit, en utilisant les composantes du cycle hydrologique (Bouanani, 2010).

Dans cette partie du travail ; nous rappellerons ce qu'est la modélisation hydrologique et nous évoquerons également les types de modèles utilisés dans ce domaine. Mais, avant d'entamer cette revue, il est utile de donner un bref rappel sur le cycle hydrologique qui est la base de toute modélisation hydrologique.

I.2 Cycle hydrologique

Le cycle hydrologique, également connu sous le nom de cycle de l'eau, décrit le mouvement continu de l'eau sur la Terre, passant à travers différents états et processus. Il se divise généralement en plusieurs composantes : les précipitations, l'évapotranspiration, l'infiltration, l'écoulement de surface, (Figure I.1). Ce cycle se déroule en permanence et de manière continue, permettant la distribution de l'eau à travers différents réservoirs (océans, atmosphère, sols, lacs, rivières) et jouant un rôle vital pour maintenir l'équilibre des écosystèmes et des ressources en eau (Henine, 2005).

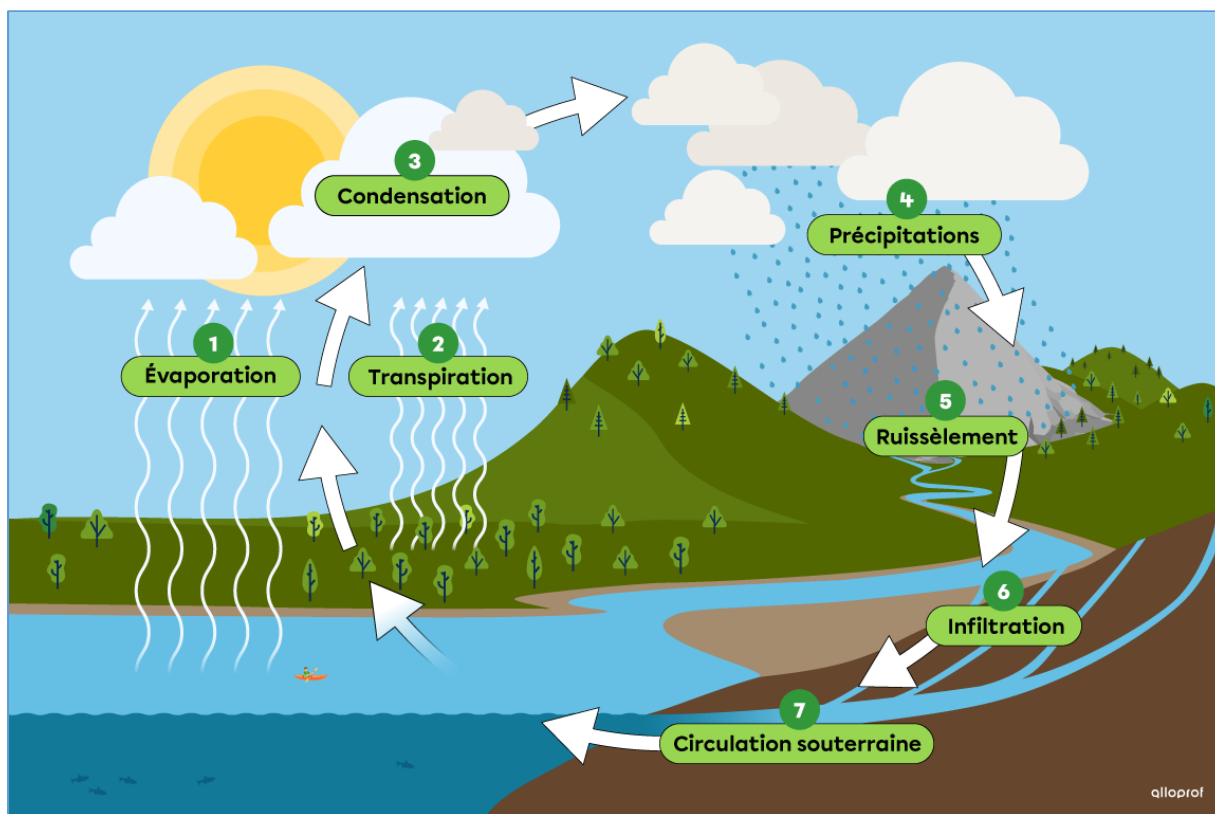


Figure I.1. Le cycle hydrologique (www.amareo.com, 2023).

I.3 La modélisation hydrologique

La modélisation hydrologique consiste à représenter mathématiquement les processus hydrologiques dans un système, pour prédire le comportement de l'eau dans cet environnement. Elle utilise des équations et des algorithmes pour simuler la manière dont l'eau se déplace, est stockée et change d'état dans un bassin versant, une région ou un système hydrologique. Autrement dit, la modélisation hydrologique est l'élaboration, par des méthodes physiques ou mathématiques, de modèles de simulation du cycle de l'eau et de son incidence sur un bassin hydrologique (Gnouma, 2006).

Un modèle hydrologique est une représentation mathématique ou informatique du cycle de l'eau dans une zone spécifique, comme un bassin versant ou une rivière. Un modèle peut être défini comme une représentation simplifiée d'un phénomène ou d'un processus. Il est généralement caractérisé par un ensemble de variables et par des équations qui décrivent la relation entre ces variables. Dans le cas de l'hydrologie, un modèle représente la partie du système environnemental terrestre qui contrôle le mouvement et le stockage de l'eau (Solomatine et Wagener, 2011).

I.3.1 Eléments d'un modèle hydrologique

Selon Singh et al. (1995), un modèle hydrologique est composé de plusieurs éléments essentiels, pour représenter avec précision les processus hydrologiques d'une zone spécifique.

- **Variables d'entrée** : sont les données d'entrée du modèle qui sont indépendantes, par exemple :

- Les données météorologiques collectées à partir de stations météorologiques ou obtenues à partir de données satellites.

- Les informations sur la topographie, la géologie, l'utilisation des terres, la végétation et d'autres caractéristiques du bassin versant, sont nécessaires pour décrire l'environnement physique où se déroulent les processus hydrologiques.

- **Variables de sortie** : il s'agit de la réponse du système.

- Débits simulés : Les débits des cours d'eau ou les niveaux d'eau prédits par le modèle.

- Autres variables hydrologiques : Comme les niveaux de nappes phréatiques, les volumes d'infiltration, etc.

- **Équations et paramètres** :

- Équations : Des équations mathématiques qui décrivent les processus hydrologiques, telles que l'équation de bilan hydrique pour estimer les débits.

- Paramètres : sont des éléments caractéristiques du site de prévision ayant un pseudo signification physique plus ou moins précise, qui permettent d'ajuster le modèle aux différentes configurations hydrologiques traitées.

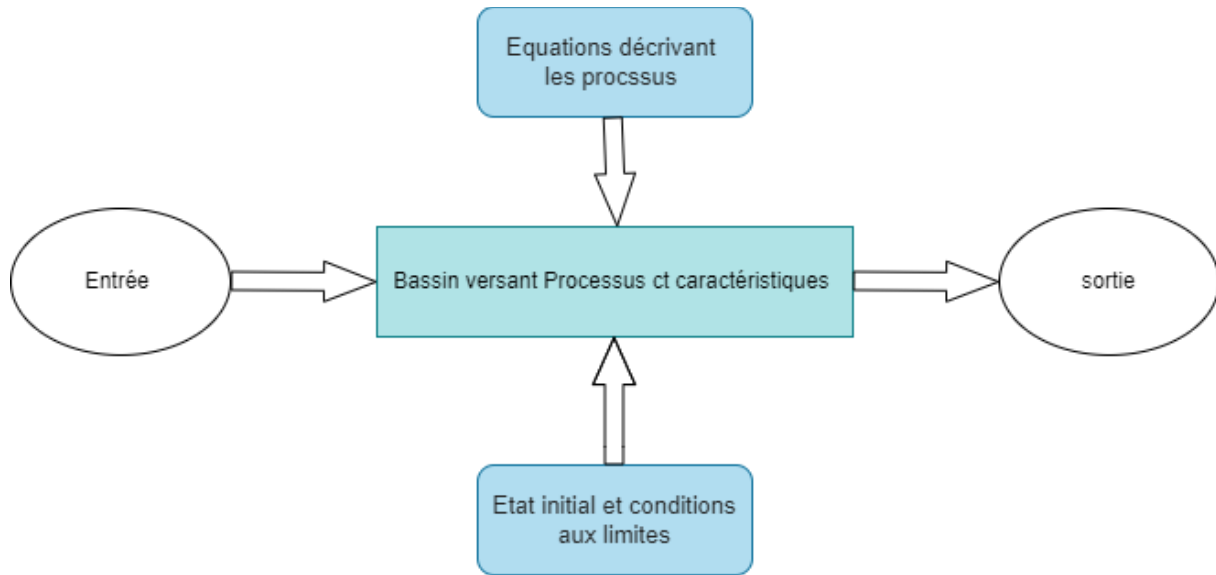


Figure I.2. Composants d'un modèle hydrologique (Singh, 1995)

I.3.2 Etapes de la modélisation hydrologique

Deux étapes essentielles sont souvent considérées comme fondamentales dans la modélisation hydrologique :

Calibration du modèle (Calage) : La calibration est un processus crucial qui vise à ajuster les paramètres du modèle, pour qu'il reproduise aussi précisément que possible les observations réelles (Laurent, 1996). L'estimation des paramètres peut se faire manuellement par une procédure « essai et erreur », ou automatiquement par une fonction d'optimisation permettant d'améliorer la cohérence entre la réponse observée et celle simulée (Gherissi, 2018).

Validation du modèle : La validation est l'étape où l'on vérifie la capacité du modèle à prédire, avec précision, les débits ou autres variables hydrologiques, dans des situations pour lesquelles il n'a pas été spécifiquement calibré (Fortin et al., 1997).

Ces deux étapes sont cruciales, car elles garantissent la fiabilité du modèle hydrologique. Un modèle correctement calibré et validé, a plus de chances de produire des résultats précis et fiables lorsqu'il est utilisé pour des prévisions, des analyses de scénarios ou des évaluations d'impact dans le domaine de la gestion des ressources en eau.

I.3.3 La modélisation pluie-débit

La modélisation pluie-débit est une partie de la modélisation hydrologique, qui se concentre sur la relation entre les précipitations et les débits des cours d'eau. Autrement dit, en

réalité, chaque point d'un cours d'eau permet de définir un bassin versant, et les débits observés en ce point sont directement liés aux précipitations tombées sur ce bassin. A partir des observations faites en quantifiant la pluie tombée, on arrive à reproduire la réponse en débit du bassin. La simulation ou la modélisation hydrologique du bassin versant, décrite comme la transformation de la pluie en débit passe par l'utilisation d'un modèle hydrologique (Haziza, 2003). La transformation de la pluie en débit au cours d'un pas de temps désiré (journalier, mensuel, annuel, pluriannuel), se traduit par une écriture mathématique qui résume les phases de cette transformation.

Un modèle pluie-débit est un modèle hydrologique qui relie les données de précipitations (pluie) aux débits des cours d'eau. Ils utilisent des données météorologiques telles que les précipitations et d'autres variables (température, évapotranspiration, etc.) pour estimer ou prédire ce dernier.

I.3.4 Intérêt de la modélisation pluie-débit

La modélisation pluie-débit revêt plusieurs intérêts significatifs :

- Recherche scientifique : Ces modèles sont également utilisés pour mieux comprendre les processus hydrologiques complexes, permettant aux chercheurs d'améliorer les théories et les connaissances sur le cycle de l'eau, et de développer des méthodes plus précises pour prédire les réponses hydrologiques. (Korichi et Hazzab, 2012 ; Otmane et al., 2019).
- La modélisation comme outil de prévision : Il s'agit de l'utilisation opérationnelle la plus courante des modèles hydrologiques pour étudier l'évolution future du débit d'un cours d'eau, exemple : la prévision des crues ou des étiages (Lehbab-Boukezzi et al., 2016 ; Fotovatikhah et al., 2018).
- La modélisation comme outil de planification et extrapolation : Lors de la conception de projets d'infrastructures telles que les barrages ou les canaux d'irrigation, les modèles pluie-débit permettent de prédire les effets potentiels sur les débits des cours d'eau, offrant ainsi des informations cruciales pour une planification et une gestion efficace (Korichi et Hazzab, 2012).

I.4 Classification des modèles pluie-débit

Les classifications de modèles pluie-débit sont nombreuses et peuvent varier en fonction de plusieurs caractéristiques, comme mentionné par Berthier en 2005. Pour plaisanter, Perrin (2002) disait qu'il existe presque autant de classifications que d'hydrologues. Le tableau suivant propose une classification des différents types de modèles selon leurs caractéristiques, en s'appuyant sur les travaux : d'Ambroise (1998), Andrassian (2002), Clarke (1973), Oudin (2004) et Perrin (2002).

Tableau 1. 1. Exemple de caractéristiques des modèles pluie-débit (Berthier, 2005)

Caractéristiques	Type de modèle
Selon la nature de la variable	Modèle déterministe (variables non aléatoires) Modèle stochastique (variables aléatoires)
Traitement de l'espace (Homogénéité du bassin)	Modèle global Modèle semi-distribué (ou semi-global) Modèle spatialisé
Fondement théorique et approche de développement	Modèle empirique Modèle conceptuel Modèle à base physique

I.4.1 Selon la nature de la variable

I.4.1.1 Modèles stochastiques

Un modèle stochastique a, au moins, une composante de caractère aléatoire qui n'est pas explicite dans l'entrée du modèle, mais seulement implicite ou "cachée" (Le Clerc, 2004). Par conséquent, des entrées identiques se traduiront généralement par des sorties différentes si elles sont exécutées dans le modèle dans des conditions identiques. Cette notion peut être étendue aux modèles dans lesquels l'entrée a un caractère stochastique direct. Les modèles stochastiques utilisent des variables aléatoires, pour représenter l'incertitude du processus et

gènèrent des résultats différents, à partir d'un ensemble de données d'entrée et de valeurs de paramètres lorsqu'ils s'exécutent dans des conditions identiques (Pechlivanidis et al., 2011).

I.4.1.2 Modèles déterministes

Un modèle est dit déterministe si aucune de ses grandeurs n'est considérée comme aléatoire (Maftei, 2002). Un tel modèle associe à chaque jeu de variables d'entrée, de variables d'état et de paramètres une valeur déterminée ou déterminable, réalisation unique des variables de sortie (Le Clerc, 2004). La majorité des modèles hydrologiques sont déterministes (Gnouma, 2006).

Les modèles déterministes sont complexes et nécessitent beaucoup de données et de temps de calcul. Ils utilisent des équations aux dérivées partielles (EDP) non linéaires pour décrire les processus hydrologiques, et il est souvent impossible de résoudre ces équations de manière analytique. Cependant, l'un des avantages des modèles déterministes est qu'ils permettent une meilleure compréhension du système hydrologique en fournissant une vue détaillée du processus (Jajarmizadeh et al., 2012).

I.4.2 Selon le traitement de l'espace (Homogénéité du bassin)

I.4.2.1 Modèles globaux

Dans les modèles tels que GR (Edijatno et Michel, 1989), HEC-1 (Hydrologic Engineering Center, 1998) ou PDM Probability Distributed Moisture (Moore, 2007), le bassin versant est considéré comme une seule entité réagissant dans son ensemble. Les caractéristiques physiques et les grandeurs météorologiques sont supposées uniformes à l'échelle du bassin, assimilé à une unité ponctuelle. Ces valeurs moyennes s'appliquent à l'ensemble du bassin versant, et les processus hydrologiques sont simulés pour l'ensemble du bassin.

I.4.2.2 Modèles semi-distribués

Ces modèles prennent en compte la variabilité spatiale des processus hydrologiques modélisés, des variables d'entrée, des conditions aux limites et des caractéristiques du bassin (Yahi, 2010). Dans les modèles semi-distribués, ces quantités peuvent varier partiellement dans l'espace en divisant le bassin en petits sous-bassins, qui sont ensuite traités comme une seule unité. On peut aussi choisir de spatialiser uniquement les facteurs dont la répartition spatiale est jugée cruciale dans la réponse hydrologique d'un bassin versant. Ces types de

modèles effectuent des prévisions distribuées dans l'espace en utilisant des variables d'état moyennées sur le carré de quadrillage. Cette approche de distribution offre une meilleure représentation de l'hétérogénéité pouvant exister sur un bassin. Cependant, la spatialisation entraîne une complexification des modèles.

I.4.2.3 Modèles distribués

Les modèles distribués, généralement associés aux modèles à base physique, présentent plusieurs avantages dans les études relatives à l'effet du changement des conditions du terrain sur les processus hydrologiques, la modélisation de la qualité de l'eau et la prévision sur les bassins versants non-jaugés. Une des raisons pour lesquelles les modèles de paramètres distribués n'ont pas été largement utilisés est l'indisponibilité de bases de données détaillées. Cependant, les améliorations futures dans l'acquisition de données, y compris l'application des systèmes d'information géographique (SIG) et des images satellitaires, vont probablement conduire à une utilisation plus étendue des modèles de paramètres distribués.

I.4.3 Selon le fondement théorique et approche de développement

On peut classer les modèles pluie-débit en trois groupes principaux : les modèles empiriques (modèles boîte noire, régression linéaire ...etc), conceptuels et les modèles à base physique.

I.4.3.1 Modèles à base physique

Les modèles physiques, également appelés modèles basés sur les processus ou modèles mécanistes, sont basés sur la compréhension de la physique liée aux processus hydrologiques. Des équations basées sur la physique régissent le modèle pour représenter plusieurs parties des réponses hydrologiques réelles dans le bassin versant (Knightes, 2017 ; Vaze et al., 2012). On peut citer les modèles HYDROTEL et ATHYS.

Ne suivant que les équations de la physique, et ne comportant idéalement aucun paramètre. Il n'existe pas de modèle à base physique au sens strict en hydrologie. Certains modèles comme le système hydrologique européen (SHE) tendent à s'en rapprocher. L'importance de l'hétérogénéité spatiale dans la réponse hydrologique des bassins versants rend cependant difficile, voire impossible, l'utilisation de tels modèles (Henine, 2005).

I.4.3.2 Modèles empirique

Les modèles empiriques reposent sur les relations observées entre les entrées et les sorties de l'hydro système considéré .Ils expriment la relation entre variables d'entrée et de sortie du système (relation pluie débit) à l'aide d'un ensemble d'équations développées et ajustées sur la base des données obtenues sur le système. Un modèle empirique ne cherche pas à décrire les causes du phénomène hydrologique considéré ni de ni à expliquer le fonctionnement du système, le système est vu comme une boîte noire. Divers outils sont utilisés pour l'élaboration des formules ou modèles reliant les entrées et les sorties : la régression, les réseaux de neurones, SVR (Sector Vector Machine for Regression) , ANFIS (Adaptive Neuro Fuzzy Inference System) , etc.

I.4.3.3 Modèles conceptuels

Les modèles conceptuels hydrologiques, représentent une approche simplifiée pour décrire les processus hydrologiques dans un bassin versant. Les modèles conceptuels, tentent à représenter le bassin versant par des analogies et des concepts. L'analogie la plus réputée en hydrologie est la représentation des fonctionnements des sols et des nappes, par des réservoirs d'humidité (d'où l'appellation modèle à réservoir) interconnecté suivant une dimension verticale, dont le débit de vidange de chaque réservoir dépend du taux de remplissage (Ambroise, 1999). Les modèles de génie rural GR sont des exemples de modèles conceptuels pour des applications d'ingénierie.

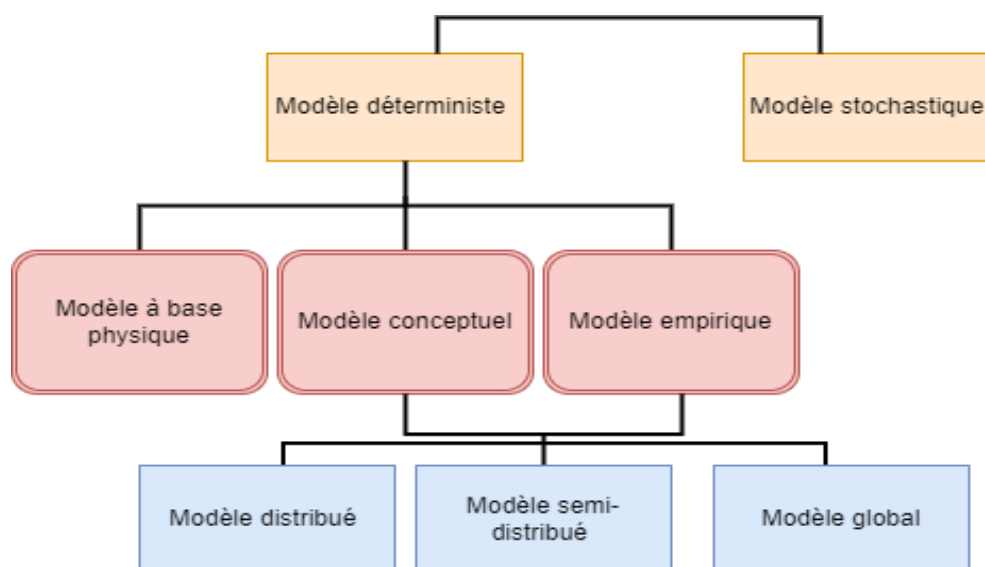


Figure I.2. Classification des modèles hydrologiques (Berthier, 2005)

I.5 Etat de l'art de la modélisation pluie-débit

Dans cette partie, nous mentionnerons certains travaux réalisés dans le monde et en Algérie, utilisant les modèles de l'intelligence artificielle et les modèles conceptuelles.

I.5.1 Les modèles conceptuels

Parmi les modèles hydrologiques conceptuels et forfaitaires actuellement utilisés, citons le modèle GR4J "Génie Rural à 4 paramètres Journalier" (Perrin et al., 2003), le GR5J- "Génie Rural à 5 paramètres Journalier" (Le Moine, 2008), le GR6J-"Génie Rural à 6 paramètres Journalier" (Pushpalatha et al., 2011), le modèle HYMOD (HYdrological MODel) (Boyle, 2000) et le modèle hydrologique HBV (Bergström 1995). Parmi de nombreux modèles proposés, des dizaines font partie de la classe des modèles à réservoirs conceptuels ou empiriques comme le modèle HBV et les modèles GR. TOPMODEL (Beven and Kirkby 1979 ; Beven et al., 1995 ; Beven 1997 et Kirkby 1997)

Edijatno et al. (1999), ont appliqué le modèle GR3J sur trois bassins versant pour modéliser le débit journalier. Dhemi Harlan et al. (2010), ont utilisé dans cette étude pour la modélisation du débit journalier, le modèle GR4J sur le bassin de la rivière Citarum Hulu. Ague (2014) a comparé un modèle conceptuel GR4J et un modèle semi-distribue GéoSFM sur le bassin versant de l'Ouémé à savè au Bénin. Anshuman et al. (2018) ont comparé deux modèles conceptuels de ruissellement pluvial, GR4J (Génie Rural) et AWBM (Australian Water Balance Model). Sadegh et al. (2019) ont appliqué les modèles GR4J, GR5J et GR6J et comparé leurs performances pour la simulation de l'écoulement des cours d'eau. Flores et al., (2021) ont utilisé les modèles hydrologiques forfaitaires pluie-débit Génie Rural à 4, 5 et 6 paramètres Journalier (GR4J, GR5J et GR6J) afin d'évaluer le modèle le plus robuste pour simuler le débit de quatre petits bassins versants dans le centre-sud du Chili.

Hassan Esmaili (2021) a utilisé cinq modèles, parmi lesquels ; le HBV pour simuler l'écoulement de la rivière Hablehroud, dans le centre-nord de l'Iran. Lirat et al. (2006) ont utilisé le modèle GR2M pour simuler le régime mensuel dans le bassin versant de Guadiana. Huard et al. (2008) ont appliqué le modèle GR2M au Canada. Yang et Michel (2000) indiquent par exemple que la simulation de deux ans de données au pas de temps horaire nécessite 72 heures de calcul pour le modèle fondé physiquement MIKE SHE et seulement deux minutes pour le modèle conceptuel distribué TOPMODEL.

Les modèles conceptuels ont été testé sur différents bassins algérien dans plusieurs études, nous citerons ; Zamoum et Souag-Gamane (2019) ont utilisé le modèle pluie-débit GR2M, dans des bassins versants jaugés dans le Nord de l'Algérie. Bachir et al. (2015) ont appliqué le modèle GR2M pour la modélisation pluie-débit dans le bassin versant du Kébir Rhumel, au Nord-Est de l'Algérie. Belaroui et al. (2019), ils ont utilisé GR2M et GR4J pour la modélisation de débit dans le bassin versant de l'oued Hammam Melouane. Bouguerra et Mansour (2023), Ils ont appliqué les modèles 'GR' à trois pas de temps : annuel (GR1A), mensuel (GR2M) et journalier (GR4J), au bassin versant de Beni Bahdel, un des sous-bassins de celui de la Tafna situé au Nord-Ouest de l'Algérie. Bouguerne (2017) a utilisé les deux modèles HBV et GR4J dans les Oueds Boussalem et Rhumel situé à l'Est algérien. Atallah et al. (2023) ont utilisé le modèle hydrologique HBV-light dans l'oued Louza dans le Nord-Ouest de l'Algérie.

Maref et al. (2023) ont modélisé la relation pluie-débit à l'aide du code TOPMODEL dans le bassin versant de l'oued El Kebir. Amireche (2018) a modélisé la relation pluie-débit sur quatre bassins versants algériens à la fois à un pas de temps mensuel et journalier en utilisant trois modèles différents : les modèles GR (Génie Rural), les modèles de type boîte noire tels que les systèmes neuro-flous, et le modèle Tank couplé au filtre de Kalman standard et étendu. Boulfekhar et al. (2016) ont étudié la modélisation pluie-débit dans le bassin versant de l'Oued Rhumel-Smendou en utilisant les modèles du Génie Rural GR1A et GR2M, avec des pas de temps annuel et mensuel. Skhakhfa et Ouerdachi (2016) ont utilisé le programme HEC-HMS (Hydrologic Modeling System), qui intègre plusieurs modèles empiriques, pour simuler les débits ans le bassin versant de Seybouse. Maref et Seddini (2018) ont utilisé le modèle distribué MERCEDES (Maillage Élémentaire Régulier Carré pour l'Etude Des Ecoulements Superficiels) pour étudier les crues éclair dans le bassin de Macta, à l'ouest de l'Algérie.

I.5.2 Les modèles à base d'intelligence artificielle

La modélisation pluie-débit à l'aide des modèles d'intelligence artificielle, revêt une importance capitale dans la gestion des ressources en eau et la prévention des risques liés aux inondations. Ces modèles permettent de prédire avec une précision accrue les débits des cours d'eau en fonction des précipitations, aidant ainsi les autorités à prendre des décisions éclairées en matière de gestion des bassins versants. Ces modèles d'IA peuvent capturer des schémas complexes et non linéaires entre les précipitations et les débits, améliorant ainsi la précision

des prévisions hydrologiques. L'intelligence Artificielle (IA) a démontré une grande précision dans de nombreux domaines de prévision en hydrologie (Wang et al., 2009 ; Yaseen et al., 2015 ; Heddami et Kisi, 2021).

Les réseaux de neurones artificiels (ANN) ont été largement utilisés dans les applications hydrologiques (Hsu et al., 1995 ; Daliakopoulos et al., 2005 ; Kalteh and Berndtsson, 2007 ; Wang et al., 2009 ; Kisi et al., 2012). Mutlu et al. (2008) ont utilisé deux modèles de réseaux neuronaux différents, le perceptron multicouche (MLP) et le réseau neuronal à base radiale (RBFNN), pour prédire le débit des cours d'eau dans quatre stations de mesure dans le Nord-Ouest de l'Arkansas et le Nord-Est de l'Oklahoma. Chen et al. (2014) ont appliqué le modèle MLPNN pour prévoir le débit de la rivière Mistassibi. Muhammad Adnan et al. (2019), comparent une série de modèles comme le réseau neuronal à base radiale (RBNN), le réseau neuronal à régression généralisée (GRNN) et le système d'inférence neuro-floue adaptatif (ANFIS) pour prédire le débit mensuel, les résultats indiquent que l'ANFIS est meilleur et plus précis que le GRNN et le RBNN. Par la suite, plusieurs nouveaux modèles sont apparus, tels que : support vector machines (SVM) (Luo et al., 2019), extreme learning machine (ELM) (Yaseen et al., 2016), modèle de régression adaptative multivariée par splines (MARS) (Yin et al., 2018), M5 model tree (M5Tree) (Nourani et al., 2019), Régression de la forêt aléatoire (RFR) (Peng et al., 2020).

Hussain et Khan (2020) ont appliqué les modèles MLP, SVR et RF pour prédire le débit mensuel de la rivière Hunza au Pakistan. Fathian et al., (2019) ont utilisé MARS et l'ont comparé aux modèles ANN et RF pour modéliser le débit mensuel des stations de Brantford et Galt sur la rivière Grand, au Canada. Tongal et Booiij (2018) utilisent un ensemble de modèles et les comparent pour la prédiction journalière du débit en utilisant les données de quatre rivières aux États-Unis, et les modèles utilisés sont MLPNN, SVM et RFR.

Avec la progression de la recherche et dans le but d'améliorer encore la précision des prévisions, la tendance la plus récente en matière de prévisions est l'hybridation de modèles d'intelligence artificielle avec des techniques de prétraitement des données, cette dernière se fait avec des algorithmes d'optimisation ou bien la décomposition de signal. Actuellement, l'hybridation avec des algorithmes méta-heuristiques inspirés de la nature, tels que l'optimisation par essaims de particules (PSO), l'optimiseur Grey Wolf (GWO), l'algorithme de la mouche à fruits (FFA), l'algorithme de recherche gravitationnelle (GSA) et l'algorithme génétique (GA), attire de plus en plus l'attention pour la prévision des débits horaires,

quotidiens et mensuels (Wang et al., 2013 ; Mehr, 2018 ; Ghorbani et al., 2018 ; Muhammad Adnan et al., 2019 ; Tikhamarine et al., 2020a ; Mohammadi et al., 2020). Dans ce contexte, Sudheer et al. (2014) ont hybridé SVM et PSO pour la prévision des débits mensuels de la rivière Swan aux États-Unis. Mohammadi et al. (2020) ont couplé MLP avec PSO et PSO couplé avec Multi-Verse Optimizer (PSO-MVO) pour la modélisation des débits journaliers sur la rivière Grand, au Canada, Tikhamarine et al. (2020a) ont couplé GWO avec SVM, MLP et MLR pour la prévision des débits mensuels sur le fleuve Nil, en Égypte.

Moeeni et al. (2017) ont utilisé un algorithme génétique (GA) comme outil d'optimisation pour déterminer le nombre optimal de couches cachées dans un réseau de neurones artificiels (RNA). Ils ont comparé les performances de ce modèle RNA-GA avec le modèle SARIMA (Seasonal Auto-regressive Integrated Moving Average). Leur étude a conclu que le modèle RNA-GA est plus efficace pour la prévision des crues. Motahari & Mazdaranizadeh (2017) ont utilisé un modèle basé sur un RNA optimisé par l'algorithme PSO pour simuler le processus pluie-débit dans la rivière Karaj.

Parmi les techniques de prétraitement basées sur la décomposition développées récemment, nous pouvons citer la transformée en ondelettes (WT) (Dabuechies, 1990), la décomposition en mode empirique (EMD) (Huang et al. 1998), la décomposition en mode empirique d'ensemble (EEMD) (Wu et Huang, 2009) et la décomposition en mode variationnel (VMD) (Liu et al., 2018). Divers modèles hybrides utilisant la technique de décomposition ont été développés et largement utilisés, pour traiter la non-linéarité et la non-stationnarité présentes dans les séries temporelles de débit. He et al. (2019) utilisant le VMD et les réseaux neuronaux profonds pour prévoir le débit journalier de la station hydrométrique de Zhangjiashan dans la rivière Jing, en Chine. Tan et al. (2018) ont appliqué l'EEMD pour obtenir des signaux plus précis à partir des données de débits mensuels dans le fleuve Yangtze avec l'ANN. Zhenghao Zhang (2018) a utilisé un MLR et un ANN hybride avec WD.

Dans le contexte algérien, plusieurs études qui ont utilisé des modèles d'intelligence artificielle, dans diverses régions, ont été menés, nous pouvons citer à titre indicatif et non exhaustif : Zakhrouf et al. (2020) ont appliqué trois différentes approches d'apprentissage automatique : ANN, ANFIS et réseaux de neurones à base d'ondelettes (WNN), pour la prévision quotidienne des débits dans le bassin du Chellif, situé au Nord de l'Algérie. Aoulmi et al. (2020) ont utilisé des ANN avec différentes entrées pour modéliser la relation pluie-débit dans le bassin de la Seybouse, situé dans une région semi-aride de l'Algérie.

Tikhamarine et al. (2019) utilisant un SVR par ondelettes basé sur un optimiseur de loup gris (WSVR – GWO), pour la prévision mensuelle du débit, à partir de deux stations de jaugeage ; Ain Bedra et Fermatou, en Algérie. Difi et al. (2022) ont comparé SVR, Gaussian process regression (GPR), MLPNN, GRNN, ELM et l'algorithme Bat-ELM (extreme learning machine metaheuristic bat algorithm) dans trois stations hydrométriques situées dans le bassin du Cheliff, en Algérie. Benzineb (2017) a comparé le modèle de réseaux de neurones, modèles de type "boîte noire" avec un modèle de type conceptuel à réservoirs, le GR4j, pour modéliser la relation pluie-débit dans un environnement semi-aride algérien, en se basant sur des données à pas de temps journalier et sur de courtes durées, dans le cas du bassin de l'oued Ouahrane.

I.6 Conclusion

Dans ce premier chapitre, nous avons présenté le cadre général de nos recherches mettant en lumière la modélisation hydrologique pluie-débit comme un élément fondamental de la prévision des débits, et l'importance de cette variable dans le domaine de l'hydraulique et du dimensionnement des ouvrages hydrauliques. Les modèles développés au cours des quarante dernières années pour la transformation de la pluie en débit sont très diversifiés, reflétant différentes perceptions du monde réel et répondant à différents objectifs. Notre analyse nous a permis d'identifier différentes catégories de modèles, dont la diversité reflète les défis rencontrés par la modélisation pour représenter le comportement du bassin versant. Ces modèles pluie-débit visent à prédire les débits de réponse d'un bassin versant aux événements pluvieux à partir d'une série d'observations pluies-débits.

Dans le cadre de cette étude, nous considérerons l'utilisation des modèles d'intelligence artificielle, tels que les réseaux de neurones artificiels et les modèles hybrides, et les modèles conceptuels tels que GR5j et HBV. Ces modèles sont d'un intérêt particulier en raison de leur émergence récente dans le domaine hydrologique et de la modélisation pluie-débit.

CHAPITRE II
PRÉSENTATION DE LA
RÉGION D'ÉTUDE

CHAPITRE II : PRÉSENTATION DE LA RÉGION D'ÉTUDE

II.1 Introduction

L'Algérie, pays d'Afrique du Nord, confronté à des problèmes de rareté et de gestion inégale de l'eau, en raison de la croissance démographique, de l'urbanisation rapide, de l'agriculture intensive et des pressions exercées sur les ressources naturelles. Les régions du Nord bénéficient généralement d'une plus grande disponibilité d'eau par rapport aux régions du Sud, souvent arides. Les autorités algériennes ont également encouragé la sensibilisation à la préservation de l'eau, et la recherche de solutions innovantes pour garantir un accès durable à cette ressource vitale, pour l'ensemble de la population et pour le développement économique du pays.

Le nord de l'Algérie a été sélectionné comme zone d'étude en raison de la concentration des problèmes de gestion des ressources en eau dans cette région. Ce chapitre présentera les caractéristiques géographiques, climatiques et hydrographiques principales de la zone d'étude.

II.2 Situation géographique

Notre zone d'étude se situe dans la partie Nord de l'Algérie, entre « 2° et 9° » de longitude Est et « 33° et 37 ° » de latitude Nord, assiégée sur une superficie d'environ 365 000 Km². Elle s'étend sur une largeur de 350 Km environ et sur 1000 Km le long du littoral (Figure II.1.). Le Maroc et la Tunisie constituent respectivement les limites Ouest et Est, la mer Méditerranéenne constitue la limite Nord et les flancs Sud de l'Atlas saharien la limite Sud. Elle est caractérisée par un climat méditerranéen dans sa partie Nord et subdésertique dans sa partie Sud. Cette zone renferme les principales ressources en eaux de surface et les infrastructures hydrauliques du pays. La partie Sud de l'Algérie est plutôt alimentée par ses ressources en eaux souterraines, principalement de la nappe albienne.




Figure II.1. Situation géographique de la zone d'étude (Benslimane et al., 2008)

II.3 Le relief

Le relief du Nord de l'Algérie est caractérisé par une diversité géographique remarquable. Dans ce contexte, l'Algérie est divisée en trois ensembles distincts : le Tell au Nord, les hauts plateaux et l'Atlas saharien au centre, et le Sahara au Sud.

- Tell

La région du Tell au Nord de l'Algérie est une bande géographique essentielle, qui s'étend le long de la côte méditerranéenne de 1 200 km de long et de 100 à 200 km de large. Elle est délimitée au Sud par une chaîne de montagne, plus ou moins parallèle au littoral, et qui s'étend de la région de Tlemcen à l'Ouest, à la frontière tunisienne à l'Est. Cette zone est reconnue pour son climat méditerranéen doux. Les terres fertiles du Tell sont propices à l'agriculture, notamment pour la culture de céréales, d'oliviers, de vignes et d'agrumes.

- Les hauts plateaux

Les hauts plateaux au Nord de l'Algérie forment une vaste région située entre le Tell et le Sahara. Ce plateau s'étend sur des centaines de kilomètres, caractérisé par un relief relativement plat avec des altitudes variant entre 500 et 1 200 mètres. Ces vastes étendues sont composées de plaines, de collines et de quelques chaînes de montagnes dispersées. Les hauts plateaux algériens présentent un climat semi-aride, avec des précipitations plus limitées

que celles du Tell. L'agriculture y est pratiquée, principalement avec des cultures céréalières et des pâturages pour l'élevage.

- L'Atlas saharien

L'Atlas saharien en Algérie fait référence à la partie saharienne de la chaîne de montagnes de l'Atlas, qui s'étend sur une grande partie du territoire algérien. Cet ensemble montagneux comprend plusieurs sous-ensembles, dont l'Atlas tellien au Nord et l'Atlas saharien au Sud.

L'Atlas saharien algérien se caractérise par des montagnes, des plateaux et des vallées qui s'étendent à travers le désert du Sahara. Ces reliefs jouent un rôle crucial dans la géographie et le climat de la région, influençant les précipitations, les cours d'eau et la vie des habitants.

II.4 Climat

L'Algérie s'étend du Nord (Mer Méditerranée) au Sud (Sahara) sur plus de 2.000 kilomètres en profondeur. Mais, les montagnes de l'Atlas Tellien et de l'Atlas Saharien divisent ce territoire en bandes orientées Est-Ouest : celle de la côte et de l'Atlas Tellien, celle des Hautes Plaines et de l'Atlas Saharien, celle du Sahara. Chacune de ces bandes a un climat particulier, caractérisé surtout par la température et la quantité de pluie de chaque mois. En examinant les températures et les quantités de pluie, on peut comprendre ce qui distingue ces trois climats : méditerranéen, continental et désertique.

Le climat méditerranéen est caractérisé par l'alternance d'hivers doux et pluvieux et d'étés chauds et secs associés à un déficit hydrique des sols relativement important (Bolle, 2003). Le climat méditerranéen se rencontre habituellement entre 30° et 40° de latitude sur la bordure occidentale des continents. Il s'étend toutefois davantage vers l'Est au tour de la Mer Méditerranée elle-même, car celle-ci représente une source d'humidité importante pour les terres situées aux alentours (Lionello et al., 2006).

Sur les Hautes Plaines et dans l'Atlas Saharien, c'est de cette région que l'on peut dire que « l'Algérie est un pays froid où le soleil est chaud ». La température descend souvent au-dessous de 0 degré en hiver En été elle dépasse 30 et même 40 degrés. Les pluies sont rares, surtout sur les Hautes Plaines d'Oranie moins élevées et moins accidentées que celles du

Constantinois. Les vents humides sont, en effet, arrêtés, à l'Ouest, par les hauteurs de l'Atlas Tellien (Kebiche, 1996).

Les régimes de pluies sont très irréguliers d'une région à l'autre, notamment entre le Nord et les hauts plateaux et entre l'Est et l'Ouest. Les précipitations en Algérie augmentent d'Ouest en Est et diminuent du Nord au Sud. La partie la plus importante des quantités de pluie sont reçues entre le mois de novembre et le mois de février. Sur la période 1936/1937-2008/2009, les pluies moyennes annuelles sont d'environ 396mm à Oran, 653mm à Berrahal, 756mm à Bir Mourad Rais et 248mm à Djelfa (Taibi, 2011). Figure II.2 la carte montre les différents niveaux de précipitations annuelles à travers la région.

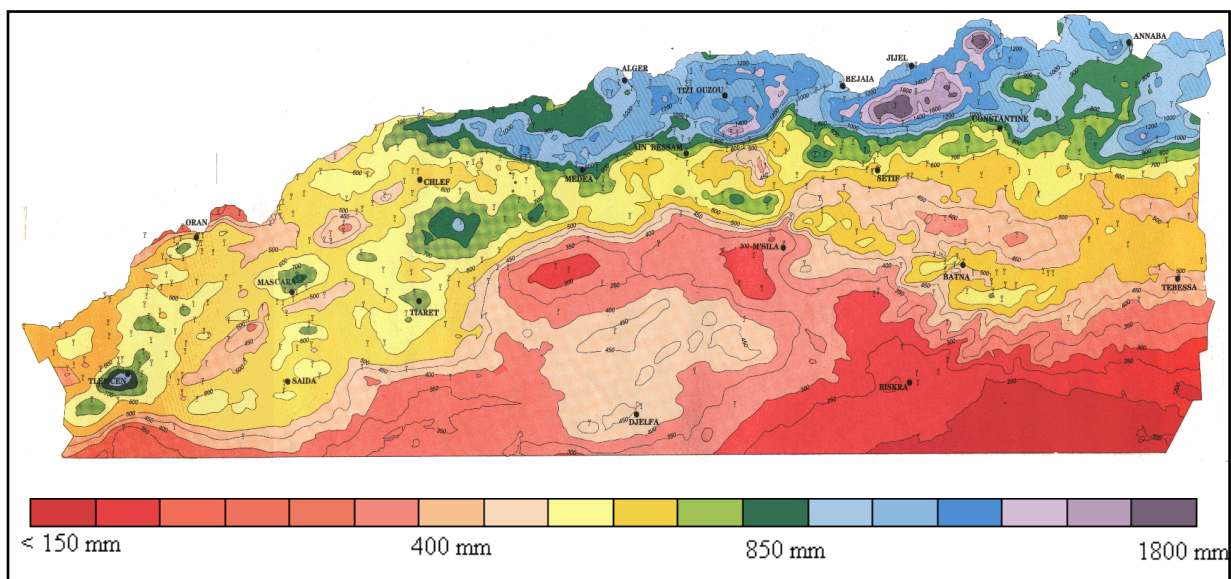


Figure II.2. Carte pluviométrique du Nord de l'Algérie (Source ANRH, 1993)

II.5 Couverture végétale

Le couvert végétal de la zone d'étude est composé de forêts de chênes et pins, des maquis et matorrals (thuya, olivier et lentisque), des steppes semi-arides et arides (alfa, sparte et armoise).

La figure II.3, représente les résultats des images de l'indice de végétation pour l'année 2004, de fortes valeurs d'indice pour des sols à recouvrement végétal élevé correspondant aux forêts qui se localisent au Nord-Est (Collo, Kabylie, Aurès-Némamcha, etc.). Les valeurs moyennes pour des sols à recouvrement végétal moyen correspondent aux terrains irrigués. Des valeurs faibles pour des zones dénudées à comportement désertique qui se trouvent généralement en région steppique.




Figure II.3. Cartographie de l'indice de végétation en 2004 (Benslimane et al., 2008)

II.6. Sol

On distingue plusieurs types de sols regroupant les sols minéraux bruts ou sols très peu évolués, les sols peu évolués, les sols calcimagnésiques, les sols isohumiques et les sols halomorphes. Dans presque toute l'étendue du Tell, le sol arable, très profond, est argilo-calcaire, mais toujours mélangé d'une proportion plus ou moins considérable de sable. Ce sol, lorsqu'il peut être irrigué, est d'une étonnante fertilité, à condition cependant que le sable n'y soit pas prédominant.

II.7 Hydrographie et hydrométrie

En totalité l'hydrographie Algérienne est divisée en dix-sept grands bassins versants par l'Agence Nationale des Ressources Hydraulique (ANRH) (Figure II.4). Pour la gestion de ces derniers, ils ont été regroupés dans cinq régions Hydrographiques gérées par l'Agence Nationale des Bassins Hydrographiques (ABH).

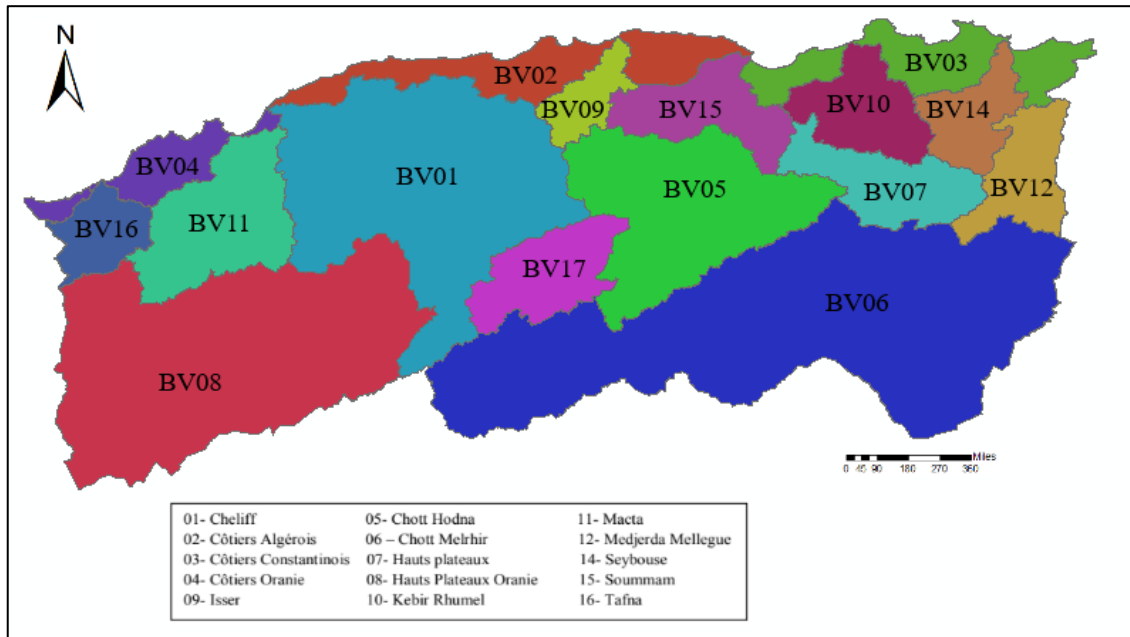


Figure II.4. Organisation des grands bassins versants du Nord de l'Algérie (Source: ANRH, 2012)

Sur la base de la disponibilité de données (série de mesures continues sans interruptions) et de la petite taille des bassins hydrologiques, les bassins suivants ont été choisis comme zone d'étude dans ce travail voir chapitre III. La figure II.5. représente la répartition des bassins versants sélectionnés.

- (01) Bassin versant du Cheliff ;
- (02) Bassin versant des Côtiers Algérois ;
- (03) Bassin versant des Côtiers Constantinois ;
- (14) Bassin versant de la Seybouse ;
- (15) Bassin versant de la Soummam.

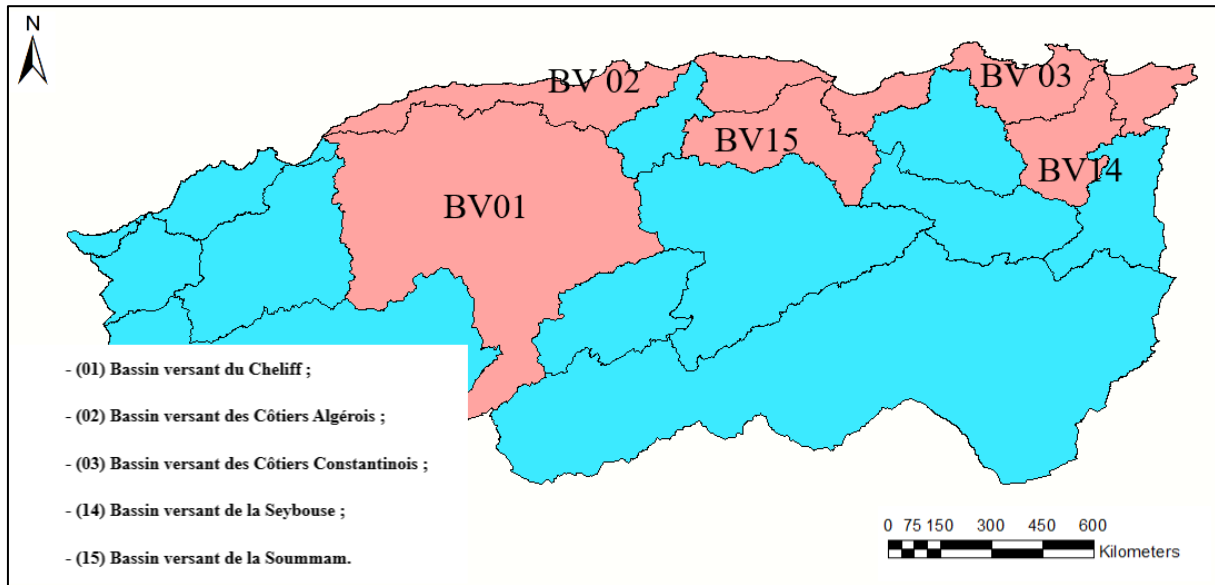


Figure II.5. Situation géographique des bassins étudiés

II.8 Caractéristiques des bassins versant étudiés

II.8.1 Bassin versant du Cheliff

Située au centre ouest de l'Algérie du Nord, Le bassin du Cheliff est limitée au Nord par le Côtiers Algérois Ouest, à l'Ouest par la Macta, au Sud par les Bassins versants : les hauts plateaux Oranais, le Sahara, Chott Melrhir et Zahrez et à l'Est par les bassins versants : Chott Hodna et Isser. La région est bordée par deux chaînes principales, l'Atlas tellien au nord et l'Atlas saharien au sud. Selon la nouvelle structuration des unités Hydrologiques en Algérie, le bassin du Cheliff appartient l'unité hydrographique du Cheliff-Zahrez, le bassin versant du Cheliff qui s'étend sur 43900 Km², Il est divisé par l'ANRH en trente-six sous bassins.

Le climat du Cheliff se caractérise par des étés chauds et secs peu orageux et des hivers doux et humides et peut être appelé méditerranéen semi-aride moyen tempéré. Les sols du Bas-Cheliff sont, soit occupés par l'agriculture, soit abandonnés pour être occupés par la végétation halophyte. L'agriculture concerne essentiellement : les vergers d'agrumes et d'oliviers, les cultures maraîchères et les cultures céréalières.

II.8.2 Bassin versant des Côtiers Algérois

Situé au Nord centre de l'Algérie, il est limité au Nord par la mer Méditerranée, à l'Est par le bassin de l'Isser, au Sud par le bassin de Cheliff qui le borde à l'Ouest aussi. La limite Sud est constituée principalement par la chaîne montagneuse de l'Atlas Tellien. La partie

Ouest du bassin appartient au bassin hydrographique Cheliff-Zahrez, tandis que la partie Est à l'Algérois-Soummam-Hodna.

Il couvre une superficie de 11 972 km², et il est divisé par l'ANRH en vingt sous bassins hydrologique. Le climat de la région est un climat type méditerranéen, pluvieux en hiver, sec en été avec une pluviométrie moyenne avoisinant les 900 mm par an, sauf que l'Est est beaucoup plus pluvieux que l'Ouest qui s'approche d'un climat semi-aride. Donc le bassin des Côtiers Algérois a un potentiel pluviométrique assez important, Le couvert végétal se compose de maquis dense de feuille de résineux et de cultures.

II.8.3 Bassin versant des Côtiers Constantinois

Le bassin hydrologique "Côtiers Constantinois" est situé dans le littoral Nord de l'Est Algérien, limité au Nord par la Méditerranée, à l'Est par la frontière tunisienne, à l'Ouest par le bassin "Soummam" et au Sud par les bassins : "Kebir Rhumel", "Seybouse" et "Medjerda".

Il couvre une superficie totale de 11 511 Km². La région d'étude est caractérisée par un climat méditerranéen, doux et pluvieux en hiver, chaud et sec en été, avec une pluviométrie de l'ordre de 650 à 1800 mm/an.

II.8.4 Bassin versant de la Seybouse

Située à l'extrême Nord-Est de l'Algérie, la Seybouse couvre une superficie d'environ 6 450 km² et s'étend des hauts plateaux constantinois aux massifs telliens, et à la plaine d'Annaba à l'aval, en bordure de la Méditerranée. La Seybouse compte au totale six (6) sous bassins versants, Il est limité au Nord par la mer méditerranéenne, à l'Est et l'Ouest par les Côtiers constantinois, au Sud par le Kébir Rhumel, les hauts plateaux Constantinois et de la Medjerda. Ce bassin se caractérise par une saison pluvieuse d'octobre à mai et par un été chaud et sec. La saison chaude est marquée par une augmentation générale de la température.

La végétation, est caractérisée par une dégradation et défrichement en montagnes très accentué ; cela est dû aux incendies, aux petites agricultures extensives et les surpâturages observés dans la région. La haute Seybouse c'est le bassin le plus dénudé en couverture végétale. Durant l'été, la végétation herbacée se réduit à presque rien. La moyenne Seybouse couverte de forêts telliennes, le type de peuplement forestier est constitué essentiellement de Chêne liège et de Chêne zen. La basse Seybouse située dans la zone Nord de la chaîne atlastique, elle est couverte de forêt tellienne de type Chêne liège et Chêne zen.

II.8.5 Bassin versant de la Soummam

Le bassin versant de la Soummam, portant le N° 15 selon la codification de l'ANRH est subdivisé en 10 sous bassins versants. Le bassin couvre une superficie de 9 109 Km² de forme irrégulièrement étirée dans la direction Est-Ouest et accède à la Méditerranée par le golf de Bejaïa.

Il est limité par les chaînes montagneuses de Djurdjura et ses contreforts qui s'étendent jusqu'à la mer au Nord, les contreforts du mont du Hodna au Sud, les chaînes des Babors et le plateau de Sétif à l'Est et le plateau de Bouira à l'Ouest. Le climat du bassin versant de la Soummam, montre une série de transition entre climat humide, dans les montagnes proches de la Méditerranée, et climat semi-aride des hautes-plaines (environ Sétif).

Mais partout les averses sont fréquentes et règne aussi en été une sécheresse prolongée. La végétation du bassin versant de la Soummam est de type méditerranéen et est très variée. Les régions alluvionnaires de la haute Soummam sont occupées par des chênaies. La basse et moyenne Soummam sont occupées par des oliveraies et des vignobles. Dans la région de la moyenne Soummam, le couvert végétal est moins dense.

II.9 Caractéristiques morphométriques des bassins versants étudiés

Les différents paramètres morphométriques, interviennent et souvent de façon combinée dans les modalités de l'écoulement. De ce fait, il convient de les préciser dans cette étude. A titre indicatif, nous citons : le temps de concentration, la taille du bassin versant (sa surface), sa forme, son élévation, sa pente et son orientation, sans oublier le type de sol, le couvert végétal et les caractéristiques du réseau hydrographique. Le tableau II.1 récapitule les principales caractéristiques morphométriques et hydrographiques des bassins aux droits de différentes stations hydrométriques étudiée.

Tableau II.1. Caractéristiques des bassins versants étudiés (Source ANRH, 2021)

Bassin	Nom de station	Code station	S (km ²)	P (km)	Ic	H _{max}	H _{min}	H _{moy}	Ip	Dd (Km/Km ²)	C _t
Cheliff	WADI LILI	012501	420	94	0.12	1267	517	887	3.4	2,44	5,4
Côtiers Algérois	FREHA	021601	100	42	1.18	1278	130	476	0,26	3.4	25
	RN 25	021909	300	73	1.18	1230	150	625	0.24	1.93	7
Côtiers constantinois	AIN EL ASSEL	031601	680	115	1.23	1494	24	298	0.15	3	16.3
Seybouse	BOUCHEGOUF	140501	550	120	1.43	1317	95	641	0.15	4	25.2
	AIN BERDA	140602	103	45	1.24	927	55	350	0.16	2.8	17.4
Soummam	FERMATOU	150601	105	60	1.09	1494	-	1205	-	2.94	18
	BOU BIREK	150703	2960	250	-	1686	220	-	-	-	-

S : surface (km²), P : Périmètre (km), Ic: Pente de roche, H_{max} : Hauteur maximale (m), H_{min} : Hauteur minimale (m), H_{moy} : Hauteur moyenne (m), Ip : Pente moyenne, Dd : Densité de drainage (Km/km²), Ct : Coefficient de torrentialité.

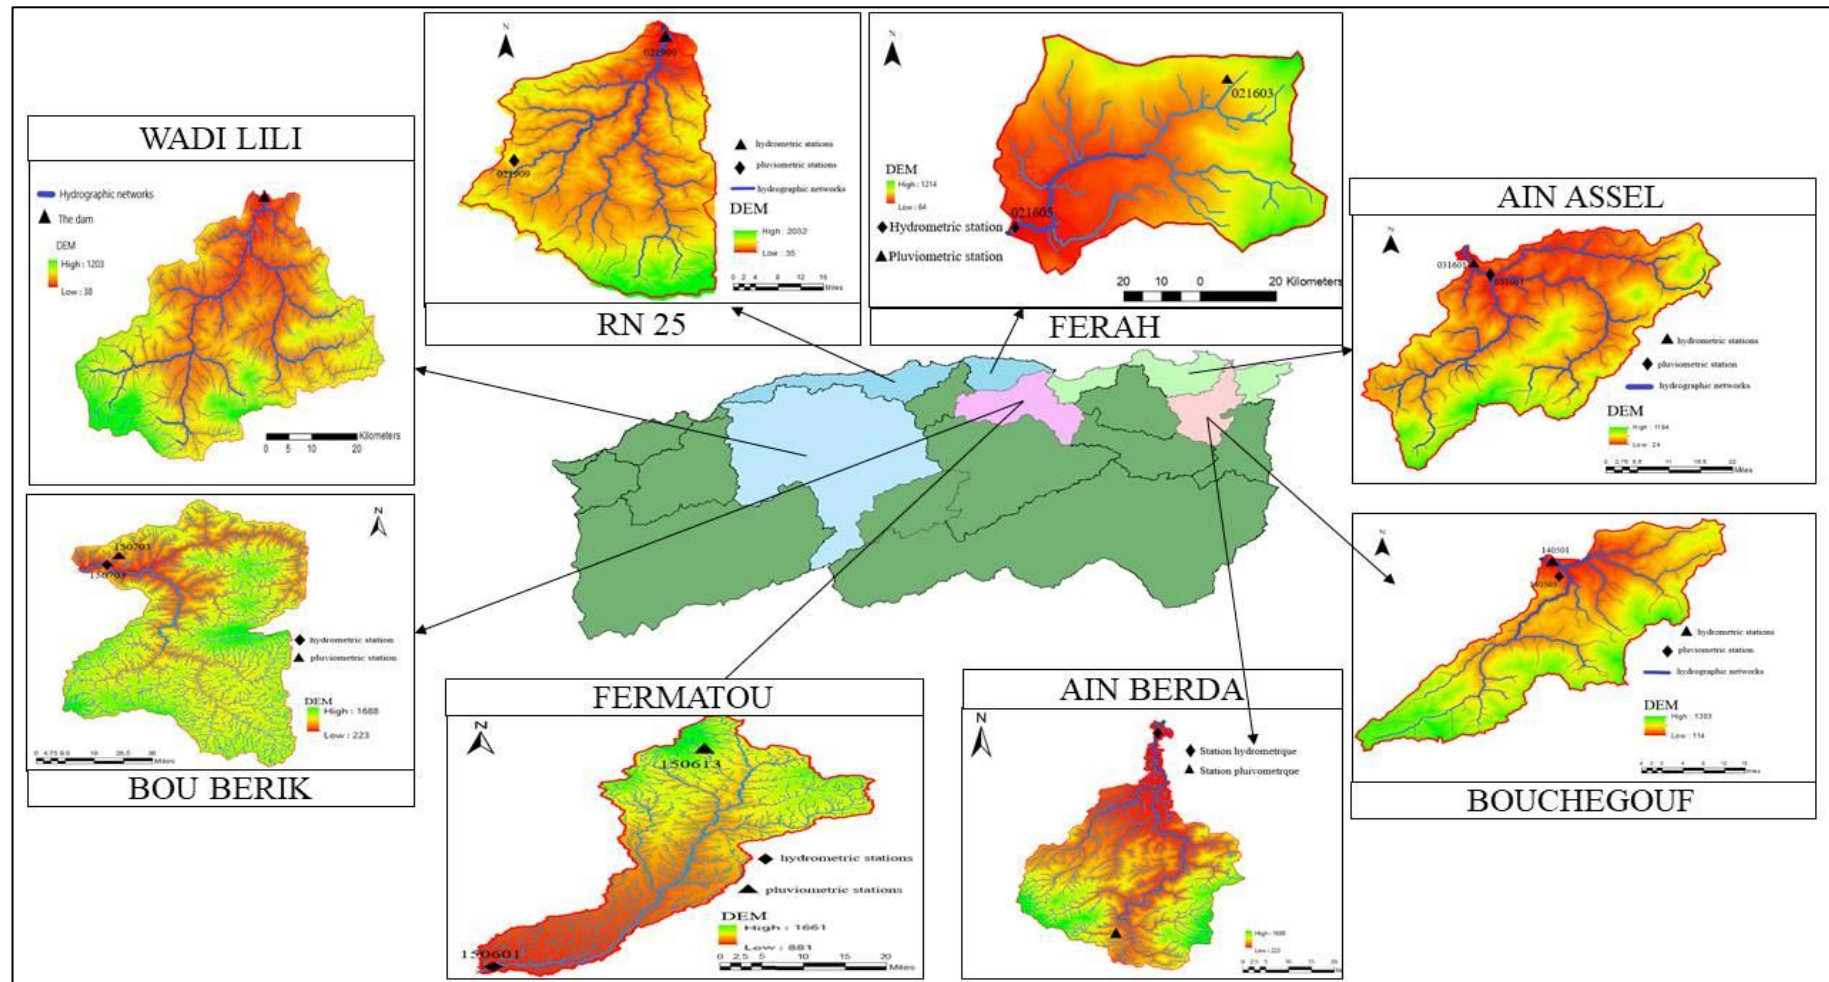


Figure II.6. Caractéristiques des bassins versants étudiés

La figure II.6 représente la délimitation des sous bassins étudié et leur position dans le nord de l'Algérie la délimitation effectuée à l'aide de logiciel arc gis. La délimitation des bassins versants est essentielle pour la modélisation du débit des cours d'eau car elle permet de définir précisément la zone d'influence qui contribue à l'écoulement de l'eau vers un point donné. Cette délimitation est réalisée en identifiant les lignes de crête qui définissent les limites du bassin versant, à partir desquelles l'eau s'écoule vers le point d'exutoire, la figure aussi représente les bassins qui a un réseau hydrographique dense, des cours d'eau supérieur à 100 mètres, Le réseau hydrographique fournit le chemin par lequel l'eau de surface s'écoule hors du bassin versant. La configuration du réseau, y compris la densité et la longueur des cours d'eau, influence la vitesse et la quantité d'eau qui atteint l'exutoire.

II.10 Conclusion

Avant tout projet, il est nécessaire d'étudier le site pour comprendre ses caractéristiques physiques ainsi que les facteurs qui influent sur la problématique étudiée. Dans ce chapitre nous avons présenté les caractéristiques morphologiques et géologiques pour les bassins étudiés qui sont répartis dans le Nord algérienne. Cette région se caractérise par un climat semi-aride, une grande diversité des unités naturelles et une variété géologique.

Les caractéristiques morphométriques qui déterminent des différences sensibles dans l'aptitude des terrains au ruissellement, un climat semi-aride à forte variabilité spatiale et surtout temporelle, ainsi qu'un couvert végétal très discontinu, essentiellement dans l'espace et secondairement dans le temps, sont les principales conditions physico-géographiques caractérisant la région. Cette combinaison est déterminante dans le comportement hydrologique des diverses unités du bassin.

CHAPITRE III
DONNEES UTILISEES
ET SELECTION DES
VARIABLES

CHAPITRE III : DONNEES UTILISEES ET SELECTION DES VARIABLES

III.1 Introduction

Dans cette partie du travail, nous présenterons les données utilisées pour bien mener cette étude. Ainsi que, de procéder à un choix préalable des variables d'entrée pour les différents modèles utilisés, en intégrant différentes méthodes de sélection permettant un choix optimal des entrées.

III.2 La collecte de données

Dans notre étude, nous avons collecté trois types de données ; hydrométriques, pluviométrique et climatiques. Pour procéder à la modélisation pluie-débit à différents pas de temps i.e. journalier, mensuel et annuel, ces dernières sont collectées au pas de temps journalier, pour qu'on puisse par la suite reconstituer les séries mensuelles et annuelles.

La collecte et la mise en forme des données est la phase la plus délicate et difficile en hydrologie. Les données hydrométriques utilisées proviennent de la banque de données de l'ANRH (Agence Nationale des Ressources Hydrauliques) en Algérie. Elles sont structurées suivant l'année hydrologique allant du 1er septembre au 31 août. Les données météorologiques utilisées proviennent de la banque de données de l'O.N.M (Office Nationale de Météorologie).

La sélection définitive des stations (hydrométriques et pluviométrique) retenues dans ce travail, est basée principalement sur l'homogénéité et la qualité des séries d'observations disponibles sur des périodes récentes et communes. La mise en forme et l'homogénéisation des séries, passent par un travail long et fastidieux suivant la nature et à la variété des bases de données informatisées de l'ANRH et de l'ONM. La plupart des séries de données sont courtes avec existence de plusieurs lacunes et parfois de valeurs bizarres, ce qui exige un certain travail statistique pour combler et homogénéiser ces séries.

Pour cette étude, nous avons collecté plus de 90 stations hydrométriques et plus de 120 stations pluviométriques situées dans le nord algérien. Après traitement et comblement des

lacunes, la plupart de ces stations ont été rejetées, comme celles des bassins 06, 07, 09 et 12 car elles contiennent de nombreuses lacunes et sont donc invalides et peu fiables.

Le comblement des lacunes d'observation a été effectué par deux méthodes : méthode de la moyenne mensuelle et la méthode de la régression linéaire.

III.3 Les stations sélectionnées

Après un processus de traitement incluant le comblement de données manquantes les stations sélectionnées sont répertoriées dans le tableau III.1. Chaque sous-bassin dispose d'une station pluviométrique, une station hydrométrique et une station climatique associée pour une couverture exhaustive.

Tableau III.1. Stations choisies dans cette étude

Bassin	Nom de la station hydrométrique	Code station	Station pluviométrique	Station climatique	Période
Cheliff	WADI LILI	012501	012501	TIARET	1992-2002
Côtiers Algérois	FREHA	021601	021603	TIZI OUZOU	1992-2002
	RN 25	021909	021909	TIZI OUZOU	1982-1993
Côtiers constantinois	AIN EL ASSEL	031601	031601	EL KALA	1993-2003
Seybouse	BOUCHEGOUF	140505	140501	GEULMA	1985-1995
	AIN BERDA	140602	140602	ANNABA	1987-1997
Soummam	FERMATOU	150601	150613	SETIF	1997-2007
	BOU BIREK	150703	150703	SETIF	2002-2012

III.4 Estimation de l'évapotranspiration

Pour notre travail, nous retenons cinq (06) stations météorologiques réparties sur différentes régions du Nord algérien voir tableau III.1. Elles sont structurées suivant l'année calendaire allant du 1er janvier au 31 décembre. Pour estimer l'évapotranspiration, nous utilisons : la température maximale (T_{max}), la température minimale (T_{min}), la pluie (P), l'humidité relative (H%), la vitesse du vent (U_2) et le rayonnement solaire (SR).

Dans un premier temps, nous estimerons l'évapotranspiration de référence, c'est à dire l'évapotranspiration qu'aurait un gazon sain, bien alimenté en eau sous l'effet de notre climat.

A l'aide de la formule de Penman-Monteith modifiée (FAO), nous calculerons l'ETP. La formule de Penman-Monteith se distingue parmi les différentes formules par son origine théorique dérivée du bilan de flux énergétique à la surface de couvert végétale, dans un souci de normalisation, la FAO, à travers son groupe d'experts opérants dans différents contextes climatiques, a adapté la formule Penman-Monteith aux conditions d'un couvert de gazon et propose la formule dérivée comme la nouvelle définition «l'évapotranspiration de référence». Allen et al. (1998) ont défini l'ET₀ comme : l'évapotranspiration d'un couvert végétale « hypothétique » de référence ayant une hauteur de 12 cm, une résistance du couvert de 70 s/m et un albédo de 23%. Un couvert de gazon se développe activement sur une grande étendue régulièrement tendu, bien alimenté en eau et indemne de maladies.

L'évapotranspiration de référence peut s'écrire selon la formule :

$$ET_0 = \frac{0,408\Delta(Rn - G) + \gamma \frac{Cste}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \quad \text{III.1}$$

Avec :

ET₀ : Evapotranspiration de référence journalière (mm/j) ;

Rn : Rayonnement net à la surface de culture (MJ/m²/j) ;

G : Flux de chaleur échangé avec le sol (MJ/m²/j) ; qui est à la l'échelle de journée pratiquement nul, en effet le gain diurne de chaleur par le sol équilibre la perte nocturne ;

T : Température moyenne journalière (°C) ;

U₂ : Vitesse moyenne journalière du vent mesuré à 2 mètres (m/s) ;

e_s et **e_a** : Sont respectivement la pression de vapeur saturante et la pression réelle de l'air à la même hauteur (kPa) ;

γ : Constant psychrométrique (kPa /°C) ;

900 : Coefficient pour la culture de référence (kg k/ kJ) liées aux unités utilisées à la distribution de variables ρ, c_p et r_a ;

0.34 : Coefficient de vent pour la culture de référence (kg K/ kJ) résultat du rapport r_s / r_a ;

0.408 : inverse de λ = 2.45 MJ/ kg ;

Δ : Pente de la courbe de pression de vapeur saturante à la température T (kPa /°C).

Où :

$$\Delta = \frac{4098 \left[0.6108 \exp\left(\frac{17.27T}{T + 237.3}\right) \right]}{(T + 237.3)^2} \quad \text{(III.2)}$$

Les données climatiques utilisées, concernent les stations suivantes : El-Kala, Guelma, Setif, Annaba et Tizi-ouzou, Tiaret.

III.5 L'analyse statistique de données utilisées

La connaissance des paramètres statistiques des données revêt une importance capitale dans la modélisation hydrologique. Ces paramètres, tels que la moyenne, la variance, la distribution et les tendances, permettent de caractériser la variabilité des phénomènes hydrologiques. Comprendre ces éléments statistiques est fondamental pour calibrer et valider les modèles hydrologiques, assurant ainsi leur précision et leur fiabilité dans la prédiction des débits, des niveaux d'eau et des événements extrêmes. En utilisant ces informations statistiques, les modélisateurs peuvent mieux appréhender les schémas de comportement des cours d'eau, des bassins versants et des systèmes hydrologiques complexes, renforçant ainsi la capacité à élaborer des stratégies de gestion des ressources en eau plus efficaces et adaptées aux variations environnementales et climatiques. Les tableaux III.2, 3 et 4 représentent les caractéristiques statistiques des séries collectées à différents pas de temps."

Tableau III.2. Paramètres statistiques des données utilisées au pas de temps journalier

Station	Variables	N	Unit	X _{max}	X _{mean}	X _{min}	S _x	C _v
WADI LILI 012501	P	3650	mm	86.4	1.11	0.00	1.88	1.86
	ETP	3650	mm	10.59	0.268	0.00	1.92	0.52
	T	3650	C°	37.18	17.02	0.00	6.80	0.40
	Q	3650	m ³ /s	72.90	2.31	0.00	2.06	0.89
FREHA 021601	P	3650	mm	78.60	1.76	0.00	6.02	3.42
	ETP	3650	mm	11.29	3.87	0.36	2.24	0.58
	T	3650	C°	38.74	1.76	0.36	6.72	3.81
	Q	3650	m ³ /s	55.36	0.78	0.00	3.62	4.61

RN 25 021901	P	3650	mm	74.20	1.92	0.00	6.57	3.43
	ETP	3650	mm	11.29	3.67	0.36	2.20	0.60
	T	3650	C°	37.17	1.92	0.36	6.85	3.57
	Q	3650	m ³ /s	18.97	0.42	0.00	0.99	2.35
AIN EL ASSEL 031601	P	3650	mm	107.40	2.11	0.00	6.62	3.15
	ETP	3650	mm	8.99	3.27	1.03	1.27	0.39
	T	3650	C°	32.08	2.11	1.03	5.10	2.42
	Q	3650	m ³ /s	46.94	0.82	0.00	3.24	3.96
BOUCHEGOUF 140501	P	3650	mm	74.10	1.34	0.00	4.57	3.40
	ETP	3650	mm	14.12	3.70	0.27	2.49	0.67
	T	3650	C°	36.64	1.34	0.27	7.67	5.72
	Q	3650	m ³ /s	25.83	0.44	0.00	1.36	3.09
AIN BERDA 140602	P	3650	mm	93.00	1.52	0.00	5.20	3.42
	ETP	3650	mm	9.70	3.32	0.98	1.26	0.38
	T	3650	C°	33.02	1.52	0.98	5.05	3.32
	Q	3650	m ³ /s	37.24	0.29	0.00	1.40	4.91
FERMATOU 150601	P	3650	mm	74.90	1.27	0.00	4.63	3.65
	ETP	3650	mm	10.98	3.50	0.27	2.37	0.68
	T	3650	C°	35.34	1.27	0.27	8.14	6.42
	Q	3650	m ³ /s	39.96	0.46	0.01	1.46	3.16
BOU BIREK 150702	P	3650	mm	100.83	3.34	0.27	2.33	0.70
	ETP	3650	mm	90.00	1.76	0.00	5.69	3.24
	T	3650	C°	34.19	3.34	0.00	8.10	2.42
	Q	3650	m ³ /s	257.73	2.55	0.00	9.31	3.65

Par exemple la station RN25, la moyenne journalière des débits est de 0,42 m³/s, avec un écart-type de 0,99 m³/s, indiquant une certaine stabilité dans les débits quotidiens. Les débits minimum et maximum enregistrés sont de 0 m³/s et 18 m³/s respectivement, illustrant une gamme modérée de débits observés. Même pour les précipitations, la moyenne journalière est de 1,9 mm, avec un écart-type de 6,8 mm, indiquant une certaine stabilité dans les quantités de pluie quotidiennes. Les jours les plus pluvieux ont enregistré jusqu'à 74 mm de précipitations, tandis que les jours les moins pluvieux sont de l'ordre de 00 mm.

En revanche, la station BOU BIREK présente une moyenne journalière de 2.55 m³/s, avec un écart-type de 9.33 m³/s, montrant une variabilité plus importante des débits. Les débits minimum et maximum pour cette station sont de 0 m³/s et 257 m³/s, montrant une plus grande amplitude dans les débits observés. Les jours les plus pluvieux ont enregistré jusqu'à 100 mm, tandis que les jours les moins pluvieux ont eu seulement 00mm montrant une variabilité plus importante dans les quantités de pluie.

L'évapotranspiration journalière présente une distribution relativement symétrique, avec des valeurs moyennes proches des médianes pour la plupart des stations.

Tableau III.3. Paramètres statistiques des données utilisées au pas de temps mensuel

Station	Variables	N	Unit	X _{max}	X _{mean}	X _{min}	S _x	C _v
WADI LILI 021601	P	120	mm	176.10	30.86	0.00	30.68	1.04
	ETP	120	mm	200.97	6.72	0.00	27.30	0.135
	Q	120	m ³ /s	3.79	0.39	0.00	0.36	0.92
FREHA 021601	P	120	mm	251.00	6.06	0.00	17.31	2.86
	ETP	120	mm	243.47	7.62	0.00	29.30	3.85
	Q	120	m ³ /s	34.19	6.06	0.00	8.48	1.40
RN 25 021901	P	120	mm	288.80	6.17	0.00	18.48	3.00
	ETP	120	mm	243.47	7.57	0.00	29.26	3.86
	Q	120	m ³ /s	34,19	6,17	0,00	8,46	1,37
AIN EL ASSEL 031601	P	120	mm	273,70	47,21	0,00	151,64	3,21
	ETP	120	mm	210,19	100,51	54,80	32,69	0,33
	Q	120	m ³ /s	102,40	6,52	0,00	13,89	2,13
BOUCHEGOUF 140501	P	120	mm	174.60	40.68	0.00	38.38	0.94
	ETP	120	mm	249.49	112.46	18.27	69.63	0.62
	Q	120	m ³ /s	26.92	2.82	0.00	4.88	1.73
AIN BERDA 140602	P	120	mm	233.30	45.37	0.00	46.66	1.03
	ETP	120	mm	249.49	114.00	24.41	68.76	0.60
	Q	120	m ³ /s	30.86	1.79	0.00	4.05	2.26
FERMATOU	P	120	mm	160.70	24.39	0.00	29.92	1.23

150601	ETP	120	mm	226.88	106.45	19.37	67.62	0.64
	Q	120	m ³ /s	45.93	6.12	0.81	9.56	1.56
BOU BIREK 150702	P	120	mm	288.80	58.30	0.00	65.25	1.12
	ETP	120	mm	241.43	111.45	24.20	60.39	0.54
	Q	120	m ³ /s	18.45	1.48	0.00	2.43	1.64

Les séries des variables au pas de temps mensuel, sont constituées à partir des séries journalières. Pour la pluie, c'est la somme des valeurs journalières pour chaque mois, et même chose pour l'évapotranspiration. Pour le débit mensuel, c'est la moyenne des débits pour chaque mois. Ceci explique l'écart important entre les valeurs minimales et maximales, en particulier pour les précipitations et l'évapotranspiration, et illustrant une gamme modérée de débits observés.

Tableau III.4. Paramètres statistiques des données utilisées ou pas de temps annuel

Station	Variables	N	Unit	X _{max}	X _{mean}	X _{min}	S _x	C _v
WADI LILI	P	10	mm	622.10	375.46	239.2	94.78	0.25
	Q	10	m ³ /s	1.21	0.47	0.09	0.33	0.71
	ETP	10	mm	1400.64	1117.78	1003.02	55.99	0.05
FREHA 021601	P	10	mm	898.80	657.85	425.10	130.77	0.20
	Q	10	m ³ /s	2.09	0.96	0.10	0.66	0.69
	ETP	10	mm	1461.84	1357.78	1233.02	65.99	0.05
RN 25 021901	P	10	mm	1438.49	1337.41	1233.02	56.55	0.04
	Q	10	m ³ /s	3.15	1.48	0.55	0.83	0.56
	ETP	10	mm	985.70	699.65	436.60	164.14	0.23
AIN EL ASSEL 031601	P	10	mm	1225.00	768.41	438.60	252.17	0.33
	Q	10	m ³ /s	21.25	6.52	0.48	6.21	0.95
	ETP	10	mm	1296.15	1206.08	1156.89	46.13	0.04
BOUCHEGOUF 140501	P	10	mm	694.60	488.19	340.80	120.04	0.25
	Q	10	m ³ /s	123.79	112.46	103.96	6.84	0.06
	ETP	10	mm	88.87	33.83	7.03	26.75	0.79
	P	10	mm	773.10	544.45	316.10	130.38	0.24

AIN BERDA 140602	Q	10	m ³ /s	4.84	1.79	0.13	2.00	1.12
	ETP	10	mm	1488.63	1368.05	1247.56	87.39	0.06
FERMATOU 150601	P	10	mm	536.70	292.63	124.10	151.73	0.52
	Q	10	m ³ /s	11.49	6.12	1.29	4.12	0.67
	ETP	10	mm	1342.16	1277.36	1206.92	43.02	0.03
BOU BIREK 150702	P	10	mm	1355.77	466.80	122.30	340.13	0.73
	Q	10	m ³ /s	1.23	0.50	0.07	0.38	0.77
	ETP	10	mm	1366.18	1173.72	666.60	195.20	0.17

Les statistiques descriptives pour les précipitations annuelles montrent une moyenne de 657,9 mm avec un écart-type de 130,8 mm à la station FREHA, de 768,4 mm avec un écart-type de 252,2 mm à la station AIN EL ASSEL, et de 536,7 mm avec un écart-type de 151,7 mm à la station FERMATOU. Cela indique une variabilité inter-stations pour les précipitations annuelles remarquable. Les stations semblent avoir des précipitations annuelles sensiblement inférieures ou supérieures, respectivement, par rapport à la moyenne des stations. Les minimums et maximums observés varient également entre les stations, avec des différences notables dans les quantités extrêmes des précipitations, la même chose pour l'évapotranspiration aussi.

III.6 L'analyse des séries des débits

Les enregistrements des débits des rivières présentent une variabilité naturelle influencée par de nombreux facteurs environnementaux par exemple facteurs physiques et géographiques influençant le débit, les caractéristiques géographiques, telles que la topographie, les précipitations locales, et la présence de lacs ou de glaciers, contribuent également à ces variations. De plus, les activités humaines telles que l'irrigation, la construction de barrages ou l'urbanisation peuvent modifier les débits naturels des rivières, introduisant ainsi une autre dimension de variabilité dans les enregistrements des débits. Il est donc nécessaire de comprendre l'évolution des données hydrométriques collectées dans une station hydrométrique, car elles seront utilisées d'une part pour l'évaluation des apports liquides à différentes échelles de temps, et d'autre part l'analyse de la variabilité événementielle du débit. Concernant la variable de débit annuel, la plage de variation est très réduite, Cela signifie qu'il existe une grande convergence entre les valeurs limites maximale et minimale indiquant une certaine stabilité dans les débits.

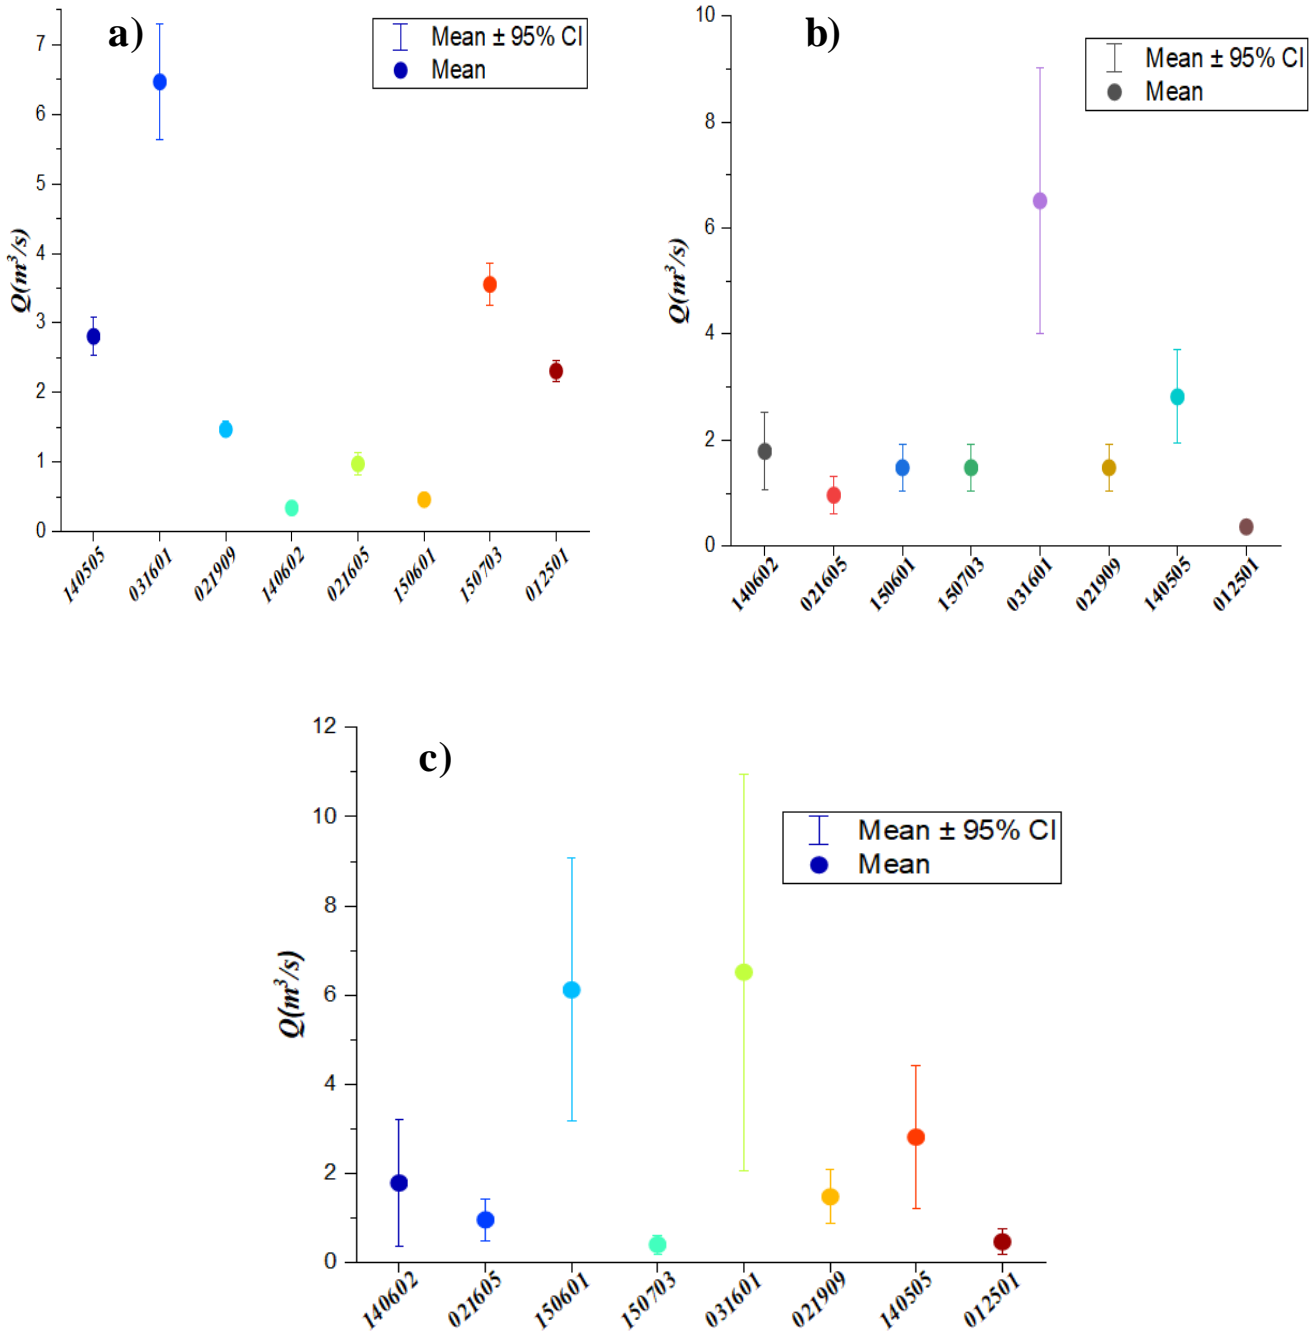


Figure III.1. Intervalle plot pour les stations hydrométriques ou pas de temps a) journalière, b) mensuel, c) annuel.

La Figure III.1 et 2 représente un intervalle plot est un graphique qui représente un intervalle de confiance autour d'une estimation statistique, souvent la moyenne, c'est-à-dire créer un intervalle de confiance autour de cette moyenne d'échantillon pour estimer la plage probable où se situe la vraie moyenne de la population. Ce qui signifie que vous êtes raisonnablement sûr à 95 % que la vraie taille moyenne de la population se situe quelque part

entre ces deux valeurs. Un intervalle plot offre une visualisation graphique utile pour comprendre la précision d'échantillon statistiques et pour déterminer la plage probable où se trouve la vraie valeur de la population que vous étudiez.

Plus l'intervalle est étroit, plus la série des écoulements est précise comme les stations 021909, 140602 et la station 150601 au pas de temps journalier. De même, un intervalle plus large signifie que la série des écoulements moins précise comme la station 031601 pour différent pas de temps.

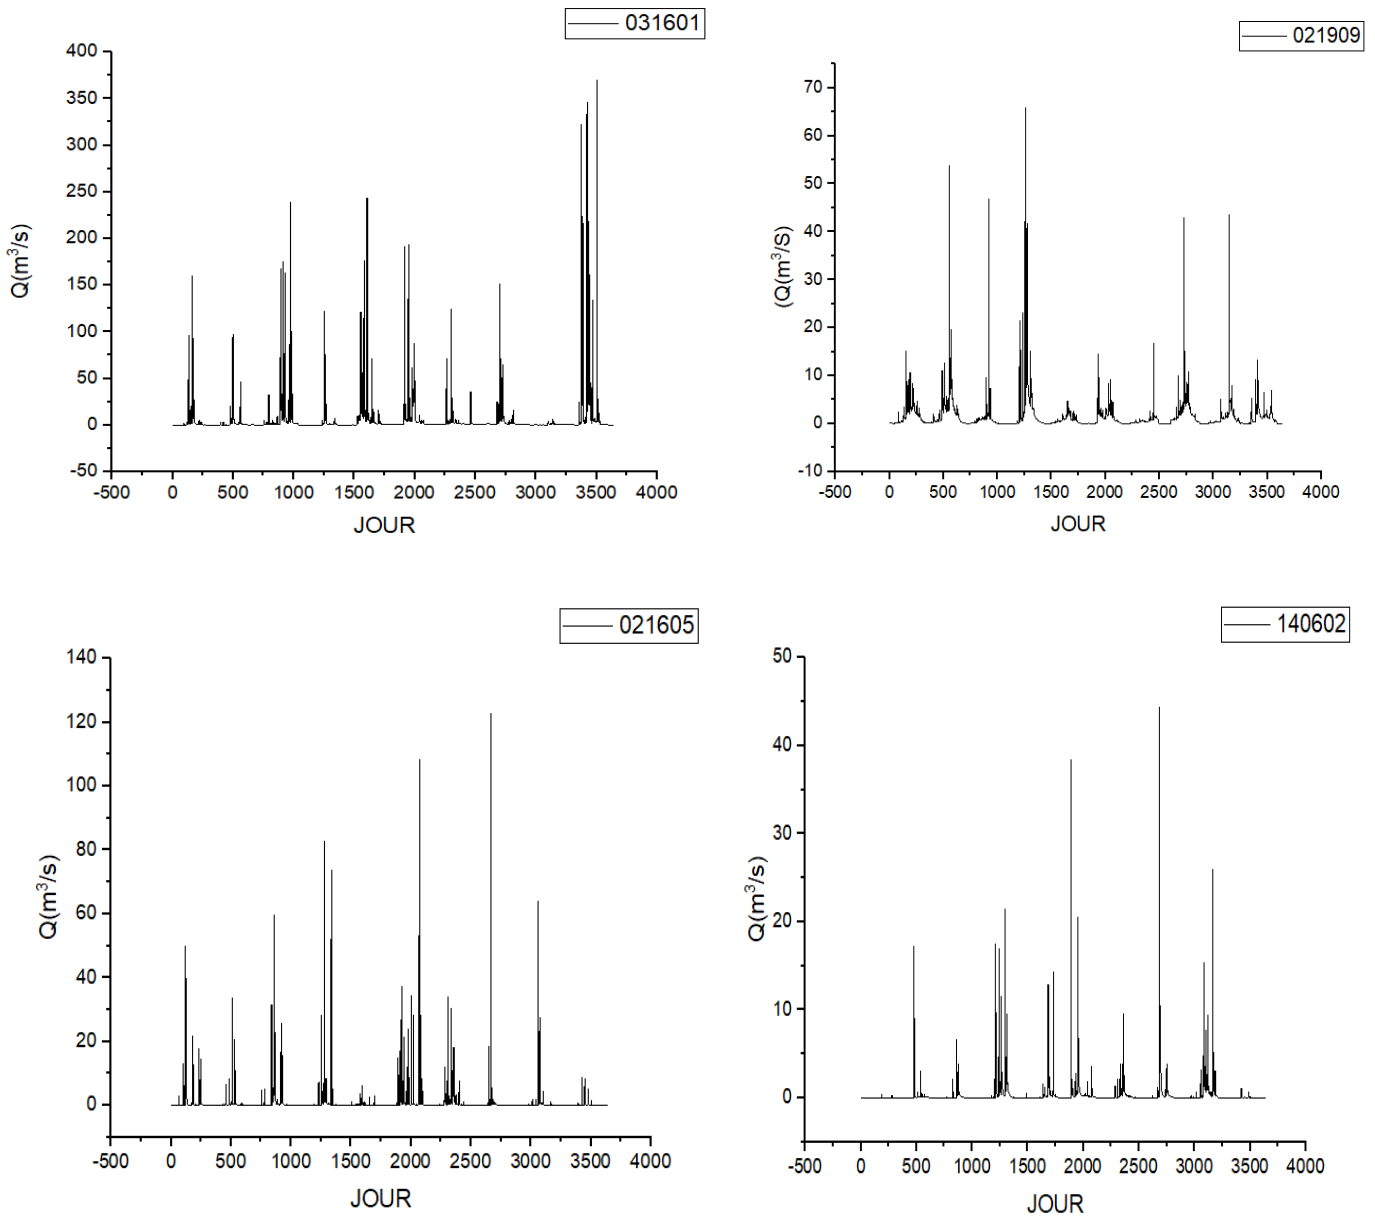


Figure III.2. Variation des débits journaliers pour quelques stations étudiées

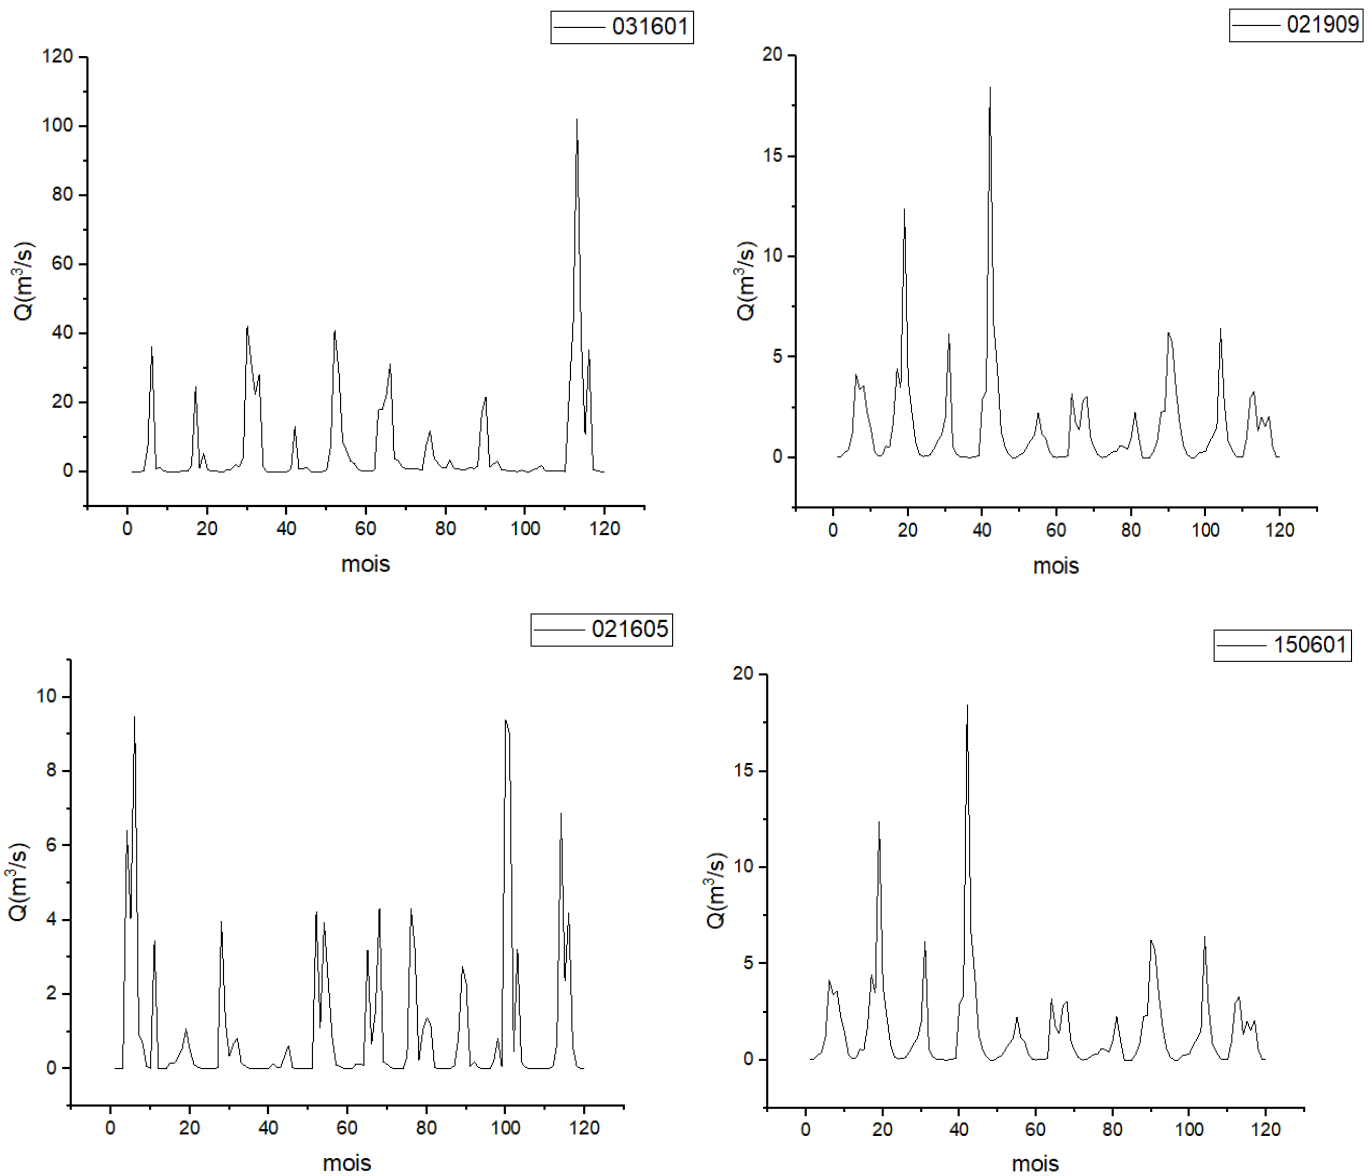


Figure III.3. Variation des débits mensuels pour quelques stations étudiées

Les courbes de variation de débit représentent graphiquement les changements du débit d'eau dans une rivière, montre les fluctuations quotidiennes, mensuelles ou saisonnières du débit d'eau. On remarque les variations illustrées en fonction du temps, permettant d'observer les augmentations et diminutions du flux d'eau sur les deux échelles de temps et montrer des pics de débit.

Basé sur les courbes des variations (Figure III.2 et 3) les données que nous avons collectées Il contient des valeurs anormales comme celle de la station 1. De même, nous constatons un déséquilibre dans le changement de débit, dû au changement climatique, et c'est en soi le plus gros problème dans le domaine de la modélisation. En ce qui concerne le pas de

temps annuel la variation de débit et moins remarquable par rapport au pas de temps journalière et mensuel.

III.7 La sélection des variables d'entrée

La sélection des variables d'entrée pour la modélisation hydrologique est une étape cruciale pour l'obtention de résultats précis. Elle implique que les facteurs pertinents qui influencent le cycle hydrologique d'un bassin versant soient identifiés et pris en compte. Ces variables peuvent inclure des données météorologiques.

III.7.1. Les modèles conceptuels

Les entrées pour les modèles GR, sont fixés en prenant en considération trois principales variables : Les données pluviométriques **P** sont fondamentales, car les précipitations représentent la principale source d'entrée d'eau dans le bassin versant, et deuxième variable évapotranspiration **ETP** Cette variable représente la perte d'eau par évaporation depuis le sol et la transpiration des plantes, elle dépend étroitement des conditions météorologiques et de la végétation, influençant ainsi le bilan hydrique du bassin. Les débits **Q** des cours d'eau mesurés constituent une variable de sortie du modèle, mais sont souvent utilisés comme données d'entrée pour calibrer et valider les modèles GR, permettant ainsi d'ajuster ses paramètres pour une meilleure représentation des processus hydrologiques du bassin. Concernant le modèle HBV, dans les mêmes variables, on ajoute uniquement la température **T**.

III.7.2 Les modèles de l'intelligence artificielle

Le choix des variables d'entrée constitue une phase importante qui conditionne la performance des résultats de la modélisation par les méthodes de l'intelligence artificielle, L'un des principaux facteurs contribuant à la fiabilité de la modélisation et la performance des résultats y afférant, est l'optimisation des variables d'entrée. Cette étape est considérée comme un défi pour les modélisateurs (Afan et al., 2020). Le processus de sélection repose souvent sur des techniques statistiques, des analyses de corrélation et des connaissances expertes pour déterminer quelles variables ont le plus grand impact sur les débits des cours d'eau ou sur d'autres paramètres hydrologiques. Une sélection judicieuse permet de simplifier les modèles tout en préservant leur précision, améliorant ainsi la compréhension des processus hydrologiques et leur prédiction.

Les variables d'entrée pour la modélisation hydrologique peuvent être sélectionnées à l'aide de diverses techniques, notamment l'analyse des fonctions d'autocorrélation (ACF), des fonctions d'autocorrélation partielle (PACF) et des fonctions d'autocorrélation croisée (XACF). L'ACF examine la corrélation linéaire entre une série temporelle et ses valeurs passées à différents retards. Cette méthode est utilisée pour identifier les dépendances entre les observations successives. Le PACF évalue les corrélations conditionnelles entre les observations, en éliminant les effets des retards intermédiaires. Il permet de déterminer les liens directs entre les observations, ce qui peut être utile pour sélectionner les variables d'entrée les plus influentes. XACF évalue les corrélations croisées entre deux séries temporelles différentes. Dans le contexte de la modélisation hydrologique, cela peut être utile pour évaluer les relations entre différentes variables météorologiques ou hydrologiques. Ces techniques d'analyse des autocorrélations aident à identifier les retards significatifs et les dépendances temporelles entre les données, ce qui peut orienter le choix des variables d'entrée pour les modèles hydrologiques. En sélectionnant les variables qui présentent des liens temporels importants avec la variable cible on peut construire des modèles plus précis et représentatifs des processus hydrologiques sous-jacents. En résumé, cette approche met en évidence l'utilisation spécifique des données de précipitations et de débits passés, en utilisant des retards temporels pour représenter les variables d'entrée dans le modèle hydrologique, afin de simuler de manière plus précise les débits observés. Concernant l'évapotranspiration et la température Nous ne les avons pas utilisés dans les modèles d'intelligence artificielle car lorsque l'on étudie le taux de corrélation avec le débit, il est faible et n'affecte pas les résultats.

Il semble que dans cette étude, l'évapotranspiration et la température n'ont pas été intégrées dans les modèles d'intelligence artificielle en raison d'un taux de corrélation faible avec les débits, ce qui indique qu'elles n'ont pas d'influence significative sur les résultats. Cette décision de ne pas inclure ces variables dans les modèles est basée sur une analyse du niveau de corrélation entre ces paramètres et les débits, montrant une relation limitée ou insignifiante. Ainsi, leur exclusion vise à simplifier le modèle en se concentrant sur les variables ayant une influence plus directe et significative sur la prédiction des débits, ce qui peut améliorer la précision et la pertinence des résultats obtenus.

La figure III.4 de décrivent la relation entre les entrées et les sorties d'un modèle, probablement utilisé pour prédire ou estimer les débits des cours d'eau. Cela semble être une

analyse de la corrélation entre les données d'entrée fournies au modèle d'intelligence artificielle et les débits réels des cours d'eau qu'il prédit.

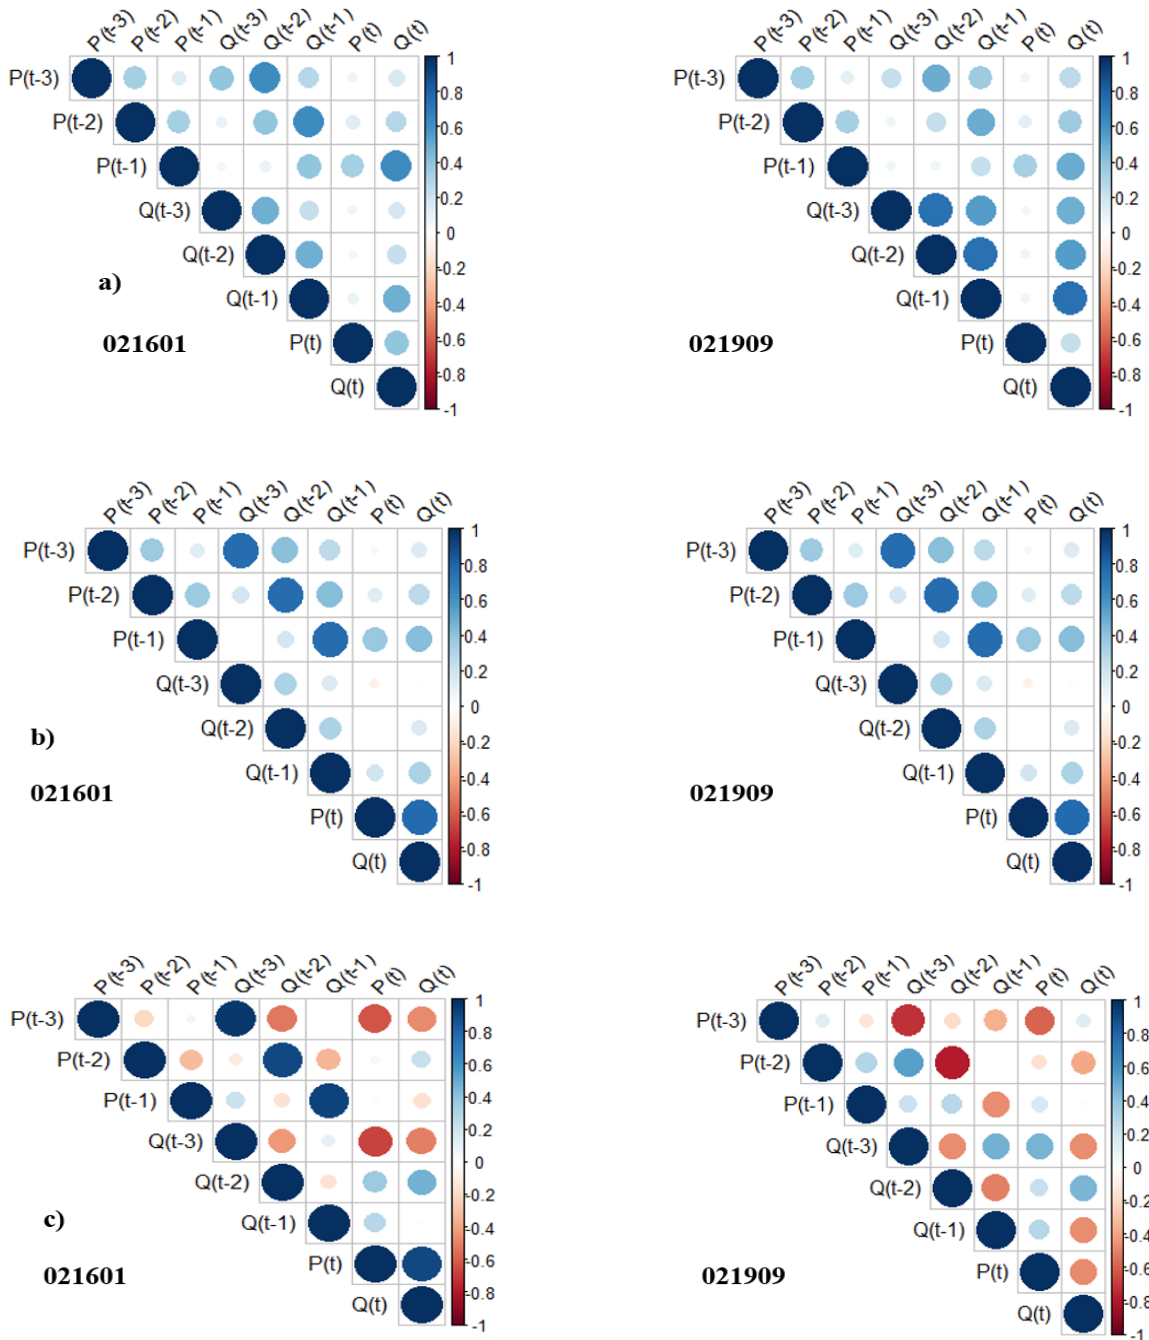


Figure III.4. Matrice de corrélation pour quelques stations étudiées ou pas de temps a) journalière, b) mensuel, c) annuel

Le Tableau III.5 montre les meilleures combinaisons obtenues pour modéliser le débit à l'aide des modèles de l'intelligence artificielle.

Tableau III.5. Les combinaisons entrées pour différents modèles

Combinaisons entrées	sortie
$Q(t-3), Q(t-2), Q(t-1), P(t-3), P(t-2), P(t-1), P(t)$	$Q(t)$
$P(t-3), P(t-2), P(t-1), P(t)$	$Q(t)$
$Q(t-3), Q(t-2), Q(t-1), P(t)$	$Q(t)$
$P(t-3), P(t-2), P(t-1)$	$Q(t)$
$Q(t-3), Q(t-2), Q(t-1)$	$Q(t)$
$P(t)$	$Q(t)$

III.8 Conclusion

Dans ce chapitre, nous avons présenté les données utilisées et les stations hydrométriques sélectionnées qui aient la même taille des séries. Différentes méthodes ont été utilisées pour identifier, de manière optimale, les variables d'entrée les plus pertinentes pour la prévision du débit à différents pas de temps, dans le but d'examiner différents modèles de prévision dans les mêmes conditions afin de confirmer la fiabilité et les performances des modèles.

CHAPITRE IV
MATÉRIELS ET
MÉTHODES

CHAPITRE IV : MATÉRIELS ET MÉTHODES

IV. 1 Introduction

La modélisation pluie-débit est un domaine crucial en hydrologie qui étudie la relation entre les précipitations et le débit des cours d'eau. Ces modèles permettent de prédire comment les précipitations affectent le ruissellement et le débit des rivières, ce qui est essentiel pour la gestion des ressources en eau, la prévention des inondations et la planification des infrastructures hydrauliques. En utilisant des données météorologiques, topographiques et hydrologiques, ces modèles mathématiques simulent les processus hydrologiques pour mieux comprendre et anticiper les variations du débit en fonction des conditions météorologiques.

Cette partie du travail, que nous consacrerons aux modèles appliqués dans cette étude, et peut être divisée en deux parties : modèles conceptuels et modèles basés sur l'intelligence artificielle.

IV.2 Les modèles conceptuels

Les modèles conceptuels pluie-débit sont des outils simplifiés mais puissants, utilisés en hydrologie pour représenter les processus d'écoulement des eaux de surface. Les modèles conceptuels simplifient les interactions entre ; les précipitations, l'écoulement et le débit, en utilisant des concepts simplifiés et des paramètres empiriques. Dans ce travail de thèse, nous avons utilisés les modèles conceptuels suivants : le modèle HBV et les modèles GR.

IV.2.1 Le modèle HBV

Le modèle pluie-débit HBV (Hydrologiska Byråns Vattenbalansavdelning) est l'un des modèles conceptuels les plus utilisés en hydrologie. Il a été développé par le Swedish Meteorological and Hydrological Institute (SMHI) pour simuler les processus hydrologiques dans les bassins versants. Le modèle hydrologique universel HBV (Lindström et al., 1997) est un modèle conceptuel global ou semi distribué à l'échelle du bassin versant et qui est capable de calculer le débit pour divers sous bassins.

Ce modèle simule le débit quotidien en utilisant comme entrées ; la température et la précipitation journalière, ainsi que l'évapotranspiration potentielle. Le modèle HBV consiste

en une fonction de production pour l'écoulement vertical (Fig. IV.1) où la fonte de la neige est calculée par la méthode des degrés-jours, la recharge de la nappe et l'évapotranspiration réelle sont des fonctions du stockage en eau actuel dans le réservoir sol et la formation de l'écoulement de surface se fait à travers trois réservoirs dont le premier est non-linéaire. Pour les fonctions de production neige et sol, les calculs sont réalisés pour chaque zone. Ainsi le modèle est semi-distribué alors que les paramètres de la fonction de transfert sont globaux par sous-bassin.

Le modèle HBV et ses variantes ont été appliqués dans un grand nombre de pays et d'environnements. Bergström (1992) mentionne des applications à plus de 200 bassins dans 30 pays, y compris des bassins nivaux et glaciaires des Alpes, de l'Himalaya, de Nouvelle-Zélande, du Groenland et d'Amérique du Nord, des bassins arctiques en Scandinavie et en Alaska du Nord, et des bassins à environnements de basse latitude tant humides que semi-arides comme au Panama.

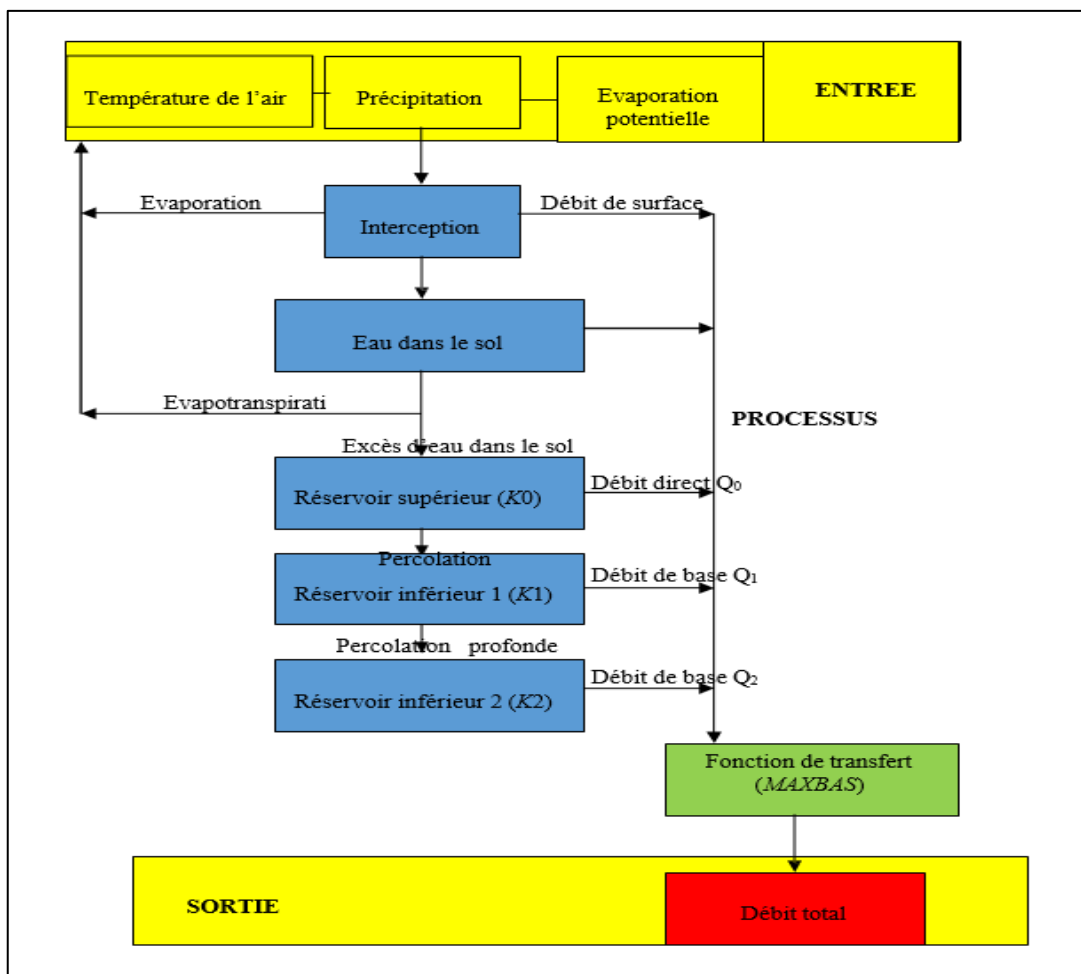


Figure IV.1. Schéma simplifié du modèle HBV (Lindström et al., 1997)

Le modèle HBV se compose de quatre principaux modules :

- ❖ Le module de la fonte des neiges et de l'accumulation des neiges ;
- ❖ Le module de la précipitation efficace, et de l'humidité du sol ;
- ❖ Module de l'évapotranspiration ;
- ❖ Module de la réponse des eaux de ruissellement.

Description des paramètres du modèle HBV

Le modèle simule le débit journalier moyen du quotidien de la pluie, la température et l'évaporation potentielle moyenne mensuelle comme entrées. Les précipitations sont simulées pour être soit de la neige ou de pluie en fonction de la température t (°C) au-dessus ou en dessous de la température critique de la fonte de neige TT [° C]. Toutes les précipitations simulées à la neige, lorsque la température est inférieure à TT , est multiplié par un facteur de correction des chutes de neige, $SFCF$ [-]. La fonte des neiges est calculée avec la méthode des degrés-jours (Equation IV. 1).

$$Eau\ de\ fonte = meltwater = CFMAX (T(t) - TT) \quad \text{en } (mm.j^{-1}) \quad \text{IV. 1}$$

L'eau de fonte de neige et les précipitations sont retenues dans le manteau neigeux jusqu'à ce qu'il dépasse une certaine fraction, CWH [-], de l'équivalent en eau de la neige. L'eau liquide dans le manteau neigeux regèle en fonction de l'équation IV. 2.

$$Fonte\ de\ la\ congélation = refreezing = CFR CFMAX (TT - T(t)) \quad \text{IV. 2}$$

Avec : $CFMAX$: Facteur du degré-jour ($mm\ ^\circ C^{-1}\ j^{-1}$) ; TT et $T(t)$ en (°C) ; C_{FR} : Coefficient de recongélation ; TT : Température critique de fonte de la neige (°C) ; $T(t)$: la température de départ (°C).

Les précipitations (P) et la fonte des neiges sont divisées par le remplissage en eau de la boîte du sol et de la recharge des eaux souterraines en fonction de la relation entre la teneur en eau dans le réservoir du sol (SM [mm]) et sa plus grande valeur (FC [mm]) (équation IV. 1).

$$\frac{recharge}{P(t)} = \left(\frac{SM(t)}{FC} \right)^{BETA} \quad \text{IV. 3}$$

Avec : FC : Humidité maximale de stockage du sol (mm) ;
 SM : Humidité du sol (mm) ;
 Recharge en eau souterraine (mm) ;

BETA : Paramètre qui détermine la contribution relative à les eaux de ruissèlement de la pluie ou la fonte des neiges (-).

NOTE : FC est un paramètre du modèle et non pas nécessairement à mesurer.

L'évaporation réelle de la boîte sol est égale à l'évaporation potentielle si SM/FC est au-dessus LP [-] tout en linéarisant, alors que la réduction est utilisée lorsque SM/FC est inférieur à LP (équation 4).

$$E_{act} = E_{pot} \cdot \min\left(\frac{SM(t)}{FC \cdot LP}, 1\right) \quad \text{IV. 4}$$

Avec : LP : Valeur d'humidité du sol au-dessus duquel E_{act} atteint E_{pot} (mm) ;

E_{pot} : Evapotranspiration (mm).

La recharge en eau souterraine est ajoutée à la zone des eaux souterraines supérieure (SUZ [mm]). $PERC$ [$mm \cdot j^{-1}$] définit la percolation maximale prise à partir de la partie supérieure de la boîte en bas des eaux souterraines (SLZ [mm]). Les eaux de ruissèlement des réservoirs des eaux souterraines sont calculées comme la somme de deux ou trois sorties d'équations linéaires selon que SUZ est supérieure à une valeur seuil, UZL [mm] (Fig. I.8). Le débit de base (groundwater GW) (avec ou sans débit de ruissèlement) est calculé par l'équation IV. 5.

$$Q_{GW}(t) = K_2 SLZ + K_1 SUZ + K_0 \max(SUZ - UZL, 0) \quad \text{IV. 5}$$

Avec : SUZ : Recharge des eaux souterraines supérieures (mm) ;

$PERC$: Percolation maximale ($mm \cdot j^{-1}$) ; j : jour.

Ce ruissèlement est enfin transformé par une fonction de pondération triangulaire définie par le paramètre $MAXBAS$ (équation IV. 6) pour donner le ruissèlement simulé $Q_{Sim}(t)$ [$mm \cdot d^{-1}$].

$$Q_{Sim}(t) = \sum_{i=1}^{MAXBAS} C_i Q_{GW}(t - i + 1) \quad \text{IV. 6}$$

$$ou C(i) = \int_{i=1}^i \left(\frac{2}{MAXBAS} - \left| u - \frac{MAXBAS}{2} \right| \frac{4}{MAXBAS^2} du \right)$$

Si on utilise les différentes zones d'altitude différentes, les précipitations et les températures changent avec l'altitude, celles-ci sont calculées en utilisant les deux paramètres $PCALT$ [% /100 m et] et $TCALT$ [° C/100 m] (Equation IV.7 et IV.8).

$$P(h) = P_o \left(1 + \frac{PCALT(h - h_o)}{10000} \right) \quad \text{IV.7}$$

$$T(h) = T_o - \frac{TCALT(h - h_o)}{100} \quad \text{IV.8}$$

Avec : P_o et T_o : Précipitations et températures mesurées (mm et °C) ;

P_{calt} : Précipitations calculées (mm) selon l'altitude $h(m)$;

T_{calt} : Températures calculées (°C) selon l'altitude $h(m)$.

La moyenne à long terme de l'évaporation potentielle, E_{pot} , pour un certain jour de l'année peut être corrigée à leur valeur au jour t , $E_{pot}(t)$, en utilisant les écarts de la température, $T(t)$, de sa moyenne à long terme T_M et C_{ET} [$^{\circ} C^{-1}$] est un facteur de correction (équation IV.9).

$$E_{pot}(t) = (1 + C_{ET}(T(t) - T_M)) \cdot E_{pot,M} \quad \text{IV.9}$$

Avec : $E_{pot}(t)$: évaporation potentiel corrigé au jour j^1 ;

C_{ET} : Facteur de correction ($^{\circ} C$) ;

$T(t)$: Température au jour t ($^{\circ} C$) ;

T_M : Température moyenne à long terme pour ce jour de l'année ($^{\circ} C$) ;

$E_{pot,M}$: Evaporation moyenne à long terme pour ce jour de l'année ($mm.j^{-1}$).

La figure IV.2. Résume l'ensemble des données des 15 paramètres optimisables du modèle HBV Light qui contribuent aux trois composantes de l'écoulement total (pur Q_1 , hypodermique Q_2 et de base Q_3).




Figure IV.2. Structure Schématique du model HBV (Seibert et Vis, 2012)

IV.2.2 Les modèles GR (génie rural)

Les modèles GR sont des modèles hydrologiques du Génie Rural, élaborés par le Cemagref. Ils ont la réputation d'être des modèles robustes et ont l'avantage de ne pas contenir beaucoup de paramètres de réglage. Ici, seules les données de pluies, de débits, d'ETP ainsi que la superficie du bassin versant sont requises.

IV.2.2.1 Modèle du Génie Rural à 1 paramètre annuel GR1A

Le modèle GR1A (modèle du Génie Rural à 1 paramètre Annuel) est un modèle pluie-débit global à un paramètre. Son développement a été initié au Cemagref à la fin des années 1990. La principale version présentée ici, est celle proposée par Mouelhi (2003) et Mouelhi et al. (2006a). Avec pour objectif de mettre au point un modèle de simulation pluie-débit robuste et fiable en vue d'utilisations pour des applications d'évaluation et de gestion de la ressource en eau.

La structure du modèle est très simple puisqu'elle se résume à une simple équation, le débit (Q_k) de l'année k étant proportionnelle à la pluie P_k de la même année, avec un coefficient d'écoulement dépendant de la pluie P_k , P_{k-1} , de l'année $k-1$ et de l'évapotranspiration potentielle annuelle moyenne E . Le modèle GR1A s'écrit sous la forme d'une simple équation :

$$Q_k = P_k \left(1 - \frac{1}{\left[1 + \left(\frac{0.7P_k + 0.3P_{k-1}}{X.E} \right)^2 \right]^{0.5}} \right) \quad \text{IV.10}$$

Où :

- ❖ Q_k est le débit simulé de l'année k ;
- ❖ P_k est la pluie observée de l'année k ;
- ❖ P_{k-1} est la pluie observée de l'année $k-1$;
- ❖ E_k est l'évapotranspiration potentielle de l'année k ;
- ❖ X est le paramètre du modèle à optimiser.

Le paramètre X traduit l'influence d'une ouverture du bassin sur l'extérieur non atmosphérique (par exemple échange avec des nappes profondes ou avec des bassins adjacents dans le cas d'une non-superposition des limites topographiques et géologiques) : si X est supérieur à 1, le système perd de l'eau et si X est plus petit que 1, le système en gagne, le tout exprimé en fraction de l'ETP.

IV.2.2.2 Modèle du Génie Rural à 2 paramètres mensuel GR2M

Le modèle GR2M (modèle du Génie Rural à 2 paramètres Mensuel) est un modèle pluie-débit global à deux paramètres. Son développement a été initié au Cemagref à la fin des années 1980, avec des objectifs d'applications dans le domaine des ressources en eau et des étiages. Ce modèle a connu plusieurs versions, proposées successivement par Kabouya (1990), Kabouya et Michel (1991), Makhlouf et Michel (1994), Mouelhi (2003) et Mouelhi et al. (2006), qui a permis d'améliorer progressivement les performances du modèle. La version présentée ici est celle de Mouelhi et al. (2006). Cette version est considérée comme la plus performante. Sa structure associe un réservoir de production et un réservoir de routage ainsi qu'une ouverture sur l'extérieur autre que le milieu atmosphérique. Ces trois fonctions permettent de simuler le comportement hydrologique du bassin.

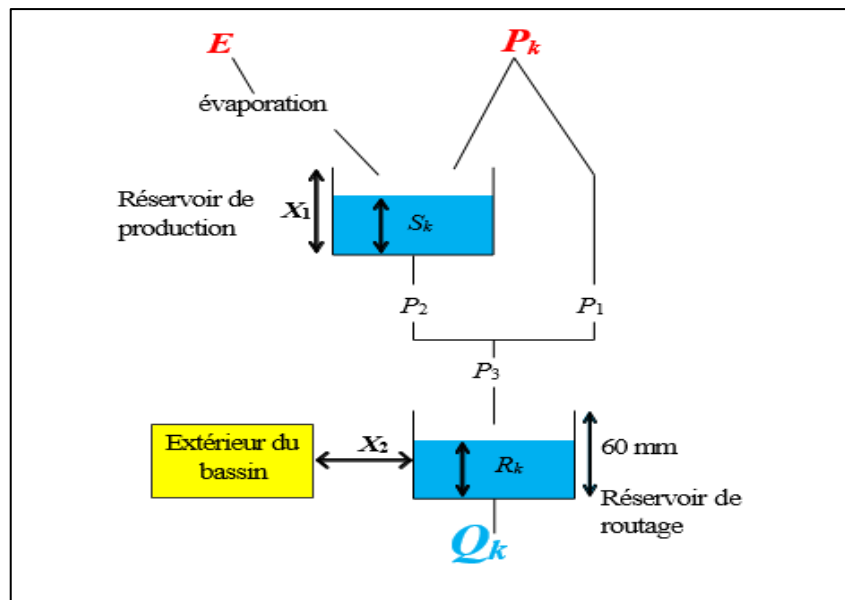


Figure IV.3. Schéma de la structure du modèle GR2M (Mouelhi, 2006)

Description mathématique

Un schéma de la structure est donné à la Figure IV.3. P_k est la pluie mensuelle du mois k et E l'évapotranspiration potentielle moyenne pour le même mois calendaire.

Les équations qui régissent le modèle sont les suivantes:

$$P_s = \frac{X_1 \cdot \left(1 - \left(\frac{S_k}{X_1}\right)^2\right) \cdot \tanh\left(\frac{P_k}{X_1}\right)}{1 + \frac{S}{X_1} \cdot \tanh\left(\frac{P_k}{X_1}\right)} \quad \text{IV.11}$$

Le paramètre X_1 , capacité du réservoir, est positif et exprimé en mm. La pluie en excès, P_1 , est donnée par :

$$P_1 = P - Ps' \quad \text{IV.12}$$

Et le contenu du réservoir est actualisé :

$$S' = S_k + PS \quad \text{IV.13}$$

Du fait de l'évapotranspiration, une quantité E_s est prélevée du réservoir :

$$E_s = \frac{S' \cdot \left(2 - \frac{S'}{X_1}\right) \cdot \tanh\left(\frac{E}{X_1}\right)}{1 + \left(1 - \frac{S'}{X_1}\right) \cdot \tanh\left(\frac{E}{X_1}\right)} \quad \text{IV.14}$$

Est l'évapotranspiration potentielle moyenne du mois calendaire considéré. Le niveau S' devient S'' :

$$S'' = S' - E_s \quad \text{IV.15}$$

- **Percolation**

Le réservoir de suivi d'humidité du sol se vidange ensuite selon une percolation P_2 :

$$P_2 = S'' \left\{ 1 - \left[1 + \left(\frac{S''}{X_1} \right)^3 \right]^{-1/3} \right\} \quad \text{IV.16}$$

Et son niveau S_{k+1} , prêt pour les calculs du mois suivant, est alors donné par :

$$S_{k+1} = S'' - P_2 \quad \text{IV.17}$$

- **Routage et échange avec l'extérieur non atmosphérique**

La quantité d'eau totale P_3 qui atteint le réservoir de routage est donnée par :

$$P_3 = P_1 + P_2 \quad \text{IV.18}$$

Le niveau R_k dans le réservoir devient alors R' :

$$R' = R_k + P_3 \quad \text{IV.19}$$

Un terme d'échange en eau souterrain F a été imposé par les données des nombreux bassins utilisés. Ignorer cette ouverture sur l'extérieur non atmosphérique conduit à une baisse considérable de l'efficacité du modèle. F est alors calculé par :

$$F = (X_2 - 1) \cdot R' \quad \text{IV.20}$$

Le paramètre X_2 est positif et adimensionnel. Le niveau dans le réservoir devient :

$$R'' = X_2 \cdot R' \quad \text{IV.21}$$

Le réservoir, de capacité fixe égale à 60 mm, se vidange pour donner le débit Q_k selon l'équation suivante :

$$Q_k = \frac{R'^2}{R'' + 60} \quad \text{IV.22}$$

Le contenu du réservoir est enfin actualisé par :

$$R_{k+1} = R'' - Q_k \quad \text{IV.23}$$

Le modèle a deux paramètres optimisables :

- ❖ X_1 : capacité du réservoir de production (mm) ;
- ❖ X_2 : coefficient d'échanges souterrains (-).

IV.2.2.3 Modèle du Génie Rural à 5 paramètres Journalier GR5J

Le modèle GR5J (Le Moine 2008) est une évolution du modèle GR4J. Ils sont donc basés sur la même structure (Figure IV.4), à savoir une association des deux réservoirs de production et de routage, de deux hydrogrammes unitaires et une fonction d'échange souterrain. Il existe des différences au niveau de la fonction d'échange. Un paramètre libre adimensionnel X_5 est ajouté à cette fonction d'échange ; ce paramètre indique le sens de l'échange avec la nappe et dépend du niveau R du réservoir de routage.

Le modèle a cinq paramètres optimisables :

- ❖ X_1 : capacité du réservoir de production (en mm) ;
- ❖ X_2 : coefficient d'échange souterrain ;
- ❖ X_3 : capacité à jour du réservoir de routage (en mm) ;
- ❖ X_4 : temps de base de l'hydrogramme unitaire (en jour) ;
- ❖ X_5 : seuil d'échange souterrain (complément de paramètre pour le GR5J).

On désigne par P (mm/jour) la hauteur de la pluie et par E (mm/jour) l'évapotranspiration potentielle (ETP). P est une estimation de la pluie de bassin et E peut être issue d'une courbe d'ETP moyenne interannuelle. Les équations suivantes correspondent aux équations intégrées sur un pas de temps. La première opération est la neutralisation de P par E pour déterminer une pluie nette P_n et une évapotranspiration nette E_n .

Description mathématique

$$\text{Si } P \geq E, Pn = P - E, En = 0 \quad \text{IV.24}$$

$$Ps = \frac{Pn \cdot \left(1 - \left(\frac{S}{330}\right)^2\right)}{1 + \frac{Pn}{330} \cdot \left(1 + \frac{S}{330}\right)} \quad \text{IV.25}$$

$$\text{Si } P < E, En = E - P, Pn = 0 \quad \text{IV.26}$$

$$Es = \frac{En \cdot \frac{S}{X1} \left(2 - \frac{S}{X1}\right)}{1 + \frac{Xn}{X1} \left(2 - \frac{S}{X1}\right)} \quad \text{IV.27}$$

$$\text{Perc} = S - \left(S^{-4} + \left(\frac{9}{4}X1\right)^{\frac{1}{4}}\right); S = S - \text{Perc} \quad \text{IV.28}$$

$$\text{Pr} = \text{Perc} + Pn - Ps \quad \text{IV.29}$$

(Pr) est divisée en deux composantes d'écoulement, 90% étant routés par un hydrogramme unitaire HU1 et un réservoir de routage et 10% par un hydrogramme unitaire symétrique HU2. HU1 et HU2 dépendent du même paramètre X4, temps de base de HU1 exprimé en jours.

Les ordonnées des hydrogrammes sont calculées à partir des courbes en S notées respectivement SH1 et SH2, qui correspondent aux fonctions cumulées de l'hydrogramme. SH1 est définie en fonction du temps par:

$$\begin{cases} 0 \leq j \leq X4, & SH1(j) = \left(\frac{j}{X4}\right)^{\frac{5}{2}} \\ j > X4, & SH1(j) = 1 \end{cases} \quad \text{IV.30}$$

$$0 \leq j \leq X4, \quad SH2(j) = \frac{1}{2} \left(\frac{j}{X4}\right)^{\frac{5}{2}} \quad \text{IV.31}$$

$$\begin{cases} X4 < j \leq 2 \cdot X4, & SH2(j) = 1 - \frac{1}{2} \left(2 - \frac{j}{X4}\right)^{\frac{5}{2}} \\ j > 2X4, & SH2(j) = 1 \end{cases}$$

Les ordonnées de HU1 et HU2 sont alors calculées par :

$$UHI(j) = SH1(j) - SH1(j-1) \quad \text{IV.32}$$

$$UH2(j) = SH2(j) - SH2(j - 1) \quad \text{IV.33}$$

Où j est un entier.

A chaque pas de temps k , les sorties $Q9$ et $Q1$ des deux hydrogrammes correspondent à la convolution des pluies antérieures par la clé de répartition donnée par l'hydrogramme discrétisé et sont calculées par : Où int désigne la partie entière.

$$Q9(k) = 0.9 \sum_{i=1}^{\text{int}(X4)+1} UH1(i) * Pr(k - i + 1) \quad \text{IV.34}$$

$$Q1(k) = 0.1 \sum_{j=1}^{\text{int}(2.X4)+1} UH2(i) * Pr(k - j + 1) \quad \text{IV.35}$$

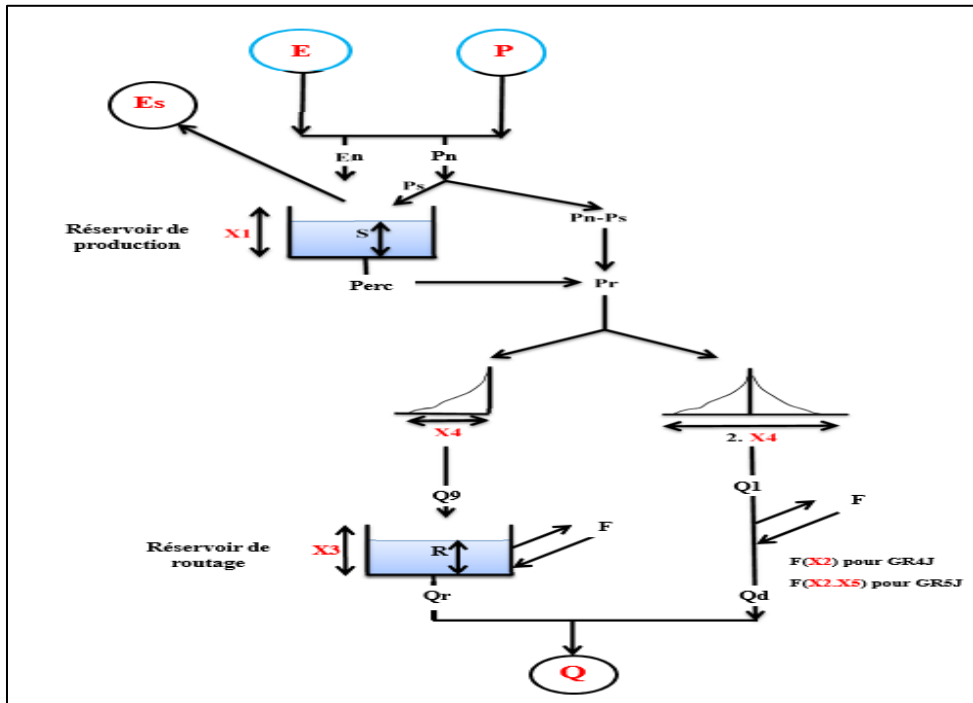


Figure IV.4. Schéma du GR5J (Moine, 2008)

$$F = X2 \left(\frac{R}{X3} - X5 \right) \quad \text{--- (pour GR5J)} \quad \text{IV.36}$$

$$Qd = \max(0, Q1(k) + F); R = \max(0, R + Q9(k) + F) \quad \text{IV.37}$$

$$Qr = R - (R^{-4} + X3^{-4})^{-\frac{1}{4}} \quad \text{IV.38}$$

$$R = R - Qr \quad \text{IV.39}$$

Le débit total Q est alors donné par :

$$Q = Qr + Q \quad \text{IV.40}$$

IV.3 Modèles basés sur l'intelligence artificielle

L'application des modèles d'intelligence artificielle (IA) en modélisation pluie-débit offre de nouvelles perspectives passionnantes pour améliorer la précision des prévisions hydrologiques. Parmi les modèles d'IA les plus couramment utilisés dans ce domaine, on trouve les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM), les arbres de décision et les méthodes d'apprentissage ensemblistes comme le Random Forest. Ces modèles d'IA peuvent être utilisés pour améliorer la modélisation pluie-débit de différentes manières. Par exemple, ils peuvent être utilisés pour capturer des relations complexes et non linéaires entre les données pluviométriques et les débits, ce qui peut être difficile à réaliser avec des modèles hydrologiques traditionnels. De plus, les modèles d'IA peuvent être plus flexibles et capables de s'adapter à une variété de conditions hydrologiques, ce qui peut améliorer la robustesse des prévisions. Dans ce qui suit nous allons présenter les modèles d'IA utilisés dans ce travail.

IV.3.1. Les réseaux de neurones artificiels

L'année 1943 est souvent considérée comme l'année initiale du développement des systèmes neuronaux artificiels. Par McCulloch et Pitts d'un modèle simplifié de neurone biologique communément appelé neurone formel (McCulloch and Pitts, 1943). Et en 1949 montré que de simples réseaux de neurones formels peuvent exécuter des fonctions logiques, symboliques et arithmétiques complexes. (Hebb, 1949). A proposé une théorie fondamentale pour l'apprentissage tandis que la proposition du réseau de neurones appelé perceptron par Rosenblatt, (1958) a permis des applications concrètes. Widrow et Off, (1960) ont proposé un nouvel algorithme d'apprentissage pour entraîner un réseau adaptatif de neurones linéaires, avec des capacités similaires à celles du perceptron. Rosenblatt (1958) et Widrow et Off (1960) Les deux auteurs sont ainsi démontré les limites des réseaux développés. Au cours de la période de 1982 à 1986, plusieurs publications fondamentales ont été publiées qui ont considérablement accru le potentiel des réseaux de neurones. Ainsi de suite, jusqu'à ce que les réseaux neuronaux se développent remarquablement et soient utilisés dans divers domaines,

dont celui de l'hydrologie. De nos jours, l'utilisation des réseaux neuronaux en hydrologie continue de croître. Les applications sont nombreuses et variées, Toutes ces études ont démontré l'efficacité de l'utilisation d'un réseau neuronal artificiel pour la modélisation hydrologique.

IV.3.1.1 Définition

Les réseaux de neurones artificiels sont des outils puissants qui peuvent apprendre à résoudre des problèmes d'une manière similaire au cerveau humain. Un neurone artificiel est un modèle informatique inspiré des neurones naturels.

Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau (Touzet, 1992).

IV.3.1.2 Principe de fonctionnement

L'information dans le réseau se propage d'une couche à l'autre. Nous distinguons trois types de couches :

- **Couche d'entrée** : les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation.

- **Couches cachées** : chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation qui est en général une fonction sigmoïde, c'est la plus adapté au modèle hydrologique. Par la suite, il envoie cette réponse aux neurones de la couche suivante

- **Couche de sortie** : elle joue le même rôle que les couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone.

Selon Dawson et Wilby (1998), un RNA est caractérisé par :

- ❖ Le nombre de couches internes du réseau.
- ❖ Le nombre de neurones dans chaque couche.
- ❖ Le paramètre de chaque connexion.
- ❖ La fonction d'activation ou de transfert

Les réseaux de neurones multicouches (MLPNN) sont une classe de réseaux de neurones artificiels caractérisée par l'organisation en plusieurs couches de neurones, comprenant une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie comme montré la figure IV.5 . Chaque neurone dans une couche est connecté à tous les neurones de la couche suivante, avec des poids associés à chaque connexion. Les MLPNN sont capables d'apprendre des modèles complexes à partir de données en ajustant les poids de leurs connexions à l'aide d'algorithmes d'apprentissage, tels que la rétropropagation du gradient. Ils sont largement utilisés dans divers domaines, y compris la modélisation pluie-débit, en raison de leur capacité à capturer des relations non linéaires entre les variables.

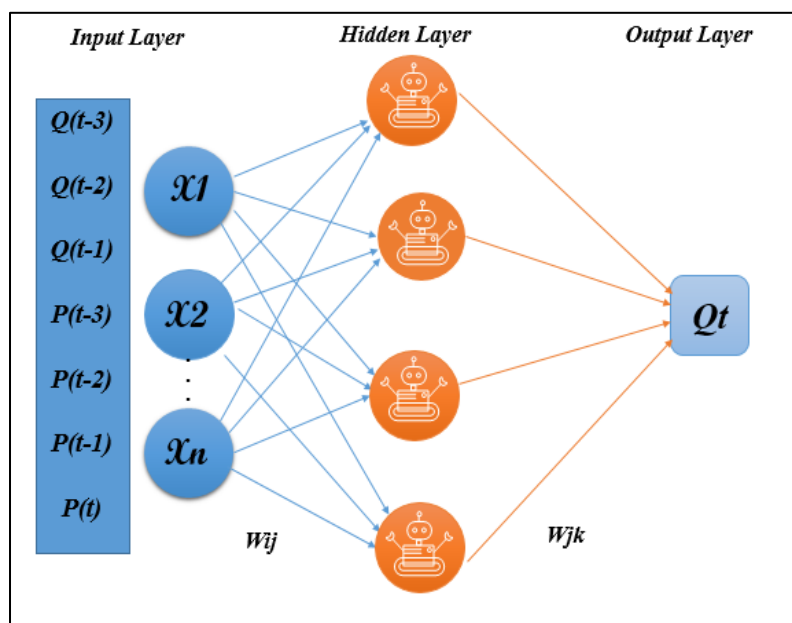


Figure IV.5. Architecture du modèle réseaux de neurone multicouche

IV.3.2 Les forêts aléatoires

IV.3.2.1 Définition

La régression par forêt aléatoire est un algorithme d'apprentissage supervisé et une technique de mise en sac qui utilise une méthode d'apprentissage d'ensemble pour la régression dans l'apprentissage automatique. Les arbres des forêts aléatoires fonctionnent en parallèle, ce qui signifie qu'il n'y a pas d'interaction entre ces arbres lors de leur construction.

Dans le cas de la régression, une forêt aléatoire est un régresseur constitué d'un certain nombre d'arbres de régression. La valeur prédite sera la moyenne de celles données par chacun des arbres pour les forêts à arbres de décision et la classe de la plus probable pour les forêts à arbres de classification. Cette méthode utilise le « bagging » et la sélection aléatoire

de descripteurs qui permet d'obtenir une plus grande variété d'arbres de régression construits à partir d'échantillons d'entraînement obtenus par bootstrapping (Breiman, 2001).

La méthode de la forêt aléatoire a également un champ d'application très large. Cette intègre plus d'un arbre de décision en utilisant l'apprentissage d'ensemble. En gros, il s'agit d'entrer un simple, d'obtenir un résultat de chaque arbre de décision et d'intégrer tous les résultats de chacun des arbres de décision. On obtient ensuite le résultat final. Et parce que le simple est traité plusieurs fois par chaque arbre de décision, le résultat sera d'une excellente précision. t parce qu'il ne nécessite pas de suppression de variables, il sera capable de traiter des ensembles de données à haute dimension et sera très efficace.

IV.3.2.2 Principe de fonctionnement

Selon la Figure IV.6, pour un ensemble de données d'apprentissage comportant (L) observations composées d'une variable dépendante, c'est-à-dire la variable réponse (Y), et d'un ensemble de variables indépendantes, c'est-à-dire les prédicteurs (x), une fonction d'approximation utilisant le modèle RFR devrait être obtenue comme suit.

Tout d'abord, le RFR génère un échantillonnage uniforme (n), c'est-à-dire de l'échantillon (1) à l'échantillon (n) à l'aide de la méthode bootstrap, c'est-à-dire la procédure d'"agrégation bootstrap. Deuxièmement, pour chaque échantillon, faites pousser un arbre, et troisièmement, faire la moyenne des réponses de tous les arbres construits arbres construits. Il est important de noter que le RFR devrait développer son propre mécanisme interne pour calculer l'erreur de prédiction désignée comme l'erreur "hors sac" "OOB", égale à l'écart-type (ET) entre les valeurs calculées et mesurées. Elle est utilisée pour classer les prédicteurs et les sélectionner (Rosecrans et al. 2022).

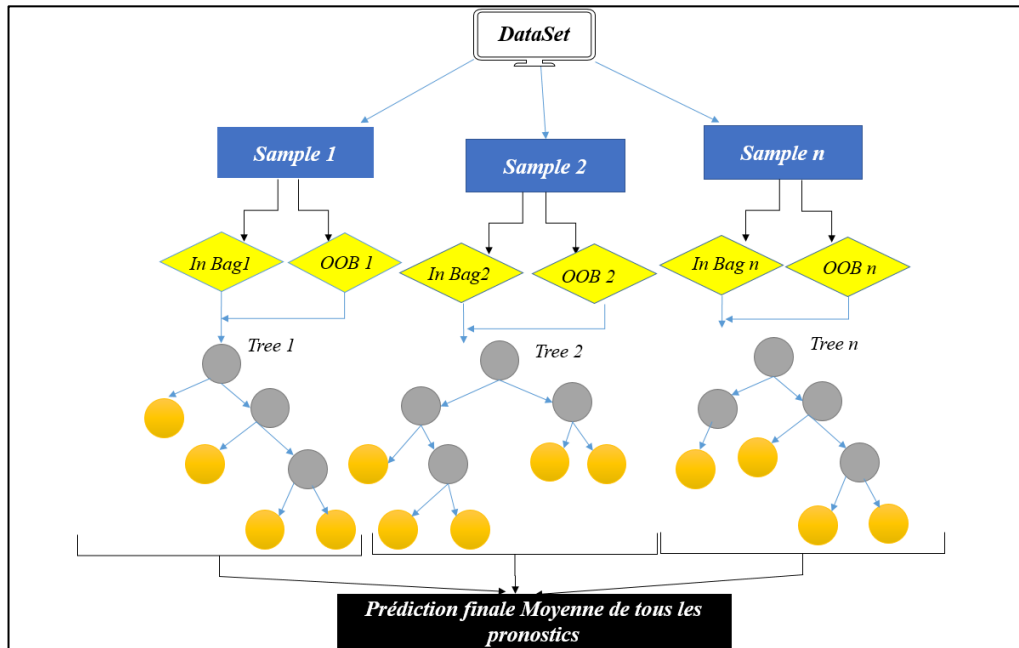


Figure IV.6. Architecture du modèle de régression de la forêt aléatoire (RFR)

IV.3.3 Apprentissage automatique extrême (ELM)

IV.3.3.1 Définition

Le modèle d'apprentissage automatique extrême (extreme learning machine ou ELM) est un type particulier de réseau de neurones artificiels composé d'une seule couche cachée. Plutôt qu'être optimisés, les poids et les biais des liens entre les nœuds de la couche d'entrée et ceux de la couche cachée sont assignés de manière aléatoire. La machine d'apprentissage extrême (ELM) a été introduite par Liang et al. (2006). Sa popularité est due à sa vitesse d'apprentissage rapide et de sa grande capacité à traiter de vastes ensembles de données. Cela résulte de la génération aléatoire des poids et des biais des entrées cachées (c'est-à-dire qu'ils forment l'entrée des couches cachées) et du calcul analytique de la matrice des poids de sortie.

IV.3.3.2 Principe de fonctionnement

L'ELM a été présenté pour la première fois en 2006 comme un nouvel algorithme corrigeant plusieurs faiblesses auparavant observées dans les réseaux de neurones artificiels comme les capacités de généralisation et d'extrapolation. Ses capacités ont d'abord été mises à l'essai sur un cas artificiel pour produire une approximation de la fonction sin C.

Pour tout ensemble de données d'apprentissage, N pour lequel x est la variable d'entrée et y correspond à la variable de sortie :

$$D = \{(x_i, y_i) \mid x_i \in \mathbb{R}^d, y_i \in \mathbb{R}\}$$

La sortie du modèle ELM avec Z neurones cachés peut être calculée comme suit :

$$Y_j = f(X_j) \sum_{i=1}^z \beta_i \cdot g(W_i \cdot b_i \cdot X_j) \quad j = 1, 2, 3 \dots Z \quad \text{IV.38}$$

Où $g(.)$ est la fonction d'activation sigmoïdale, w_{ij} est le poids entre la couche d'entrée et la couche cachée, b_i est le biais du $i^{\text{ème}}$ nœud caché, et β_i est le poids de sortie (c.-à-d. de la couche cachée à la couche de sortie) (Figure IV.7). L'équation précédente peut être reformulée comme suit :

$$H\beta = T$$

$$H = \begin{pmatrix} h & \ddots & (x1) \\ \vdots & \ddots & \vdots \\ h & \ddots & (xn) \end{pmatrix} = \begin{bmatrix} g(w1, b1, x1) & \cdots & g(wz, bz, x1) \\ \vdots & \ddots & \vdots \\ g(w1, b1, xn) & \cdots & g(wz, bz, xn) \end{bmatrix} \quad \text{IV.39}$$

H est la matrice de sortie, c'est-à-dire l'activation des neurones de la couche cachée. β est le poids de sortie reliant les neurones cachés au neurone de sortie, et T est la matrice cible de l'algorithme ELM.

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_z^T \end{bmatrix} \quad \beta = \begin{bmatrix} t_1^T \\ \vdots \\ t_z^T \end{bmatrix} \quad \text{IV.40}$$

$$\beta = H^+ \cdot T \quad \text{IV.41}$$

H^+ correspond à l'inverse généralisé de Moore-Penrose de la matrice H.




Figure IV.7 Organigramme de l'architecture du modèle ELM

IV.3.4 Modèle de M5tree régression

IV.3.4 Définition

Le modèle est basé sur une approche de division et de conquête pour développer une relation entre les variables indépendantes et dépendantes. Contrairement à l'arbre de décision qui est utilisé pour les données catégorielles, il peut être utilisé pour les données qualitatives (catégorielles) et quantitatives. Ce modèle est analogue aux fonctions linéaires par morceaux avec la combinaison des concepts de régression linéaire et d'arbre de régression concepts. Pour l'approche par arbre de régression, l'ensemble données est divisé en sous-ensembles (également appelés feuilles, nœuds enfants ou sous arbres) et leurs relations au niveau des sous-ensembles (ou des feuilles) sont représentées par des valeurs numériques moyennes. (Singh et al. 2010) Comme le montre la figure IV.8.

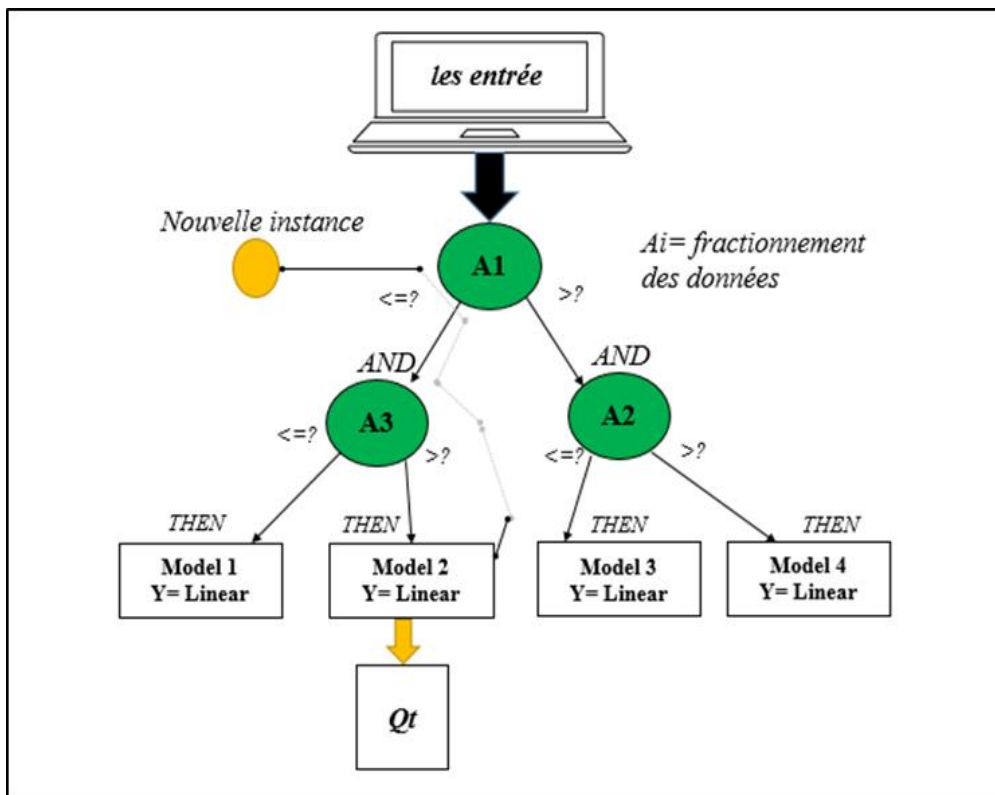


Figure IV.8. Organigramme de l'architecture du modèle M5tree

IV.3.4.2 Principe de fonctionnement

La construction d'un arbre de modèle M5 (M5Tree) comprend deux étapes :

- 1) La création d'un arbre de décision à l'aide d'un critère de division et,
- 2) La conception de l'arbre modèle par l'élagage de l'arbre en surnombre.

Le découpage dans l'approche M5Tree applique l'idée d'un arbre de décision, mais au lieu des étiquettes de classe, il est composé de régressions linéaires. Il est composé de fonctions de régression linéaire aux feuilles, qui peuvent estimer des attributs numériques continus.

Considérons un ensemble de M exemples d'apprentissage avec des paramètres indépendants comme entrée et une cible associée comme valeur de sortie. Les paramètres peuvent être soit associés à une feuille, soit divisés en sous-ensembles à l'aide d'un critère de division, soit en sous-ensembles à l'aide d'un critère de découpage. Dans le critère M5Tree, l'écart-type (sd) des valeurs de classe qui atteignent un nœud (en tant que mesure de l'erreur à ce nœud) est attribué comme critère de division. Par conséquent, la réduction de l'écart-type (SDR) est utilisée pour calculer la réduction attendue de l'écart-type.

$$SDR = sd(M) - \sum \frac{|M_i|}{|M|} sd(M_i) \quad \text{IV.42}$$

Où M représente les exemples de formation qui atteignent le nœud et M_i représente le sous-ensemble d'exemples avec le $i^{\text{ème}}$ résultat de l'ensemble potentiel.

IV.4 Les modèles de l'intelligence artificielle hybrides

Les modèles d'intelligence artificielle hybrides combinent différentes techniques ou approches pour résoudre des problèmes complexes. Ces approches hybrides peuvent mélanger des méthodes symboliques (basées sur des règles et des connaissances explicites), avec des méthodes d'apprentissage automatique ou des réseaux de neurones. L'idée fondamentale derrière les modèles hybrides est de fusionner plusieurs paradigmes d'intelligence artificielle afin de créer des systèmes plus performants et polyvalents. L'hybridation des modèles d'intelligence artificielle peut prendre différentes formes, selon la manière dont les différentes approches sont combinées pour créer des modèles hybrides. Ces méthodes basées sur l'hybridation avec des algorithmes d'optimisation et/ou l'hybridation avec la décomposition de signal. Dans notre travail, nous avons utilisé les deux méthodes.

IV.4.1 Les transformations en ondelettes

Les transformées en ondelettes sont devenues un outil puissant pour la modélisation hydrologique en raison de leur capacité à représenter et à analyser les signaux temporels de manière multi-scale. Elles sont utilisées dans plusieurs domaines de l'hydrologie pour comprendre et modéliser les processus hydrologiques.

Les séries temporelles hydrologiques sont souvent complexes et présentent des variations à différentes échelles de temps. Les transformées en ondelettes permettent de décomposer ces séries temporelles en différentes composantes fréquentielles, offrant ainsi une représentation multi-scale des données. Cette approche permet d'identifier les tendances, les variations saisonnières, les événements extrêmes et les changements à différentes échelles de temps.

IV.4.1.1 Maximum overlap discrete wavelet transform (MODWT)

Maximum overlap discrete wavelet transform MODWT est une méthode de décomposition de signal basée sur la transformée en ondelettes. Contrairement à la transformée en ondelettes discrète (DWT) classique, qui utilise des filtres à réponse finie, la MODWT utilise des filtres à réponse infinie pour une meilleure représentation des bords et une réduction des effets de bord.

La MODWT fonctionne en divisant un signal en différentes résolutions, en commençant par les basses fréquences et en se déplaçant progressivement vers les hautes fréquences. Chaque niveau de décomposition produit des coefficients d'ondelettes qui représentent les différentes composantes du signal dans cette résolution spécifique (Percival et Walden, 2000).

IV.4.1.1 Variational Mode Decomposition (VMD)

VMD est une méthode de décomposition de signal avancée qui vise à séparer un signal en différentes composantes, appelées "modes", qui représentent différentes échelles de temps et de fréquences. Contrairement à d'autres méthodes de décomposition telles que la transformée en ondelettes ou la transformée de Fourier, la VMD est adaptative et peut s'ajuster aux caractéristiques locales du signal. Cette méthode a été introduite par Dragomiretskiy et Zosso, (2014).

Le processus de décomposition en VMD consiste à estimer les différents modes de manière itérative en optimisant une fonction objective qui mesure à la fois la séparation des modes et la fidélité au signal d'origine. Cette méthode permet de séparer efficacement les différentes composantes d'un signal complexe, ce qui la rend particulièrement utile dans des domaines tels que le traitement du signal, l'imagerie médicale, la géophysique et l'hydrologie.

IV.4.2 Les algorithmes d'Optimisation

L'hybridation des modèles a considérablement amélioré l'efficacité des modèles d'intelligence artificielle, trouvant des applications dans divers domaines, y compris

l'hydrologie et la prévision du débit des cours d'eau. Actuellement, l'hybridation de ces modèles avec des algorithmes méta-heuristiques inspirés de la nature, tels que l'optimisation par essaims de particules (PSO), l'optimiseur Grey Wolf (GWO), et l'algorithme génétique (GA), suscite un intérêt croissant. Cette approche est de plus en plus utilisée pour la prévision des débits horaires, journaliers et mensuels, comme le montrent les études (Wang et al., 2013 ; Mehr, 2018 ; Ghorbani et al., 2018 ; Tikhamarine et al., 2020a ; Mohammadi et al., 2020).

L'amélioration des réseaux neuronaux artificiels pour la régression résulte de l'intégration d'algorithmes d'optimisation, affinant les performances de ces modèles dans la prédiction de valeurs continues. Il s'agit d'ajuster de manière itérative les poids et les biais du réseau afin de minimiser les erreurs de prédiction. Ces algorithmes identifient efficacement les paramètres optimaux, améliorant la capacité du modèle à représenter avec précision et souplesse des relations complexes dans les tâches de régression.

IV.4.2.1 Particle Swarm Optimization (PSO)-Grey Wolf Optimizer (GWO)

L'algorithme hybride récemment proposé d'optimisation Şenel et al., (2019) par essaim de particules - l'optimiseur de loup gris (PSO-GWO) combine la convergence rapide de PSO avec la plus grande capacité d'exploration de GWO pour optimiser les problèmes complexes. Cette métaheuristique hybride peut être utilisée pour rechercher les valeurs optimales des poids et des biais d'un réseau de neurones artificiels (ANN). L'algorithme initialise une population de particules représentant des valeurs de poids/biais candidates. L'erreur de l'ANN est évaluée pour chaque particule et sert de mesure de sa performance. Les particules mettent à jour itérativement leurs positions en fonction des équations de mise à jour de la vitesse de PSO et de GWO pour explorer l'espace des poids/biais. Périodiquement, certaines particules sont remplacées par de nouvelles issues de GWO pour améliorer l'exploration. Ce cycle se répète jusqu'à ce que le nombre maximum d'itérations ou le seuil d'erreur de l'ANN soit atteint. Les positions finales des particules représentent les poids/biais d'ANN optimisés trouvés par l'algorithme hybride PSO-GWO. Cette approche hybride équilibre la recherche locale de PSO avec la recherche globale de GWO, surmontant la faiblesse de PSO à rester bloqué dans les optima locaux. La méthode peut permettre un entraînement efficace des modèles ANN en trouvant des valeurs quasi-optimales pour la recherche des paramètres de poids/biais, qui sont notoirement difficiles.

IV.4.2.2 l'algorithme d'optimisation Mayfly

L'entraînement des réseaux de neurones artificiels implique l'optimisation de paramètres de poids et de biais en haute dimension pour minimiser l'erreur du réseau. Cependant, les techniques d'entraînement traditionnelles comme la rétropropagation ont souvent tendance à être piégées dans des optima locaux et échouent à trouver des solutions globales. Récemment, Zervoudakis et Tsafarakis, (2020) ont proposé l'algorithme d'optimisation Mayfly, une nouvelle approche bio-inspirée puissante pour l'optimisation. Cette méthode imite les comportements d'accouplement et d'essaim des éphémères pour atteindre un équilibre efficace entre exploration et exploitation dans la recherche d'espaces complexes. Les mécanismes fondamentaux de la coopération des mâles, de l'accouplement des femelles et des mutations de danse nuptiale peuvent être adaptés pour rechercher efficacement les espaces de poids et de biais des réseaux neuronaux. Une population de solutions vecteurs de poids/biais candidates représentant des mâles et des femelles éphémères serait initialisée. L'erreur d'entraînement du réseau sert de fonction de fitness pour l'optimisation. À chaque génération, l'essaim masculin vole vers de bonnes solutions en se basant sur les meilleures positions personnelles et globales, exploitant les zones prometteuses. Pendant ce temps, le processus d'accouplement des femelles génère des solutions améliorées via le croisement des valeurs parentales de poids/biais, explorant de nouvelles zones. Des mutations occasionnelles de la danse nuptiale améliorent l'exploration pour éviter les optima locaux. Au fil des itérations, la population en constante évolution guidée par ces opérateurs bio-inspirés peut converger vers des paramètres de réseau quasi optimaux.

IV.4.2.3 The Artificial Rabbits Optimization (ARO)

ARO est une méthode utilisée pour entraîner Wang et al., (2023) un Réseau de Neurones Artificiels (ANN). Il débute par l'initialisation d'une population de solutions où chaque solution représente un ensemble potentiel de valeurs de poids et de biais pour l'ANN. La qualité de chaque solution est évaluée en fonction de l'erreur de la sortie de l'ANN par rapport à la sortie désirée. À chaque itération, l'algorithme ARO sélectionne une solution et génère une nouvelle solution candidate en ajoutant une perturbation aléatoire. Si la nouvelle solution candidate a une meilleure qualité, elle remplace la solution originale dans la population. Ce processus se poursuit jusqu'à ce qu'un critère d'arrêt soit atteint, tel que l'atteinte d'un nombre maximal d'itérations ou l'obtention d'un niveau d'erreur acceptable. Le jeu final de solutions dans la population représente les poids et les biais optimisés pour l'ANN. La capacité de l'algorithme ARO à équilibrer l'exploration (recherche de nouvelles

zones) et l'exploitation (raffinement des zones prometteuses) en fait un outil efficace pour l'entraînement des ANNs. Il peut rechercher efficacement l'espace de paramètres de poids/biais, hautement dimensionnel et non linéaire, et trouver des solutions quasi-optimales qui minimisent l'erreur de l'ANN.

IV.5 Critères d'évaluation de la qualité de modèles

Évaluer la qualité d'un modèle est crucial pour comprendre ses performances et sa capacité à résoudre un problème donné. Les critères de performance (numériques ou graphiques), sont un outil utile pour estimer les résultats obtenus et analyser l'efficacité et l'efficacité des modèles utilisés. Voici les critères numériques utilisés pour évaluer la qualité des modèles d'IA dans ce travail :

- Coefficient de corrélation (R)

Le coefficient de corrélation décrit la proportion de la variance totale dans les données observées qui peut être expliquée par le modèle. Il varie de 0 à 1, les valeurs les plus élevées indiquant une meilleure corrélation, et est donné sous la forme ;

$$R = \frac{\sum_{i=1}^N (Q_{O,i} - \bar{Q}_O)(Q_{P,i} - \bar{Q}_P)}{\sqrt{\sum_{i=1}^N (Q_{O,i} - \bar{Q}_O)^2 \sum_{i=1}^N (Q_{P,i} - \bar{Q}_P)^2}} \quad (-1 < R < 1) \quad \text{IV.43}$$

- Critère de Nash-Sutcliffe (NSE)

On définit le coefficient d'efficacité qui va de moins l'infini à 1 avec des valeurs plus élevées indiquant un meilleur accord comme ;

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (Q_{O,i} - Q_{P,i})^2}{\sum_{i=1}^N (Q_{O,i} - \bar{Q}_O)^2} \right] \quad (-\infty < NSE < 1) \quad \text{IV.44}$$

- La racine de l'erreur quadratique moyenne (RMSE)

Est un des deux indicateurs de performance principaux pour un modèle prédictif de régression. Elle mesure l'écart moyen entre les valeurs prédites par votre modèle prédictif et les valeurs réelles. Elle estime dans quelle mesure le modèle prédictif est capable de prévoir la valeur cible (précision).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{P,i} - Q_{O,i})^2} \quad (0 < RMSE < \infty) \quad \text{IV.45}$$

- L'erreur moyenne absolue (MAE)

Ces métriques sont utilisées pour évaluer les modèles de régression. MSE mesure la moyenne des carrés des différences entre les prédictions et les vraies valeurs, tandis que MAE mesure la moyenne des différences absolues.

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |Q_{O,i} - Q_{P,i}| \quad (0 < \text{MAE} < \infty) \quad \text{IV.46}$$

IV.6 Logiciels utilisés

Dans notre étude, pour les modèles conceptuels, nous avons utilisé les deux packages airGR pour les modèle GR et HYDROMAD pour le modèle HBV. Ces deux packages, sont utilisés dans le programme R.

AirGR est un package qui intègre dans le logiciel R les outils de modélisation hydrologique utilisés et développés au sein du Groupe de Recherche en Hydrologie des Bassins Versants de l'INRAE (France), dont les modèles pluie-débit GR. Sept modèles hydrologiques et un modèle de fonte et d'accumulation de neige sont mis en œuvre dans airGR (GR4H, GR4J, GR5J, GR6J, GR2M, GR1A...etc.). HYDROMAD est un paquetage R (statistique R), il fournit un cadre de modélisation pour l'hydrologie environnementale : comptabilité du bilan hydrique et routage des flux dans des bassins versants agrégés dans l'espace. Il permet la simulation, l'estimation, l'évaluation et la visualisation de la réponse du débit aux séries temporelles de précipitations et d'autres facteurs.

Quant aux modèles d'intelligence artificielle, pour leur application, nous avons utilisé le MATLAB, qui est un langage de programmation de quatrième génération et un environnement d'analyse numérique. MATLAB permet de faire du calcul matriciel, de développer et d'exécuter des algorithmes, de créer des interfaces utilisateur (IU) et de visualiser des données. L'environnement informatique numérique multiparadigme permet aux développeurs d'interagir avec des programmes développés dans différents langages et d'exploiter les atouts uniques de chacun de ces derniers à différentes fins. Une description sommaire de l'outil est donnée par la Figure IV.9.

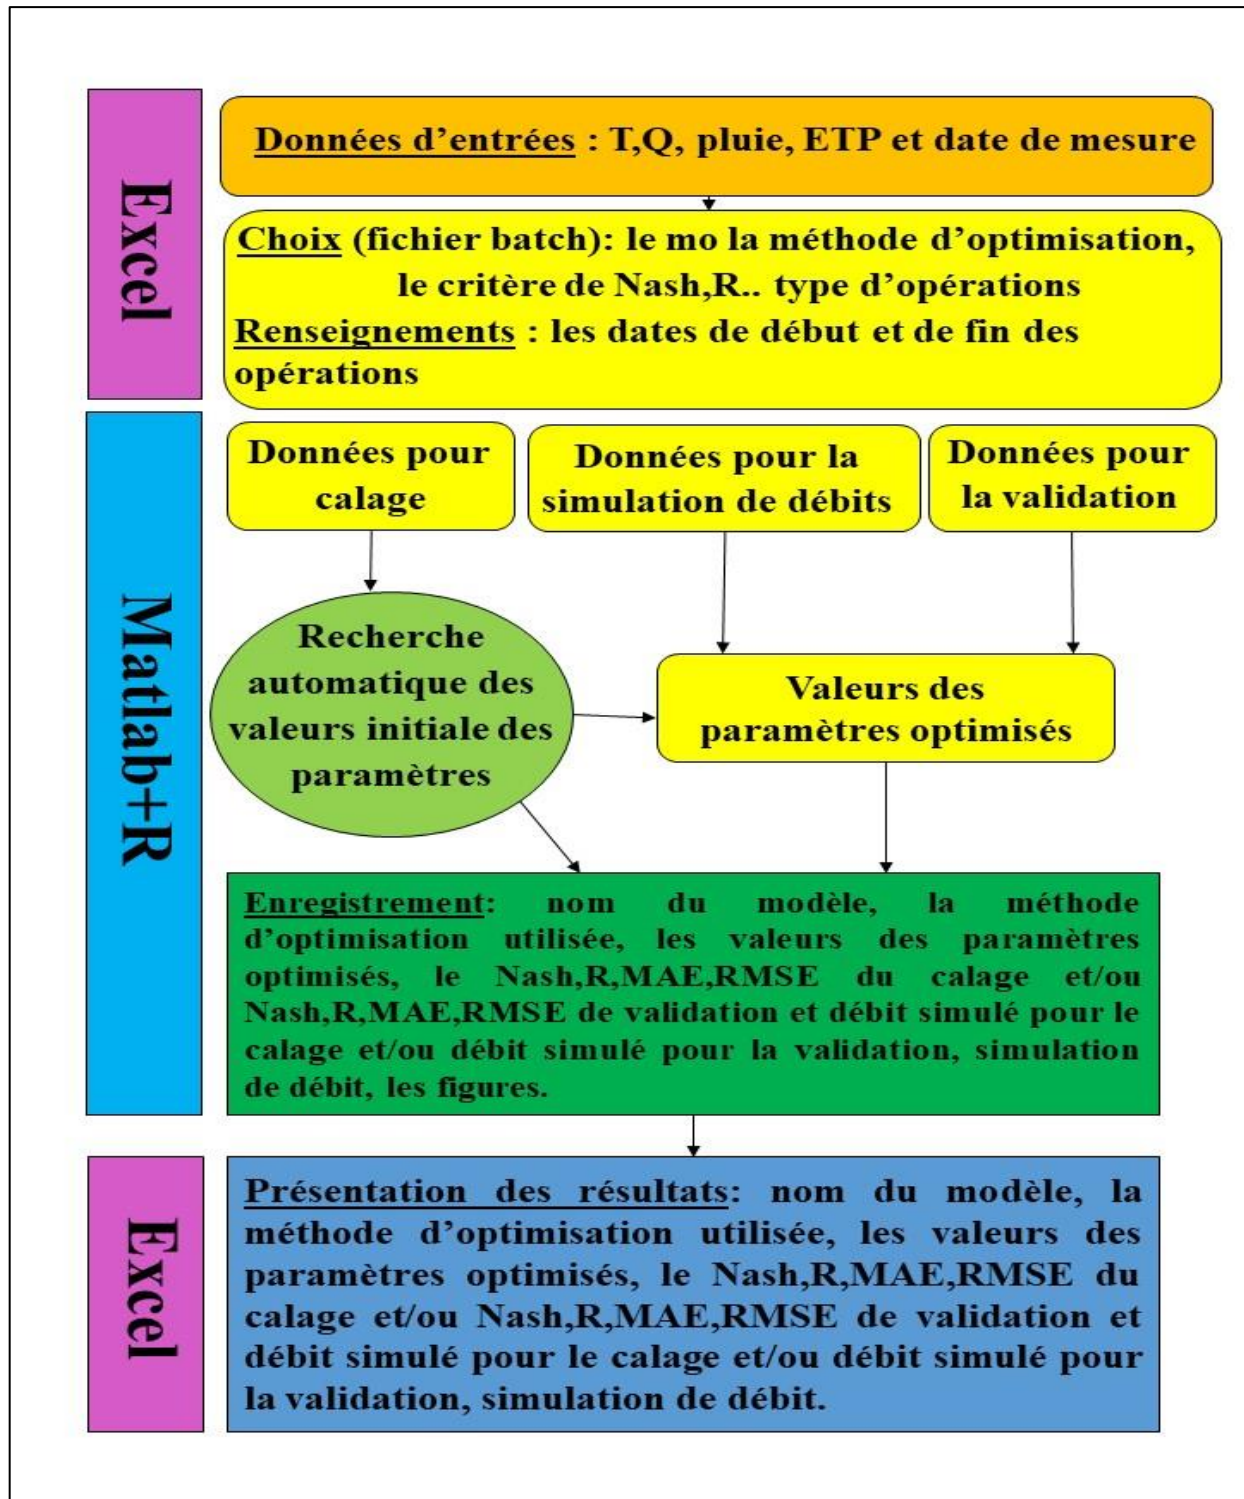


Figure IV.9. Schéma descriptif de l'outil utilisé pour les tests

IV.7 Conclusion

Ce chapitre est consacré à la présentation des différents modèles d'intelligence artificielle et conceptuels appliqués dans cette recherche, pour la modélisation des débits journaliers, mensuel et annuel, ainsi que les critères utilisés pour juger la performance de ces modèles.

L'utilisation de logiciels tels que MATLAB et R, nous permis de faciliter la tâche de la modélisation de la relation pluie-débit, ainsi d'avoir des résultats précis et efficace constituant un outil précieux pour la gestion des ressources en eau.

CHAPITRE V
RÉSULTATS ET
DISCUSSIONS

CHAPITRE V : RÉSULTATS ET DISCUSSIONS

V.1 Introduction

Le présent chapitre constitue le cœur de notre exploration dans le domaine de la modélisation pluie-débit, offrant un aperçu détaillé des résultats obtenus au cours de cette étude.

Notre objectif principal était de comprendre les relations complexes entre les précipitations et les débits dans un contexte hydrologique spécifique. Après avoir exposé l'architecture des trois approches de modélisation adoptées dans le chapitre IV, à savoir ; les modèles conceptuels, les modèles basés sur l'intelligence artificielle et les modèles hybrides d'intelligence artificielle.

Ce chapitre expose tous les résultats obtenus dans ce travail, ces derniers sont divisés en trois parties fondamentales, chacune est consacrée à une approche de modélisation parmi celles citées en haut. Ainsi qu'une comparaison entre les performances des modèles étudiés de chaque approche séparément dans les régions d'étude par le biais de la procédure de calibrage-validation est donnée. Finalement, nous procédons à la sélection du modèle optimal en utilisant les critères statistiques et graphiques.

V.2 Les modèles conceptuels

Dans ce travail, la modélisation pluie-débit se fait au pas de temps journalier, mensuel et annuel. Pour le modèle HBV, les variables d'entrée comprennent la température, l'évapotranspiration et les précipitations. En revanche, pour les modèles GR, seules les précipitations et l'évapotranspiration sont utilisées comme variables d'entrée, et ce, conformément aux fondements des modèles utilisés.

Les paramètres des modèles ont été déterminés automatiquement par optimisation à l'aide de deux packages : « airGR » pour les modèles GR et « hydromad » pour le modèle HBV. Cette optimisation des paramètres vise à obtenir automatiquement les meilleures performances possibles du modèle en ajustant les paramètres pour minimiser la différence entre les débits simulés et ceux observés.

Le tableau V.1 présente les deux périodes de calibrage pour les modèles conceptuels.

Tableau V.1. Durées de calibrage et validation

Nom station	Code station	Période de calibrage	Période de validation
WADI LILI	012501	1992-1999	1997-2002
FREHA	021601	1992-1999	1999-2003
RN 25	021909	1983-1990	1990-1993
AIN EL ASSEL	031601	1992-1999	1999-2002
BOUCHEGOUF	140505	1995-1992	1992-1995
AIN BERDA	140602	1987-1994	1994-1997
FERMATOU	150601	1997-2004	2004-2007
BOU BIREK	150703	2000-2007	2007-2012

V.2.1 Pas de temps journalier

Les modèles conceptuels GR5J et HBV, appliqués au pas de temps journalier, ont été utilisés pour modéliser les données des huit stations utilisées dans cette étude. Les meilleurs paramètres pour les deux modèles sont donnés dans les tableaux V.2 et 3.

Tableau V.2. Paramètres de calibration du modèle GR5J

Nom station	Code station	X1	X2	X3	X4	X5
WADI LILI	012501	125.321	0.012	17.432	1.132	0.531
FREHA	021601	200.201	0.062	33.210	1.021	0.910
RN 25	021909	712.893	-0.092	37.003	1.176	0.999
AIN EL ASSEL	031601	159.174	0.746	13.066	1.847	0.442
BOUCHEGOUF	140505	202.020	0.717	8.325	1.278	0.454
AIN BERDA	140602	154.604	0.499	7.477	0.997	0.745
FERMATOU	150601	157.120	0.629	11.477	1.321	0.231
BOU BIREK	150703	3372.00	-1.183	12.822	1.354	0.393

Tableau V.3. Paramètres de calibration du modèle HBV

Nom station	Code station	perc	uzl	k0	k1	k2	maxbas	tt	cfmax	sfcf	cfr	cwh	fc	ip	beta
WADI LILI	012501	2.312	23.213	0.289	0.288	0.071	2.194	1.341	4.118	0.429	0.021	0.143	300.321	1.000	2.939
FREHA	021601	0.225	3.015	0.500	0.293	0.064	2.654	0.170	3.182	0.661	0.084	0.135	193.380	1.000	2.947
RN 25	021909	2.859	75.758	0.309	0.237	0.042	2.251	-2.146	4.818	0.509	0.010	0.152	500.000	0.609	2.013
AIN EL ASSEL	031601	0.605	1.717	0.279	0.300	0.070	3.352	1.141	7.182	0.455	0.069	0.139	202.008	1.000	5.769
BOUCHEGOUF	140505	1.058	66.667	0.159	0.238	0.043	2.294	1.934	2.408	0.718	0.037	0.153	198.828	1.000	2.797
AIN BERDA	140602	0.804	9.489	0.500	0.300	0.058	2.119	-0.429	4.273	0.582	0.074	0.065	171.554	0.999	5.264
FERMATOU	150601	0.215	13.907	0.103	0.098	0.006	2.090	1.897	3.995	1.000	0.078	0.093	334.157	1.000	3.439
BOU BIREK	150703	2.473	74.748	0.200	0.134	0.001	2.637	0.427	4.157	0.400	0.007	0.087	500.000	0.300	3.782

Les résultats des critères de performance R, NSE, RMSE et MAE calculés pour les phases de calibrage et de validation des modèles GR5J et HBV, pour les 08 huit étudiées, sont présentés dans le tableau V.4.

Tableau V.4. Valeurs des critères d'évaluation des modèles conceptuels au pas de temps journalier

Station	Code	Calage				Validation			
		R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
<i>Résultats obtenus avec le modèle GR5j</i>									
WADI LILI	012501	0.82	0.67	1.01	0.51	0.80	0.65	0.22	0.18
FREHA	021601	0.80	0.60	2.05	0.44	0.83	0.69	0.99	0.16
RN 25	021909	0.85	0.72	0.44	0.12	0.88	0.75	0.31	0.10
AIN EL ASSEL	031601	0.84	0.70	1.08	0.27	0.81	0.60	2.24	0.46
BOUCHEGOUF	140505	0.83	0.67	0.53	0.11	0.84	0.67	0.54	0.14
AIN BERDA	140602	0.80	0.60	2.05	0.44	0.83	0.69	0.99	0.16
FERMATOU	150601	0.81	0.60	0.96	0.18	0.80	0.67	0.63	0.12
BOU BIREK	150703	0.90	0.81	0.09	0.03	0.83	0.65	0.12	0.03
<i>Résultats obtenus avec le modèle HBV</i>									
WADI LILI	012501	0.83	0.67	1.41	0.41	0.81	0.66	0.42	0.18
FREHA	021601	0.85	0.73	1.08	0.18	0.88	0.77	1.21	0.16
RN 25	021909	0.85	0.66	0.45	0.12	0.86	0.74	0.31	0.09
AIN EL ASSEL	031601	0.85	0.71	0.96	0.18	0.82	0.60	0.76	0.16
BOUCHEGOUF	140505	0.84	0.66	0.37	0.07	0.80	0.62	0.60	0.12
AIN BERDA	140602	0.82	0.68	0.67	0.09	0.85	0.72	0.69	0.10
FERMATOU	150601	0.85	0.70	0.86	0.28	0.81	0.67	0.60	0.11
BOU BIREK	150703	0.80	0.60	0.96	0.44	0.78	0.59	1.01	0.50

D'après le tableau V.4, on peut conclure que les résultats obtenus pour simuler les débits au pas de temps journalier des stations étudiées, présentent une performance acceptable. Pour le modèle GR5J, les valeurs de R se situent entre 0.80 et 0.88, tandis que les valeurs de NSE se situent entre 0.60 et 0.75. Les valeurs de RMSE et MAE varient respectivement entre 0.12 et 2.24, et entre 0.03 et 0.46. Pour le modèle HBV, les résultats sont également acceptables, avec des valeurs de R entre 0.78 et 0.88, des valeurs de NSE entre 0.59 et 0.77, et des valeurs de RMSE et MAE entre 0.31 et 1.21, et entre 0.09 et 0.40 respectivement. La station RN 25 présente les meilleures performances pour le modèle GR5J par rapport aux autres stations lors de la phase validation, avec des valeurs de corrélation plus élevées (R=88%) et un NSE de 75%. De même, les stations de Freha et Bou Chegouf affichent des critères acceptables par rapport aux autres stations, avec des valeurs de corrélation de 83% et 84% et des valeurs de NSE de 69% chacune.

Pour les résultats du modèle HBV, la station d'Ain Freha présente les meilleurs critères parmi les autres stations lors de la phase validation, avec des valeurs de corrélation plus élevées ($R=88\%$) et un NSE de 77%. De même, les stations de RN25 et Ain Berda affichent des critères acceptables par rapport aux autres stations, avec des valeurs de corrélation de 86% et 85% et des valeurs de NSE de 75% et 74% respectivement. Le modèle HBV se révèle préférable au modèle GR5J pour la modélisation des débits dans les cours d'eau pour plusieurs raisons. Tout d'abord, les résultats obtenus montrent que le modèle HBV offre généralement de meilleures performances en termes de corrélation et de NSE par rapport au modèle GR5J, comme le montrent les valeurs plus élevées de R et de NSE pour plusieurs stations. Par exemple, la station d'Ain Freha présente des valeurs de R et de NSE plus élevées avec le modèle HBV par rapport au modèle GR5J.

Les résultats sont également appuyés par des analyses graphiques. La figure V.1 illustre une comparaison entre les débits calculés et observés pour les meilleures stations étudiées, pour la phase de validation, et pour les mêmes périodes de simulation. Les droites et les coefficients de corrélation entre les débits observés et calculés par les modèles GR5j et HBV sont présentés dans ces figures pour confirmer visuellement la performance des modèles.

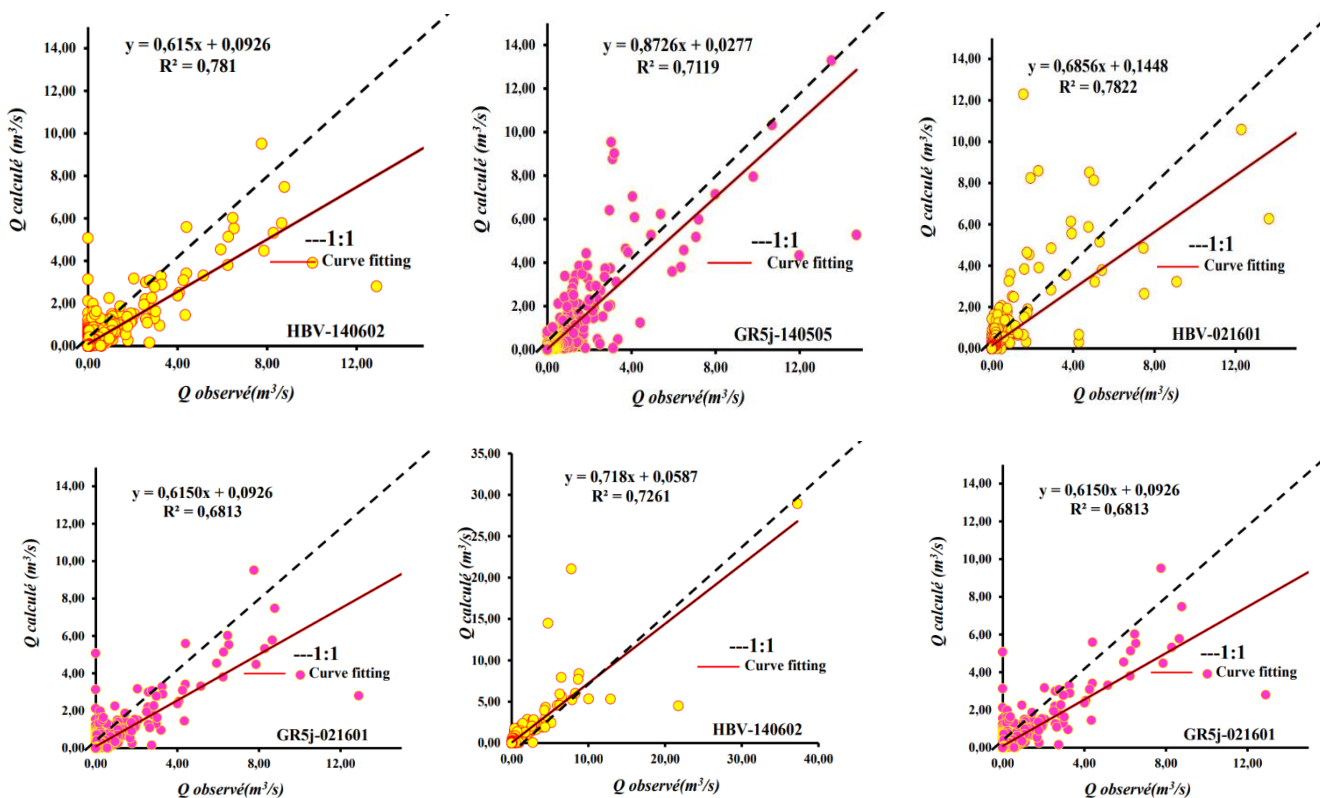


Figure.V.1. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles dans la phase validation

V.2.2 Pas de temps mensuel et annuel

Du même que pour le pas de temps journalier, le calibrage du modèle GR2M au pas de temps mensuel consiste à introduire les données et à vérifier l'ajustement du modèle en analysant les résultats numériques et graphiques. Pour évaluer la précision des résultats, nous avons utilisé les quatre critères d'ajustement utilisés auparavant : R, NSE, MAE et RMSE. Nous avons ajusté les valeurs des paramètres X1 et X2 du modèle dans des plages limitées, entre [140 et 2254] mm pour X1 et [0.414 à 3.762] mm pour X2, jusqu'à ce que les valeurs des coefficients de détermination et du critère de Nash soient optimales (valeur égale ou supérieure à 70%). Les résultats du calage et validation sont présentés dans le tableau V.5.

Tableau V.5. Résultats obtenus par le modèle GR2M

Nom de station	Code station	Calage						Validation			
		X1	X2	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
WADI LILI	012501	171.48	1.21	0.90	0.71	1.23	0.63	0.81	0.64	2.11	0.43
FREHA	021601	181.27	1.09	0.90	0.81	3.13	0.32	0.80	0.54	4.81	0.53
RN 25	021909	347.234	0.712	0.95	0.91	1.42	0.16	0.88	0.77	1.27	0.16
AIN EL ASSEL	031601	228.1	1.1	0.90	0.73	3.35	0.37	0.90	0.70	0.03	0.61
BOUCHEGOUF	140505	186.793	1.050	0.94	0.86	0.93	0.10	0.86	0.68	1.25	0.18
AIN BERDA	140602	160.774	0.625	0.90	0.65	1.36	0.13	0.85	0.64	1.91	0.18
FERMATOU	150601	140.953	3.762	0.95	0.77	21.42	3.20	0.96	0.78	0.83	0.77
BOU BIREK	150703	2245.025	0.414	0.95	0.89	0.13	0.01	0.93	0.77	0.19	0.02

Les résultats du modèle GR2M pour les huit stations montrent des performances acceptables. Pour les stations FERMATOU, BOU BIREK et AIN EL ASSEL le modèle présente de bonnes performances avec des coefficients de corrélation R supérieurs à 0.90 et des valeurs de NSE supérieurs à 0.70, avec des valeurs proches de 0 pour RMSE et MAE, indiquant ainsi une bonne concordance entre les débits simulés et observés pour la phase de validation.

En revanche, le reste des stations ont eu des résultats moyens à acceptables, avec des R autour de 0.80 et des valeurs de NSE autour de 0.60, avec des valeurs supérieures à 1 pour RMSE et MAE. Cela s'explique par une corrélation modérée entre les débits simulés et observés, indiquant que le modèle a plus de difficultés à reproduire les débits pour ces stations.

Le modèle GR2M se distingue par ses performances remarquables dans la simulation des débits mensuels pour les huit stations étudiées. Les résultats obtenus révèlent une

excellente adéquation entre les débits simulés et observés. Ces résultats témoignent de la capacité du modèle GR2M à reproduire fidèlement les débits mensuels, confirmant ainsi son utilité et sa fiabilité dans le domaine de la modélisation hydrologique.




Figure.V.2. Nuage de points entre les débits mensuel mesurés et calculés pour les meilleurs modèles dans la phase de validation

Le modèle GR1A a été utilisé pour simuler les débits annuels pour les huit stations hydrologiques étudiées situées dans le Nord algérien. Les résultats obtenus avec le modèle GR1A au pas de temps annuel sont présentés dans le tableau ci-dessous.

Tableau V.6. Résultats obtenus par le modèle GR1A

Nom station	Code station	Calage					Validation				
		X1	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	
WADI LILI	012501	0.872	0.79	0.48	3.96	0.21	0.70	0.35	3.19	0.21	
FREHA	021601	0.782	0.79	0.49	3.06	0.11	0.71	0.15	2.69	0.11	
RN 25	021909	2.499	0.71	0.41	3.02	0.99	0.74	0.40	7.99	0.63	
AIN EL ASSEL	031601	0,8213	0.56	0.50	8.90	0.35	0.47	0.42	2.98	1.50	
BOUCHEGOUF	140505	0.7590	0.95	0.81	3.36	0.13	0.56	0.49	9.83	0.50	
AIN BERDA	140602	0.181	0.62	0.45	12.43	0.48	0.40	0.49	44.15	2.23	
FERMATOU	150601	0.298	0.56	0.50	8.90	0.35	0.47	0.22	22.98	1.50	
BOU BIREK	150703	0.718	0.43	0.48	9.07	0.34	0.36	0.19	28.46	1.92	

Les résultats montrent un écart important entre les débits simulés et les débits observés, pour toutes les stations, avec un RMSE élevé de 44 mm, un MAE de 2 mm et un coefficient de corrélation R entre 0.36 et 0.71 et de NSE entre 0.15 et 0.49, indiquent que le modèle ne parvient pas à capturer les variations et les tendances du débit réel. Les résultats suggèrent que les paramètres du modèle ne sont pas bien ajustés pour cette région, ce qui peut être dû à des caractéristiques hydrologiques spécifiques non prises en compte ou à des données d'entrée de mauvaise qualité et les tailles courtes pour les séries annuels.

Les modèles conceptuels ont produit des résultats satisfaisants lorsqu'ils ont été utilisés pour des pas de temps mensuels et journaliers. Leur performance a été évaluée comme étant peu efficace dans certains cas, mais jamais considérée comme faible. Pour les données mensuelles, les modèles ont démontré une capacité adéquate à représenter les processus hydrologiques, avec des résultats cohérents et proches des observations. Cependant, pour les pas de temps journaliers, la performance a été plus variable, montrant parfois des écarts plus importants par rapport aux données observées. Ces résultats soulignent l'importance de considérer le pas de temps approprié en fonction de la résolution des données et des objectifs de modélisation.

V.3 Les modèles à base d'intelligence artificielle

La prévision du débit journalier, mensuel et annuel a été réalisée en utilisant quatre modèles appelés MLPNN, ELM, M5Tree et ELM. La raison de la sélection de ces modèles est qu'ils sont les plus récemment utilisés dans ce domaine dans le monde, et ils sont rarement utilisés en Algérie. Le débit à l'instant (t) sera prédit en utilisant plusieurs retards de Q et P , et afin de déterminer le meilleur décalage de temps approprié, l'ACF, le PACF et le XCF seront utilisés. Nous appelons ces variables d'entrée $Q(t-3)$, $Q(t-2)$, $Q(t-1)$, $P(t-3)$, $P(t-2)$, $P(t-1)$, $P(t)$, la structure des modèles sélectionnés est présentée dans le tableau.III.3 ci-dessus. Le cadre de modélisation proposé est illustré à la figure.V.3.

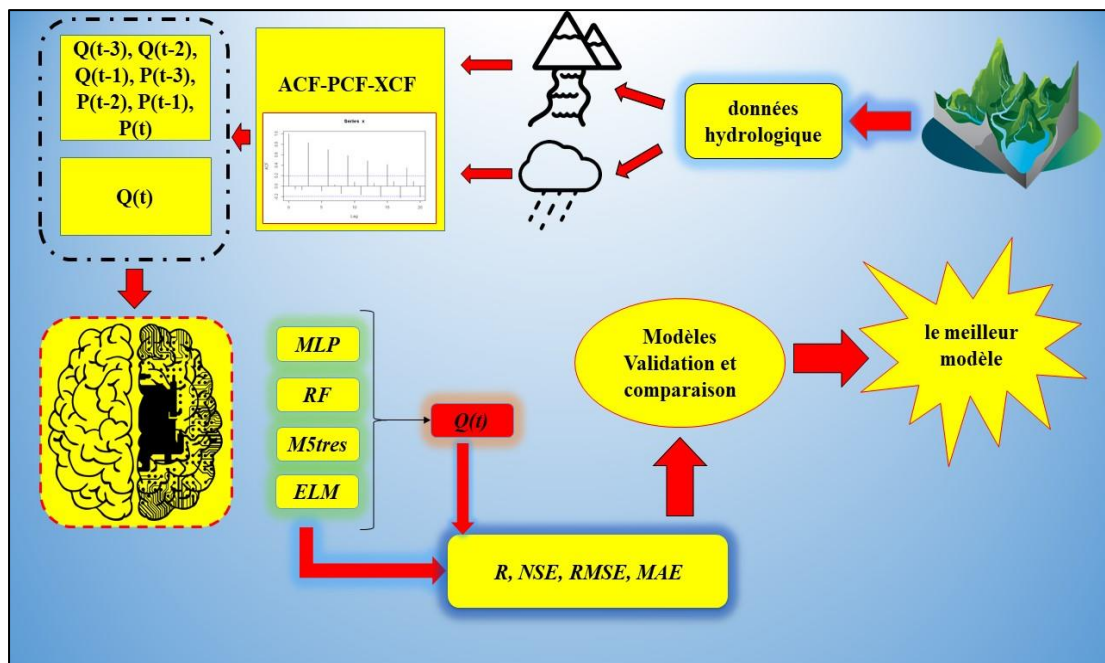


Figure.V.3. Organigramme du cadre de modélisation pluie-débit

V.3.1 Pas de temps journalier

Les résultats obtenus par les modèles de l'intelligence artificielle pour les stations RN25 et AIN ASSEL sont présentés dans les tableaux ci-dessous, le reste des résultats sont reportés dans l'annexe 1.

Tableau.V.7. Performances des différents modèles autonomes pour la station RN25 au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.934	0.873	1.043	0.233	0.889	0.790	0.982	0.235
MLPNN2	0.672	0.451	2.695	1.282	0.583	0.340	2.295	1.281
MLPNN3	0.896	0.803	1.613	0.402	0.788	0.620	1.738	0.426
MLPNN4	0.606	0.367	2.893	1.341	0.573	0.330	2.316	1.27
MLPNN5	0.833	0.694	2.012	0.435	0.732	0.541	1.926	0.406
MLPNN6	0.337	0.114	3.424	1.541	0.234	0.052	2.756	1.456
RFR1	0.939	0.869	1.059	0.164	0.860	0.710	1.150	0.243
RFR2	0.770	0.561	2.409	1.150	0.478	0.212	2.507	1.384
RFR3	0.897	0.795	1.645	0.335	0.719	0.516	1.966	0.512
RFR4	0.726	0.484	2.614	1.228	0.495	0.245	2.454	1.324
RFR5	0.869	0.742	1.846	0.397	0.683	0.465	2.066	0.561
RFR6	0.456	0.198	3.257	1.474	0.150	0.056	2.903	1.473
M5Tree1	0.958	0.911	0.838	0.166	0.844	0.607	1.145	0.191
M5Tree2	0.705	0.498	2.578	1.218	0.407	0.025	2.789	1.451
M5Tree3	0.901	0.812	1.575	0.335	0.684	0.464	2.069	0.440
M5Tree4	0.740	0.548	2.445	1.213	0.333	0.177	3.064	1.421
M5Tree5	0.860	0.740	1.855	0.415	0.681	0.463	2.070	0.435
M5Tree6	0.330	0.109	3.433	1.532	0.203	0.321	2.890	1.479
ELM1	0.922	0.850	1.134	0.301	0.806	0.647	1.267	0.275
ELM2	0.477	0.227	3.197	1.416	0.517	0.262	2.427	1.267
ELM3	0.757	0.573	2.376	0.701	0.692	0.449	2.097	0.609
ELM4	0.524	0.275	3.097	1.393	0.519	0.269	2.415	1.301
ELM5	0.793	0.628	2.218	0.489	0.711	0.497	2.004	0.406
ELM6	0.317	0.101	3.449	1.551	0.225	0.048	2.756	1.466

Tableau.V.8. Performances des différents modèles autonomes pour la station AIN ASSEL au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.954	0.911	4.647	1.212	0.900	0.776	13.493	2.762
MLPNN2	0.703	0.494	13.775	5.007	0.739	0.539	25.648	8.243
MLPNN3	0.836	0.699	10.629	3.037	0.828	0.686	21.181	5.499
MLPNN4	0.701	0.491	13.813	5.043	0.720	0.512	26.407	8.781
MLPNN5	0.810	0.656	11.365	2.967	0.815	0.665	21.873	5.567
MLPNN6	0.263	0.069	18.685	7.141	0.257	0.074	36.375	15.717
RFR1	0.961	0.911	4.640	0.896	0.870	0.753	14.165	2.403
RFR2	0.851	0.703	10.546	3.961	0.628	0.390	29.518	8.487
RFR3	0.909	0.814	8.360	2.044	0.793	0.632	22.934	5.498
RFR4	0.813	0.634	11.712	4.411	0.645	0.389	29.540	8.606
RFR5	0.885	0.764	9.414	2.456	0.761	0.579	24.523	5.950
RFR6	0.385	0.145	17.901	6.862	0.201	0.035	37.120	11.569
M5Tree1	0.940	0.867	5.332	1.038	0.870	0.724	15.327	2.682
M5Tree2	0.824	0.679	10.975	4.014	0.488	0.199	33.820	10.137
M5Tree3	0.882	0.777	9.137	2.164	0.720	0.504	26.620	7.002
M5Tree4	0.807	0.652	11.427	4.137	0.514	0.257	32.570	9.802
M5Tree5	0.899	0.808	8.493	2.009	0.676	0.434	28.431	7.680
M5Tree6	0.258	0.067	18.707	7.184	0.265	0.081	36.220	13.567
ELM1	0.935	0.875	5.513	1.521	0.861	0.711	15.318	3.046
ELM2	0.815	0.665	11.210	4.494	0.544	0.053	36.770	10.841
ELM3	0.863	0.745	9.776	2.733	0.618	0.184	34.136	8.009
ELM4	0.786	0.617	11.982	4.508	0.488	0.066	36.517	10.587
ELM5	0.851	0.725	10.157	2.650	0.534	-0.97	53.027	9.951
ELM6	0.253	0.064	18.736	7.197	0.035	0.07	53501.796	1735.144

D'après les tableaux V.7 et V.8 les quatre modèles utilisés dans les huit stations susmentionnées ont donné des résultats différents, allant d'une précision prédictive très faible à bonne et acceptable. Les résultats numériques pour MLPNN, ELM, M5Tree et RFR montrent que le modèle avec huit variables d'entrée, c'est-à-dire le scénario (S1) : $P(t)$, $P(t-1)$, $P(t-2)$, $P(t-3)$, $Q(t-1)$, $Q(t-2)$ et $Q(t-3)$, présente la meilleure performance des quatre modèles utilisés dans les huit stations. Les résultats montrent que le modèle MLPNN se distingue par sa plus grande précision par rapport aux autres, tandis que l'ELM se révèle être le moins précis.

À la station RN25, le modèle MLPNN1 a obtenu les valeurs les plus élevées pour R (0.889) et NSE (0.79), ainsi que les valeurs les plus faibles pour RMSE et MAE, soit environ 0.982 m³/s et 0.235 m³/s respectivement. Pour la station d'AIN EL ASSEL, le modèle MLPNN1 a présenté des performances remarquables avec des valeurs de R autour de 0.9, de NSE environ 0.78 m³/s, de RMSE d'environ 13.49 m³/s et de MAE d'environ 2.762.

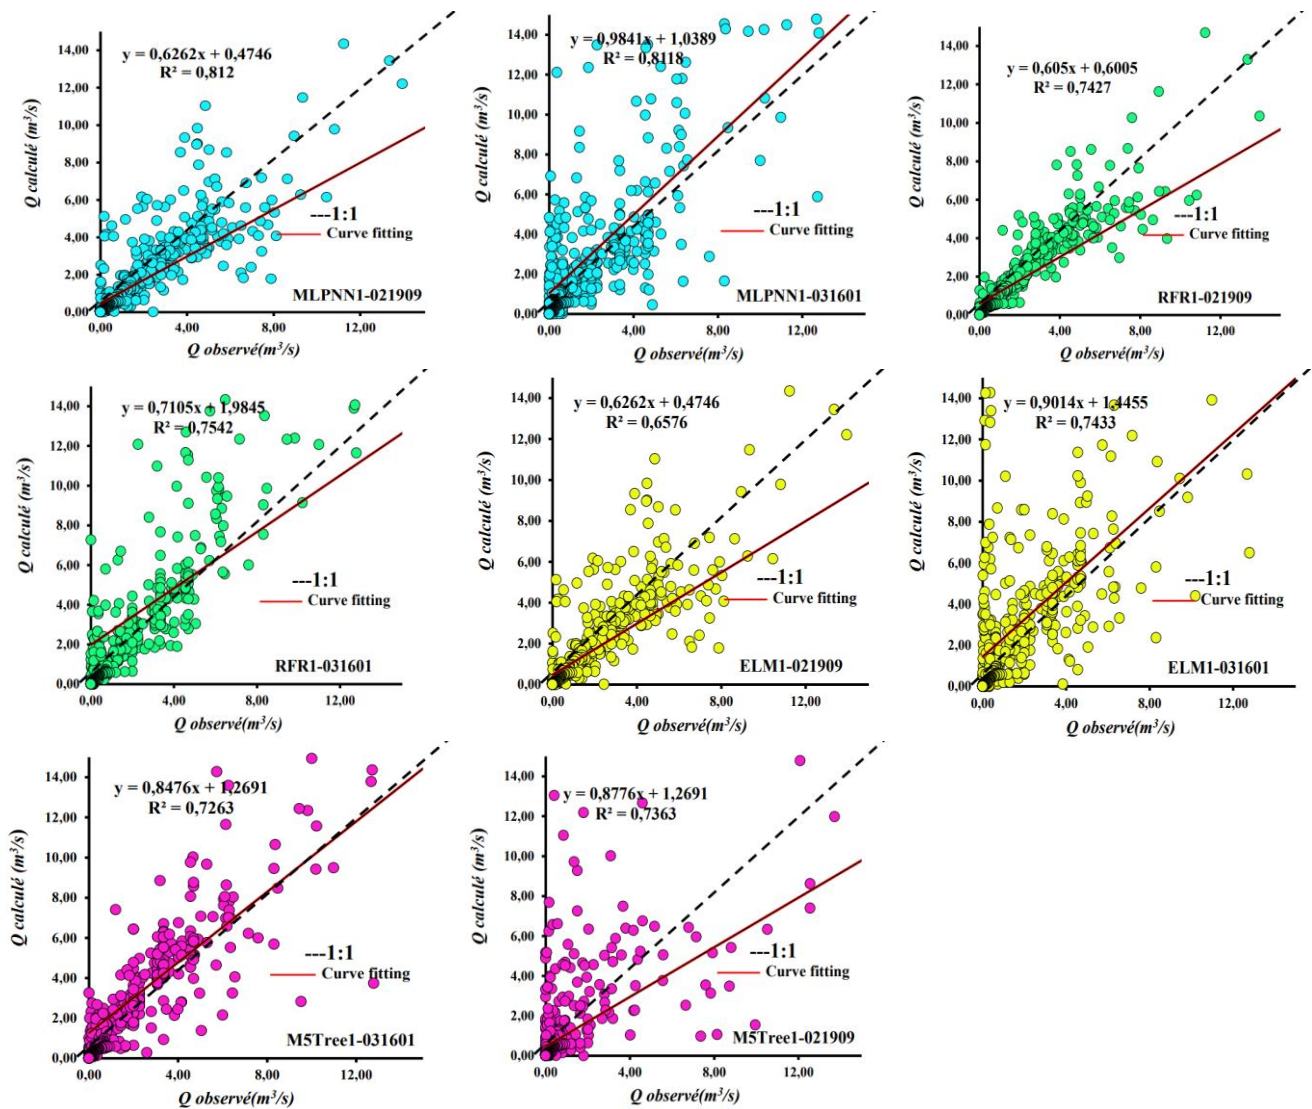


Figure.V.4. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles de l'intelligence artificielle dans la phase validation

Les autres modèles (RFR, M5Tree et ELM) ont fourni les meilleures prédictions pour le premier scénario (S1) avec les RMSE les plus faibles (1.15 m³/s, 1.15 m³/s, 1.27 m³/s), les MAE les plus faibles (0.243 m³/s, 0.191 m³/s, 0.275 m³/s), et les coefficients de corrélation (R) les plus élevés (0.86, 0.844, 0.806), ainsi que des valeurs élevées de l'efficacité du modèle (NSE) (0.71, 0.61, 0.65) respectivement pour RN25. La station AIN ASSEL présente les performances suivantes ; pour RFR1 (0.87, 0.75, 14.16 m³/s, 2.403 m³/s),

M5Tree1 (0.87, 0.71, 15.33 m³/s, 2,682 m³/s) et ELM1 (0.861, 0.71, 15.32 m³/s, 3.046 m³/s) respectivement.

Selon les résultats obtenus, jusqu'à présent, par les modèles autonomes présentés dans les tableaux, nous constatons que le modèle MLPNN, pour les deux phases (apprentissage et validation) et pour toutes les stations étudiées, présente les meilleures performances parmi tous les modèles utilisés pour la modélisation des débits journaliers. Cela ne signifie pas que les autres modèles ont donné de mauvais résultats mais, en général, ces derniers étaient acceptables à satisfaisants.

V.3.2 Pas de temps mensuel

Les modèles MLPNN, RFR, ELM et M5Tree ont été appliqués aux données mensuelles. Les résultats obtenus pour ces modèles sont présentés dans les tableaux V.9 et V.10, tandis que les résultats pour les autres stations sont présentés dans l'annexe.

Tableau.V.9. Performances des différents modèles autonomes pour la station RN25 au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
MLPNN1	0.982	0.959	0.049	0.003	0.948	0.866	0.092	0.011
MLPNN2	0.915	0.967	0.045	0.002	0.913	0.527	0.173	0.016
MLPNN3	0.992	0.977	0.037	0.002	0.894	0.714	0.135	0.012
MLPNN4	0.850	0.323	0.201	0.009	0.853	0.561	0.315	0.027
MLPNN5	0.984	0.990	0.024	0.001	0.830	0.607	0.158	0.012
MLPNN6	0.854	0.588	0.157	0.008	0.580	0.239	0.220	0.023
RFR1	0.882	0.765	0.119	0.004	0.815	0.637	0.152	0.015
RFR2	0.863	0.726	0.128	0.005	0.787	0.588	0.162	0.017
RFR3	0.878	0.810	0.107	0.005	0.761	0.556	0.168	0.016
RFR4	0.765	0.540	0.166	0.006	0.722	0.606	0.158	0.016
RFR5	0.767	0.581	0.158	0.008	0.582	0.519	0.175	0.016
RFR6	0.765	0.695	0.135	0.008	0.480	0.057	0.245	0.024
M5Tree1	0.977	0.926	0.067	0.003	0.824	0.708	0.136	0.012
M5Tree2	0.967	0.915	0.071	0.003	0.791	0.613	0.157	0.012
M5Tree3	0.929	0.841	0.098	0.005	0.810	0.617	0.156	0.012
M5Tree4	0.674	0.569	0.161	0.007	0.516	0.318	0.208	0.020
M5Tree5	0.578	0.352	0.197	0.010	0.568	0.529	0.173	0.016
M5Tree6	0.687	0.526	0.168	0.011	0.510	0.063	0.244	0.024
ELM1	0.970	0.960	0.049	0.003	0.797	0.732	0.130	0.014
ELM2	0.963	0.944	0.058	0.004	0.823	0.743	0.128	0.014
ELM3	0.988	0.967	0.044	0.003	0.677	0.543	0.170	0.016
ELM4	0.983	0.992	0.022	0.001	0.447	2.244	1.215	0.066

ELM5	0.909	0.762	0.119	0.008	0.084	1.584	8.896	0.384
ELM6	0.918	0.831	0.101	0.006	0.153	1.953	0.433	0.038

Tableau.V.10. Performances des différents modèles autonomes pour la station AIN ASSEL au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.999	0.999	0.026	0.002	0.943	0.800	1.685	0.511
MLPNN2	0.932	0.869	0.656	0.057	0.838	11.870	13.722	1.346
MLPNN3	0.997	0.995	0.133	0.012	0.921	2.057	6.688	0.736
MLPNN4	0.992	0.983	0.233	0.024	0.840	0.632	2.322	0.275
MLPNN5	0.910	0.828	0.750	0.071	0.905	0.667	2.207	0.213
MLPNN6	0.746	0.556	1.205	0.120	0.807	0.079	3.972	0.402
RFR1	0.914	0.800	0.810	0.077	0.744	0.562	2.532	0.262
RFR2	0.905	0.793	0.824	0.077	0.743	0.561	2.534	0.281
RFR3	0.892	0.762	0.883	0.086	0.755	0.566	2.520	0.232
RFR4	0.849	0.674	1.033	0.104	0.544	0.284	3.237	0.326
RFR5	0.769	0.534	1.235	0.136	0.642	0.386	2.998	0.318
RFR6	0.781	0.608	1.133	0.117	0.684	0.380	3.011	0.318
M5Tree1	0.900	0.811	0.787	0.068	0.746	0.511	2.675	0.292
M5Tree2	0.836	0.698	0.994	0.088	0.725	0.522	2.644	0.269
M5Tree3	0.913	0.833	0.739	0.064	0.449	0.507	4.696	0.448
M5Tree4	0.841	0.707	0.979	0.088	0.473	0.184	3.455	0.352
M5Tree5	0.730	0.534	1.236	0.118	0.699	0.481	2.756	0.221
M5Tree6	0.770	0.593	1.154	0.123	0.684	0.355	3.072	0.328
ELM1	0.982	0.964	0.343	0.039	0.806	9.751	12.542	1.384
ELM2	0.909	0.826	0.755	0.076	0.839	5.497	9.749	1.212
ELM3	0.953	0.908	0.550	0.064	0.686	11.215	13.368	1.414
ELM4	0.925	0.855	0.688	0.074	0.179	1.263	4303.123	359.52
ELM5	0.813	0.661	1.053	0.115	0.029	-11.219	13.370	0.949
ELM6	0.770	0.593	1.154	0.114	0.322	2.500	4.450	1.734

Parmi les quatre modèles étudiés, le MLPNN a donné les valeurs les plus faibles du RMSE et MAE et les plus élevées de R et NSE, tant pour l'ensemble d'apprentissage que pour la validation. Cela montre que le MLPNN est capable de capturer efficacement les variations mensuelles du débit. Ainsi que, le scénario 1 présente la meilleure performance des quatre modèles utilisés dans les huit stations.

Pour la station RN25, le modèle MLPNN1 a donné les valeurs les plus élevées pour R et NSE, soit environ 0.094 pour R et 0.866 pour NSE, ainsi que les valeurs les plus faibles pour RMSE et MAE, soit environ 0.09 m3/s et 0.011 m3/s respectivement. Pour la station d'AIN EL ASSEL, le modèle MLPNN1 a présenté des performances remarquables avec des

valeurs de R autour de 0.943, de NSE environ 0.8 m³/s, de RMSE d'environ 1.68 m³/s et de MAE d'environ 0.5.

Le M5Tree a donné des performances satisfaisantes, bien qu'inférieures à celles du MLPNN. Le M5T se distingue par sa capacité à produire des modèles simples et interprétables, ce qui en fait un choix intéressant pour les applications où la compréhension des processus hydrologiques est essentielle. Enfin, ELM a donné les performances les plus faibles comme pour le pas de temps journalier.

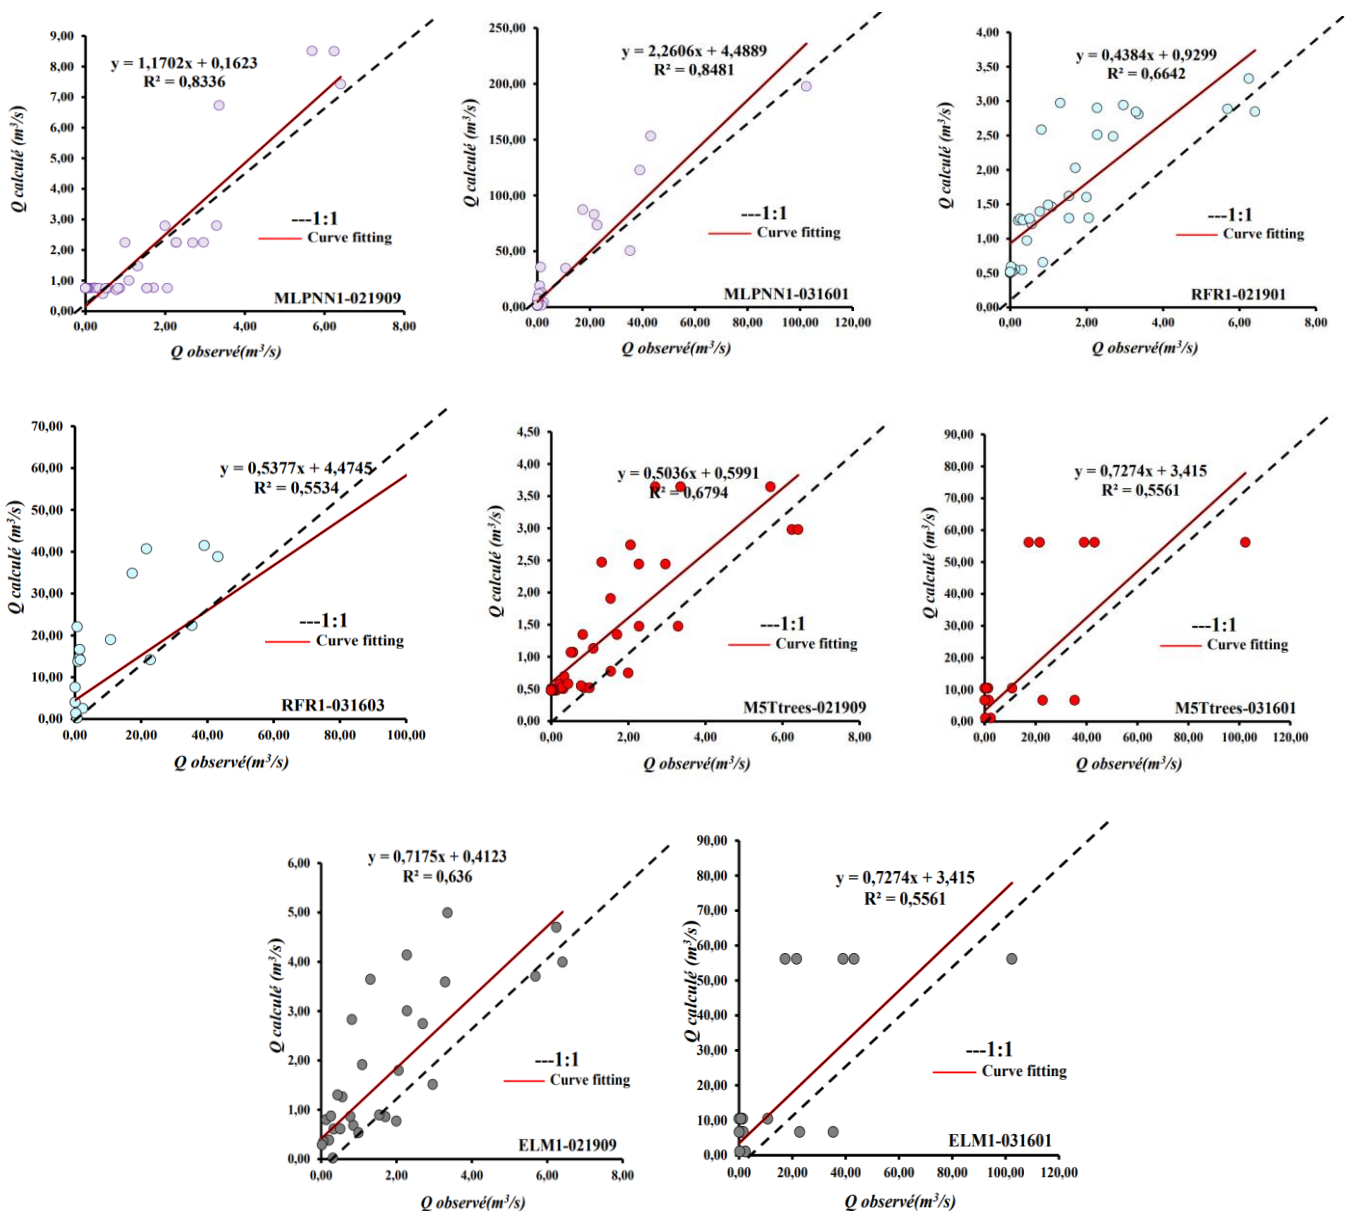


Figure.V.5. Nuage de points entre les débits mensuels mesurés et calculés pour les meilleurs modèles de l'intelligence artificielle hybridée dans la phase de validation

V.4 Les modèles à base de l'intelligence artificielle hybrides

Les modèles hybrides d'intelligence artificielle combinent différentes techniques pour améliorer la précision et la robustesse des prévisions. Dans notre travail de thèse, nous avons donc exploré deux approches d'hybridation : une fois en utilisant des algorithmes et une autre fois en utilisant des transformations en ondelettes.

V.4.1 Les transformations en ondelettes

Pour améliorer les performances des modèles autonomes, une nouvelle approche de modélisation a été proposée basée sur la combinaison des modèles de l'IA avec un algorithme de décomposition du signal. L'approche générale de cette technique, a été réalisée en divisant chaque entrée en plusieurs sous signal $Q(t-3)$, $Q(t-2)$, $Q(t-1)$, $P(t-3)$, $P(t-2)$, $P(t-1)$ en un certain nombre de sous-séries individuelles, c'est-à-dire le IMF en utilisant le VMD et le MRA en utilisant le MODWT. Pour démontrer l'efficacité des approches des modèles proposées, les performances prédictives de ces derniers ont été présentée dans cette partie de l'étude. Le cadre de modélisation proposé est présenté dans la figure.V.6.

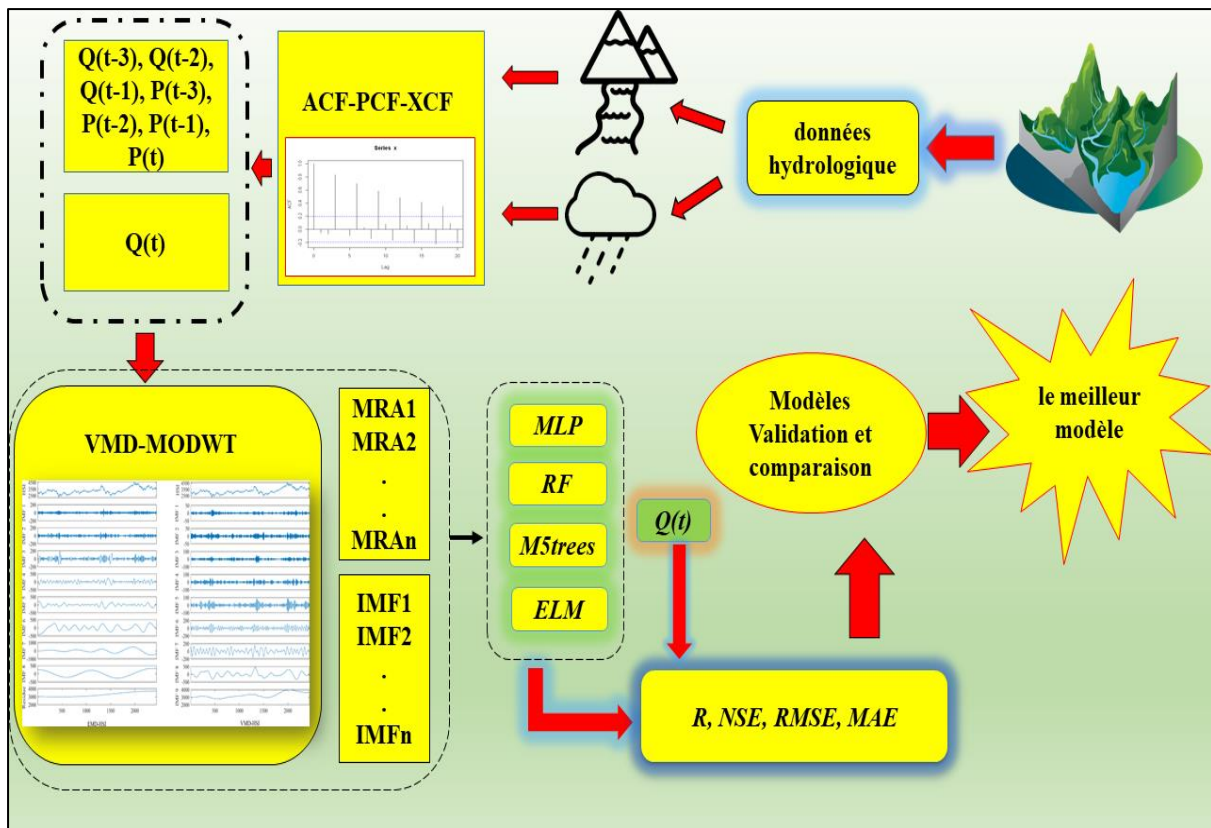


Figure.V.6. Organigramme du cadre de modélisation pluie-débit $Q(t)$

V.4.1.1 Pas de temps journalier

Les résultats de l'hybridation de MODWT et VMD avec les 4 modèles d'intelligence artificielle autonomes pour les deux meilleures stations, et pour un pas de temps journalier sont présentés dans les tableaux V.11, 12, 13 et 14. Les résultats pour les autres stations sont présentés dans l'annexe.

Tableau.V.11. Performance des modèles hybrides basés sur le MODWT pour la station RN 25

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MODWT-MLPNN1	0.995	0.987	0.410	0.287	0.993	0.985	0.347	0.236
MODWT-MLPNN2	0.950	0.902	1.136	0.550	0.849	0.675	1.611	0.685
MODWT-MLPNN3	1.000	1.000	0.044	0.023	0.994	0.985	0.343	0.243
MODWT-MLPNN4	0.927	0.860	1.361	0.627	0.860	0.738	1.445	0.823
MODWT-MLPNN5	1.000	1.000	0.055	0.027	0.994	0.984	0.362	0.257
MODWT-MLPNN6	0.749	0.561	2.411	1.110	0.486	0.140	2.620	1.508
MODWT-RFR1	0.971	0.927	0.986	0.181	0.896	0.738	1.447	0.663
MODWT-RFR2	0.940	0.852	1.401	0.290	0.507	0.231	2.477	1.277
MODWT-RFR3	0.968	0.923	1.008	0.197	0.897	0.746	1.423	0.624
MODWT-RFR4	0.939	0.851	1.403	0.295	0.522	0.251	2.444	1.253
MODWT-RFR5	0.966	0.919	1.033	0.209	0.896	0.747	1.421	0.603
MODWT-RFR6	0.903	0.784	1.692	0.393	0.385	0.098	2.683	1.375
MODWT-M5Tree1	0.999	0.998	0.172	0.064	0.989	0.977	0.428	0.267
MODWT-M5Tree2	0.959	0.920	1.027	0.180	0.348	-0.407	3.351	1.549
MODWT-M5Tree3	0.999	0.997	0.194	0.049	0.988	0.976	0.440	0.271
MODWT-M5Tree4	0.959	0.919	1.033	0.182	0.342	0.137	3.359	1.549
MODWT-M5Tree5	0.999	0.997	0.194	0.049	0.989	0.976	0.440	0.271
MODWT-M5Tree6	0.938	0.880	1.260	0.234	0.254	-0.575	3.545	1.583
MODWT-ELM1	0.861	0.742	1.848	1.066	0.800	0.517	1.963	1.345
MODWT-ELM2	0.672	0.452	2.692	1.328	0.492	0.200	2.527	1.487
MODWT-ELM3	0.909	0.826	1.517	0.884	0.825	0.560	1.874	1.175
MODWT-ELM4	0.668	0.447	2.705	1.350	0.476	0.189	2.544	1.470
MODWT-ELM5	0.940	0.883	1.243	0.630	0.809	0.462	2.073	1.206
MODWT-ELM6	0.641	0.411	2.792	1.367	0.443	0.158	2.592	1.374

Tableau.V.12. Performance des modèles hybrides à base de MODWT pour la station de BOUCHEGOUF

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MODWT-MLPNN1	0.999	0.998	0.433	0.273	0.959	0.912	1.892	0.933
MODWT-MLPNN2	0.726	0.518	6.359	2.211	0.653	0.423	4.853	2.138
MODWT-MLPNN3	0.992	0.983	1.199	0.448	0.950	0.889	2.132	1.000
MODWT-MLPNN4	0.762	0.577	5.959	2.228	0.621	0.385	5.010	2.367
MODWT-MLPNN5	1.000	0.999	0.276	0.113	0.951	0.874	2.264	0.861
MODWT-MLPNN6	0.656	0.431	6.915	2.343	0.514	0.257	5.508	2.163
MODWT-RFR1	0.968	0.919	2.610	0.473	0.946	0.852	2.461	1.209
MODWT-RFR2	0.908	0.781	4.286	0.856	0.417	0.029	6.297	3.107
MODWT-RFR3	0.963	0.904	2.844	0.524	0.946	0.853	2.453	1.196
MODWT-RFR4	0.908	0.782	4.276	0.860	0.453	0.117	6.004	2.939
MODWT-RFR5	0.960	0.897	2.935	0.543	0.936	0.844	2.525	1.220
MODWT-RFR6	0.848	0.675	5.227	1.161	0.367	0.033	6.283	2.992
MODWT-M5Tree1	0.993	0.987	1.061	0.276	0.935	0.863	2.363	1.024
MODWT-M5Tree2	0.856	0.733	4.735	0.963	0.329	0.093	6.086	2.317
MODWT-M5Tree3	0.992	0.984	1.169	0.256	0.914	0.823	2.687	1.048
MODWT-M5Tree4	0.932	0.869	3.315	0.558	0.318	0.080	6.127	2.337
MODWT-M5Tree5	0.992	0.984	1.169	0.260	0.914	0.823	2.685	1.045
MODWT-M5Tree6	0.932	0.868	3.326	0.715	0.250	-0.082	6.647	2.770
MODWT-ELM1	0.865	0.748	4.596	2.702	0.814	0.641	3.829	2.483
MODWT-ELM2	0.608	0.370	7.274	3.371	0.421	0.158	5.863	3.129
MODWT-ELM3	0.898	0.806	4.036	2.342	0.829	0.651	3.774	2.667
MODWT-ELM4	0.575	0.330	7.498	3.309	0.489	0.240	5.569	2.928
MODWT-ELM5	0.859	0.738	4.689	2.045	0.767	0.520	4.425	2.587
MODWT-ELM6	0.605	0.366	7.296	3.200	0.452	0.176	5.799	2.680

Les tableaux V.11 et V.12 donnent les résultats obtenus par les modèles MLPNN, RFR, M5Tree et ELM, basée sur l'hybridation avec le MODWT. Ces derniers présentaient de meilleures performances en termes de précision, de fortes diminutions de MAE et du RMSE, et de fortes augmentations des valeurs R et NSE par rapport aux modèles autonomes. Les modèles des scénarios ; un, trois et cinq présentent les meilleures performances. Les résultats des tableaux donnent une première impression de l'augmentation des performances des modèles. Les modèles les plus efficaces et les plus robustes sont MODWT-MLPNN et MODWT-M5Tree, dont les résultats sont très similaires. Ils sont suivis de MODWT-RFR et de MODWT-ELM, ce dernier étant le moins performant de tous les modèles.

Les résultats pour la station RN25 sont présentés dans le tableau V.11. Les modèles les plus efficaces pour cette station sont MODWT-MLPNN avec les trois scénarios 1, 3 et 5, avec les performances suivantes : S1 ($R \approx 0.993$, $NSE \approx 0.985$, $RMSE \approx 0.347$ m³/s, $MAE \approx 0.236$ m³/s), S3 et S5 ($R \approx 0.994$, 0.994), $NSE (\approx 0.985, 0.984)$, $RMSE (\approx 0.343$ m³/s, 0.362 m³/s), $MAE (\approx 0.243, 0.257$ m³/s) respectivement. Les modèles classés en deuxième position en termes d'efficacité sont MODWT-M5Tree1, MODWT-M5Tree3 et MODWT-M5Tree5, avec les performances suivantes : R (0.989, 0.988, 0.989), $NSE (0.977, 0.976, 0.976)$, $RMSE (0.267, 0.440, 0.440)$ m³/s, $MAE (0.243, 0.271, 0.271)$ m³/s respectivement.

Pour la station BOUCHEGOUF (tableau V.12), les résultats obtenus par la décomposition MODWT maintiennent le même ordre de bon à mauvais ; MLPNN, M5Tree, RFR et ELM respectivement, avec de bons résultats pour les trois scénarios ; MODWT-MLPNN1 (0.959, 0.912, 1.892 m³/s, 0.933 m³/s), MODWT-MLPNN3 (0.950, 0.889, 2.132 m³/s, 1.000 m³/s), MODWT-MLPNN5 (0.951, 0.874, 2.264 m³/s, 0.861 m³/s) et pour M5Tree ; MODWT-M5Tree1 (0.935, 0.863, 2.363 m³/s, 1.024 m³/s), MODWT-M5Tree3 (0.914, 0.823, 2.687 m³/s, 1.048 m³/s), MODWT-M5Tree5 (0.914, 0.823, 2.685 m³/s, 1.045 m³/s), et pour l'hybridation MODWT avec RFR ; MODWT-RFR1 (0.946, 0.852, 2.461 m³/s, 1.209 m³/s), MODWT-RFR3 (0.946, 0.853, 2.453 m³/s, 1,196 m³/s), MODWT-RFR5 (0.936, 0,844, 2,525 m³/s, 1,220 m³/s), et à la fin le modèle hybride entre MODWT et ELM.

Les résultats obtenus par l'hybridation avec VMD et présentés sur les tableaux V.13 et V.14 ainsi que sur les tableaux de l'annexe, sont très proches des résultats du MODWT. Les meilleurs résultats sont obtenus avec le scénario un, le scénario trois et cinq, avec une supériorité marquée pour les modèles VMD-MLPNN et VMD-M5Tree, et des résultats acceptables pour le VMD-RFR.

Tableau.V.13. Performance des modèles hybrides à base de VMD pour la station de FREHA

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.999	0.999	0.216	0.125	0.982	0.967	0.508	0.158
VMD-MLPNN2	0.889	0.790	2.648	1.176	0.788	0.656	1.628	0.746
VMD-MLPNN3	1.000	0.999	0.179	0.095	0.980	0.964	0.526	0.165
VMD-MLPNN4	0.831	0.683	3.255	1.045	0.769	0.630	1.690	0.528
VMD-MLPNN5	0.999	0.997	0.316	0.160	0.978	0.960	0.554	0.194
VMD-MLPNN6	0.749	0.561	2.411	1.110	0.486	0.140	2.620	1.508
VMD-RFR1	0.962	0.889	1.930	0.441	0.815	0.668	1.599	0.389
VMD-RFR2	0.898	0.755	2.862	0.682	0.478	0.281	2.355	0.623
VMD-RFR3	0.960	0.883	1.982	0.462	0.801	0.645	2.248	0.455
VMD-RFR4	0.902	0.756	2.856	0.688	0.493	0.298	2.327	0.620
VMD-RFR5	0.961	0.886	1.949	0.476	0.539	0.345	2.248	0.448
VMD-RFR6	0.595	0.372	4.655	1.934	0.435	0.277	2.272	0.720
VMD-M5Tree1	0.997	0.995	0.421	0.212	0.978	0.955	0.592	0.191
VMD-M5Tree2	0.934	0.873	2.062	0.318	0.462	0.130	2.590	0.660
VMD-M5Tree3	0.997	0.995	0.441	0.212	0.976	0.955	0.592	0.191
VMD-M5Tree4	0.997	0.993	0.478	0.202	0.446	-0.008	2.789	0.443
VMD-M5Tree5	1.000	0.999	0.179	0.095	0.960	0.924	0.626	0.165
VMD-M5Tree6	0.721	0.461	1.411	1.810	0.486	0.140	2.620	1.508
VMD-ELM1	0.819	0.671	3.318	1.730	0.656	0.476	2.010	0.837
VMD-ELM2	0.595	0.352	4.655	1.934	0.244	0.074	2.672	0.936
VMD-ELM3	0.819	0.671	3.618	1.730	0.656	0.477	2.210	0.857
VMD-ELM4	0.598	0.356	4.642	1.887	0.227	0.069	2.680	0.894
VMD-ELM5	0.886	0.785	2.684	1.117	0.277	0.037	2.725	0.575
VMD-ELM6	0.548	0.256	4.742	1.887	0.227	0.069	2.680	0.894

Tableau.V.14. Performance des modèles hybrides à base de VMD pour la station d'AIN BERDA

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.993	0.984	0.189	0.076	0.998	0.973	0.339	0.146
VMD-MLPNN2	0.901	0.806	0.662	0.273	0.769	0.575	1.353	0.570
VMD-MLPNN3	0.999	0.998	0.070	0.032	0.993	0.973	0.344	0.100
VMD-MLPNN4	0.901	0.763	0.732	0.178	0.758	0.551	1.392	0.389
VMD-MLPNN5	1.000	0.999	0.036	0.017	0.994	0.960	0.415	0.099
VMD-MLPNN6	0.656	0.431	6.915	2.343	0.514	0.257	5.508	2.163
VMD-RFR1	0.952	0.879	0.523	0.092	0.892	0.771	0.993	0.214
VMD-RFR2	0.946	0.894	0.488	0.081	0.559	-0.092	2.169	0.558
VMD-RFR3	0.953	0.874	0.532	0.096	0.908	0.808	0.911	0.209
VMD-RFR4	0.809	0.628	0.732	0.178	0.628	0.506	2.392	1.389
VMD-RFR5	0.949	0.867	0.549	0.101	0.906	0.807	0.912	0.210
VMD-RFR6	0.810	0.652	5.273	1.614	0.376	0.331	5.283	1.992
VMD-M5Tree1	0.978	0.957	0.310	0.103	0.997	0.975	0.485	0.145
VMD-M5Tree2	0.903	0.772	0.717	0.172	0.761	0.558	1.380	0.393
VMD-M5Tree3	0.996	0.991	0.139	0.051	0.991	0.973	0.342	0.114
VMD-M5Tree4	0.881	0.658	0.732	0.195	0.658	0.561	1.492	0.689
VMD-M5Tree5	0.996	0.991	0.141	0.036	0.971	0.937	0.522	0.167
VMD-M5Tree6	0.848	0.675	5.227	1.161	0.367	0.033	6.283	2.992
VMD-ELM1	0.825	0.680	0.850	0.461	0.788	0.611	1.295	0.773
VMD-ELM2	0.539	0.285	1.270	0.581	0.570	0.327	1.703	0.761
VMD-ELM3	0.544	0.288	1.267	0.577	0.622	0.389	1.622	0.756
VMD-ELM4	0.512	0.255	1.296	0.582	0.593	0.354	1.668	0.730
VMD-ELM5	0.893	0.798	0.676	0.265	0.814	0.654	1.222	0.493
VMD-ELM6	0.635	0.346	6.296	2.200	0.452	0.176	5.799	2.680

La figure V.7, donne le nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur MODWT et VMD dans la phase validation, pour plusieurs stations.

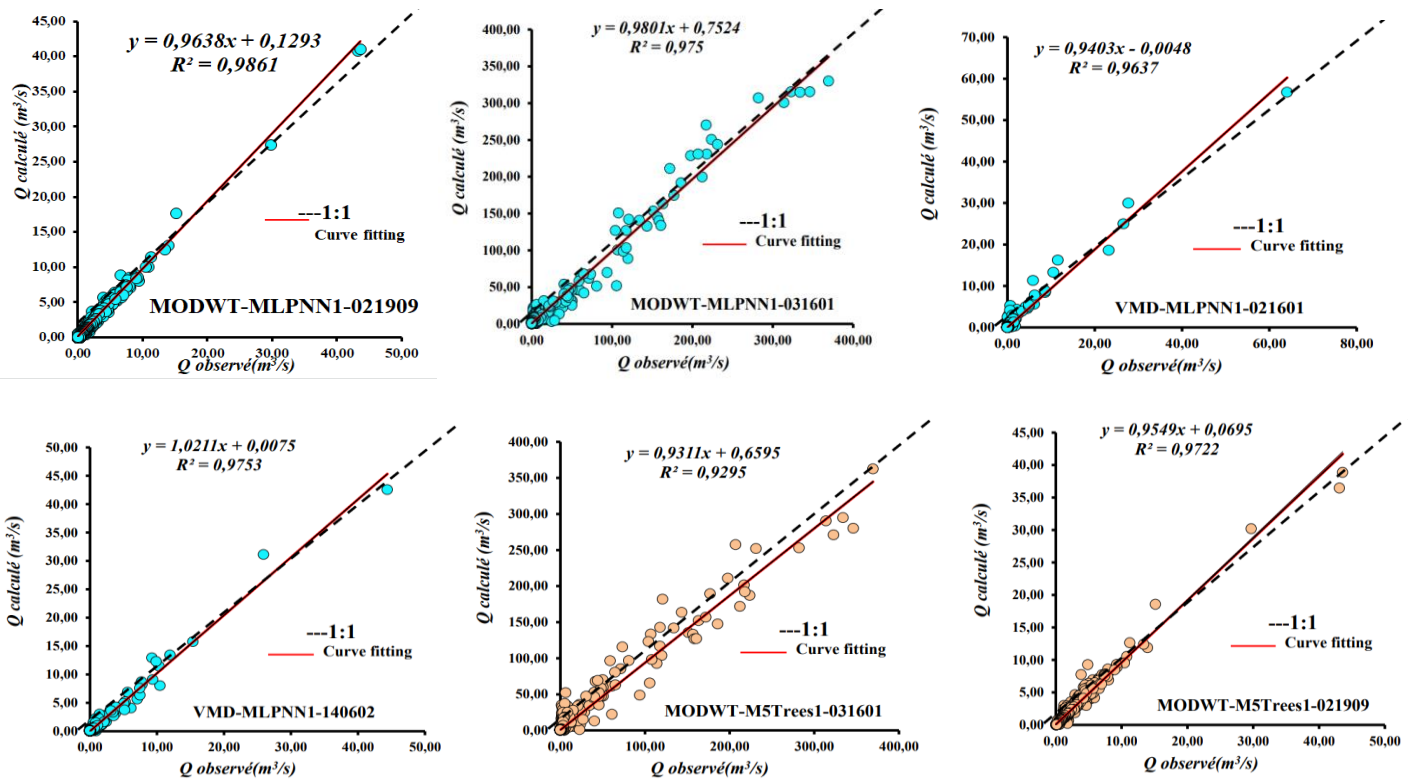


Figure V.7. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur MODWT et VMD dans la phase validation

Les résultats obtenus dans cette section de l'étude, ont démontré l'efficacité de la transformée en ondelettes VMD et MODWT dans la modélisation de la relation pluie-débit pour la prévision des débits. L'hybridation avec MLPNN et M5Tree présentent une bonne capacité prédictive. Les performances de prévision hydrologique de MODWT-MLPNN, MODWT-M5Tree, de VMD-MLPNN, VMD-M5Tree dépassent celles des autres modèles sur la base de quatre indices statistiques différents. La raison pour laquelle les modèles hybrides ont donné de meilleures performances, peut-être s'expliquer par le fait que les modèles hybrides ont utilisé des sous-séries temporelles comme entrées du modèle, tandis que les modèles autonomes ont utilisé les séries originales comme entrées du modèle sans décomposition. Les séries temporelles peuvent capturer le degré élevé de variation qui existe dans les séries originales, ce qui permet notamment de comprendre et de capturer l'effet de la saisonnalité, qui inclut diverses informations sur le phénomène étudié, ainsi que la transformation en ondelettes permet également de réduire le bruit dans les séries temporelles de débit, ce qui se traduit par des prévisions plus fiables et précises (Tiwari et Chatterjee, 2010).

V.4.1.2 Pas de temps mensuel

Dans le domaine de la modélisation, il est déconseillé d'utiliser les décompositions de signal pour la modélisation des courtes séries, pour notre cas on parle donc, de la modélisation en pas de temps mensuel et annuel. L'utilisation des décompositions de signaux pour modéliser les débits mensuels peut être limitée par la courte durée des séries temporelles. Selon une étude récente de Chen et al., (2018), ces techniques nécessitent généralement des données sur une période suffisamment longue pour identifier avec précision les tendances et les motifs saisonniers. Avec des séries temporelles de débits mensuels de courte durée, il est peut-être difficile d'extraire des informations significatives à partir des décompositions de signaux. Dans de tels cas, d'autres approches de modélisation des séries temporelles, telles que les modèles hydrologiques ou les méthodes d'apprentissage automatique adaptées aux données peu nombreuses, peuvent être plus appropriées pour capturer les caractéristiques temporelles des débits mensuels.

V.4.2 Les algorithmes d'optimisation

L'intégration de techniques d'optimisation basées sur des algorithmes d'optimisation avec des réseaux de neurones artificiels (ANN), offre un potentiel considérable pour améliorer la modélisation des débits journaliers, mensuels et annuels. Trois algorithmes d'Optimisation couramment utilisés dans ce contexte sont ARO, GWO-PSO et MAO. Ces algorithmes sont appliqués pour optimiser les paramètres du ANN, tels que les poids des connexions et les biais, afin d'améliorer sa capacité de prédiction. Les trois méthodes ont été comparées sur la base d'une combinaison de six entrées indiquées dans le tableau III.5. Cette section présente les performances prédictives des méthodes proposées. Le cadre de modélisation proposé est présenté dans la figure V.8.

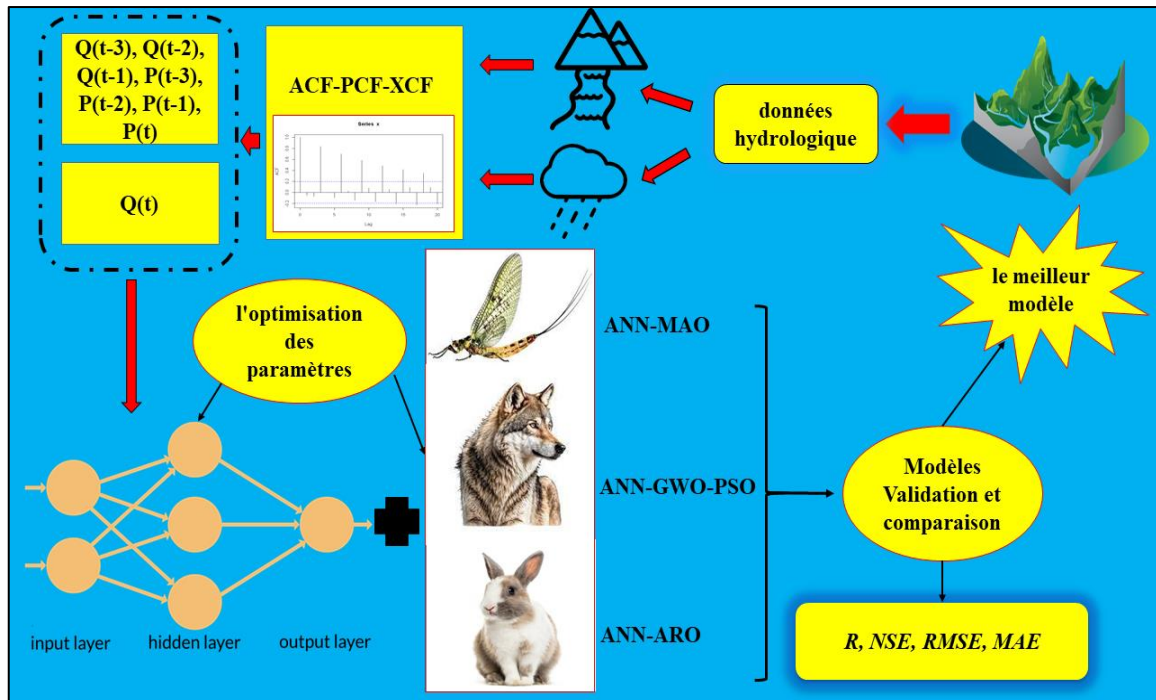


Figure.V.8. Organigramme du cadre de modélisation pluie-débit $Q(t)$ en utilisant les algorithmes d'optimisation

V.4.2.1 Pas de temps journalier

Les meilleurs résultats obtenus par les trois algorithmes d'optimisation utilisés sont présentés dans les tableaux suivants. Le reste des résultats des autres stations sont envoyés vers l'annexe.

Sur la base des résultats obtenus dans les tableaux V.15, V.16 et dans le reste des tableaux de l'annexe, en utilisant les trois algorithmes cités en haut étaient satisfaisants. Les modèles les plus efficaces sont obtenus avec le scénario numéro un. Les résultats indiquent une légère supériorité de l'algorithme ARO par rapport aux deux autres algorithmes mais, d'une manière générale, les résultats sont proches. Concernant l'amélioration de l'efficacité des modèles, nous n'avons pas constaté d'amélioration significative au pas de temps journalier.

Tableau.V.15. Performance des modèles hybrides à base des algorithmes d'optimisation de pour la station de FREHA

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.922	0.850	1.209	0.642	0.919	0.842	1.083	0.576
ANN-ARO2	0.524	0.274	5.456	2.570	0.504	0.236	5.499	2.681
ANN-ARO3	0.858	0.730	2.717	0.811	0.833	0.694	3.152	0.765
ANN-ARO4	0.897	0.694	5.955	0.920	0.788	0.620	3.511	1.136
ANN-ARO5	0.708	0.443	3.904	1.628	0.695	0.483	4.097	1.039
ANN-ARO6	0.674	0.453	4.210	1.497	0.672	0.453	10.218	1.256
ANN-GWO-PSO1	0.901	0.812	2.468	0.693	0.907	0.815	2.253	0.755
ANN-GWO-PSO2	0.541	0.292	5.390	2.535	0.528	0.279	5.342	2.040
ANN-GWO-PSO3	0.848	0.715	3.042	0.873	0.828	0.646	3.116	0.724
ANN-GWO-PSO4	0.845	0.714	2.798	0.722	0.774	0.599	3.605	1.074
ANN-GWO-PSO5	0.722	0.402	4.047	1.381	0.687	0.472	4.140	1.030
ANN-GWO-PSO6	0.686	0.470	4.145	1.526	0.666	0.470	8.445	1.159
ANN-MAO1	0.924	0.854	2.178	0.613	0.913	0.831	2.148	0.765
ANN-MAO2	0.573	0.328	5.252	2.482	0.492	0.328	6.670	2.360
ANN-MAO3	0.855	0.610	3.267	0.673	0.773	0.597	3.616	0.923
ANN-MAO4	0.856	0.678	2.968	0.749	0.791	0.625	3.488	1.034
ANN-MAO5	0.813	0.533	3.576	1.450	0.688	0.473	4.133	1.033
ANN-MAO6	0.588	0.344	4.611	1.530	0.569	0.327	4.293	1.109

Tableau.V.16. Performance des modèles hybrides à base des algorithmes d'optimisation de pour la station de RN25

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.946	0.895	1.172	0.277	0.927	0.851	1.095	0.312
ANN-ARO2	0.731	0.534	2.473	1.230	0.566	0.105	2.681	1.325
ANN-ARO3	0.913	0.833	1.480	0.393	0.816	0.661	1.649	0.450
ANN-ARO4	0.894	0.798	1.626	0.384	0.732	0.534	1.934	0.412
ANN-ARO5	0.818	0.669	2.082	0.451	0.729	0.529	1.945	0.434
ANN-ARO6	0.340	0.115	3.407	1.489	0.238	0.052	2.759	1.435
ANN-GWO-PSO1	0.975	0.951	0.800	0.250	0.891	0.794	1.286	0.356
ANN-GWO-PSO2	0.731	0.530	2.484	1.218	0.568	0.306	2.362	1.303
ANN-GWO-PSO3	0.884	0.782	1.691	0.397	0.810	0.654	1.668	0.417
ANN-GWO-PSO4	0.708	0.499	2.563	1.246	0.583	0.247	2.460	1.287
ANN-GWO-PSO5	0.816	0.665	2.095	0.448	0.731	0.532	1.938	0.423
ANN-GWO-PSO6	0.302	0.114	3.069	1.892	0.216	0.022	3.759	1.635
ANN-MAO1	0.924	0.854	1.385	0.350	0.880	0.774	1.348	0.346
ANN-MAO2	0.717	0.513	2.527	1.241	0.576	0.324	2.330	1.296
ANN-MAO3	0.936	0.874	1.286	0.413	0.806	0.639	1.704	0.469
ANN-MAO4	0.694	0.481	2.610	1.299	0.599	0.305	2.363	1.291
ANN-MAO5	0.819	0.670	2.080	0.440	0.728	0.530	1.943	0.430
ANN-MAO6	0.353	0.124	3.390	1.495	0.245	0.050	2.762	1.449

Pour les huit stations, le modèle le plus efficace est celui de l'ANN-ARO1. Par exemple, la station FERAH avec les performances suivantes ($R \approx 0.919$, $NSE \approx 0.842$, $RMSE \approx 1.081$ m³/s, $MAE \approx 0.578$ m³/s), et la station RN25 avec les performances suivantes ($R \approx 0.927$, $NSE \approx 0.851$, $RMSE \approx 1.095$ m³/s, $MAE \approx 0.312$ m³/s). Pour deux autres modèles, les résultats étaient très proches, puisque R varier entre 0.90 et 0.92 pour toutes les stations.

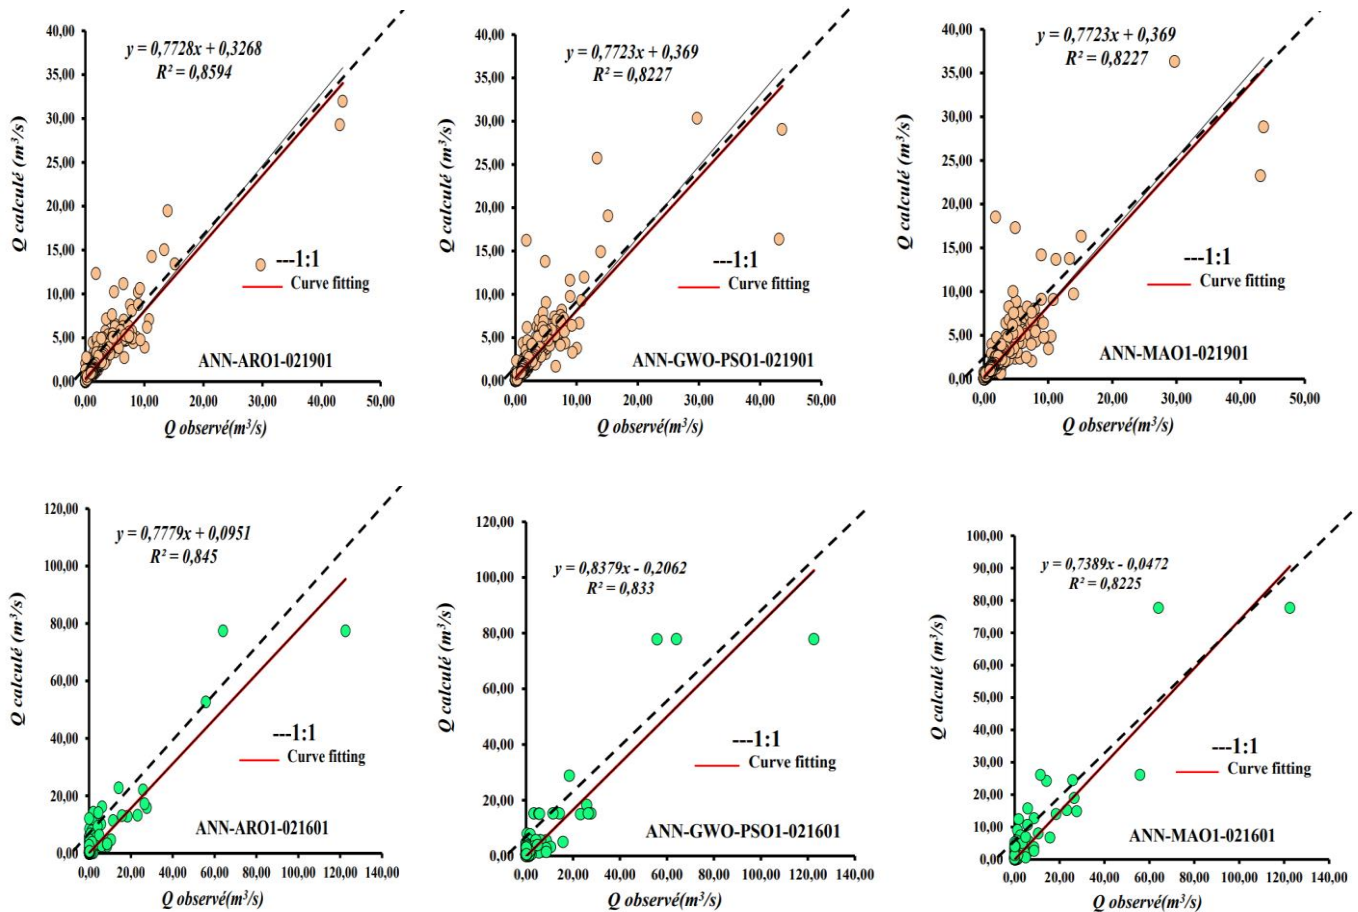


Figure.V.9. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur algorithmes dans la phase validation

V.4.2.2 Pas de temps mensuel

Les résultats obtenus au pas de temps mensuel pour les trois modèles hybridés avec les algorithmes d'optimisation utilisés, pour les deux meilleures stations sont présentés dans les tableaux ci-dessous.

Tableau.V.17. Les performances des modèles hybrides à la base des algorithmes d'optimisation pour la station FERMATOU

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.991	0.976	0.434	0.068	0.982	0.960	0.829	0.119
ANN-ARO2	0.884	0.782	0.945	0.162	0.876	0.784	1.156	0.236
ANN-ARO3	0.910	0.732	1.790	0.407	0.909	0.712	1.907	0.464
ANN-ARO4	0.668	0.278	2.653	0.438	0.667	0.259	2.891	0.517
ANN-ARO5	0.828	0.677	1.351	0.265	0.812	0.652	1.350	0.265
ANN-ARO6	0.810	0.601	1.327	0.205	0.721	0.561	1.467	0.235
ANN-GWO-PSO1	0.997	0.995	0.218	0.029	0.970	0.926	0.970	0.163
ANN-GWO-PSO2	0.853	0.695	1.638	0.256	0.836	0.691	2.014	0.351
ANN-GWO-PSO3	0.897	0.801	1.308	0.225	0.869	0.744	1.926	0.325
ANN-GWO-PSO4	0.623	0.234	2.831	0.486	0.611	0.223	2.891	0.527
ANN-GWO-PSO5	0.801	0.641	1.353	0.269	0.794	0.630	1.450	0.275
ANN-GWO-PSO6	0.772	0.561	1.432	0.255	0.677	0.260	2.891	0.517
ANN-MAO1	0.997	0.994	0.238	0.037	0.946	0.878	1.173	0.176
ANN-MAO2	0.851	0.675	1.233	0.242	0.817	0.603	1.944	0.399
ANN-MAO3	0.896	0.765	1.511	0.292	0.832	0.611	2.107	0.428
ANN-MAO4	0.603	0.204	2.931	0.496	0.601	0.221	2.892	0.530
ANN-MAO5	0.797	0.641	1.391	0.276	0.772	0.623	1.862	0.530
ANN-MAO6	0.712	0.501	1.662	0.530	0.621	0.381	2.862	0.528

Tableau.V.18. Les performances des modèles hybrides à la base des algorithmes d'optimisation pour la station BOUBRIK

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.990	0.978	0.313	0.051	0.981	0.962	0.436	0.067
ANN-ARO2	0.889	0.800	0.699	0.114	0.870	0.750	0.980	0.176
ANN-ARO3	0.908	0.794	0.973	0.152	0.900	0.810	0.946	0.185
ANN-ARO4	0.628	0.278	2.653	0.438	0.517	0.259	2.891	0.516
ANN-ARO5	0.811	0.666	1.149	0.220	0.790	0.652	1.149	0.245
ANN-ARO6	0.716	0.497	1.467	0.205	0.701	0.461	1.567	0.285
ANN-GWO-PSO1	0.997	0.993	0.173	0.023	0.940	0.874	0.762	0.135
ANN-GWO-PSO2	0.871	0.654	1.270	0.244	0.843	0.622	1.320	0.269
ANN-GWO-PSO3	0.903	0.805	0.911	0.157	0.828	0.677	1.351	0.265
ANN-GWO-PSO4	0.610	0.252	2.633	0.438	0.517	0.259	2.862	0.519
ANN-GWO-PSO5	0.802	0.666	1.149	0.220	0.754	0.622	1.168	0.345
ANN-GWO-PSO6	0.727	0.495	1.467	0.205	0.633	0.401	1.567	0.285
ANN-MAO1	0.995	0.991	0.192	0.031	0.942	0.873	0.896	0.147
ANN-MAO2	0.818	0.614	1.380	0.245	0.811	0.665	1.148	0.221
ANN-MAO3	0.865	0.722	1.129	0.199	0.857	0.707	1.182	0.220
ANN-MAO4	0.600	0.242	2.613	0.428	0.507	0.259	2.862	0.519
ANN-MAO5	0.764	0.602	1.168	0.245	0.724	0.599	1.168	0.365
ANN-MAO6	0.692	0.451	1.567	0.285	0.662	0.438	1.667	0.485

Sur la base des résultats des critères de performances présentés dans les tableaux V.17, V.18, la figure V.10 et les autres stations qui sont dans l'annexe 2, les trois modèles hybrides sont performants, mais le meilleur et le plus efficace parmi eux est l'ANN-ARO, suivi par le modèle ANN-GWO-PSO et le moins efficace d'entre eux est l'ANN-MOA. Les résultats numériques pour ANN-ARO, ANN-GWO-PSO et ANN-MOA montrent que le modèle avec sept variables d'entrée, c'est-à-dire le scénario (S1) : $P(t)$, $P(t-1)$, $P(t-2)$, $P(t-3)$, $Q(t-1)$, $Q(t-2)$ et $Q(t-3)$ présente la meilleure performance des trois modèles utilisés dans tous les stations.

A la station de FERMATOU (Tableau V.17), l'ANN-ARO1 a donné les valeurs R et NSE les plus élevées ($R \approx 0.982$ et $NSE \approx 0.960$), les valeurs RMSE et MAE les plus faibles de $0.829 \text{ m}^3/\text{s}$ et $0.119 \text{ m}^3/\text{s}$ respectivement. Pour la station de BOU BIREK (Tableau V.18), le modèle ANN1 présente les valeurs de performance les plus efficaces avec les valeurs suivantes: $R \approx 0.981$, $NSE \approx 0.961$, $RMSE \approx 0.436 \text{ m}^3/\text{s}$ et $MAE \approx 0.067 \text{ m}^3/\text{s}$. Les deux modèles ANN-GWO-PSO et ANN-MAO ont fourni, à la station FERMATOU, les meilleures prédictions pour le premier scénario (S1) avec les RMSE ($0.970 \text{ m}^3/\text{s}$, $1.173 \text{ m}^3/\text{s}$), MAE ($0.163 \text{ m}^3/\text{s}$, $0.176 \text{ m}^3/\text{s}$) et R (0.97 , 0.946), NSE (0.926 , 0.873) les plus élevés respectivement. La station BOU BIREK a les performances suivantes de R, NSE, RMSE et MAE pour ANN-GWO-PSO1 (0.94 , 0.874 , $0.762 \text{ m}^3/\text{s}$, $0.135 \text{ m}^3/\text{s}$), ANN-MAO1 (0.942 , 0.873 , $0.896 \text{ m}^3/\text{s}$, $0.147 \text{ m}^3/\text{s}$) respectivement.

L'utilisation de modèles hybrides avec des algorithmes d'optimisation peut être préférable dans la modélisation pluie-débit au pas de temps mensuel par rapport à une utilisation au pas de temps journalier. L'utilisation d'algorithmes d'optimisation peut aider à trouver plus facilement les paramètres optimaux du modèle pour la modélisation au pas de temps mensuel, où les interactions entre la pluie et le débit sont plus prononcées et nécessitent une calibration précise (Li et al., 2018). Ainsi, l'utilisation de modèles hybrides avec des algorithmes d'optimisation peut être une approche prometteuse pour améliorer la modélisation pluie-débit au pas de temps mensuel.

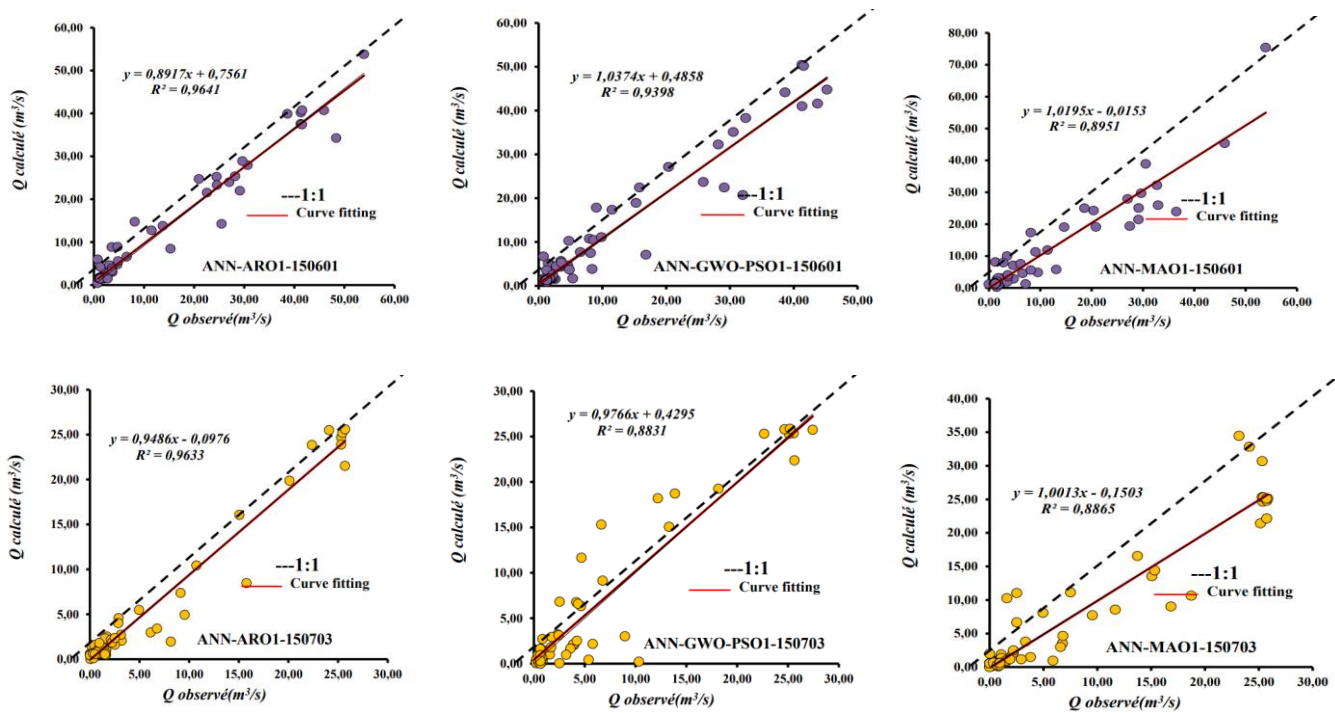


Figure.V.10. Nuage de points entre les débits mensuel mesurés et calculés pour les meilleurs modèles d'intelligence artificielle hybrides basés sur algorithmes dans la phase validation

V.4.2.3 Pas de temps annuel

L'utilisation des modèles d'intelligence artificielle avec des séries chronologiques très courtes pour la modélisation pluie-débit peut poser plusieurs défis. Tout d'abord, les séries chronologiques courtes peuvent ne pas contenir suffisamment d'informations pour capturer les variations complexes du débit résultant de la pluie. Cela peut entraîner une faible précision des prévisions, car les modèles d'intelligence artificielle ont besoins d'une taille importante de données historiques pour apprendre et généraliser des débits efficacement (Adamowski et al., 2014).

De plus, les modèles d'intelligence artificielle peuvent être sensibles au surapprentissage (overfitting), lorsqu'ils sont entraînés avec des séries chronologiques très courtes. Le surapprentissage se produit lorsque le modèle s'adapte trop aux données d'entraînement spécifiques et ne parvient pas à généraliser correctement aux données de test (Razavi et al., 2012). Cela peut entraîner des performances médiocres lors de la prédiction du débit en utilisant de nouvelles données.

En outre, les modèles d'intelligence artificielle peuvent être plus complexes à mettre en œuvre et à calibrer, que les modèles hydrologiques traditionnels lorsqu'ils sont utilisés avec

des séries chronologiques très courtes. Ils peuvent nécessiter une expertise technique et des ressources informatiques plus importantes pour être utilisés efficacement, ce qui peut limiter leur applicabilité dans les régions où ces ressources sont limitées (Dawson et al., 2006).

En résumé, bien que les modèles d'intelligence artificielle offrent un potentiel pour améliorer la modélisation pluie-débit, leur utilisation avec des séries chronologiques très courtes peut être limitée en raison de leur sensibilité au surapprentissage, de leur complexité et de leur besoin en données suffisantes pour l'entraînement. Ces limitations soulignent l'importance d'une approche prudente et de la prise en compte des spécificités des données hydrologiques lors de l'utilisation des modèles d'intelligence artificielle pour la modélisation pluie-débit.

V.5 Conclusion

En conclusion de ce chapitre, nous avons examiné divers modèles, à savoir : des modèles conceptuels, des modèles d'intelligence artificielle simple et des modèles d'intelligence artificielle hybridés avec la décomposition du signal et les algorithmes d'optimisation, pour la modélisation des débits à différents pas de temps (journalier, mensuel et annuel).

Les résultats obtenus, montrent que les modèles conceptuels peuvent être efficaces pour la modélisation des débits annuels, en particulier lorsque les données sont limitées. Cependant, pour des pas de temps plus fins tels que le débit journalier, les modèles d'intelligence artificielle hybridés avec la décomposition du signal ont, généralement, produit de meilleures performances. L'utilisation de modèles d'intelligence artificielle hybrides avec les algorithmes d'optimisation, qui combinent plusieurs techniques de modélisation, s'est avérée particulièrement efficace pour améliorer la précision des prévisions, en particulier pour les débits mensuels où la variabilité est plus importante.

CHAPITRES VI
ANALYSE
COMPARATIVE DES
METHODES DE
PREDICTION DU DEBIT "
INTER-COMPARAISON
DES MODÈLES"

CHAPITRES VI : ANALYSE COMPARATIVE DES METHODES DE PREDICTION DU DEBIT " Inter-Comparaison Des Modèles"

VI.1 Introduction

Dans ce chapitre, nous analyserons et comparerons les diverses approches de modélisation du débit utilisées dans ce travail, en nous appuyant sur des critères à la fois numériques et graphiques. Cette évaluation portera sur l'efficacité prédictive, la robustesse, ainsi que la capacité de chaque modèle à généraliser les meilleurs résultats. Nous chercherons à déterminer quelle est l'approche la plus performante pour la modélisation du débit, en mettant en évidence les points forts et faibles de chaque approche. En comprenant mieux les performances de ces différents modèles, nous espérons contribuer à améliorer la précision des prévisions de débit et à mieux comprendre les processus hydrologiques sous-jacents.

VI.2 Comparaison et évaluation des modèles

Pour notre étude, nous avons exploré diverses approches de modélisation, à savoir les modèles conceptuels, les modèles basés sur l'intelligence artificielle (IA) autonome et les modèles d'IA hybrides, pour différents pas de temps : journalier, mensuel et annuel. Afin de déterminer la meilleure approche pour la modélisation, nous allons comparer ces modèles pour chaque pas de temps.

Les trois critères de visualisations graphiques, que nous allons utiliser dans ce travail sont des outils puissants pour comparer les performances des modèles pluie-débit :

- Le boxplot est utile pour visualiser la distribution des données de sortie (débit simulé) générées par chaque modèle. Il vous permet de comparer la médiane, les quartiles et les valeurs extrêmes, ce qui peut indiquer la cohérence et la dispersion des prédictions entre les modèles. Un boxplot serré et symétrique indique une bonne concordance entre les modèles, tandis qu'un boxplot étendu ou asymétrique peut indiquer des différences significatives de performance ;
- Le violin plot complète le boxplot en montrant la distribution des données sous-jacentes de manière plus détaillée. Il représente la densité de probabilité des données, permettant une meilleure visualisation des variations et des asymétries entre les modèles. Les violin plots peuvent révéler des informations subtiles sur la distribution

des performances des modèles, en mettant en évidence les différences dans les pics et les étendues des distributions ;

- Le diagramme de Taylor est particulièrement utile pour comparer les performances des modèles en termes de corrélation, d'écart-type et de biais par rapport aux données observées. Il place les modèles sur un graphique en fonction de leur écart-type et de leur corrélation par rapport aux données réelles, en le comparant à une référence idéale. Cela permet de visualiser rapidement les performances relatives des modèles en termes de précision, de dispersion et de biais.

En utilisant ces trois types de visualisations ensemble avec les critères numériques, nous obtenons une vue complète et détaillée des performances des modèles pluie-débit, ce qui peut nous aider à identifier les modèles les plus performants et à comprendre les différences de performance entre eux.

VI.2.1 Pas de temps journalier

Pour cette étude, nous avons utilisé un total de 17 modèles pour la modélisation pluie-débit, tous fonctionnant à un pas de temps journalier. Ces derniers comprennent des modèles conceptuels, des modèles d'AI autonomes, ainsi que des modèles d'AI hybrides. Les modèles hybrides ont été combinés avec des décompositions de signaux et des algorithmes d'optimisation pour améliorer les performances des modèles autonomes. Cette approche nous a permis d'explorer différentes techniques de modélisation pluie-débit, et d'identifier les modèles les plus performants pour cette application spécifique.

Les tableaux VI.1, 2 et 3, donnent les performances des modèles sélectionnés dans cette étude pour les stations : RN25, Ain Assel et Bouchegouf, en se basant sur les critères numériques.

Tableau.VI.1. Récapitule des résultats de tous les modèles pour RN25 au pas de temps journalier

Modèle	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR5j	0.850	0.720	0.440	0.120	0.880	0.750	0.310	0.100
HBV	0.850	0.660	0.450	0.120	0.860	0.740	0.310	0.090
MLPNN1	0.934	0.873	1.043	0.233	0.889	0.790	0.982	0.235
RFR1	0.939	0.869	1.059	0.164	0.860	0.710	1.150	0.243
M5Tree1	0.958	0.911	0.838	0.166	0.844	0.607	1.145	0.191
ELM1	0.922	0.850	1.134	0.301	0.806	0.647	1.267	0.275
MODWT-MLPNN1	0.995	0.987	0.410	0.287	0.993	0.985	0.347	0.236
MODWT-RFR1	0.971	0.927	0.986	0.181	0.896	0.738	1.447	0.663
MODWT-M5Tree1	0.999	0.998	0.172	0.064	0.989	0.977	0.428	0.267
MODWT-ELM1	0.861	0.742	1.848	1.066	0.800	0.517	1.963	1.345
VMD-MLPNN1	0.999	0.997	0.193	0.085	0.995	0.990	0.287	0.141
VMD-RFR1	0.961	0.905	1.120	0.231	0.896	0.757	1.393	0.533
VMD-M5Tree1	0.996	0.991	0.337	0.130	0.986	0.972	0.473	0.213
VMD-ELM1	0.800	0.641	2.180	1.197	0.778	0.561	1.871	1.190
ANN-ARO1	0.932	0.868	1.322	0.334	0.939	0.879	0.981	0.371
ANN-GWO-PSO1	0.944	0.891	1.201	0.357	0.900	0.809	1.234	0.470
ANN-MAO1	0.945	0.893	1.191	0.303	0.898	0.807	1.242	0.365

Tableau.VI.2. Récapitule des résultats de tous les modèles pour AIN ASSEL au pas de temps journalier

Modèle	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR5j	0.840	0.700	1.080	0.270	0.810	0.600	2.240	0.460
HBV	0.850	0.710	0.960	0.180	0.820	0.600	0.760	0.160
MLPNN1	0.934	0.873	1.043	0.233	0.889	0.790	0.982	0.235
RFR1	0.939	0.869	1.059	0.164	0.860	0.710	1.150	0.243
M5Tree1	0.958	0.911	0.838	0.166	0.844	0.607	1.145	0.191
ELM1	0.922	0.850	1.134	0.301	0.806	0.647	1.267	0.275
MODWT-MLPNN1	0.995	0.987	0.410	0.287	0.993	0.985	0.347	0.236
MODWT-RFR1	0.971	0.927	0.986	0.181	0.896	0.738	1.447	0.663
MODWT-M5Tree1	0.999	0.998	0.172	0.064	0.989	0.977	0.428	0.267
MODWT-ELM1	0.861	0.742	1.848	1.066	0.800	0.517	1.963	1.345
VMD-MLPNN1	0.990	0.978	2.861	1.136	0.987	0.975	5.962	2.646
VMD-RFR1	0.982	0.950	4.339	1.289	0.882	0.771	18.074	5.561

VMD-M5Tree1	0.980	0.960	3.849	1.400	0.964	0.930	9.970	4.294
VMD-ELM1	0.836	0.698	10.634	6.338	0.801	0.646	22.471	12.785
ANN-ARO1	0.918	0.821	8.186	2.096	0.906	0.816	16.222	3.928
ANN-GWO-PSO1	0.957	0.916	5.597	1.579	0.910	0.804	16.709	3.849
ANN-MAO1	0.927	0.860	7.244	2.433	0.899	0.810	16.493	4.601

Tableau.VI.3. Récapitule des résultats de tous les modèles pour BOUCHEGOUF au pas de temps journalier

Modèle	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR5j	0.830	0.670	0.530	0.110	0.840	0.670	0.540	0.140
HBV	0.840	0.660	0.370	0.070	0.800	0.620	0.600	0.120
MLPNN1	0.925	0.855	2.802	0.602	0.900	0.801	2.155	0.495
RFR1	0.914	0.813	3.188	0.453	0.896	0.799	2.166	0.486
M5Tree1	0.935	0.874	2.614	0.437	0.833	0.690	2.688	0.491
ELM1	0.908	0.825	3.083	0.893	0.824	0.566	3.178	0.773
MODWT-MLPNN1	0.999	0.998	0.433	0.273	0.959	0.912	1.892	0.933
MODWT-RFR1	0.968	0.919	2.610	0.473	0.946	0.852	2.461	1.209
MODWT-M5Tree1	0.993	0.987	1.061	0.276	0.935	0.863	2.363	1.024
MODWT-ELM1	0.865	0.748	4.596	2.702	0.814	0.641	3.829	2.483
VMD-MLPNN1	0.988	0.974	1.465	0.742	0.950	0.902	2.001	0.929
VMD-RFR1	0.961	0.901	2.881	0.621	0.927	0.817	2.732	1.028
VMD-M5Tree1	0.989	0.978	1.346	0.495	0.946	0.884	2.176	0.809
VMD-ELM1	0.855	0.732	4.745	2.702	0.785	0.570	4.188	2.835
ANN-ARO1	0.993	0.987	1.061	0.276	0.935	0.863	2.363	1.024
ANN-GWO-PSO1	0.952	0.723	4.827	1.142	0.917	0.841	2.546	0.744
ANN-MAO1	0.979	0.772	4.378	1.066	0.915	0.835	2.596	0.791

Tandis que les figures VI.1, 2 et 3, montrent les performances des modèles sélectionnés dans cette étude pour les stations : RN25, Ain Assel et Bouchegouf, en se basant sur les critères graphiques.

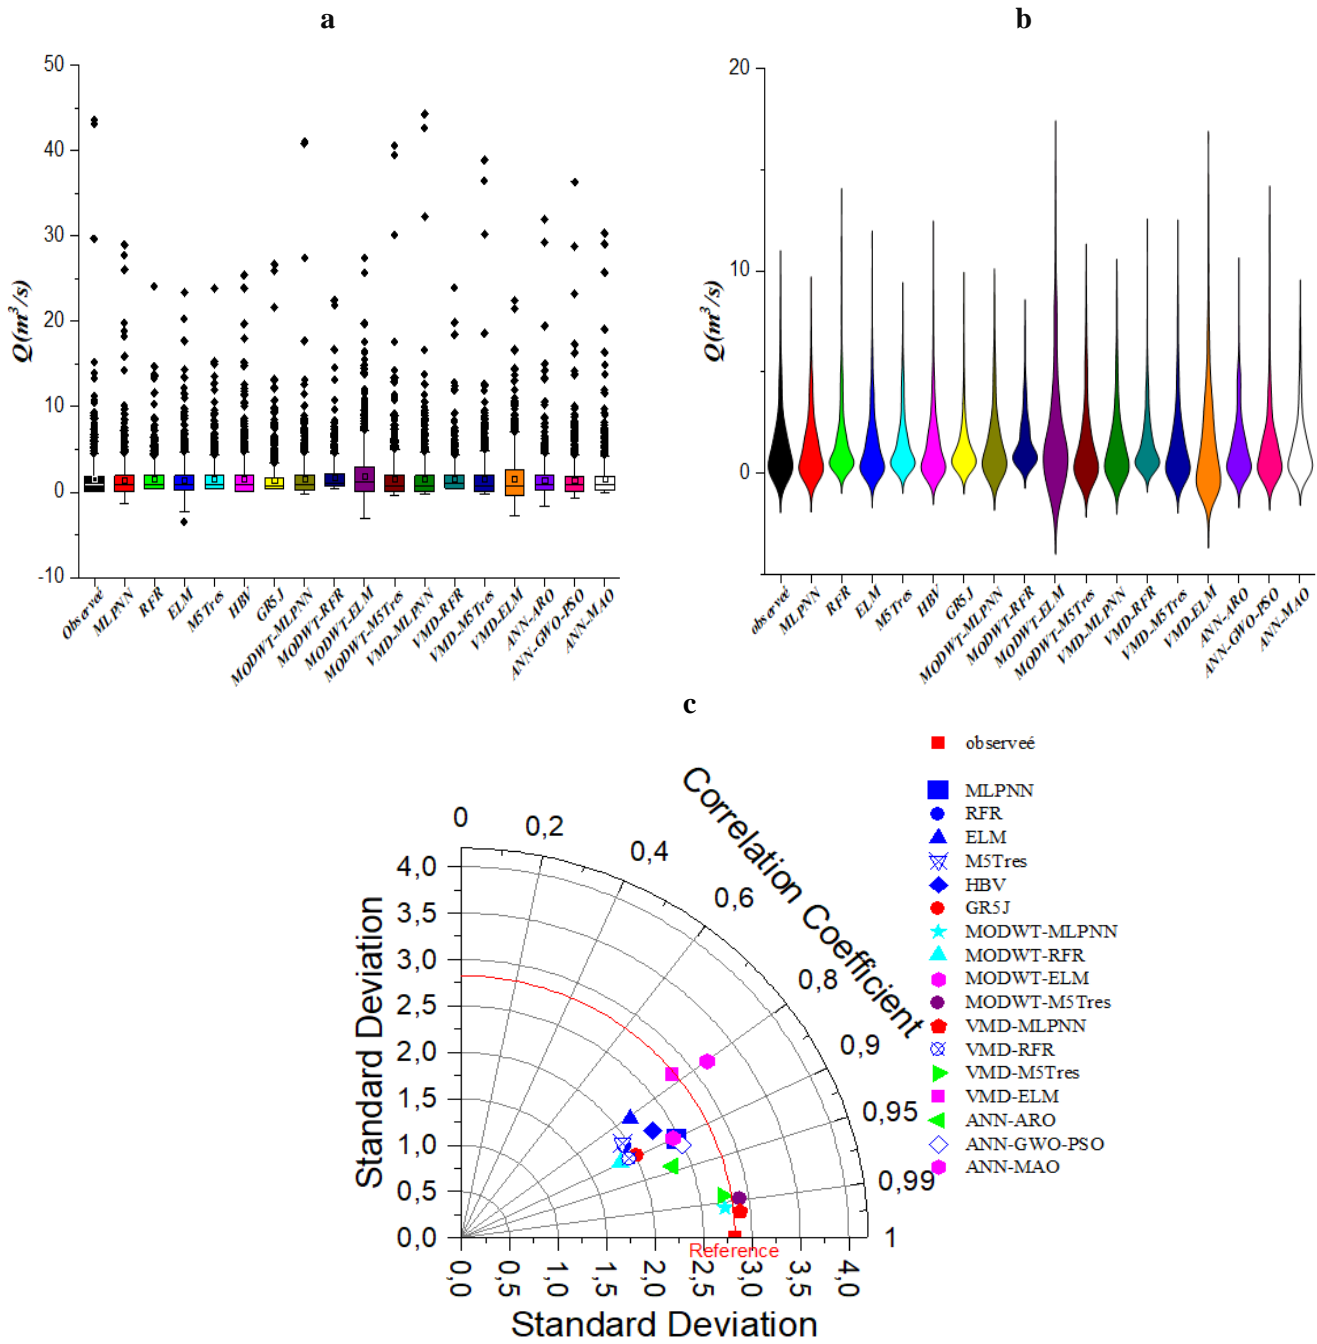


Figure.VI.1. Performances des meilleurs modèles en phase validation à la station RN25 : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

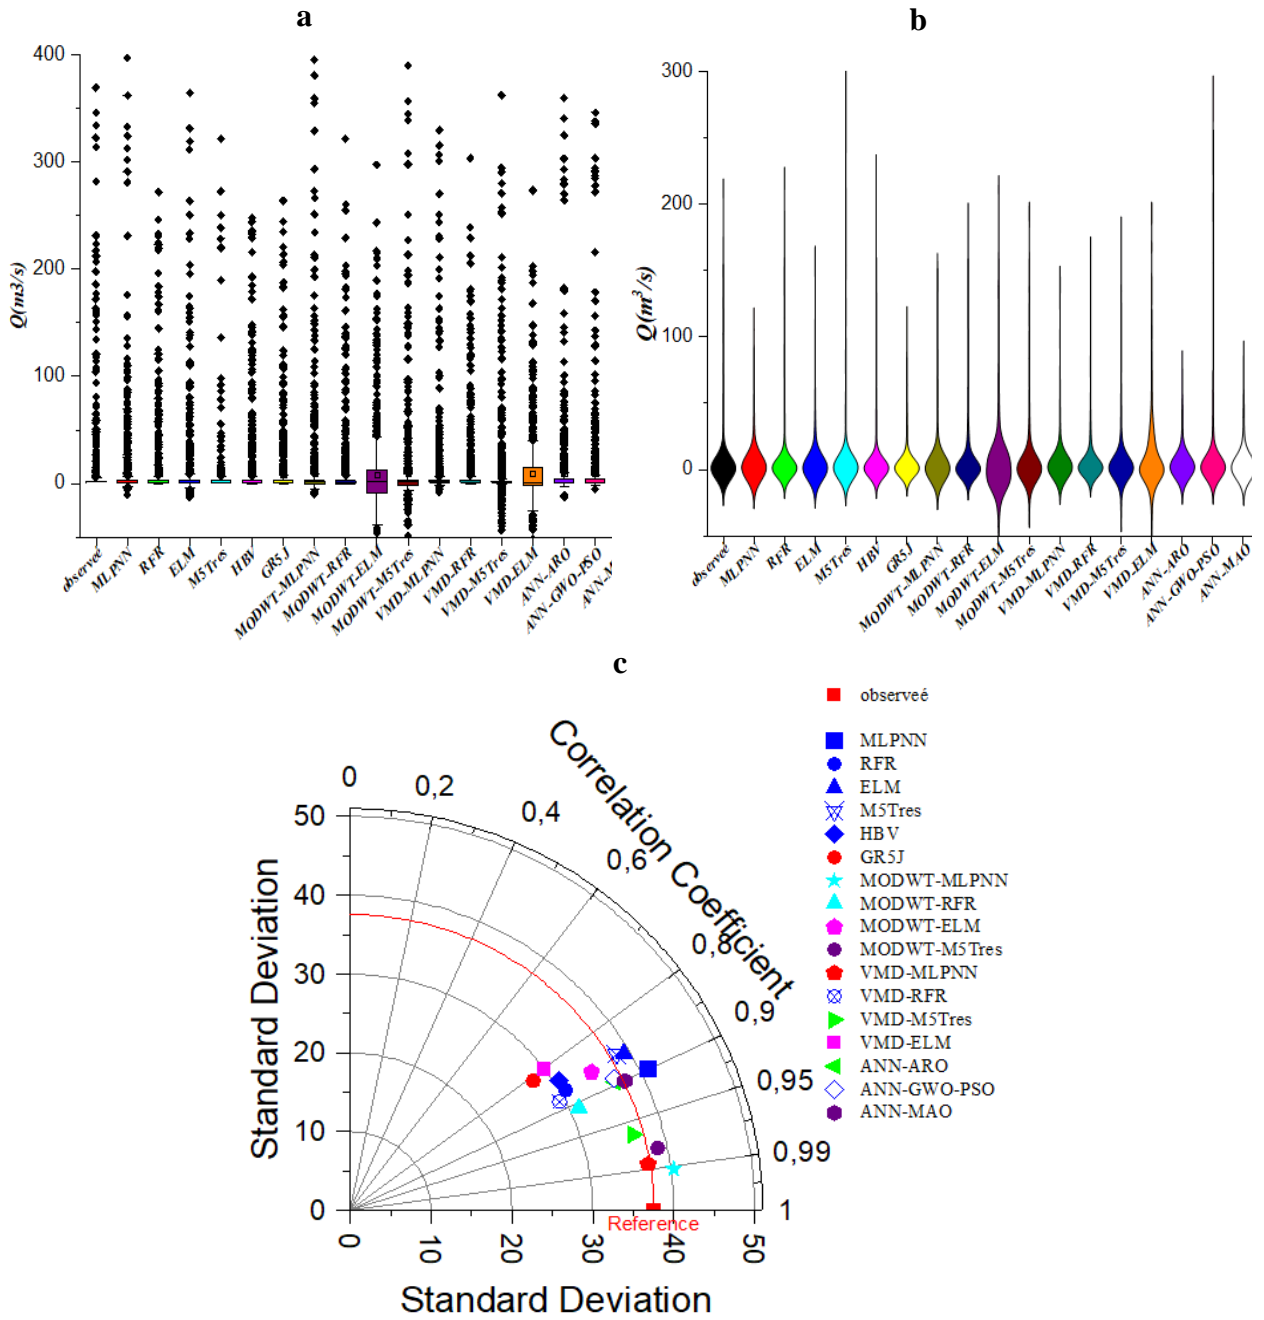


Figure.VI.2. Performances des meilleurs modèles en phase validation à la station AIN ASSEL :
 (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

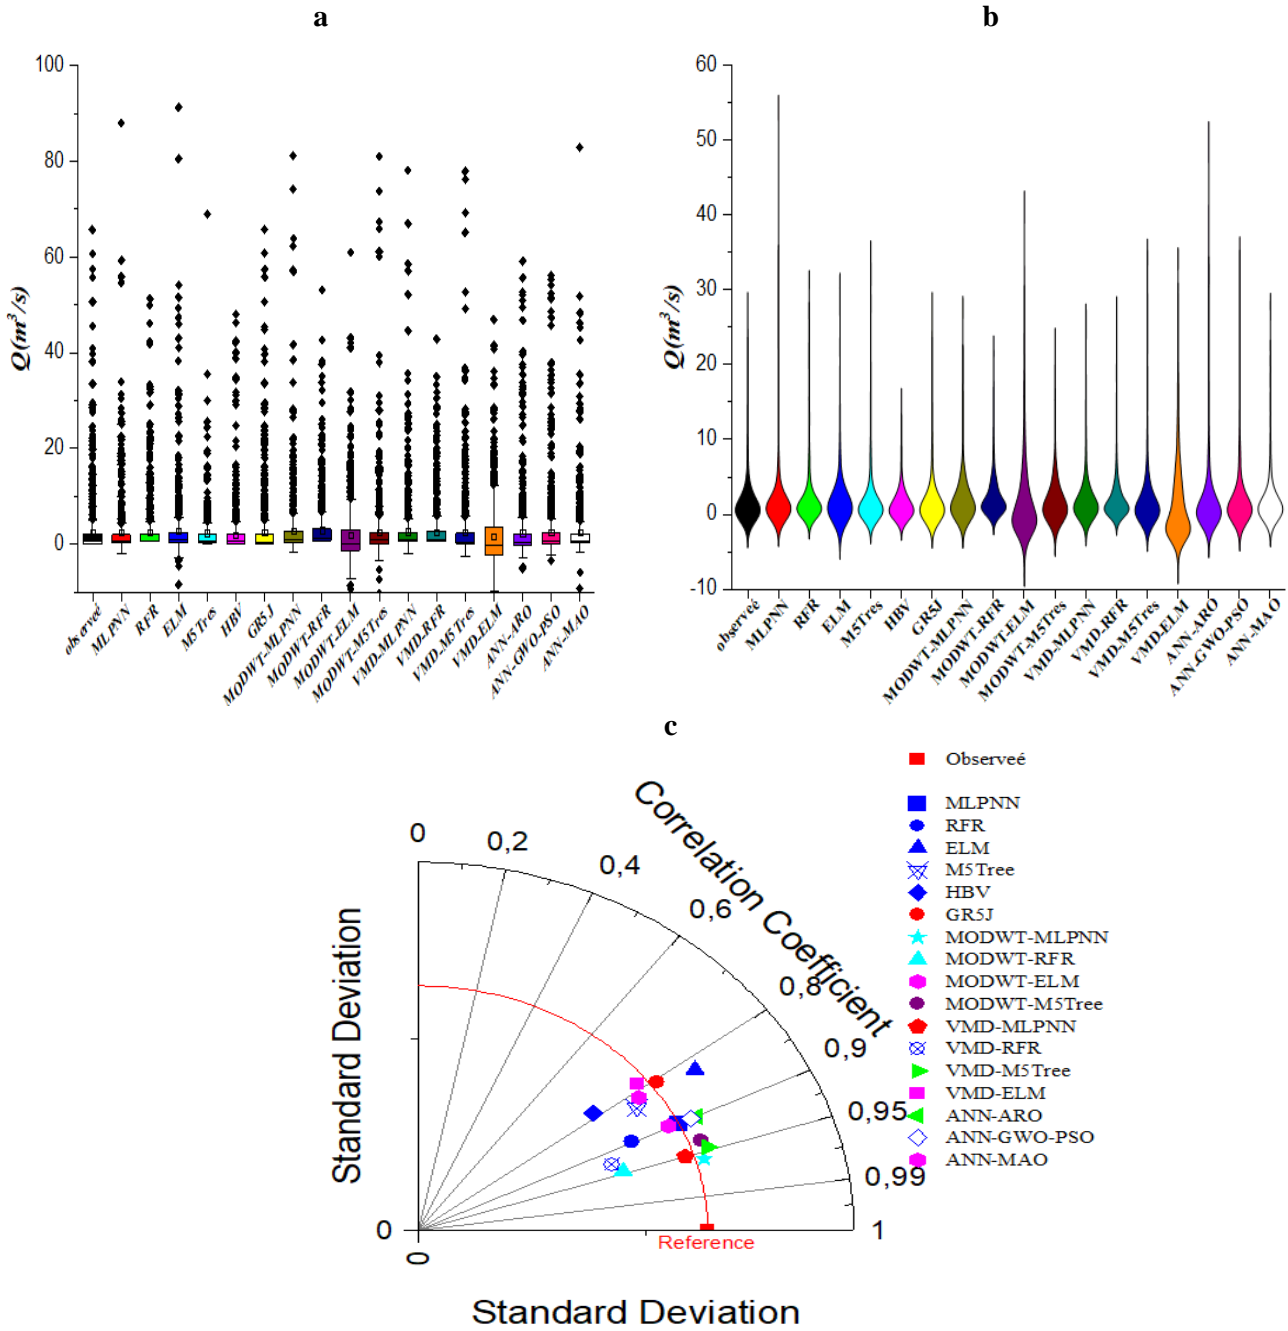


Figure.VI.3. Performances des meilleurs modèles en phase validation à la station BOUCHEGOUF : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor

Les résultats obtenus pour les trois stations (RN25, AIN ASSEL, BOUCHEGOUF) révèlent des différences notables dans les performances des modèles utilisés, critères graphiques dans les figures VI.1, 2 et 3 et les critères numériques dans les tableaux VI.1, 2 et 3.

Pour la station RN25, les modèles hybrides avec décomposition de signal (MODWT et VMD) ont montré des performances supérieures par rapport aux modèles autonomes et

conceptuels. Les modèles MODWT-MLPNN, MODWT-M5Tree, MODWT-MLPNN et MODWT-M5Tree ont particulièrement bien performé avec des valeurs de NSE proches de 1, indiquant une très bonne concordance entre les valeurs observées et simulées. A titre d'exemple, le MODWT-MLPNN a atteint un NSE de 0.987 en calage et de 0.985 en validation, avec des RMSE faibles (0.410 m³/s en calage et 0.347 m³/s en validation), et le MODWT-M5Tree a obtenu des résultats exceptionnels avec un NSE de 0.998 en calage et de 0.977 en validation, et des RMSE encore plus faibles (0.172 m³/s en calage et 0.428 m³/s en validation). Ces résultats montrent que la décomposition MODWT améliore significativement la précision des prédictions des modèles MLPNN et M5Tree. Les modèles conceptuels (GR5J et HBV) ont montré des performances acceptables mais inférieures aux modèles hybrides, avec des NSE variant entre 0.720 et 0.750 en validation.

Pour la station AIN ASSEL, les résultats sont similaires avec les modèles hybrides offrant les meilleures performances. Cependant, il est notable que les modèles VMD associés à des algorithmes d'optimisation n'ont pas montré une amélioration significative, voire des performances inférieures dans certains cas. Le MODWT-MLPNN, a de nouveau montré des performances supérieures avec un NSE de 0.987 en calage et de 0.985 en validation, et le MODWT-M5Tree avec un NSE de 0.998 en calage et de 0.977 en validation, similaire aux résultats de la station RN25. Les modèles VMD-M5Tree et VMD-MLPNN ont également montré de bonnes performances.

Pour la station BOUCHEGOUF, les résultats sont similaires, avec des modèles hybrides offrant les meilleures performances. Le MODWT-MLPNN, bien que performant avec un NSE de 0.998 en calage, il a montré une baisse significative en validation (NSE de 0.912). Le NMODWT-M5Tree, a maintenu de bonnes performances avec un NSE de 0.987 en calage et de 0.863 en validation. Les modèles conceptuels (GR5J et HBV), ont montré des performances acceptables mais surpassés par les modèles hybrides, que ce soit avec les algorithmes d'optimisation ou les décompositions de signal. Les résultats montrent également que les modèles d'apprentissage automatique simples (MLPNN, RFR et ELM) ont des performances variables, souvent inférieures aux modèles hybrides.

Les résultats montrent que les modèles hybrides, en particulier ceux utilisant des techniques de décomposition de signal (MODWT et VMD) et des algorithmes d'optimisation (ANN-ARO et ANN-GWO-PSO), offrent les meilleures performances en termes de précision et de robustesse pour toutes les stations. Ils présentent des valeurs de R et NSE très élevées,

ainsi que des valeurs de RMSE et MAE plus faibles par rapport aux modèles conceptuels (GR5J et HBV) et aux modèles d'IA autonomes (MLPNN, RFR, ELM et M5tree).

Les modèles conceptuels, bien que fiables et robustes, ne parviennent pas à atteindre le niveau de précision des modèles hybrides avancés. Les modèles d'IA autonomes montrent des performances intermédiaires mais sont souvent surpassés par les modèles hybrides.

Ainsi, pour une application efficace de la modélisation pluie-débit, l'intégration de techniques avancées comme la décomposition de signal et l'optimisation est fortement recommandée. Ces modèles hybrides permettent d'améliorer significativement la capacité de prévision et la précision des résultats.

Les résultats de notre étude, sur la modélisation pluie-débit au pas de temps journalier, ont montré que les modèles hybrides, combinant des décompositions de signaux (comme MODWT et VMD) avec des algorithmes d'optimisation, ont offert les meilleures performances par rapport aux modèles conceptuels et aux modèles d'intelligence artificielle autonomes. En particulier, les modèles MODWT-MLPNN et MODWT-M5Tree ont constamment montré des résultats supérieurs dans les différentes stations étudiées, avec des valeurs élevées du coefficient de corrélation (R) et du coefficient de Nash-Sutcliffe (NSE), ainsi que des valeurs réduites de l'erreur quadratique moyenne (RMSE) et de l'erreur absolue moyenne (MAE). Cette approche intégrée a permis une modélisation plus précise et fiable des relations pluie-débit, démontrant l'efficacité des techniques hybrides dans l'amélioration des prévisions hydrologiques au pas de temps journalier.

VI.2.2 Pas de temps mensuel et annuels

Dans cette partie, nous nous sommes concentrés sur la modélisation du débit mensuel en utilisant différentes approches. Tout d'abord, nous avons utilisé un modèle conceptuel GR2M, qui est largement utilisé pour la modélisation hydrologique à l'échelle mensuelle en raison de sa simplicité. Ensuite, nous avons exploré quatre modèles d'intelligence artificielle autonomes : MLPNN, RFR, ELM et M5Tree. Ces modèles ont été choisis pour leur capacité à apprendre à partir des données et à capturer les relations complexes entre les variables hydrologiques. Enfin, nous avons utilisé trois modèles d'intelligence artificielle hybrides avec des algorithmes d'optimisation ; ARO, PSO-GWO, MAO. Ces modèles combinent les avantages des approches d'optimisation et d'apprentissage automatique pour améliorer la précision des prévisions de débit mensuel.

Tableau.VI.4. Récapitule des résultats de tous les modèles pour RN25 au pas de temps mensuel

Modele	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR2M	0.950	0.910	1.420	0.160	0.880	0.770	1.270	0.160
MLPNN1	0.915	0.967	0.045	0.002	0.913	0.527	0.173	0.016
RFR1	0.882	0.765	0.119	0.004	0.815	0.637	0.152	0.012
M5Tree1	0.977	0.926	0.067	0.003	0.824	0.708	0.136	0.012
ELM1	0.970	0.960	0.049	0.003	0.797	0.732	0.130	0.014
ANN-ARO1	0.981	0.951	0.054	0.003	0.944	0.719	0.176	0.023
ANN-GWO-PSO1	0.913	0.880	0.085	0.005	0.942	0.786	0.117	0.012
ANN-MAO1	0.987	0.976	0.038	0.002	0.899	0.696	0.139	0.015

Tableau.VI.5. Récapitule des résultats de tous les modèles pour AIN ASSEL au pas de temps mensuel

Modele	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR2M	0.900	0.730	3.350	0.370	0.900	0.700	0.030	0.610
MLPNN1	0.997	0.995	0.133	0.012	0.921	0.800	1.685	0.511
RFR1	0.914	0.800	0.810	0.077	0.744	0.562	2.532	0.262
M5Tree1	0.900	0.811	0.787	0.068	0.746	0.511	2.675	0.292
ELM1	0.982	0.964	0.343	0.039	0.806	9.751	12.542	1.384
ANN-ARO1	1.000	0.999	0.055	0.005	0.930	0.798	5.129	0.561
ANN-GWO-PSO1	0.997	0.994	0.136	0.011	0.922	0.720	2.024	0.240
ANN-MAO1	0.997	0.995	0.129	0.010	0.894	0.784	5.380	0.531

Tableau.VI.6. Récapitule des résultats de tous les modèles pour BOUCHEGOUF au pas de temps mensuel

Modele	Calage				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
GR2M	0.940	0.860	0.930	0.100	0.860	0.680	1.250	0.180
MLPNN1	0.998	1.000	0.013	0.001	0.910	0.793	0.322	0.025
RFR1	0.927	0.775	0.294	0.014	0.614	0.354	0.570	0.046
M5Tree1	0.969	0.912	0.183	0.008	0.581	0.392	0.553	0.038
ELM1	0.953	0.961	0.123	0.008	0.540	0.172	0.645	0.057
ANN-ARO1	1.000	1.000	0.006	0.000	0.925	0.903	0.221	0.021
ANN-GWO-PSO1	0.998	1.000	0.013	0.001	0.910	0.793	0.322	0.025
ANN-MAO1	0.994	0.998	0.026	0.001	0.904	0.751	0.354	0.027

Tandis que les figures VI.4, 5 et 6, montrent les performances des modèles sélectionnés dans cette étude pour les stations : RN25, Ain Assel et Bouchegouf, en se basant sur les critères graphiques.

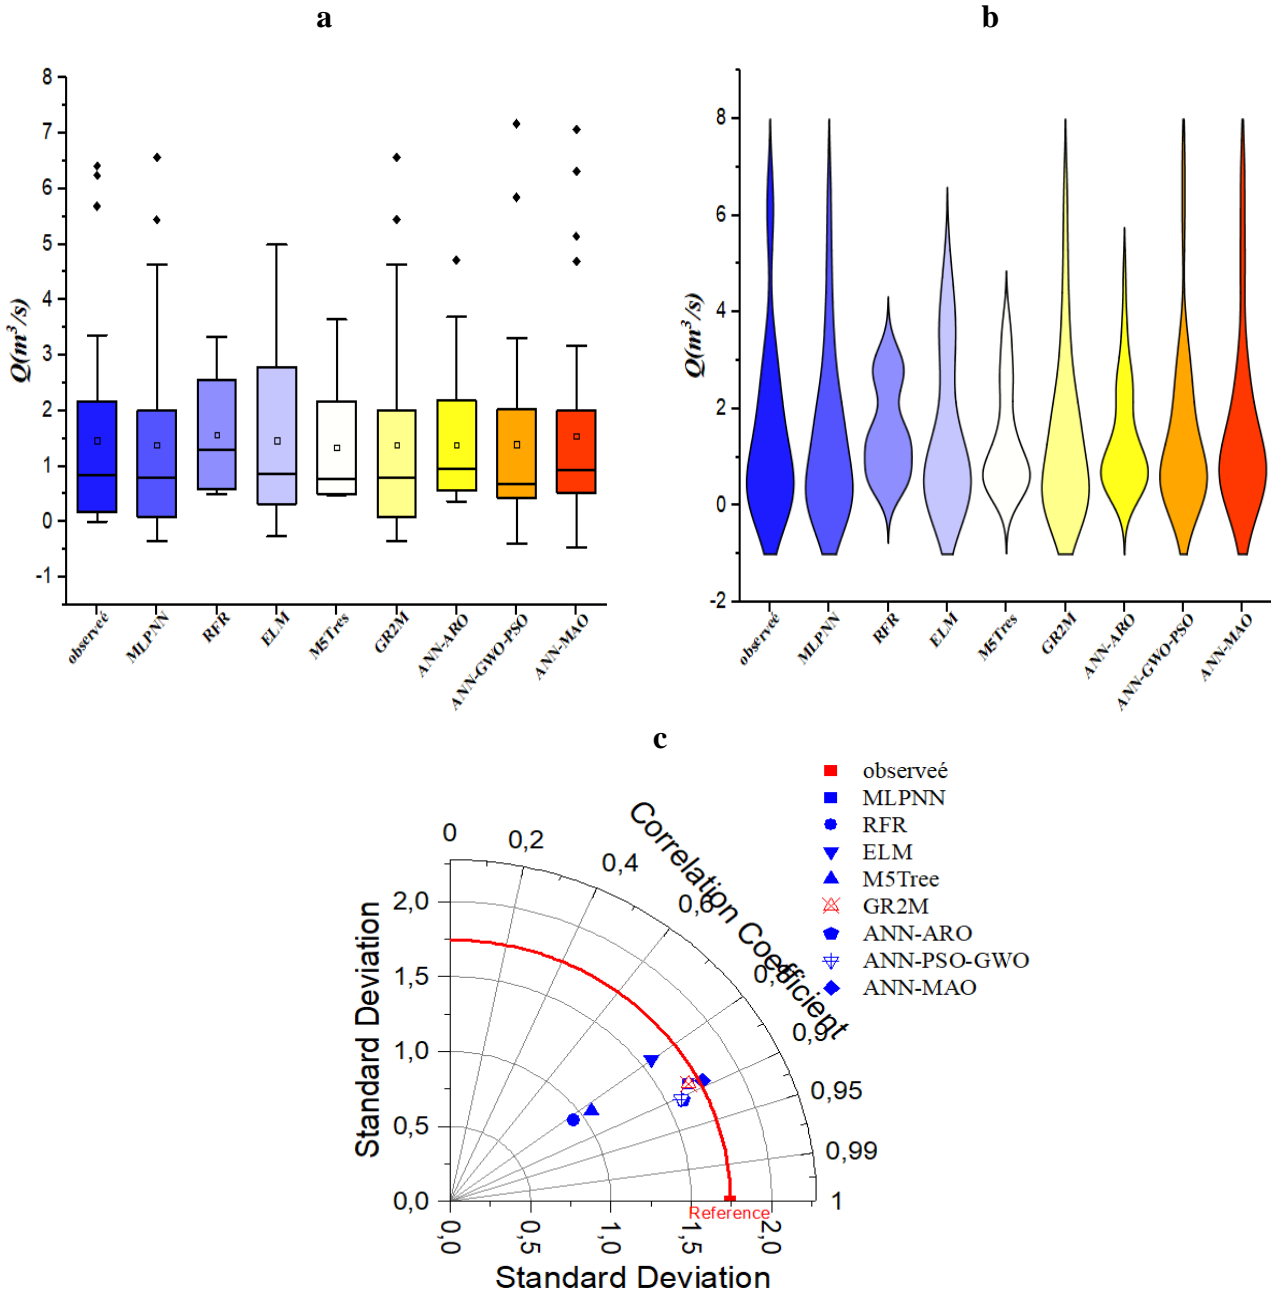


Figure.VI.4. Performance des meilleurs modèles en phase validation à la station RN25 : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor

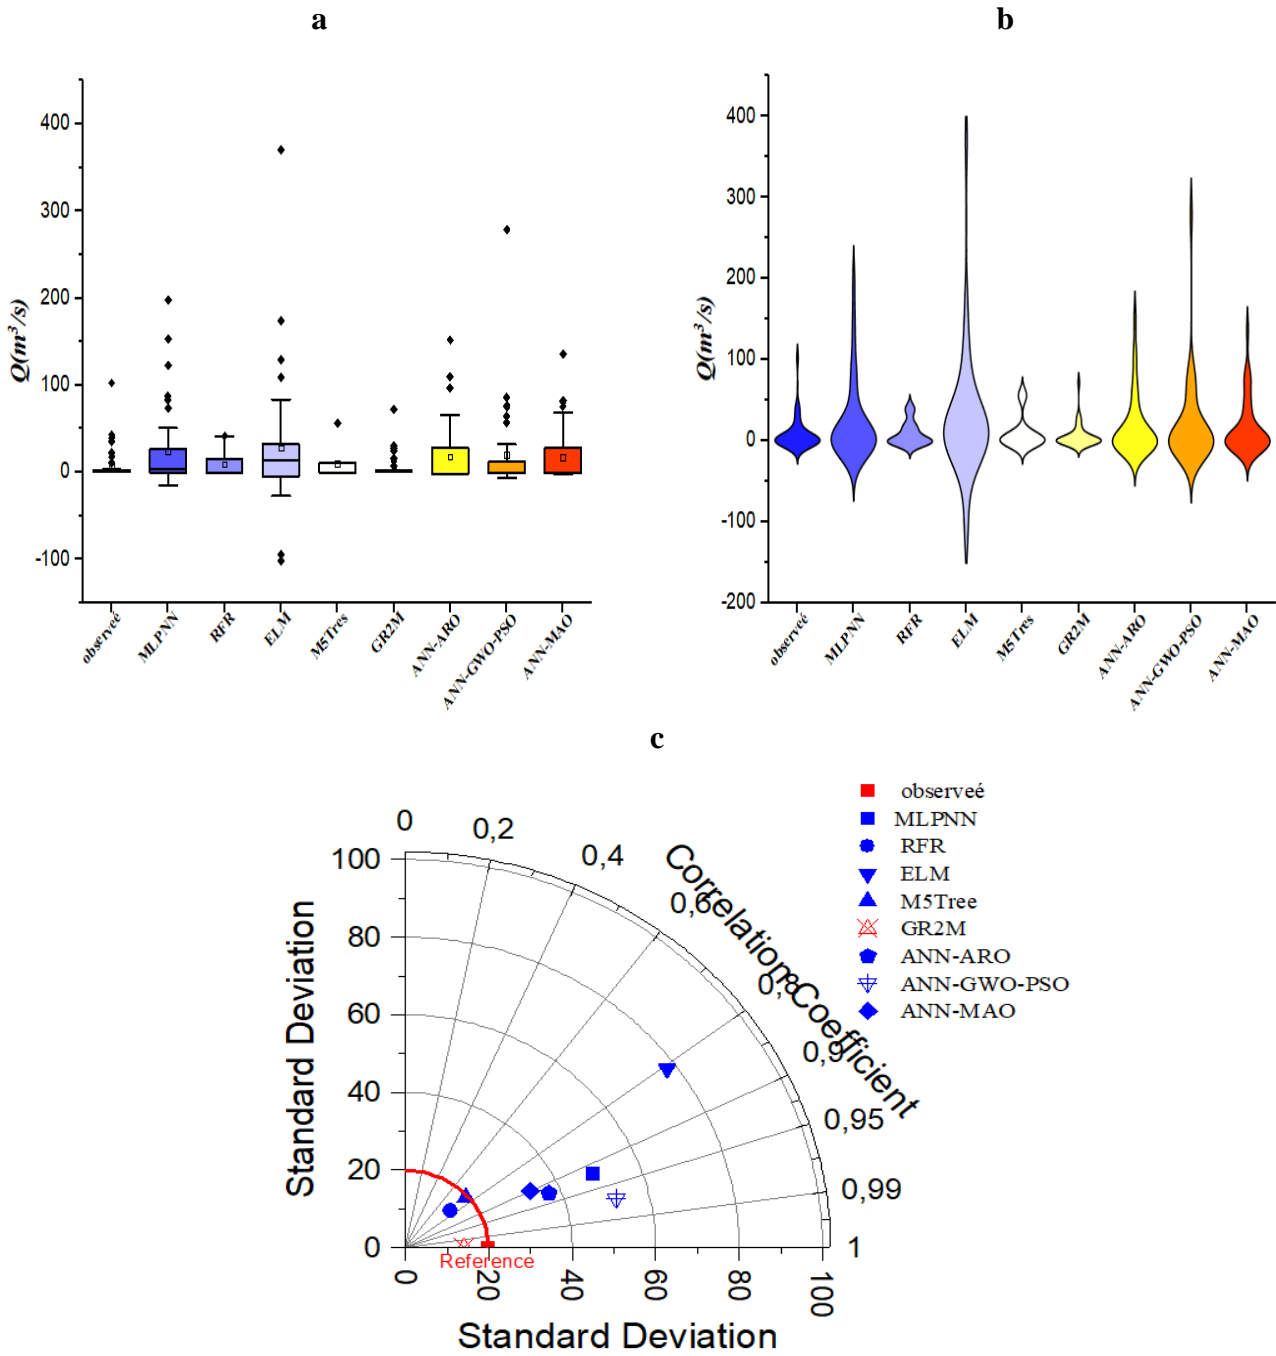


Figure.VI.4. Performance des meilleurs modèles en phase validation à la station AIN ASSEL :

(a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor

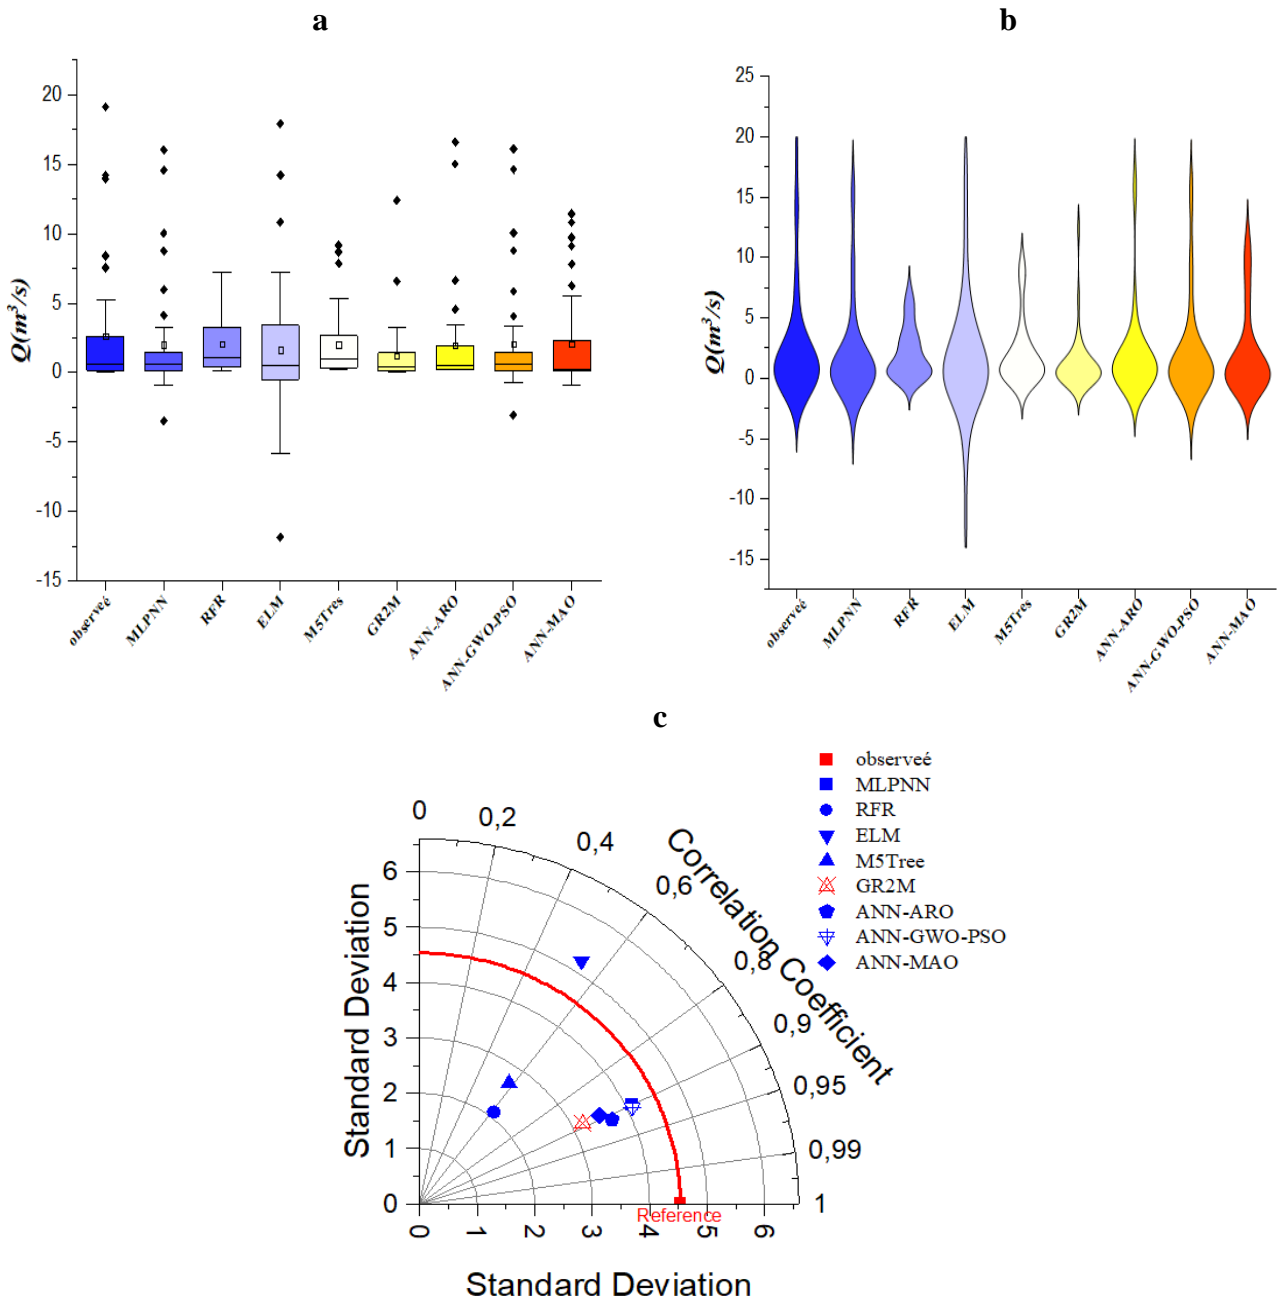


Figure.VI.5. Performances des meilleurs modèles en phase validation à la station BOUCHEGOUF : (a) Boxplot, (b) Violin plot, et (c) Diagramme de Taylor

Les résultats obtenus des différentes approches de modélisation du débit mensuel montrent des variations significatives en termes de performances, particulièrement lors de la phase de validation. Les modèles hybrides, tels que l'ANN-ARO1, ANN-GWO-PSO1 et ANN-MAO1, affichent des coefficients de corrélation (R) élevés (souvent supérieurs à 0.90) pour les trois stations, indiquant une forte capacité à prédire avec précision les débits mensuels. A titre indicatif, pour la station RN25, le

modèle ANN-ARO1 a un coefficient de corrélation de 0.944, tandis que le modèle GR2M a un coefficient de 0.880.

Les modèles d'intelligence artificielle autonomes (MLPNN, RFR, ELM et M5Tree) ont également montré des performances intéressantes, bien que légèrement inférieures aux modèles hybrides. Le modèle MLPNN1, par exemple, a présenté un coefficient de corrélation de 0.913 pour la station RN25. Le modèle conceptuel GR2M, bien qu'efficace et simple, a montré des performances moindres en termes de précision comparé aux modèles d'intelligence artificielle, avec des coefficients de corrélation légèrement plus bas.

Les performances supérieures des modèles hybrides peuvent être attribuées à leur capacité à combiner les avantages des algorithmes d'optimisation et des techniques d'apprentissage automatique. Les algorithmes d'optimisation, tels que ARO, GWO-PSO et MAO, améliorent l'apprentissage des modèles en ajustant les paramètres de manière plus précise, ce qui conduit à une meilleure modélisation des relations complexes entre les variables hydrologiques.

Cependant, la complexité accrue des modèles hybrides peut représenter une barrière à leur utilisation dans certaines applications pratiques, où la simplicité et la robustesse sont prioritaires. Le modèle GR2M, bien que moins performant en termes de précision, offre une solution robuste et facile à mettre en œuvre, ce qui peut être avantageux dans des contextes où les ressources et les données sont limitées.

La station Ain Assel illustre bien cette discussion ; bien que les modèles hybrides et autonomes montrent des coefficients de corrélation élevés, le modèle GR2M a maintenu une performance relativement stable avec un coefficient de corrélation de 0.900, démontrant ainsi sa robustesse et sa fiabilité.

Les résultats de cette étude montrent, que les modèles hybrides sont les plus performants pour la modélisation du débit mensuel, grâce à leur capacité à modéliser les relations complexes entre les variables. Cependant, le choix du modèle doit être guidé par les besoins spécifiques de l'application, la disponibilité des données et les ressources techniques disponibles.

Pour des applications nécessitant une précision élevée et disposant des ressources nécessaires pour implémenter des modèles complexes, les modèles hybrides (ANN-ARO1 et ANN-GWO-PSO1) sont recommandés. En revanche, pour des situations où la simplicité et la robustesse sont primordiales, le modèle conceptuel GR2M reste une option viable.

En conclusion, la sélection du modèle pour la modélisation du débit mensuel doit être adaptée aux conditions spécifiques de l'étude et aux objectifs de la modélisation. Les modèles hybrides offrent

des performances supérieures en termes de précision, tandis que le modèle GR2M fournit une solution simple et robuste pour des applications pratiques. Cette étude met en lumière l'importance de l'approche hybride dans l'amélioration de la précision des prévisions hydrologiques, tout en reconnaissant la valeur des modèles conceptuels pour leur simplicité et leur robustesse.

Les résultats obtenus par le modèle GR1A (Tableau V.5 chapitre V) pour la modélisation des débits annuels dans plusieurs stations, montrent des performances variables selon les stations, avec des valeurs de NSE allant de 0.15 à 0.81 en phase de validation. Par exemple, la station de Bouchegouf affiche une performance élevée avec un NSE de 0.81, indiquant une bonne correspondance entre les valeurs observées et modélisées, tandis que la station de Fermatou présente un NSE de 0.22 seulement, révélant une performance moins satisfaisante. Ces variations peuvent être attribuées aux caractéristiques spécifiques de chaque bassin versant, telles que la topographie, l'utilisation des sols et les conditions climatiques, qui influencent la réponse hydrologique.

En généralisant ces résultats, il est évident que le modèle GR1A peut fournir des prédictions fiables pour certains bassins versants mais peut nécessiter des ajustements et des calibrations supplémentaires pour d'autres. Cela souligne l'importance d'une évaluation locale minutieuse et d'une adaptation des paramètres du modèle aux conditions spécifiques de chaque site pour améliorer la précision des prévisions annuelles. Ces résultats mettent également en évidence la nécessité d'utiliser une combinaison de modèles et de techniques d'évaluation pour capturer efficacement la variabilité des débits annuels à travers différentes régions.

VI. 3 Performances des Modèles Testés aux pas de Temps Journalier et Mensuel

Ce paragraphe, donne une comparaison des résultats des modèles testés dans ce travail, avec ceux trouvés par d'autres chercheurs dans des études antérieures concernant la relation pluie-débit. L'objectif est d'évaluer la performance de nos approches de modélisation à la fois pour les échelles journalière et mensuelle, en appuyant sur la littérature existante. Cette comparaison nous permettra de situer nos résultats par rapport à l'état de l'art de la modélisation hydrologique et d'identifier les points forts et les points faibles de nos approches. Nous nous concentrerons, notamment, sur les critères d'évaluation couramment utilisés tels que ; R, NSE, RMSE et MAE. En analysant ces résultats, nous pourrons tirer des conclusions sur la performance relative de nos modèles et proposer des recommandations pour de futures améliorations.

Selon une recherche précédemment menée, Tikhamarine et al. (2019) utilisent le SVR à base d'ondelettes - optimisé par l'optimiseur du loup gris (WSVR-GWO), pour la prédiction mensuelle des débits, à partir de deux stations de jaugeage, Ain Bedra et Fermatou, en Algérie. Les résultats obtenus montrent que R et NSE sont presque égaux à 0.978 et 0.95 pour la station Ain Berda, et 0.98 et 0.96 pour la station Fermatou respectivement. Comparés à ceux obtenus dans notre étude, nous pouvons conclure que nos résultats sont meilleurs, étant donné que nous travaillons à un pas de temps journalier. Khazae Poul et al. (2019) ont couplé la MLR, l'ANN, l'ANFIS et les K plus proches voisins (KNN) avec la WT, pour prédire le débit mensuel d'une rivière entre les États-Unis et le Canada. Le meilleur modèle, pour eux, est WT-ANN avec les performances suivantes : R= 0.965, NSE=0.930, qui sont inférieures aux valeurs obtenues dans notre étude. Kambalimath et Paresh (2021) évaluent l'amélioration des performances du modèle SVM en utilisant la DWT pour la prévision quotidienne du débit d'eau pour le bassin versant de la rivière Malaprabha, un sous-bassin du bassin de la rivière Krishna en Inde. Les performances du modèle SVM ont nettement augmenté lorsque la méthode DWT est couplée. Il est à noter que la valeur de R^2 pour l'utilisation de SVM est de 0.91, cependant, lorsque la méthode des ondelettes est couplée au modèle SVM, le R^2 augmente à 0.99. En termes d'amélioration des performances, nos résultats sont plus efficaces. Xie et al., (2022) dans cette étude, une hybridation entre un LSTM et DWT est proposée pour gérer les prévisions de débit journalières. Dans les séquences de débit journalier de sept ans de trois affluents d'un cours d'eau, ils ont constaté que le modèle hybride avec DWT donne le plus haut R = 0,99. Ces résultats sont similaires à ceux obtenus dans notre étude. Rezaie-Balf et al., (2019) ont utilisé une hybridation entre les modèles EEMD, M5Tree et MARS pour la prévision du débit journalier des rivières pérennes en Iran et en Corée du Sud. Ils ont constaté que le modèle EEMD-MARS offre la meilleure performance avec un NSE de 0,819 et un RMSE de 7,206. Hui Hu et al., (2021) ont hybridé le VMD et les réseaux neuronaux à rétropropagation (BPNN) pour les séries de débits journaliers des stations hydrologiques de Laoyukou et Wushan en Chine. Les performances d'estimation du modèle VMD-BPNN étaient supérieures à celles de cinq autres modèles à la station de Wushan. Leurs performances étaient RMSE=2,62 m³/s, MAE=1,38 m³/s, NSE=0,9792. Comparées aux deux études mentionnées précédemment, les résultats obtenus dans notre étude étaient plus précis. Seo et al., (2018) proposent deux modèles d'apprentissage automatique hybrides couplés avec VMD. Les modèles LSSVR et VMD-LSSVR atteignent la meilleure performance dans la modélisation du débit journalier. Zakhrouf et al. (2020)

appliquent ANN, les systèmes neuro-flous adaptatifs (ANFIS) et les réseaux de neurones basés sur les ondelettes (WNN), pour la prévision du débit journalier dans le bassin de Chellif, situé dans le nord de l'Algérie. Selon les résultats statistiques du modèle hybride, WNN fonctionne mieux que les modèles autonomes ANN et ANFIS, avec un NSE de 0,8 et un R de 0,917, des valeurs inférieures à celles obtenues par hybridation avec MODWT dans notre étude. Tikhamarine et al. (2020a) ont utilisé l'optimiseur du loup gris (GWO) pour prédire le débit mensuel du Nil, qui traverse l'Égypte, en conjonction avec trois modèles (ANN, SVR et MLR). Notre étude montre des valeurs de R (0,942 à 0,982) et de NSE (0,873 à 0,960) plus élevées par rapport à leurs résultats. Difi et al. (2022) ont utilisé ELM avec BAT pour prévoir le débit mensuel dans le bassin de Cheliff, en Algérie, et ont obtenu une valeur de R de 0,973, inférieure aux valeurs obtenues par ANN-ARO dans notre étude.

Samanataray et Abinash, (2021) ont couplé ANFIS avec PSO pour la prévision mensuelle des débits dans le bassin de la rivière Barak en Inde, obtenant un R^2 de 0.9668 et un NSE de 0.961. Cependant, les résultats de notre étude ont été jugés précis. Guo et al., (2011) ont utilisé SVR et un algorithme PSO amélioré pour prédire le débit mensuel en Chine. En comparaison avec nos résultats, leur étude a produit des valeurs plus faibles pour le R à 0.913 et NSE à 0,834. Sezen and Partal, (2019) dans cette étude, ils ont comparé les performances du modèle ANN, du modèle de réseau neuronal artificiel basé sur les ondelettes (WANN) et de GR4J pour la modélisation journalière de débit de deux rivières aux États-Unis. Il a été obtenu que le WANN présente la meilleure performance avec des coefficients de corrélation supérieurs à 0,97 pour les deux stations, et cela est très proche de nos résultats.

Sohrabi et al., (2021) pour la modélisation de pluie-debit, ont utilisé le modèle HBV et RFR dans le bassin versant de Bazoft en Iran. Les résultats des modèles HBV et RFR ont révélé que le modèle RFR était plus performant que le HBV. Mvoundou et al., (2022) ont utilisé le modèle GR2M pour la prévision de débit mensuel dans le bassin du Kouilou-Niari, Congo. Les valeurs du critère de NSE et celles du R obtenues sont supérieures à 80% en validation, ce qui explique la performance et la robustesse du modèle GR2M sur ce bassin. Sezen and Partal (2019) dans cette étude, une comparaison est faite entre les performances des modèles conceptuels agrégés (Génie Rural à 4 paramètres Journalier (GR4J), Génie Rural à 6 paramètres Journalier (GR6J)) et des modèles basés sur les ondelettes (Wavelet-Genetic, algorithm-Artificial neural network (WGANN), Wavelet-based support vector regression (WSVR)) dans les zones semi-arides et humides du bassin d'Antalya en Turquie. Les résultats étaient les suivants WGANN (NSE = 0,96, RMSE = 0,5 mm/j), WSVR (NSE = 0,95, RMSE

= 0,6 mm/j) contre GR4J (NSE = 0,53, d = 0,79, RMSE = 1,8 mm/j) et GR6J (NSE = 0,49, d = 0,78, RMSE = 1,8 mm/j).

Abda et Chettih (2018) ont mené une enquête sur les modèles hybrides intelligents intégrant les transformations de wavelet et Hilbert-Huang pour prédire les débits journaliers dans le bassin de Sebaou, situé au nord de l'Algérie. Leur étude évalue deux méthodologies hybrides distinctes qui combinent un système de déduction neuro-flou adaptatif (ANFIS) et un réseau de neurones artificiels (ANN) avec la décomposition modale empirique (EMD) et les transformations de wavelet. Le modèle le plus efficace s'est avéré être le modèle Wavelet-ANN, atteignant une valeur R de 0.86, fournissant ainsi des résultats plus précis. Zakhrouf et al. (2020a) ont exploré la mise en œuvre de techniques d'apprentissage automatique évolutives pour prévoir les débits fluviaux dans la rivière Seybous, en Algérie. Cette recherche combine plusieurs modèles d'apprentissage automatique, notamment les réseaux de neurones artificiels (ANN), les systèmes de déduction neuro-flou adaptatif (ANFIS) et les réseaux de neurones basés sur les wavelets (WNN), avec un algorithme d'optimisation évolutif visant à améliorer la précision des prévisions de débit fluvial. L'étude a obtenu les meilleurs résultats avec le modèle Wavelet-ANN, enregistrant une valeur R de 0.969, indiquant une précision supérieure des résultats par rapport aux études précédentes. Tikhamarine et al. (2022) introduisent une nouvelle approche de prédiction des débits fluviaux combinant une transformation en ondelettes discrètes (DWT) avec un réseau de neurones artificiels (ANN) pour analyser les données de débit mensuel de la station de jauge Bouchegouf dans le bassin versant de la Seybouse. Les résultats de cette approche sont prometteurs, le réseau Wavelet-ANN (WANN) atteignant une valeur R de 0.96 et une efficacité NSE de 0.93, démontrant son efficacité dans la prédiction des débits fluviaux.

VI.4. Conclusion

Dans ce chapitre, nous avons comparé les performances des modèles de prévision du débit pour différents pas de temps : journalier, mensuel et annuel. Nous avons constaté que les modèles utilisant la décomposition de signal sont les plus performants pour le pas de temps journalier. En revanche, pour le pas de temps mensuel, les modèles hybrides avec des algorithmes d'optimisation se sont révélés plus efficaces, tandis que les modèles conceptuels ont été plus appropriés pour le pas de temps annuel. Ces résultats mettent en évidence l'importance de choisir le bon type de modèle en fonction de la périodicité de l'analyse hydrologique.

CONCLUSION

GENERALE

CONCLUSION GENERALE

Dans cette thèse, notre objectif principal était de modéliser la relation entre les précipitations et les débits, l'étude appliquée sur huit stations qui sont réparties dans le Nord algérien. Nous avons cherché à comprendre comment différents modèles peuvent être utilisés pour représenter cette relation à différentes échelles de temps (journalière, mensuelle et annuelle). En utilisant une variété de modèles, y compris des modèles d'apprentissage automatique, des modèles conceptuels et des modèles hybrides, nous avons cherché à déterminer les modèles les plus performants pour chaque échelle de temps, pour améliorer la modélisation des débits dans cette région, en mettant en évidence les approches les plus efficaces pour prédire les débits en fonction des précipitations.

Pour l'échelle journalière, nous avons utilisé une gamme de modèles, telle que les modèles d'apprentissage automatique simple, à savoir : MLPNN, RFR, ELM et M5Tree. Nous avons également inclus des modèles conceptuels bien établis comme GR5J et HBV, ainsi que des modèles hybrides avec décomposition de signal ; VMD et MODWT, et des modèles hybrides avec des algorithmes d'optimisation comme ARO, MAO et GWO-MAO. Pour le pas de temps mensuel, nous avons utilisé les quatre modèles d'apprentissage automatique simples mentionnés précédemment, ainsi qu'un modèle conceptuel (GR2M) et les trois modèles hybrides avec les algorithmes d'optimisation. Nous avons utilisé uniquement des modèles GR1A pour le pas de temps annuel.

Les résultats obtenus à partir des différents modèles utilisés pour le pas de temps journalier, nous permettent de tirer les conclusions suivantes :

- Les modèles conceptuels GR5J et HBV ont montré des performances acceptables. Cependant, ces modèles ont tendance à sous-estimer les débits élevés, suggérant une capacité limitée à capturer les valeurs aberrantes. De plus, les modèles conceptuels ont présenté des écarts significatifs entre les débits observés et simulés pendant certaines périodes, indiquant des limitations dans la représentation des processus hydrologiques complexes.
- Les résultats les plus performants ont été observés pour les modèles d'intelligence artificielle hybrides et simples avec le scénario numéro 1, impliquant sept variables d'entrée.

-
- Les résultats des modèles d'intelligence artificielle autonomes et hybrides avec des algorithmes d'optimisation ont été globalement acceptables, démontrant une capacité raisonnable à prédire les débits dans la région étudiée.
 - Les modèles d'apprentissage automatique hybrides avec décompositions de signal VMD et MODWT se sont généralement révélés plus performants que les autres approches en termes de performance. Les résultats obtenus par les modèles hybrides basés sur l'analyse par ondelettes utilisant le MODWT et VMD ont démontré leur capacité à identifier les séries temporelles non linéaires, les changements de tendance dans les données hydrologiques et les valeurs aberrantes. La décomposition du signal a fourni des informations précieuses pour améliorer la modélisation et la prévision hydrologiques. Les modèles hydrologiques traditionnels qui supposent la linéarité et la stationnarité peuvent ne pas capturer efficacement les variations complexes et les valeurs aberrantes dans les données. En incorporant des informations provenant de la décomposition du signal, les modèles peuvent être adaptés pour mieux tenir compte de ces caractéristiques et améliorer leurs performances prédictives. Les modèles hybrides semblent offrir des avantages significatifs pour l'intégration des flux quotidiens.

Les résultats obtenus à partir des différents modèles utilisés pour le pas de temps mensuel et annuel, nous permettent de tirer les conclusions suivantes :

- Les résultats indiquent que les modèles d'intelligence artificielle hybrides avec les algorithmes d'optimisation ont obtenu les meilleurs résultats en termes de précision et de capacité à capturer les caractéristiques complexes des données hydrologiques. Avec une nette supériorité du modèle ANN-ARO. Ces modèles se sont avérés être des outils efficaces pour la modélisation des débits mensuels, offrant des perspectives intéressantes pour une meilleure gestion des ressources en eau.
- Les résultats ont été satisfaisants pour le reste des modèles, tels que : MLPNN, GR2M. Ils peuvent être de bonnes alternatives.
- Dans le cas des pas de temps annuels, les résultats ont été moins satisfaisants en raison de la courte durée des séries temporelles disponibles. Cette limitation peut avoir un impact sur la capacité du modèle à capturer les variations annuelles et les tendances à long terme, ce qui peut entraîner des performances moins bonnes. Il serait donc important d'envisager des stratégies pour obtenir des séries temporelles plus longues ou pour adapter les modèles à des données de taille réduite.

Pour aller plus loin, il serait intéressant d'explorer d'autres modèles hybrides en intégrant des approches plus récentes telles que les réseaux de neurones convolutifs ou les réseaux de neurones récurrents. Ces modèles pourraient permettre une meilleure capture des dépendances temporelles et spatiales dans les données hydrologiques, améliorant ainsi la précision des prévisions. De plus, l'ajout de variables supplémentaires telles que les données météorologiques ou les caractéristiques du bassin versant pourrait enrichir les modèles et fournir des informations plus complètes sur les processus hydrologiques.

Par ailleurs, étant donné l'importance croissante du changement climatique, il serait judicieux de mener des études supplémentaires pour évaluer l'impact de ces changements sur les débits dans la région étudiée. Cela permettrait d'anticiper les éventuelles variations des ressources en eau et d'adapter les stratégies de gestion en conséquence.

Enfin, il est essentiel de partager les résultats de cette recherche avec les décideurs et les parties prenantes impliqués dans la gestion des ressources en eau. Ces résultats pourraient fournir des informations précieuses pour soutenir des décisions éclairées et une gestion plus durable des ressources en eau dans la région du Nord de l'Algérie.

REFERENCES BIBLIOGRAPHIQUES

1. Abda, Z., & Chettih, M. (2018). Forecasting daily flow rate-based intelligent hybrid models combining wavelet and Hilbert–Huang transforms in the mediterranean basin in northern Algeria. *ActaGeophysica*, 66(5), 1131-1150. <https://doi.org/10.1007/s11600-018-0188-0>
2. Adamowski, J., Chan, H. F., Prasher, S. O., & Sharda, V. N. (2012). Comparison of multivariate adaptive regression splines with coupled wavelet transform artificial neural networks for runoff forecasting in Himalayan micro-watersheds with limited data. *Journal of hydroinformatics*, 14(3), 731-744. <https://doi.org/10.2166/hydro.2011.044>
3. Ague, A. I., Afouda, A., & Lanhoussi, F. (2014). Etude comparative d'un modèle conceptuel global (GR4J) et d'un modèle semi-distribué (GéoSFM) sur le bassin versant de l'Ouémé à Savè (Bénin, Afrique de l'Oest). *Revue Scientifique et Technique*, 24, 1-8.
4. Ambroise, B. (1999). La dynamique du cycle de l'eau dans un bassin versant : processus, facteurs, modèles. Edition HGA, Bucarest, 200 p.
5. Amireche, M. (2018). Modélisation de la relation pluie-débit à différents pas de temps par les modèles conceptuels, neuro-flous et par le filtre de kalman (Thèse de doctorat, Université Kasdi Merbah - Ouargla), 256 p.
6. Andréassian, V. (2002). Impact de l'évolution du couvert forestier sur le comportement hydrologique des bassins versants (Thèse de doctorat, Paris 6), 206 p.
7. Anshuman, A., Kunnath-Poovakka, A., & Eldho, T. I. (2021). Performance evaluation of conceptual rainfall-runoff models GR4J and AWBM. *ISH Journal of Hydraulic Engineering*, 27(4), 365-374. <https://doi.org/10.1080/09715010.2018.1556124>
8. Aoulmi, Y., Marouf, N., Rasouli, K., & Panahi, M. (2023). Runoff predictions in a semiarid watershed by convolutional neural networks improved with metaheuristic algorithms and forced

- with reanalysis and climate data. *Journal of Hydrologic Engineering*, 28(7), 04023018. <https://doi.org/10.1061/JHYEFF.HEENG-5920>
9. Atallah, M. H., Djellouli, F., Bouanani, A., Baba-Hamed, K., Faisal, A. A., & Hasan, K. (2023). Assessment of catchment behavior of the Wadi Louza in NW-Algeria under hydrological drought conditions. *Earth Systems and Environment*, 7(1), 297-306. <https://doi.org/10.1007/s41748-022-00325-x>
 10. Bachir, S., Nouar, B., Hicham, C., Azzedine, H., & Larbi, D. (2015). Application of GR2M for rainfall-runoff modeling in Kébir Rhumel Watershed, north east of Algeria. *World applied sciences journal*, 33(10), 1623-1630. <https://doi.org/10.5829/idosi.wasj.2015.33.10.367>
 11. Belaroui, A., Haouchine, F. Z., & Haouchine, A. (2019). Rainfall-runoff modeling: flow characterization of Hammam Melouane Wadi Algeria. *Arabian Journal of Geosciences*, 12, 1-11. <https://doi.org/10.1007/s12517-019-4610-y>
 12. Benzineb, K., (2017). Modélisation des débits de crues du bassin d'oued Ouahrane par les réseaux de neurones artificiels. (Thèse de doctorat. Université Hassiba Benbouali de Chlef), 182 p.
 13. Bergström, S. (1995). The HBV model. *Computer models of watershed hydrology.*, 443-476.
 14. Berthier, C. H. (2005). Quantification des incertitudes des débits calculés par un modèle pluie-débit empirique. Université Paris Sud XI, Paris.
 15. Beven, K. (1979). On the generalized kinematic routing method. *Water Resources Research*, 15(5), 1238-1242, p. 1238.
 16. Beven, K. J. (2012). *Rainfall-runoff modelling*. John Wiley & Sons, 2nd ed., 488 p.
 17. Beven, K. J., & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological sciences journal*, 24(1), 43-69. <https://doi.org/10.1080/02626667909491834>
 18. Bouanani, A. (2004). Hydrologie, transport solide et modélisation. Etude de quelques sous bassins de la Tafna (NW Algérie). (Thèse de doctorat, Université de Tlemcen, Algérie), 249 p.

19. Bouguerne, A. (2017). Relation pluie-débit et concentration des polluants dans les Oueds Boussalem et Rhumel. Est Algérien (Thèse de doctorat, Université de Batna 2), 202 p.
20. Bouguerra, S. A., & Mansour, B. (2023). Rainfall-flow Modeling Using a Global Conceptual Model: Case of the Beni Bahdel Watershed (Northwest of Algeria). *Journal of Water Management Modeling*. <https://doi.org/10.14796/JWMM.C500>
21. Boyle, D. P., Gupta, H. V., & Sorooshian, S. (2000). Toward improved calibration of hydrologic models: Combining the strengths of manual and automatic methods. *Water Resources Research*, 36(12), 3663-3674. <https://doi.org/10.1029/2000WR900207>
22. Breiman, L. (2001). Random forests *Mach Learn* 45 (1): 5-32.
23. Chen, L., Singh, V. P., Guo, S., Zhou, J., & Ye, L. (2014). Copula entropy coupled with artificial neural network for rainfall-runoff simulation. *Stochastic environmental research and risk assessment*, 28, 1755-1767. <https://doi.org/10.1007/s00477-013-0838-3>
24. Chen, Y., Zhang, Y., & Liu, P. (2018). A review on hydrological time series decomposition: Recent developments, challenges and perspectives. *Water*, 10(6), 746.
25. Clarke, R. T. (1973). A review of some mathematical models used in hydrology, with observations on their calibration and use. *Journal of hydrology*, 19(1), 1-20. [https://doi.org/10.1016/0022-1694\(73\)90089-9](https://doi.org/10.1016/0022-1694(73)90089-9)
26. Coulibaly, P., Anctil, F., & Bobée, B. (2000). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230(3-4), 244-257. [https://doi.org/10.1016/S0022-1694\(00\)00214-6](https://doi.org/10.1016/S0022-1694(00)00214-6)
27. Daliakopoulos, I. N., Coulibaly, P., & Tsanis, I. K. (2005). Groundwater level forecasting using artificial neural networks. *Journal of hydrology*, 309(1-4), 229-240. <https://doi.org/10.1016/j.jhydrol.2004.12.001>
28. Daubechies, I. (1990). The wavelet transform time-frequency localization and signal analysis. *IEEE transactions on information theory*, 36(5), 961-1005.

-
29. Dawson, C. W., & Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 43(1), 47-66. <https://doi.org/10.1080/02626669809492102>
30. Dawson, C. W., & Wilby, R. L. (2001). Hydrological modelling using artificial neural networks. *Progress in physical Geography*, 25(1), 80-108. <https://doi.org/10.1177/030913330102500104>
31. Difi, S., Elmeddahi, Y., Hebal, A., Singh, V. P., Heddami, S., Kim, S., & Kisi, O. (2022). Monthly streamflow prediction using hybrid extreme learning machine optimized by bat algorithm: a case study of Cheliff watershed, Algeria. *Hydrological Sciences Journal*, 1-20. <https://doi.org/10.1080/02626667.2022.2149334>.
32. Dingman, S. L. (2015). *Physical hydrology*. Waveland Press. 3rd ed., 643 p.
33. Dragomiretskiy, K., & Zosso, D. (2013). Variational mode decomposition. *IEEE transactions on signal processing*, 62(3), 531-544. <https://doi.org/10.1109/TSP.2013.2288675>
34. Edijatno, D., Yang, X., Makhlouf, Z., & Michel, C. (1999). GR3J: a daily watershed model with three free parameters. *Hydrological sciences journal*, 44(2), 263-277. <https://doi.org/10.1080/02626669909492221>
35. Esmaeili-Gisavandani, H., Lotfirad, M., Sofla, M. S. D., & Ashrafzadeh, A. (2021). Improving the performance of rainfall-runoff models using the gene expression programming approach. *Journal of Water and Climate Change*, 12(7), 3308-3329. <https://doi.org/10.2166/wcc.2021.064>
36. Fathian, F., Mehdizadeh, S., Sales, A. K., & Safari, M. J. S. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models. *Journal of Hydrology*, 575, 1200-1213. <https://doi.org/10.1016/j.jhydrol.2019.06.025>
37. Flores, N., Rodríguez, R., Yépez, S., Osorio, V., Rau, P., Rivera, D., & Balocchi, F. (2021). Comparison of three daily rainfall-runoff hydrological models using four evapotranspiration models

- in four small forested watersheds with different land cover in South-Central Chile. *Water*, 13(22), 3191. <https://doi.org/10.3390/w13223191>
38. Fortin, V., Bernier, J., & Bobée, B. (1997). Simulation, Bayes, and bootstrap in statistical hydrology. *Water Resources Research*, 33(3), 439-448. <https://doi.org/10.1029/96WR03355>
39. Fotovatikhah, F., Herrera, M., Shamshirband, S., Chau, K. W., Faizollahzadeh Ardabili, S., & Piran, M. J. (2018). Survey of computational intelligence as basis to big flood management: Challenges, research directions and future work. *Engineering Applications of Computational Fluid Mechanics*, 12(1), 411-437. <https://doi.org/10.1080/19942060.2018.1448896>
40. Freeze, R. A., & Harlan, R. L. (1969). Blueprint for a physically-based, digitally-simulated hydrologic response model. *Journal of hydrology*, 9(3), 237-258. [https://doi.org/10.1016/0022-1694\(69\)90020-1](https://doi.org/10.1016/0022-1694(69)90020-1)
41. Ghorbani, M. A., Khatibi, R., Karimi, V., Yaseen, Z. M., & Zounemat-Kermani, M. (2018). Learning from multiple models using artificial intelligence to improve model prediction accuracies: application to river flows. *Water resources management*, 32, 4201-4215. <https://doi.org/10.1007/s11269-018-2038-x>
42. Gleick, P. H., & Howe, C. W. (1995). Water in crisis: a guide to the world's fresh water resources. *Climatic Change*, 31(1), 119-122.
43. Gnouma, R. (2006). Aide à la calibration d'un modèle hydrologique distribué au moyen d'une analyse des processus hydrologiques: application au bassin versant de l'Yzeron (Thèse de doctorat, INSA Lyon), 254 p.
44. Guo, J., Zhou, J., Qin, H., Zou, Q., & Li, Q. (2011). Monthly streamflow forecasting based on improved support vector machine model. *Expert Systems with Applications*, 38(10), 13073-13081. <https://doi.org/10.1016/j.eswa.2011.04.114>

-
45. Harlan, D., Wangsadipura, M., & Munajat, C. M. (2010, June). Rainfall-Runoff Modeling of citarum hulu river basin by using GR4j. In Proceedings of the world congress on engineering, 2, 1607-1611.
46. Haziza, E. (2003). Modélisation mensuelle pluie-débit-apports de la spatialisation-cas des données de sols (Thèse de doctorat, Université Montpellier II), 367 p.
47. He, X., Luo, J., Zuo, G., & Xie, J. (2019). Daily runoff forecasting using a hybrid model based on variational mode decomposition and deep neural networks. *Water resources management*, 33, 1571-1590. <https://doi.org/10.1007/s11269-019-2183-x>
48. Hebb, D. O. (1949). Organization of behavior. new york: Wiley. *J. Clin. Psychol*, 6(3), 335-307.
49. Heddam, S., & Kişi, Ö. (2021). A new heuristic model for monthly streamflow forecasting: outlier-robust extreme learning machine. In *Advances in Streamflow Forecasting* (pp. 281-303). Elsevier. <https://doi.org/10.1016/B978-0-12-820673-7.00005-6>
50. Henine, H. (2005). Interfaçage entre un modèle hydrologique et un modèle hydrodynamique au sein d'un système d'information intégré sous web incluant les SIG (Thèse de doctorat, Alger, Ecole Nationale Polytechnique), 272 p.
51. Hsu, K. L., Gupta, H. V., & Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water resources research*, 31(10), 2517-2530. <https://doi.org/10.1029/95WR01955>
52. Hu, H., Zhang, J., & Li, T. (2021). A novel hybrid decompose-ensemble strategy with a VMD-BPNN approach for daily streamflow estimating. *Water Resources Management*, 35, 5119-5138. <https://doi.org/10.1007/s11269-021-02990-5>
53. Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., & Liu, H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995. <https://doi.org/10.1098/rspa.1998.0193>.

-
54. Huard, D., & Mailhot, A. (2008). Calibration of hydrological model GR2M using Bayesian uncertainty analysis. *Water Resources Research*, 44(2). <https://doi.org/10.1029/2007WR005949>
55. Hussain, D., & Khan, A. A. (2020). Machine learning techniques for monthly river flow forecasting of Hunza River, Pakistan. *Earth Science Informatics*, 13(3), 939-949. <https://doi.org/10.1007/s12145-020-00450-z>
56. Jajarmizadeh, M., Harun, S., & Salarpour, M. (2012). A review on theoretical consideration and types of models in hydrology. *Journal of Environmental Science and Technology*, 5(5), 249-261.
57. Kabouya, M. (1990). Rainfall-runoff modeling at monthly and annual time steps in northern Algeria (Thèse de doctorat, Thèse de doctorat, University of Paris South Orsay), 374 p .
58. Kabouya, M., & Michel, C. (1991). Estimation des ressources en eau superficielle aux pas de temps mensuel et annuel, application à un pays semi-aride. *Revue des Sciences de l'Eau*, 4(4), 569-587. <https://doi.org/10.7202/705116ar>
59. Kalteh, A. M., & Berndtsson, R. (2007). Interpolating monthly precipitation by self-organizing map (SOM) and multilayer perceptron (MLP). *Hydrological sciences journal*, 52(2), 305-317. <https://doi.org/10.1623/hysj.52.2.305>
60. Kambalimath S.S., & Deka, P.C. (2021). Performance enhancement of SVM model using discrete wavelet transform for daily streamflow forecasting. *Environmental Earth Sciences*, 80(3), 101. <https://doi.org/10.1007/s12665-021-09394-z>
61. Kebiche, M. (1996). Climat, santé et tourisme: Application à un climat méditerranéen semi-continental atténué: La région de Sétif (Algérie). *Travaux de l'Institut de Géographie de Reims*, 24(93), 129-139.
62. Khazae Poul, A., Shourian, M., & Ebrahimi, H. (2019). A comparative study of MLR, KNN, ANN and ANFIS models with wavelet transform in monthly stream flow prediction. *Water Resources Management*, 33, 2907-2923. <https://doi.org/10.1007/s11269-019-02273-0>.

-
63. Kisi, O., Dailr, A. H., Cimen, M., & Shiri, J. (2012). Suspended sediment modeling using genetic programming and soft computing techniques. *Journal of Hydrology*, 450, 48-58. <https://doi.org/10.1016/j.jhydrol.2012.05.031>
64. Korichi, K., & Hazzab, A. (2012). Hydrodynamic investigation and numerical simulation of intermittent and ephemeral flows in semi-arid regions: Wadi Mekerra, Algeria. *Journal of Hydrology and Hydromechanics*, 60(2), 125-142. <https://doi.org/10.2478/v10098-012-0011-6>
65. Laurent, F. (1996). Outils de modélisation spatiale pour la gestion intégrée des ressources en eau: Application aux Schémas d'Aménagement et de Gestion des Eaux (Thèse de doctorat, Ecole Nationale Supérieure des Mines de Paris), 214 p.
66. Le Clerc, S. (2004). Revisiter la notion de scénario hydrologique de référence pour la caractérisation des inondations (Thèse de doctorat, Doctorat Mécanique des Milieux Géophysiques et Environnement, Université Joseph Fourier Grenoble), 265 p.
67. Le Moine, N. (2008). Le bassin versant de surface vu par le souterrain: une voie d'amélioration des performances et du réalisme des modèles pluie-débit? (Thèse de doctorat, Doctorat Géosciences et Ressources Naturelles, Université Pierre et Marie Curie Paris VI), 324 p.
68. Lehabab-Boukezzi, Z., Boukezzi, L., & Errih, M. (2016). Uncertainty analysis of HEC-HMS model using the GLUE method for flash flood forecasting of Mekerra watershed, Algeria. *Arabian Journal of Geosciences*, 9, 1-12. <https://doi.org/10.1007/s12517-016-2771-5>
69. Liang, N. Y., Huang, G. B., Saratchandran, P., & Sundararajan, N. (2006). A fast and accurate online sequential learning algorithm for feedforward networks. *IEEE Transactions on neural networks*, 17(6), 1411-1423. <https://doi.org/10.1109/TNN.2006.880583>
70. Lindström, G., Johansson, B., Persson, M., Gardelin, M., & Bergström, S. (1997). Development and test of the distributed HBV-96 hydrological model. *Journal of hydrology*, 201(1-4), 272-288. [https://doi.org/10.1016/S0022-1694\(97\)00041-3](https://doi.org/10.1016/S0022-1694(97)00041-3)
71. Linsley, R. K., Kohler, M. A., & Paulhus, J. L. (1975). *Hydrology for engineers* 2nd ed., pp. 512.

-
72. Lionello, P., Malanotte-Rizzoli, P., Boscolo, R., Alpert, P., Artale, V., Li, L., & Xoplaki, E. (2006). The Mediterranean climate: an overview of the main characteristics and issues. *Developments in earth and environmental sciences*, 4, 1-26. [https://doi.org/10.1016/S1571-9197\(06\)80003-0](https://doi.org/10.1016/S1571-9197(06)80003-0)
73. Liu, C., Zhu, L., & Ni, C. (2018). Chatter detection in milling process based on VMD and energy entropy. *Mechanical Systems and Signal Processing*, 105, 169-182. <https://doi.org/10.1016/j.ymssp.2017.11.046>
74. Luo, X., Lin, F., Zhu, S., Yu, M., Zhang, Z., Meng, L., & Peng, J. (2019). Mine landslide susceptibility assessment using IVM, ANN and SVM models considering the contribution of affecting factors. *PloS one*, 14(4), e0215134. <https://doi.org/10.1371/journal.pone.0215134>
75. Maftai, C. P. (2002). Etudes concernant les écoulements superficiels: Modélisation spatialisée de l'écoulement sur le bassin versant de Voinesti, Roumanie (Thèse de doctorat, Université Ovidius, Montpellier, FRA), 233 p.
76. Makhlof, Z., & Michel, C. (1994). A two-parameter monthly water balance model for French watersheds. *Journal of Hydrology*, 162(3-4), 299-318. [https://doi.org/10.1016/0022-1694\(94\)90233-X](https://doi.org/10.1016/0022-1694(94)90233-X)
77. Maref, N., & Seddini, A. (2018). Modeling of flood generation in semi-arid catchment using a spatially distributed model: case of study Wadi Mekerra catchment (Northwest Algeria). *Arabian Journal of Geosciences*, 11, 1-15. <https://doi.org/10.1007/s12517-018-3461-2>
78. Maref, N., Korichi, K., & Mahfoud, Z. (2023). Modeling the Rainfall-Runoff Relationship with TOPMODEL in the Wadi El Kebir Watershed. *Journal of Water Management Modeling*. <https://doi.org/10.14796/JWMM.C497>
79. McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133. <https://doi.org/10.1007/BF02478259>

-
80. Mehr, A. D. (2018). An improved gene expression programming model for streamflow forecasting in intermittent streams. *Journal of hydrology*, 563, 669-678. <https://doi.org/10.1016/j.jhydrol.2018.06.049>
81. Moeeni, H., Bonakdari, H., Fatemi, S. E., & Zaji, A. H. (2017). Assessment of stochastic models and a hybrid artificial neural network-genetic algorithm method in forecasting monthly reservoir inflow. *INAE Letters*, 2, 13-23. <https://doi.org/10.1007/s41403-017-0017-9>
82. Mohammadi, B., Ahmadi, F., Mehdizadeh, S., Guan, Y., Pham, Q. B., Linh, N. T. T., & Tri, D. Q. (2020). Developing novel robust models to improve the accuracy of daily streamflow modeling. *Water Resources Management*, 34, 3387-3409. <https://doi.org/10.1007/s11269-020-02619-z>
83. Moore, R. J. (2007). The PDM rainfall-runoff model. *Hydrology and Earth System Sciences*, 11(1), 483–499. <https://doi.org/10.5194/hess-11-483-2007>
84. Moradkhani, H., Hsu, K. L., Gupta, H. V., & Sorooshian, S. (2004). Improved streamflow forecasting using self-organizing radial basis function artificial neural networks. *Journal of Hydrology*, 295(1-4), 246-262. <https://doi.org/10.1016/j.jhydrol.2004.03.027>
85. Mouelhi, S., Michel, C., Perrin, C., & Andréassian, V. (2006). Linking stream flow to rainfall at the annual time step: the Manabe bucket model revisited. *Journal of hydrology*, 328(1-2), 283-296. <https://doi.org/10.1016/j.jhydrol.2005.12.022>
86. Muhammad Adnan, R., Yuan, X., Kisi, O., Yuan, Y., Tayyab, M., & Lei, X. (2019, June). Application of soft computing models in streamflow forecasting. In *Proceedings of the institution of civil engineers-water management* (Vol. 172, No. 3, pp. 123-134). Thomas Telford Ltd. <https://doi.org/10.1680/jwama.16.00075>
87. Mutlu, E., Chaubey, I., Hexmoor, H., & Bajwa, S. G. (2008). Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. *Hydrological Processes: An International Journal*, 22(26), 5097-5106. <https://doi.org/10.1002/hyp.7136>

-
88. Mvoundou, C. N., Tathy, C., Obami-Ondon, H., Moukoko, G. B. M., & Niere, R. R. (2022). Calibration and validation of the GR2M hydrologic model in the Kouilou-Niari Basin in Southwestern Congo-Brazzaville. *Open Journal of Modern Hydrology*, 12(3), 109-124. <https://doi.org/10.4236/ojmh.2022.123007>
89. Nourani, V., Davanlou Tajbakhsh, A., Molajou, A., & Gokcekus, H. (2019). Hybrid wavelet-M5 model tree for rainfall-runoff modeling. *Journal of Hydrologic Engineering*, 24(5), 04019012. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001777](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001777)
90. Otmane, A., Hamed, K. B., & Bouanani, A. (2019). Contribution of the spatial variability of basin physical characteristics in hydrological rainfall-runoff modeling and by-products of hydrological balance: case of Lower Mekerra watershed, Algeria. *Revue des Sciences de l'Eau: Journal of Water Science*, 32(2), 117-144. <https://doi.org/10.7202/1065203ar>
91. Oudin, L. (2004). Recherche d'un modèle d'évapotranspiration potentielle pertinent comme entrée d'un modèle pluie-débit global (Thèse de doctorat, ENGREF (AgroParisTech)), 496 p .
92. Pechlivanidis, I. G., Jackson, B. M., Mcintyre, N. R., & Wheater, H. S. (2011). Catchment scale hydrological modelling: A review of model types, calibration approaches and uncertainty analysis methods in the context of recent developments in technology and applications. *Global NEST journal*, 13(3), 193-214.
93. Peng, J., Manevski, K., Kørup, K., Larsen, R., & Andersen, M. N. (2021). Random forest regression results in accurate assessment of potato nitrogen status based on multispectral data from different platforms and the critical concentration approach. *Field Crops Research*, 268, 108158. <https://doi.org/10.1016/j.fcr.2021.108158>
94. Percival, D. B., & Walden, A. T. (2000). *Wavelet methods for time series analysis*. Cambridge University Press, 1st ed., Vol. 4, pp. 620.
95. Perrin, C. (2002). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative. *La Houille Blanche*, 88(6-7), 84-91. <https://doi.org/10.1051/lhb/2002089>.

-
96. Perrin, C., Michel, C., & Andréassian, V. (2003). Improvement of a parsimonious model for streamflow simulation. *Journal of hydrology*, 279(1-4), 275-289. [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7)
97. Pushpalatha, R., Perrin, C., Le Moine, N., Mathevet, T., & Andréassian, V. (2011). A downward structural sensitivity analysis of hydrological models to improve low-flow simulation. *Journal of hydrology*, 411(1-2), 66-76. <https://doi.org/10.1016/j.jhydrol.2011.09.034>
98. Razavi, S., Tolson, B. A., & Burn, D. H. (2012). Review of surrogate modeling in water resources. *Water Resources Research*, 48(7). <https://doi.org/10.1029/2011WR011527>
99. Rezaie-Balf, M., Kim, S., Fallah, H., & Alaghmand, S. (2019). Daily river flow forecasting using ensemble empirical mode decomposition based heuristic regression models: Application on the perennial rivers in Iran and South Korea. *Journal of hydrology*, 572, 470-485. <https://doi.org/10.1016/j.jhydrol.2019.03.046>
100. Rosecrans, C. Z., Belitz, K., Ransom, K. M., Stackelberg, P. E., & McMahon, P. B. (2022). Predicting regional fluoride concentrations at public and domestic supply depths in basin-fill aquifers of the western United States using a random forest model. *Science of The Total Environment*, 806, 150960. <https://doi.org/10.1016/j.scitotenv.2021.150960>
101. Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386. <https://doi.org/10.1037/h0042519>
102. Sadegh, M., AghaKouchak, A., Flores, A., Mallakpour, I., & Nikoo, M. R. (2019). A multi-model nonstationary rainfall-runoff modeling framework: analysis and toolbox. *Water Resources Management*, 33, 3011-3024. <https://doi.org/10.1007/s11269-019-02283-y>
103. Samanataray, S., & Sahoo, A. (2021). A comparative study on prediction of monthly streamflow using hybrid ANFIS-PSO approaches. *KSCE Journal of Civil Engineering*, 25(10), 4032-4043. <https://doi.org/10.1007/s12205-021-2223-y>

-
104. Seibert, J., & Vis, M. J. (2012). Teaching hydrological modeling with a user-friendly catchment-runoff-model software package. *Hydrology and Earth System Sciences*, 16(9), 3315-3325. <https://doi.org/10.5194/hess-16-3315-2012>
105. Şenel, F. A., Gökçe, F., Yüksel, A. S., & Yiğit, T. (2019). A novel hybrid PSO–GWO algorithm for optimization problems. *Engineering with Computers*, 35, 1359-1373. <https://doi.org/10.1007/s00366-018-0668-5>
106. Seo, Y., Kim, S., & Singh, V. P. (2018). Machine learning models coupled with variational mode decomposition: A new approach for modeling daily rainfall-runoff. *Atmosphere*, 9(7), 251. <https://doi.org/10.3390/atmos9070251>
107. Sezen, C., & Partal, T. (2019). The utilization of a GR4J model and wavelet-based artificial neural network for rainfall–runoff modelling. *Water Supply*, 19(5), 1295-1304. <https://doi.org/10.2166/ws.2018.189>
108. Sezen, C., & Partal, T. (2022). The utilisation of conceptual and data-driven models for hydrological modelling in semi-arid and humid areas of the Antalya basin in Turkey. *Acta Geophysica*, 70(2), 897-915. <https://doi.org/10.1007/s11600-022-00746-2>
109. Singh, K. K., Pal, M., & Singh, V. P. (2010). Estimation of mean annual flood in Indian catchments using backpropagation neural network and M5 model tree. *Water resources management*, 24, 2007-2019. <https://doi.org/10.1007/s11269-009-9535-x>
110. Singh, P., Ramasastri, K. S., Singh, U. K., Gergan, J. T., & Dobhal, D. P. (1995). Hydrological characteristics of the Dokriani Glacier in the Garhwal Himalayas. *Hydrological Sciences Journal*, 40(2), 243-257. <https://doi.org/10.1080/02626669509491407>
111. Skhakhfa, I. D., & Ouerdachi, L. (2016). Hydrological modelling of wadi Ressoul watershed, Algeria, by HEC-HMS model. *Journal of Water and Land Development*, 31(1), 139. <https://doi.org/10.1515/jwld-2016-0045>

-
112. Solomatine, D. P., & Wagener, T. (2011). Hydrological modelling. In *Treatise on Water Science* (pp. 435-457), edited by P. Wilderer, Oxford Academic Press.
113. Sudheer, C., Maheswaran, R., Panigrahi, B. K., & Mathur, S. (2014). A hybrid SVM-PSO model for forecasting monthly streamflow. *Neural Computing and Applications*, 24, 1381-1389. <https://doi.org/10.1007/s00521-013-1341-y>
114. Taibi, S. (2011). *Analyse du régime climatique au Nord de l'Algérie* (Thèse de doctorat, École Nationale Supérieure Agronomique), 205 p.
115. Tan, Q. F., Lei, X. H., Wang, X., Wang, H., Wen, X., Ji, Y., & Kang, A. Q. (2018). An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*, 567, 767-780. <https://doi.org/10.1016/j.jhydrol.2018.01.015>
116. Tikhamarine, Y., Souag-Gamane, D., & Kisi, O. (2019). A new intelligent method for monthly streamflow prediction: hybrid wavelet support vector regression based on grey wolf optimizer (WSVR-GWO). *Arabian Journal of Geosciences*, 12, 1-20. <https://doi.org/10.1007/s12517-019-4697-1>
117. Tikhamarine, Y., Souag-Gamane, D., Ahmed, A. N., Kisi, O., & El-Shafie, A. (2020). Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm. *Journal of Hydrology*, 582, 124435. <https://doi.org/10.1016/j.jhydrol.2019.124435>
118. Tiwari, M. K., & Chatterjee, C. (2010). Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *Journal of Hydrology*, 394(3-4), 458-470. <https://doi.org/10.1016/j.jhydrol.2010.10.001>
119. Tongal, H., & Booij, M. J. (2018). Simulation and forecasting of streamflows using machine learning models coupled with base flow separation. *Journal of Hydrology*, 564, 266-282. <https://doi.org/10.1016/j.jhydrol.2018.07.004>
120. Touzet, C. (1992). *Les réseaux de neurones artificiels : introduction au connexionnisme. Cours, exercices et travaux pratiques*. Éd Nanterre : EC2, Collection de l'EERIE (Nîmes), p. 148.

-
121. Vorosmarty, C. J., Green, P., Salisbury, J., & Lammers, R. B. (2000). Global water resources: vulnerability from climate change and population growth. *science*, 289(5477), 284-288. <https://doi.org/10.1126/science.289.5477.284>
122. Wang, L., Cao, Q., Zhang, Z., Mirjalili, S., & Zhao, W. (2022). Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems. *Engineering Applications of Artificial Intelligence*, 114, 105082. <https://doi.org/10.1016/j.engappai.2022.105082>
123. Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), 294-306. <https://doi.org/10.1016/j.jhydrol.2009.06.019>
124. Wang, W. C., Xu, D. M., Chau, K. W., & Chen, S. (2013). Improved annual rainfall-runoff forecasting using PSO–SVM model based on EEMD. *Journal of Hydroinformatics*, 15(4), 1377-1390. <https://doi.org/10.2166/hydro.2013.134>
125. Widrow, B. (1965). Adaptive Switching Circuits. *IRE Wescon Conv. Rec.*, 4, 547-587.
126. Wittenberg, H. (1999). Baseflow recession and recharge as nonlinear storage processes. *Hydrological processes*, 13(5), 715-726. [https://doi.org/10.1002/\(SICI\)1099-1085](https://doi.org/10.1002/(SICI)1099-1085)
127. Wu, Z., & Huang, N. E. (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01), 1-41. <https://doi.org/10.1142/S1793536909000047>
128. Xie, M., Wang, B., Zhu, S., Ma, G., Yang, Z., Liu, B., & Jia, Y. (2022, May). Daily streamflow forecasting using hybrid long short-term memory model. In *Journal of Physics: Conference Series* (Vol. 2271, No. 1, p. 012019). IOP Publishing. <https://doi.org/10.1088/1742-6596/2271/1/012019>
129. Yaseen, Z. M., Ebtahaj, I., Bonakdari, H., Deo, R. C., Mehr, A. D., Mohtar, W. H. M. W., ... & Singh, V. P. (2017). Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. *Journal of Hydrology*, 554, 263-276. <https://doi.org/10.1016/j.jhydrol.2017.09.007>

-
130. 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>
131. Zakhrouf, M., Bouchelkia, H., Stamboul, M., & Kim, S. (2020). Novel hybrid approaches based on evolutionary strategy for streamflow forecasting in the Chellif River, Algeria. *Acta Geophysica*, 68, 167-180. <https://doi.org/10.1007/s11600-019-00380-5>
132. Zakhrouf, M., Bouchelkia, H., Stamboul, M., Kim, S., & Singh, V. P. (2020a). Implementation on the evolutionary machine learning approaches for streamflow forecasting: Case study in the Seybous River, Algeria. *Journal of Korea Water Resources Association*, 53(6), 395-408. <https://doi.org/10.3741/JKWRA.2020.53.6.395>
133. Zamoum, S., & Souag-Gamane, D. (2019). Monthly streamflow estimation in ungauged catchments of northern Algeria using regionalization of conceptual model parameters. *Arabian Journal of Geosciences*, 12(11), 342. <https://doi.org/10.1007/s12517-019-4487-9>
134. Zervoudakis, K., & Tsafarakis, S. (2020). A mayfly optimization algorithm. *Computers & Industrial Engineering*, 145, 106559. <https://doi.org/10.1016/j.cie.2020.106559>
135. Zhang, Z., Zhang, Q., & Singh, V. P. (2018). Univariate streamflow forecasting using commonly used data-driven models: literature review and case study. *Hydrological Sciences Journal*, 63(7), 1091-1111. <https://doi.org/10.1080/02626667.2018.1469756>

LES ANNEXES

Annexe A : Résultats obtenus avec les modèles d'intelligence artificielle autonome au pas de temps journalier

Tableau A.1. Performances des différents modèles autonomes pour la station WADI LILI au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.977	0.955	0.061	0.018	0.907	0.821	0.038	0.011
MLPNN2	0.922	0.849	0.414	0.084	0.639	0.150	0.308	0.043
MLPNN3	0.975	0.950	0.238	0.045	0.873	0.760	0.164	0.027
MLPNN4	0.822	0.749	0.413	0.184	0.539	0.151	0.308	0.043
MLPNN5	0.801	0.641	0.637	0.086	0.215	0.362	0.390	0.036
MLPNN6	0.412	0.023	1.351	0.159	0.392	0.214	0.314	0.041
RFR1	0.836	0.652	0.627	0.077	0.732	0.687	0.319	0.030
RFR2	0.836	0.652	0.627	0.077	0.232	0.087	0.319	0.030
RFR3	0.961	0.882	0.366	0.042	0.776	0.604	0.210	0.028
RFR4	0.719	0.494	1.596	1.298	0.554	0.275	1.876	1.438
RFR5	0.755	0.445	1.562	1.398	0.540	0.202	1.856	1.464
RFR6	0.622	0.123	2.688	1.988	0.173	0.093	0.318	0.031
M5Tree1	0.975	0.950	0.238	0.045	0.830	0.760	0.164	0.027
M5Tree2	0.893	0.798	0.478	0.056	0.123	0.462	0.404	0.050
M5Tree3	0.905	0.802	0.366	0.042	0.662	0.490	0.239	0.034
M5Tree4	0.632	0.494	1.962	1.298	0.559	0.275	1.876	1.438
M5Tree5	0.719	0.374	0.964	0.482	0.619	0.374	0.264	0.132
M5Tree6	0.212	0.023	1.051	0.159	0.192	0.114	0.314	0.041
ELM1	0.856	0.733	0.550	0.263	0.609	0.374	0.264	0.112
ELM2	0.856	0.733	0.550	0.263	0.609	0.374	0.264	0.132
ELM3	0.856	0.733	0.550	0.263	0.609	0.374	0.243	0.121
ELM4	0.632	0.494	1.962	1.298	0.459	0.275	1.956	0.978
ELM5	0.619	0.374	1.964	0.982	0.519	0.374	0.964	0.482
ELM6	0.168	0.001	1.063	0.155	0.226	0.123	0.313	0.042

Tableau A.2. Performances des différents modèles autonomes pour la station FERAH au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.935	0.880	2.050	0.597	0.915	0.821	1.126	0.293
MLPNN2	0.869	0.758	1.308	0.329	0.809	0.669	3.400	0.988
MLPNN3	0.750	0.579	3.832	0.909	0.769	0.531	1.823	0.418
MLPNN4	0.531	0.312	4.899	1.223	0.528	0.267	2.279	0.411
MLPNN5	0.616	0.405	4.555	1.109	0.590	0.302	2.224	0.577
MLPNN6	0.598	0.385	4.633	1.538	0.596	0.204	2.375	0.565
RFR1	0.904	0.818	1.873	0.476	0.887	0.759	1.363	0.362
RFR2	0.835	0.679	3.344	0.866	0.700	0.468	1.941	0.462

RFR3	0.818	0.661	3.437	0.724	0.632	0.397	2.067	0.448
RFR4	0.751	0.538	4.013	0.936	0.434	0.195	2.388	0.498
RFR5	0.767	0.561	3.915	1.058	0.573	0.313	2.206	0.458
RFR6	0.552	0.326	4.849	1.507	0.448	0.202	2.378	0.639
M5Tree1	0,910	0,828	1,596	0,368	0,824	0,828	2,876	0,368
M5Tree2	0,810	0,647	1,996	0,998	0,624	0,379	2,956	1,478
M5Tree3	0,880	0,765	1,621	0,811	0,712	0,498	2,676	1,338
M5Tree4	0,710	0,494	2,596	1,298	0,534	0,275	4,876	2,438
M5Tree5	0,888	0,779	1,296	0,648	0,704	0,486	3,076	1,538
M5Tree6	0,510	0,250	4,596	2,298	0,424	0,170	4,876	2,438
ELM1	0,904	0,808	1,873	0,937	0,822	0,665	1,172	0,586
ELM2	0,704	0,486	3,873	1,937	0,618	0,372	2,152	1,076
ELM3	0,774	0,590	2,731	1,366	0,692	0,469	3,122	1,561
ELM4	0,604	0,355	3,873	1,937	0,522	0,262	4,192	2,096
ELM5	0,710	0,495	1,731	0,866	0,722	0,511	2,172	1,086
ELM6	0,504	0,244	4,873	2,437	0,322	0,094	5,112	2,556

Tableau A.3. Performances des différents modèles autonomes pour la station BOUCHEGOUF au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMS E, m3/s	MAE , m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
MLPNN1	0.909	0.824	3.094	0.656	0.912	0.830	1.990	0.498
MLPNN2	0.538	0.289	7.726	2.882	0.533	0.285	5.403	2.490
MLPNN3	0.721	0.520	6.350	1.489	0.848	0.716	3.404	1.185
MLPNN4	0.546	0.293	7.703	2.842	0.574	0.326	5.247	2.463
MLPNN5	0.699	0.488	6.556	1.543	0.828	0.683	3.599	1.032
MLPNN6	0.260	0.068	8.848	3.435	0.294	0.080	6.129	2.961
RFR1	0.914	0.813	3.188	0.453	0.896	0.799	2.166	0.486
RFR2	0.756	0.538	6.229	2.391	0.568	0.323	5.257	2.349
RFR3	0.858	0.715	4.893	0.940	0.855	0.730	3.317	1.076
RFR4	0.701	0.457	6.752	2.589	0.561	0.310	5.306	2.319
RFR5	0.822	0.653	5.398	1.115	0.809	0.648	3.790	1.194
RFR6	0.422	0.174	8.330	3.259	0.216	0.047	6.236	3.124
M5Tree1	0.935	0.856	2.614	0.437	0.833	0.623	2.688	0.491
M5Tree2	0.890	0.793	4.174	0.810	0.295	0.070	6.162	2.309
M5Tree3	0.805	0.648	5.439	1.055	0.714	0.493	4.549	1.131
M5Tree4	0.615	0.378	7.225	2.744	0.468	0.192	5.743	2.511
M5Tree5	0.803	0.645	5.461	1.105	0.682	0.431	4.818	1.292
M5Tree6	0.313	0.098	8.702	3.380	0.185	0.033	6.282	2.956
ELM1	0.908	0.825	3.083	0.893	0.824	0.566	3.178	0.773
ELM2	0.698	0.488	6.559	2.657	0.343	0.206	7.019	2.827
ELM3	0.838	0.703	4.995	1.222	0.493	0.045	11.15	2.167
ELM4	0.659	0.434	6.891	2.713	0.439	0.276	9.640	2.956
ELM5	0.750	0.562	6.062	1.456	0.653	0.025	6.309	1.694
ELM6	0.240	0.057	8.897	3.439	0.262	0.066	6.175	3.081

Tableau A.4. Performances des différents modèles autonomes pour la station AIN BERDA au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.924	0.853	0.463	0.081	0.903	0.740	0.800	0.147
MLPNN2	0.818	0.660	0.863	0.368	0.603	0.354	1.998	0.368
MLPNN3	0.900	0.801	0.463	0.231	0.743	0.543	0.976	0.488
MLPNN4	0.638	0.398	1.627	0.813	0.535	0.276	1.800	0.900
MLPNN5	0.884	0.771	0.963	0.481	0.701	0.482	1.098	0.549
MLPNN6	0.668	0.437	2.463	1.231	0.603	0.354	2.800	1.400
RFR1	0.900	0.771	0.785	0.067	0.820	0.666	0.906	0.121
RFR2	0.773	0.587	0.978	0.368	0.625	0.381	1.206	0.368
RFR3	0.888	0.778	0.785	0.392	0.720	0.509	0.906	0.453
RFR4	0.679	0.451	2.572	1.286	0.520	0.261	1.958	0.979
RFR5	0.773	0.587	0.578	0.289	0.820	0.663	0.906	0.453
RFR6	0.286	0.072	6.578	3.289	0.205	0.032	8.906	4.453
M5Tree1	0.905	0.819	0.514	0.092	0.819	0.627	0.929	0.171
M5Tree2	0.725	0.515	1.785	0.368	0.625	0.381	1.106	0.368
M5Tree3	0.632	0.390	1.746	0.873	0.725	0.516	0.946	0.473
M5Tree4	0.479	0.219	2.572	1.286	0.413	0.161	1.983	0.991
M5Tree5	0.773	0.587	2.578	1.289	0.825	0.671	1.006	0.503
M5Tree6	0.263	0.059	6.568	3.284	0.215	0.036	6.906	3.453
ELM1	0.896	0.804	0.535	0.130	0.794	0.468	1.143	0.272
ELM2	0.786	0.608	1.378	0.368	0.630	0.386	1.266	0.368
ELM3	0.893	0.787	0.790	0.395	0.720	0.509	0.906	0.453
ELM4	0.574	0.319	2.572	1.286	0.420	0.167	2.933	1.467
ELM5	0.234	0.045	2.578	1.289	0.620	0.375	1.206	0.603
ELM6	0.286	0.072	6.578	3.289	0.205	0.032	3.906	1.953

Tableau A.5. Performances des différents modèles autonomes pour la station FERMATOU au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMS E, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE , m3/s
MLPNN1	0.868	0.754	0.713	0.144	0.891	0.789	0.444	0.096
MLPNN2	0.922	0.849	0.414	0.084	0.639	0.150	0.308	0.043
MLPNN3	0.820	0.518	0.997	0.168	0.832	0.695	0.533	0.100
MLPNN4	0.822	0.749	0.514	0.184	0.539	0.050	0.408	0.143
MLPNN5	0.868	0.754	0.713	0.144	0.815	0.789	0.444	0.096
MLPNN6	0.722	0.649	0.614	0.284	0.439	-0.050	0.508	0.243
RFR1	0.899	0.705	0.780	0.104	0.822	0.670	0.555	0.087
RFR2	0.856	0.705	0.780	0.104	0.822	0.670	0.555	0.087
RFR3	0.814	0.647	0.853	0.119	0.757	0.580	0.626	0.094

RFR4	0.756	0.605	0.880	0.204	0.722	0.570	0.655	0.187
RFR5	0.852	0.701	0.721	0.104	0.807	0.662	0.571	0.084
RFR6	0.656	0.505	0.980	0.304	0.622	0.470	0.755	0.287
M5Tree1	0.898	0.754	0.713	0.144	0.891	0.789	0.444	0.096
M5Tree2	0.850	0.646	0.855	0.221	0.506	0.400	0.916	0.274
M5Tree3	0.890	0.559	1.035	0.396	0.610	0.496	1.656	0.915
M5Tree4	0.750	0.546	0.955	0.321	0.406	0.300	1.016	0.374
M5Tree5	0.801	0.552	1.235	0.596	0.620	0.487	1.662	0.995
M5Tree6	0.650	0.446	1.055	0.421	0.306	0.200	1.116	0.474
ELM1	0.759	0.576	0.935	0.396	0.700	0.496	0.686	0.292
ELM2	0.820	0.646	0.466	0.221	0.306	0.100	0.916	0.274
ELM3	0.759	0.576	0.935	0.396	0.700	0.496	0.686	0.292
ELM4	0.720	0.546	0.566	0.321	0.206	0.000	1.016	0.374
ELM5	0.767	0.559	2.935	0.996	0.700	0.496	0.686	0.292
ELM6	0.620	0.446	0.666	0.421	0.106	-0.100	1.116	0.474

Tableau A.6. Performances des différents modèles autonomes pour la station BOU BIREK au pas de temps journalier

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.965	0.930	2.222	0.641	0.930	0.872	1.333	0.358
MLPNN2	0.874	0.739	4.299	0.546	0.784	0.644	2.224	0.380
MLPNN3	0.950	0.902	2.636	0.632	0.855	0.743	1.889	0.392
MLPNN4	0.774	0.639	4.399	0.646	0.684	0.544	2.324	0.480
MLPNN5	0.850	0.802	2.736	0.732	0.755	0.643	1.989	0.492
MLPNN6	0.674	0.539	4.499	0.746	0.584	0.444	2.424	0.580
RFR1	0.880	0.635	5.087	0.655	0.768	0.633	2.260	0.413
RFR2	0.842	0.639	4.992	0.746	0.735	0.643	2.217	0.804
RFR3	0.810	0.635	5.087	0.655	0.768	0.633	2.260	0.413
RFR4	0.742	0.539	5.092	0.846	0.635	0.543	2.317	0.904
RFR5	0.710	0.535	5.187	0.755	0.668	0.533	2.360	0.513
RFR6	0.642	0.439	5.192	0.946	0.535	0.443	2.417	1.004
M5Tree1	0.865	0.631	5.569	0.655	0.784	0.692	2.265	0.613
M5Tree2	0.767	0.589	5.399	2.256	0.672	0.514	2.600	1.125
M5Tree3	0.868	0.690	2.395	2.103	0.732	0.557	2.747	1.344
M5Tree4	0.667	0.489	5.499	2.356	0.572	0.414	2.700	1.225
M5Tree5	0.768	0.590	2.495	2.203	0.632	0.457	2.847	1.444
M5Tree6	0.567	0.389	5.599	2.456	0.472	0.314	2.800	1.325
ELM1	0.767	0.589	5.399	2.256	0.672	0.514	2.600	1.125
ELM2	0.759	0.576	0.935	0.396	0.700	0.496	0.686	0.292
ELM3	0.767	0.589	5.399	2.256	0.672	0.514	2.600	1.125
ELM4	0.659	0.476	1.035	0.496	0.600	0.396	0.786	0.392
ELM5	0.667	0.489	5.499	2.356	0.572	0.414	2.700	1.225
ELM6	0.559	0.376	1.135	0.596	0.500	0.296	0.886	0.492

Annexe B : Résultats obtenus avec les modèles d'intelligence artificielle autonome au pas de temps mensuel

Tableau.B.1. Performances des différents modèles autonomes pour la station WADI LILI au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.971	0.943	0.026	0.002	0.905	0.835	0.042	0.006
MLPNN2	0.771	0.743	0.226	0.202	0.705	0.635	0.242	0.206
MLPNN3	0.860	0.832	0.137	0.113	0.794	0.724	0.153	0.117
MLPNN4	0.660	0.632	0.337	0.313	0.594	0.524	0.353	0.317
MLPNN5	0.749	0.721	0.248	0.224	0.683	0.613	0.264	0.228
MLPNN6	0.549	0.521	0.448	0.424	0.483	0.413	0.464	0.428
RFR1	0.914	0.785	0.050	0.005	0.684	0.551	0.069	0.007
RFR2	0.714	0.585	0.250	0.205	0.484	0.351	0.269	0.207
RFR3	0.803	0.674	0.161	0.116	0.573	0.440	0.180	0.118
RFR4	0.603	0.474	0.361	0.316	0.373	0.240	0.380	0.318
RFR5	0.692	0.563	0.272	0.227	0.462	0.329	0.291	0.229
RFR6	0.492	0.363	0.472	0.427	0.262	0.129	0.491	0.429
M5Tree1	0.924	0.854	0.041	0.003	0.531	0.321	0.085	0.008
M5Tree2	0.724	0.654	0.241	0.203	0.331	0.121	0.285	0.208
M5Tree3	0.813	0.743	0.152	0.114	0.420	0.210	0.196	0.119
M5Tree4	0.613	0.543	0.352	0.314	0.220	0.010	0.396	0.319
M5Tree5	0.702	0.632	0.263	0.225	0.309	0.099	0.307	0.230
M5Tree6	0.502	0.432	0.463	0.425	0.109	0.101	0.507	0.430
ELM1	0.904	0.817	0.046	0.006	0.676	0.543	0.070	0.009
ELM2	0.704	0.617	0.246	0.206	0.476	0.343	0.270	0.209
ELM3	0.793	0.706	0.157	0.117	0.565	0.432	0.181	0.120
ELM4	0.593	0.506	0.357	0.317	0.365	0.232	0.381	0.320
ELM5	0.682	0.595	0.268	0.228	0.454	0.321	0.292	0.231
ELM6	0.482	0.395	0.468	0.428	0.254	0.121	0.492	0.431

Tableau.B.2. Performances des différents modèles autonomes pour la station FERAH au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.975	0.951	0.064	0.009	0.809	0.636	0.285	0.030
MLPNN2	0.775	0.751	0.264	0.209	0.609	0.436	0.485	0.230
MLPNN3	0.864	0.840	0.175	0.120	0.698	0.525	0.396	0.141
MLPNN4	0.664	0.640	0.375	0.320	0.498	0.325	0.596	0.341
MLPNN5	0.753	0.729	0.286	0.231	0.587	0.414	0.507	0.252
MLPNN6	0.553	0.529	0.486	0.431	0.387	0.214	0.707	0.452

RFR1	0.905	0.765	0.141	0.013	0.671	0.451	0.350	0.036
RFR2	0.705	0.565	0.341	0.213	0.471	0.251	0.550	0.236
RFR3	0.794	0.654	0.252	0.124	0.560	0.340	0.461	0.147
RFR4	0.594	0.454	0.452	0.324	0.360	0.140	0.661	0.347
RFR5	0.683	0.543	0.363	0.235	0.449	0.229	0.572	0.258
RFR6	0.483	0.343	0.563	0.435	0.249	0.029	0.772	0.458
M5Tree1	0.947	0.897	0.093	0.007	0.674	0.432	0.356	0.031
M5Tree2	0.747	0.697	0.293	0.207	0.474	0.232	0.556	0.231
M5Tree3	0.836	0.786	0.204	0.118	0.563	0.321	0.467	0.142
M5Tree4	0.636	0.586	0.404	0.318	0.363	0.121	0.667	0.342
M5Tree5	0.725	0.675	0.315	0.229	0.452	0.210	0.578	0.253
M5Tree6	0.525	0.475	0.515	0.429	0.252	0.010	0.778	0.453
ELM1	0.846	0.715	0.155	0.011	0.625	0.366	0.376	0.037
ELM2	0.646	0.515	0.355	0.211	0.425	0.166	0.576	0.237
ELM3	0.735	0.604	0.266	0.122	0.514	0.255	0.487	0.148
ELM4	0.535	0.404	0.466	0.322	0.314	0.055	0.687	0.348
ELM5	0.624	0.493	0.377	0.233	0.403	0.144	0.598	0.259
ELM6	0.424	0.293	0.577	0.433	0.203	-0.056	0.798	0.459

Tableau.B.3. Performances des différents modèles autonomes pour la station BOUCHEGOUF au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m ³ /s	MAE, m ³ /s	R	NSE	RMSE, m ³ /s	MAE, m ³ /s
MLPNN1	0.998	1.000	0.013	0.001	0.910	0.793	0.322	0.025
MLPNN2	0.798	0.800	0.213	0.201	0.710	0.593	0.522	0.225
MLPNN3	0.887	0.889	0.124	0.112	0.799	0.682	0.433	0.136
MLPNN4	0.687	0.689	0.324	0.312	0.599	0.482	0.633	0.336
MLPNN5	0.776	0.778	0.235	0.223	0.688	0.571	0.544	0.247
MLPNN6	0.576	0.578	0.435	0.423	0.488	0.371	0.744	0.447
RFR1	0.927	0.775	0.294	0.014	0.614	0.354	0.570	0.046
RFR2	0.727	0.575	0.494	0.214	0.414	0.154	0.770	0.246
RFR3	0.816	0.664	0.405	0.125	0.503	0.243	0.681	0.157
RFR4	0.616	0.464	0.605	0.325	0.303	0.043	0.881	0.357
RFR5	0.705	0.553	0.516	0.236	0.392	0.132	0.792	0.268
RFR6	0.505	0.353	0.716	0.436	0.192	-0.068	1.992	1.468
M5Tree1	0.969	0.912	0.183	0.008	0.581	0.392	0.553	0.038
M5Tree2	0.769	0.712	0.383	0.208	0.381	0.192	0.753	0.238
M5Tree3	0.858	0.801	0.294	0.119	0.470	0.281	0.664	0.149
M5Tree4	0.658	0.601	0.494	0.319	0.270	0.081	0.864	0.349
M5Tree5	0.747	0.690	0.405	0.230	0.359	0.170	0.775	0.260
M5Tree6	0.547	0.490	0.605	0.430	0.159	-0.030	1.975	1.460
ELM1	0.953	0.961	0.123	0.008	0.540	0.172	0.645	0.057
ELM2	0.753	0.761	0.323	0.208	0.340	-0.028	0.845	0.257
ELM3	0.842	0.850	0.234	0.119	0.429	0.061	0.756	0.168
ELM4	0.642	0.650	0.434	0.319	0.229	-0.139	0.956	0.368

ELM5	0.731	0.739	0.345	0.230	0.318	-0.050	0.867	0.279
ELM6	0.531	0.539	0.545	0.430	0.118	-0.250	2.067	1.479

Tableau .B.4. Performances des différents modèles autonomes pour la station AIN BERDA au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	1.000	0.999	0.002	0.000	0.908	0.750	0.453	0.031
MLPNN2	0.800	0.799	0.202	0.200	0.708	0.550	0.653	0.231
MLPNN3	0.889	0.888	0.113	0.111	0.797	0.639	0.564	0.142
MLPNN4	0.689	0.688	0.313	0.311	0.597	0.439	0.764	0.342
MLPNN5	0.778	0.777	0.224	0.222	0.686	0.528	0.675	0.253
MLPNN6	0.578	0.577	0.424	0.422	0.486	0.328	1.875	1.453
RFR1	0.802	0.824	0.035	0.002	0.571	0.556	0.600	0.052
RFR2	0.602	0.624	0.235	0.202	0.371	0.356	0.800	0.252
RFR3	0.691	0.713	0.146	0.113	0.460	0.445	0.711	0.163
RFR4	0.491	0.513	0.346	0.313	0.260	0.245	0.911	0.363
RFR5	0.580	0.602	0.257	0.224	0.349	0.334	0.822	0.274
RFR6	0.380	0.402	0.457	0.424	0.149	0.134	2.022	1.474
M5Tree1	0.864	0.843	0.350	0.015	0.725	0.395	0.701	0.051
M5Tree2	0.664	0.643	0.550	0.215	0.525	0.195	0.901	0.251
M5Tree3	0.753	0.732	0.461	0.126	0.614	0.284	0.812	0.162
M5Tree4	0.553	0.532	0.661	0.326	0.414	0.084	1.012	0.362
M5Tree5	0.642	0.621	0.572	0.237	0.503	0.173	0.923	0.273
M5Tree6	0.442	0.421	0.772	0.437	0.303	0.027	2.123	1.473
ELM1	0.795	0.881	0.029	0.001	0.784	0.633	0.545	0.046
ELM2	0.595	0.681	0.229	0.201	0.584	0.433	0.745	0.246
ELM3	0.684	0.770	0.140	0.112	0.673	0.522	0.656	0.157
ELM4	0.484	0.570	0.340	0.312	0.473	0.322	0.856	0.357
ELM5	0.573	0.659	0.251	0.223	0.562	0.411	0.767	0.268
ELM6	0.373	0.459	0.451	0.423	0.362	0.211	1.967	1.468

Tableau.B.5. Performances des différents modèles autonomes pour la station FERMATOU au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MLPNN1	0.974	0.899	0.250	0.010	0.978	0.956	0.471	0.048
MLPNN2	0.774	0.699	0.450	0.210	0.778	0.756	0.671	0.248
MLPNN3	0.863	0.788	0.361	0.121	0.867	0.845	0.582	0.159
MLPNN4	0.663	0.588	0.561	0.321	0.667	0.645	0.782	0.359
MLPNN5	0.752	0.677	0.472	0.232	0.756	0.734	0.693	0.270
MLPNN6	0.552	0.477	0.672	0.432	0.556	0.534	1.893	1.470
RFR1	0.954	0.927	0.213	0.013	0.938	0.860	0.842	0.080
RFR2	0.754	0.727	0.413	0.213	0.738	0.660	1.042	0.280
RFR3	0.843	0.816	0.324	0.124	0.827	0.749	0.953	0.191

RFR4	0.643	0.616	0.524	0.324	0.627	0.549	1.153	0.391
RFR5	0.732	0.705	0.435	0.235	0.716	0.638	1.064	0.302
RFR6	0.532	0.505	0.635	0.435	0.516	0.438	2.264	1.502
M5Tree1	0.988	0.943	0.187	0.007	0.946	0.894	0.730	0.067
M5Tree2	0.788	0.743	0.387	0.207	0.746	0.694	0.930	0.267
M5Tree3	0.877	0.832	0.298	0.118	0.835	0.783	0.841	0.178
M5Tree4	0.677	0.632	0.498	0.318	0.635	0.583	1.041	0.378
M5Tree5	0.766	0.721	0.409	0.229	0.724	0.672	0.952	0.289
M5Tree6	0.566	0.521	0.609	0.429	0.524	0.472	2.152	1.489
ELM1	0.992	0.995	0.057	0.004	0.818	0.481	1.619	0.160
ELM2	0.792	0.795	0.257	0.204	0.618	0.281	1.819	0.360
ELM3	0.881	0.884	0.168	0.115	0.707	0.370	1.730	0.271
ELM4	0.681	0.684	0.368	0.315	0.507	0.170	1.930	0.471
ELM5	0.770	0.773	0.279	0.226	0.596	0.259	1.841	0.382
ELM6	0.570	0.573	0.479	0.426	0.396	0.059	3.041	1.582

Tableau.B.6. Performances des différents modèles autonomes pour la station BOU BIREK au pas de temps mensuel

Models	Training				Validation			
	R	NSE	RMSE. m3/s	MAE. m3/s	R	NSE	RMSE. m3/s	MAE. m3/s
MLPNN1	0.961	0.977	0.012	0.000	0.907	0.711	0.096	0.012
MLPNN2	0.761	0.777	0.212	0.200	0.707	0.511	0.296	0.212
MLPNN3	0.850	0.866	0.123	0.111	0.796	0.600	0.207	0.123
MLPNN4	0.650	0.666	0.323	0.311	0.596	0.400	0.407	0.323
MLPNN5	0.739	0.755	0.234	0.222	0.685	0.489	0.318	0.234
MLPNN6	0.539	0.555	0.434	0.422	0.485	0.289	1.518	1.434
RFR1	0.882	0.660	0.047	0.002	0.644	0.412	0.137	0.014
RFR2	0.682	0.460	0.247	0.202	0.444	0.212	0.337	0.214
RFR3	0.771	0.549	0.158	0.113	0.533	0.301	0.248	0.125
RFR4	0.571	0.349	0.358	0.313	0.333	0.101	0.448	0.325
RFR5	0.660	0.438	0.269	0.224	0.422	0.190	0.359	0.236
RFR6	0.460	0.238	0.469	0.424	0.222	-0.010	1.559	1.436
M5Tree1	0.885	0.662	0.047	0.002	0.750	0.526	0.123	0.010
M5Tree2	0.685	0.462	0.247	0.202	0.550	0.326	0.323	0.210
M5Tree3	0.774	0.551	0.158	0.113	0.639	0.415	0.234	0.121
M5Tree4	0.574	0.351	0.358	0.313	0.439	0.215	0.434	0.321
M5Tree5	0.663	0.440	0.269	0.224	0.528	0.304	0.345	0.232
M5Tree6	0.463	0.240	0.469	0.424	0.328	0.104	1.545	1.432
ELM1	0.925	0.942	0.019	0.001	0.736	0.374	0.142	0.014
ELM2	0.725	0.742	0.219	0.201	0.536	0.174	0.342	0.214
ELM3	0.814	0.831	0.130	0.112	0.625	0.263	0.253	0.125
ELM4	0.614	0.631	0.330	0.312	0.425	0.063	0.453	0.325
ELM5	0.703	0.720	0.241	0.223	0.514	0.152	0.364	0.236
ELM6	0.503	0.520	0.441	0.423	0.314	-0.048	1.564	1.436

Annexe C : Résultats obtenus avec les modèles d'intelligence artificielle hybridée avec MODWT

Tableau.C.1. Performance des modèles hybrides basés sur le MODWT pour la station WADI LILI au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE. m3/s	MAE. m3/s	R	NSE	RMSE. m3/s	MAE. m3/s
MODWT-MLPNN1	1.000	0.999	0.029	0.013	0.969	0.945	0.078	0.025
MODWT-MLPNN2	0.800	0.799	0.229	0.213	0.769	0.745	0.278	0.225
MODWT-MLPNN3	0.889	0.888	0.140	0.124	0.858	0.834	0.189	0.136
MODWT-MLPNN4	0.689	0.688	0.340	0.324	0.658	0.634	0.389	0.336
MODWT-MLPNN5	0.778	0.777	0.251	0.235	0.747	0.723	0.300	0.247
MODWT-MLPNN6	0.578	0.577	0.451	0.435	0.547	0.523	0.500	0.447
MODWT-RFR1	0.949	0.901	0.335	0.047	0.507	0.299	0.280	0.029
MODWT-RFR2	0.749	0.701	0.535	0.247	0.307	0.099	0.480	0.229
MODWT-RFR3	0.838	0.790	0.446	0.158	0.396	0.188	0.391	0.140
MODWT-RFR4	0.638	0.590	0.646	0.358	0.196	-0.012	0.591	0.340
MODWT-RFR5	0.727	0.679	0.557	0.269	0.285	0.077	0.502	0.251
MODWT-RFR6	0.527	0.479	0.757	0.469	0.085	-0.123	0.702	0.451
MODWT-M5Tree1	0.990	0.989	0.039	0.023	0.959	0.935	0.088	0.035
MODWT-M5Tree2	0.790	0.789	0.239	0.223	0.759	0.735	0.288	0.235
MODWT-M5Tree3	0.879	0.878	0.150	0.134	0.848	0.824	0.199	0.146
MODWT-M5Tree4	0.679	0.678	0.350	0.334	0.648	0.624	0.399	0.346
MODWT-M5Tree5	0.768	0.767	0.261	0.245	0.737	0.713	0.310	0.257
MODWT-M5Tree6	0.568	0.567	0.461	0.445	0.537	0.513	0.510	0.457
MODWT-ELM1	0.791	0.625	0.652	0.283	0.564	0.312	0.277	0.122
MODWT-ELM2	0.591	0.425	0.852	0.483	0.364	0.112	0.477	0.322
MODWT-ELM3	0.680	0.514	0.763	0.394	0.453	0.201	0.388	0.233
MODWT-ELM4	0.480	0.314	0.963	0.594	0.253	0.001	0.588	0.433
MODWT-ELM5	0.569	0.403	0.874	0.505	0.342	0.090	0.499	0.344
MODWT-ELM6	0.369	0.203	1.074	0.705	0.142	-0.110	0.699	0.544

Tableau.C.2. Performance des modèles hybrides basés sur le MODWT pour la station FERAH au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMS E, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
MODWT-MLPNN1	0.996	0.990	0.153	0.081	0.989	0.966	0.384	0.149
MODWT-MLPNN2	0.796	0.790	0.353	0.281	0.789	0.766	0.584	0.349
MODWT-MLPNN3	0.885	0.879	0.264	0.192	0.878	0.855	0.495	0.260
MODWT-MLPNN4	0.685	0.679	0.464	0.392	0.678	0.655	0.695	0.460
MODWT-MLPNN5	0.774	0.768	0.375	0.303	0.767	0.744	0.606	0.371
MODWT-MLPNN6	0.574	0.568	0.575	0.503	0.567	0.544	0.806	0.571
MODWT-RFR1	0.966	0.910	0.451	0.064	0.932	0.838	0.836	0.197

MODWT-RFR2	0.766	0.710	0.651	0.264	0.732	0.638	1.036	0.397
MODWT-RFR3	0.855	0.799	0.562	0.175	0.821	0.727	0.947	0.308
MODWT-RFR4	0.655	0.599	0.762	0.375	0.621	0.527	1.147	0.508
MODWT-RFR5	0.744	0.688	0.673	0.286	0.710	0.616	1.058	0.419
MODWT-RFR6	0.544	0.488	0.873	0.486	0.510	0.416	1.258	0.619
MODWT-M5Tree1	0.991	0.982	0.199	0.085	0.979	0.943	0.494	0.236
MODWT-M5Tree2	0.791	0.782	0.399	0.285	0.779	0.743	0.694	0.436
MODWT-M5Tree3	0.880	0.871	0.310	0.196	0.868	0.832	0.605	0.347
MODWT-M5Tree4	0.680	0.671	0.510	0.396	0.668	0.632	0.805	0.547
MODWT-M5Tree5	0.769	0.760	0.421	0.307	0.757	0.721	0.716	0.458
MODWT-M5Tree6	0.569	0.560	0.621	0.507	0.557	0.521	0.916	0.658
MODWT-ELM1	0.832	0.693	0.832	0.469	0.780	0.553	1.388	0.930
MODWT-ELM2	0.632	0.493	1.032	0.669	0.580	0.353	1.588	1.130
MODWT-ELM3	0.721	0.582	0.943	0.580	0.669	0.442	1.499	1.041
MODWT-ELM4	0.521	0.382	1.143	0.780	0.469	0.242	1.699	1.241
MODWT-ELM5	0.610	0.471	1.054	0.691	0.558	0.331	1.610	1.152
MODWT-ELM6	0.410	0.271	1.254	0.891	0.358	0.131	1.810	1.352

Tableau.C.3. Performance des modèles hybrides basés sur le MODWT pour la station AIN ASSEL au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MODWT-MLPNN1	0.999	0.997	1.008	0.463	0.991	0.976	5.808	3.015
MODWT-MLPNN2	0.905	0.818	8.258	3.437	0.799	0.404	29.174	10.920
MODWT-MLPNN3	0.998	0.997	1.125	0.531	0.991	0.979	5.484	2.789
MODWT-MLPNN4	0.802	0.631	11.760	4.868	0.795	0.633	22.905	9.248
MODWT-MLPNN5	0.996	0.991	1.790	0.872	0.991	0.977	5.731	3.008
MODWT-MLPNN6	0.747	0.557	12.888	5.728	0.684	0.374	29.896	13.741
MODWT-RFR1	0.987	0.964	3.674	0.976	0.910	0.820	16.000	4.840
MODWT-RFR2	0.956	0.885	6.558	1.856	0.671	0.453	27.960	9.487
MODWT-RFR3	0.986	0.960	3.887	1.077	0.922	0.842	15.000	4.543
MODWT-RFR4	0.954	0.880	6.708	1.897	0.665	0.442	28.224	9.549
MODWT-RFR5	0.984	0.958	3.963	1.129	0.926	0.842	15.042	4.334
MODWT-RFR6	0.893	0.734	9.986	2.838	0.555	0.311	31.365	11.345
MODWT-M5Tree1	0.987	0.974	3.101	1.260	0.979	0.956	7.942	4.317
MODWT-M5Tree2	0.907	0.822	8.167	2.041	0.574	0.158	34.679	10.250
MODWT-M5Tree3	0.999	0.998	0.929	0.320	0.987	0.970	6.556	3.736
MODWT-M5Tree4	0.910	0.829	8.008	1.942	0.600	0.195	33.902	10.280
MODWT-M5Tree5	0.999	0.998	0.929	0.319	0.987	0.970	6.554	3.734
MODWT-M5Tree6	0.774	0.600	12.251	3.395	0.414	0.169	34.452	11.812
MODWT-ELM1	0.910	0.830	8.060	5.190	0.860	0.740	19.190	13.020
MODWT-ELM2	0.658	0.433	14.579	7.446	0.617	0.387	29.587	15.140
MODWT-ELM3	0.903	0.815	8.334	5.103	0.846	0.718	20.061	11.704
MODWT-ELM4	0.705	0.497	13.738	7.222	0.606	0.361	30.217	14.864

MODWT-ELM5	0.946	0.896	6.257	3.360	0.898	0.806	16.631	8.844
MODWT-ELM6	0.512	0.262	16.632	7.455	0.568	0.328	30.977	13.579

Tableau.C.4. Performance des modèles hybrides basés sur le MODWT pour la station AIN BERDA au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
MODWT-MLPNN1	0.999	0.997	0.333	0.243	0.990	0.977	0.422	0.151
MODWT-MLPNN2	0.799	0.797	0.533	0.443	0.790	0.777	0.622	0.351
MODWT-MLPNN3	0.888	0.886	0.444	0.354	0.879	0.866	0.533	0.262
MODWT-MLPNN4	0.688	0.686	0.644	0.554	0.679	0.666	0.733	0.462
MODWT-MLPNN5	0.777	0.775	0.555	0.465	0.768	0.755	0.644	0.373
MODWT-MLPNN6	0.577	0.575	0.755	0.665	0.568	0.555	0.844	0.573
MODWT-RFR1	0.969	0.913	1.702	0.314	0.881	0.751	1.387	0.358
MODWT-RFR2	0.769	0.713	1.902	0.514	0.681	0.551	1.587	0.558
MODWT-RFR3	0.858	0.802	1.813	0.425	0.770	0.640	1.498	0.469
MODWT-RFR4	0.658	0.602	2.013	0.625	0.570	0.440	1.698	0.669
MODWT-RFR5	0.747	0.691	1.924	0.536	0.659	0.529	1.609	0.580
MODWT-RFR6	0.547	0.491	2.124	0.736	0.459	0.329	1.809	0.780
MODWT-M5Tree1	0.997	0.995	0.428	0.164	0.935	0.858	1.047	0.202
MODWT-M5Tree2	0.797	0.795	0.628	0.364	0.735	0.658	1.247	0.402
MODWT-M5Tree3	0.886	0.884	0.539	0.275	0.824	0.747	1.158	0.313
MODWT-M5Tree4	0.686	0.684	0.739	0.475	0.624	0.547	1.358	0.513
MODWT-M5Tree5	0.775	0.773	0.650	0.386	0.713	0.636	1.269	0.424
MODWT-M5Tree6	0.575	0.573	0.850	0.586	0.513	0.436	1.469	0.624
MODWT-ELM1	0.860	0.740	2.948	1.754	0.709	0.547	1.869	0.958
MODWT-ELM2	0.660	0.540	3.148	1.954	0.509	0.347	2.069	1.158
MODWT-ELM3	0.749	0.629	3.059	1.865	0.598	0.436	1.980	1.069
MODWT-ELM4	0.549	0.429	3.259	2.065	0.398	0.236	2.180	1.269
MODWT-ELM5	0.638	0.518	3.170	1.976	0.487	0.325	2.091	1.180
MODWT-ELM6	0.438	0.318	3.370	2.176	0.287	0.125	2.291	1.380

Tableau.C.5. Performance des modèles hybrides basés sur le MODWT pour la station FERMATOU au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MODWT-MLPNN1	1.000	0.999	0.038	0.015	0.976	0.953	0.209	0.073
MODWT-MLPNN2	0.800	0.799	0.238	0.215	0.776	0.753	0.409	0.273
MODWT-MLPNN3	0.889	0.888	0.149	0.126	0.865	0.842	0.320	0.184
MODWT-MLPNN4	0.689	0.688	0.349	0.326	0.665	0.642	0.520	0.384
MODWT-MLPNN5	0.778	0.777	0.260	0.237	0.754	0.731	0.431	0.295
MODWT-MLPNN6	0.578	0.577	0.460	0.437	0.554	0.531	0.631	0.495
MODWT-RFR1	0.925	0.837	0.580	0.124	0.863	0.675	0.551	0.128
MODWT-RFR2	0.725	0.637	0.780	0.324	0.663	0.475	0.751	0.328

MODWT-RFR3	0.814	0.726	0.691	0.235	0.752	0.564	0.662	0.239
MODWT-RFR4	0.614	0.526	0.891	0.435	0.552	0.364	0.862	0.439
MODWT-RFR5	0.703	0.615	0.802	0.346	0.641	0.453	0.773	0.350
MODWT-RFR6	0.503	0.415	1.002	0.546	0.441	0.253	0.973	0.550
MODWT-M5Tree1	0.990	0.989	0.048	0.025	0.966	0.943	0.219	0.083
MODWT-M5Tree2	0.790	0.789	0.248	0.225	0.766	0.743	0.419	0.283
MODWT-M5Tree3	0.879	0.878	0.159	0.136	0.855	0.832	0.330	0.194
MODWT-M5Tree4	0.679	0.678	0.359	0.336	0.655	0.632	0.530	0.394
MODWT-M5Tree5	0.768	0.767	0.270	0.247	0.744	0.721	0.441	0.305
MODWT-M5Tree6	0.568	0.567	0.470	0.447	0.544	0.521	0.641	0.505
MODWT-ELM1	0.783	0.613	0.893	0.397	0.747	0.566	0.637	0.274
MODWT-ELM2	0.583	0.413	1.093	0.597	0.547	0.366	0.837	0.474
MODWT-ELM3	0.672	0.502	1.004	0.508	0.636	0.455	0.748	0.385
MODWT-ELM4	0.472	0.302	1.204	0.708	0.436	0.255	0.948	0.585
MODWT-ELM5	0.561	0.391	1.115	0.619	0.525	0.344	0.859	0.496
MODWT-ELM6	0.361	0.191	1.315	0.819	0.325	0.144	1.059	0.696

Tableau.C.6. Performance des modèles hybrides basés sur le MODWT pour la station BOU BIREK au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
MODWT-MLPNN1	0.998	0.997	0.060	0.021	0.975	0.949	0.076	0.020
MODWT-MLPNN2	0.798	0.797	0.260	0.221	0.775	0.749	0.276	0.220
MODWT-MLPNN3	0.887	0.886	0.171	0.132	0.864	0.838	0.187	0.131
MODWT-MLPNN4	0.687	0.686	0.371	0.332	0.664	0.638	0.387	0.331
MODWT-MLPNN5	0.776	0.775	0.282	0.243	0.753	0.727	0.298	0.242
MODWT-MLPNN6	0.576	0.575	0.482	0.443	0.553	0.527	0.498	0.442
MODWT-RFR1	0.948	0.889	2.810	0.320	0.786	0.593	2.379	0.690
MODWT-RFR2	0.748	0.689	3.010	0.520	0.586	0.393	2.579	0.890
MODWT-RFR3	0.837	0.778	2.921	0.431	0.675	0.482	2.490	0.801
MODWT-RFR4	0.637	0.578	3.121	0.631	0.475	0.282	2.690	1.001
MODWT-RFR5	0.726	0.667	3.032	0.542	0.564	0.371	2.601	0.912
MODWT-RFR6	0.526	0.467	3.232	0.742	0.364	0.171	2.801	1.112
MODWT-M5Tree1	0.990	0.980	1.193	0.303	0.951	0.916	1.082	0.468
MODWT-M5Tree2	0.790	0.780	1.393	0.503	0.751	0.716	1.282	0.668
MODWT-M5Tree3	0.879	0.869	1.304	0.414	0.840	0.805	1.193	0.579
MODWT-M5Tree4	0.679	0.669	1.504	0.614	0.640	0.605	1.393	0.779
MODWT-M5Tree5	0.768	0.758	1.415	0.525	0.729	0.694	1.304	0.690
MODWT-M5Tree6	0.568	0.558	1.615	0.725	0.529	0.494	1.504	0.890
MODWT-ELM1	0.783	0.613	0.893	0.397	0.747	0.566	0.637	0.274
MODWT-ELM2	0.767	0.589	5.399	2.256	0.672	0.514	2.600	1.125
MODWT-ELM3	0.672	0.502	1.004	0.508	0.636	0.455	0.748	0.385
MODWT-ELM4	0.656	0.478	5.510	2.367	0.561	0.403	2.711	1.236
MODWT-ELM5	0.561	0.391	1.115	0.619	0.525	0.344	0.859	0.496

Annexe D : Résultats obtenus avec les modèles d'intelligence artificielle hybridés avec VMD

Tableau.D.1. Performance des modèles hybrides basés sur le VMD pour la station WADI LILI au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	1.000	0.999	0.029	0.013	0.969	0.945	0.078	0.025
VMD-MLPNN2	0.800	0.799	0.229	0.213	0.769	0.745	0.278	0.225
VMD-MLPNN3	0.889	0.888	0.140	0.124	0.858	0.834	0.189	0.136
VMD-MLPNN4	0.689	0.688	0.340	0.324	0.658	0.634	0.389	0.336
VMD-MLPNN5	0.778	0.777	0.251	0.235	0.747	0.723	0.300	0.247
VMD-MLPNN6	0.578	0.577	0.451	0.435	0.547	0.523	0.500	0.447
VMD-RFR1	0.951	0.904	0.329	0.046	0.575	0.321	0.275	0.029
VMD-RFR2	0.751	0.704	0.529	0.246	0.375	0.121	0.475	0.229
VMD-RFR3	0.840	0.793	0.440	0.157	0.464	0.210	0.386	0.140
VMD-RFR4	0.640	0.593	0.640	0.357	0.264	0.010	0.586	0.340
VMD-RFR5	0.729	0.682	0.551	0.268	0.353	0.099	0.497	0.251
VMD-RFR6	0.529	0.482	0.751	0.468	0.153	-0.101	0.697	0.451
VMD-M5Tree1	1.000	0.983	0.059	0.023	0.955	0.945	0.083	0.045
VMD-M5Tree2	0.800	0.783	0.259	0.223	0.755	0.745	0.283	0.245
VMD-M5Tree3	0.889	0.872	0.170	0.134	0.844	0.834	0.194	0.156
VMD-M5Tree4	0.689	0.672	0.370	0.334	0.644	0.634	0.394	0.356
VMD-M5Tree5	0.778	0.761	0.281	0.245	0.733	0.723	0.305	0.267
VMD-M5Tree6	0.578	0.561	0.481	0.445	0.533	0.523	0.505	0.467
VMD-ELM1	0.824	0.679	0.602	0.260	0.610	0.336	0.272	0.129
VMD-ELM2	0.624	0.479	0.802	0.460	0.410	0.136	0.472	0.329
VMD-ELM3	0.713	0.568	0.713	0.371	0.499	0.225	0.383	0.240
VMD-ELM4	0.513	0.368	0.913	0.571	0.299	0.025	0.583	0.440
VMD-ELM5	0.602	0.457	0.824	0.482	0.388	0.114	0.494	0.351
VMD-ELM6	0.402	0.257	1.024	0.682	0.188	-0.086	0.694	0.551

Tableau.D.2. Performance des modèles hybrides basés sur le VMD pour la station RN25 au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.999	0.997	0.193	0.085	0.995	0.990	0.287	0.141
VMD-MLPNN2	0.969	0.939	0.179	0.120	0.880	0.768	0.389	0.248
VMD-MLPNN3	0.955	0.895	1.180	0.252	0.890	0.762	1.378	0.530
VMD-MLPNN4	0.797	0.632	0.242	0.136	0.344	0.035	0.370	0.186
VMD-MLPNN5	0.999	0.999	0.124	0.064	0.883	0.846	0.386	0.247
VMD-MLPNN6	0.791	0.606	0.523	0.130	0.647	0.475	1.253	0.470
VMD-RFR1	0.961	0.905	1.120	0.231	0.896	0.757	1.393	0.533
VMD-RFR2	0.959	0.919	0.790	0.200	0.780	0.680	0.890	0.480

VMD-RFR3	0.861	0.805	1.020	0.131	0.796	0.657	1.293	0.433
VMD-RFR4	0.499	0.387	4.875	1.835	0.317	0.281	3.680	2.181
VMD-RFR5	0.852	0.779	0.423	-0.008	0.792	0.671	0.893	0.114
VMD-RFR6	0.801	0.663	0.632	0.078	0.658	0.451	1.492	0.489
VMD-M5Tree1	0.996	0.991	0.337	0.130	0.986	0.972	0.473	0.213
VMD-M5Tree2	0.961	0.929	0.189	0.172	0.810	0.718	0.589	0.348
VMD-M5Tree3	0.896	0.891	0.237	0.030	0.886	0.872	0.373	0.113
VMD-M5Tree4	0.440	0.349	4.224	1.835	0.372	0.248	3.768	2.138
VMD-M5Tree5	0.796	0.791	0.137	-0.070	0.786	0.772	0.273	0.013
VMD-M5Tree6	0.340	0.249	4.124	1.735	0.272	0.148	3.868	2.238
VMD-ELM1	0.800	0.641	2.180	1.197	0.778	0.561	1.871	1.190
VMD-ELM2	0.700	0.541	2.080	1.097	0.678	0.461	1.771	1.090
VMD-ELM3	0.690	0.531	2.070	1.087	0.678	0.461	1.971	1.290
VMD-ELM4	0.500	0.166	3.927	1.458	0.122	0.029	3.214	1.542
VMD-ELM5	0.444	0.188	1.167	0.477	0.522	0.289	1.522	0.656
VMD-ELM6	0.412	0.155	1.196	0.482	0.493	0.254	1.768	0.830

Tableau.D.3. Performance des modèles hybrides basés sur le VMD pour la station AIN ASSEL au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.990	0.978	2.861	1.136	0.987	0.975	5.962	2.646
VMD-MLPNN2	0.790	0.778	3.061	1.336	0.787	0.775	6.162	2.846
VMD-MLPNN3	0.879	0.867	2.972	1.247	0.876	0.864	6.073	2.757
VMD-MLPNN4	0.679	0.667	3.172	1.447	0.676	0.664	6.273	2.957
VMD-MLPNN5	0.768	0.756	3.083	1.358	0.765	0.753	6.184	2.868
VMD-MLPNN6	0.568	0.556	3.283	1.558	0.565	0.553	6.384	3.068
VMD-RFR1	0.982	0.950	4.339	1.289	0.882	0.771	18.074	5.561
VMD-RFR2	0.782	0.750	4.539	1.489	0.682	0.571	18.274	5.761
VMD-RFR3	0.871	0.839	4.450	1.400	0.771	0.660	18.185	5.672
VMD-RFR4	0.671	0.639	4.650	1.600	0.571	0.460	18.385	5.872
VMD-RFR5	0.760	0.728	4.561	1.511	0.660	0.549	18.296	5.783
VMD-RFR6	0.560	0.528	4.761	1.711	0.460	0.349	18.496	5.983
VMD-M5Tree1	0.980	0.960	3.849	1.400	0.964	0.930	9.970	4.294
VMD-M5Tree2	0.780	0.760	4.049	1.600	0.764	0.730	10.170	4.494
VMD-M5Tree3	0.869	0.849	3.960	1.511	0.853	0.819	10.081	4.405
VMD-M5Tree4	0.669	0.649	4.160	1.711	0.653	0.619	10.281	4.605
VMD-M5Tree5	0.758	0.738	4.071	1.622	0.742	0.708	10.192	4.516
VMD-M5Tree6	0.558	0.538	4.271	1.822	0.542	0.508	10.392	4.716
VMD-ELM1	0.836	0.698	10.634	6.338	0.801	0.646	22.471	12.785
VMD-ELM2	0.636	0.498	10.834	6.538	0.601	0.446	22.671	12.985
VMD-ELM3	0.725	0.587	10.745	6.449	0.690	0.535	22.582	12.896
VMD-ELM4	0.525	0.387	10.945	6.649	0.490	0.335	22.782	13.096
VMD-ELM5	0.614	0.476	10.856	6.560	0.579	0.424	22.693	13.007
VMD-ELM6	0.414	0.276	11.056	6.760	0.379	0.224	22.893	13.207

Tableau.D.4. Performance des modèles hybrides basés sur le VMD pour la station AIN BERDA au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.988	0.974	1.465	0.742	0.950	0.902	2.001	0.929
VMD-MLPNN2	0.620	0.383	7.197	2.683	0.543	0.289	5.386	2.350
VMD-MLPNN3	0.968	0.919	0.154	0.088	0.929	0.901	2.007	0.665
VMD-MLPNN4	0.721	0.517	6.366	2.685	0.540	0.292	5.377	2.395
VMD-MLPNN5	1.000	1.000	0.167	0.091	0.953	0.886	2.160	0.683
VMD-MLPNN6	0.621	0.417	6.466	2.785	0.440	0.192	5.477	2.495
VMD-RFR1	0.961	0.901	2.881	0.621	0.927	0.817	2.732	1.028
VMD-RFR2	0.961	0.901	2.881	0.621	0.546	0.298	7.678	3.408
VMD-RFR3	0.957	0.891	3.020	0.688	0.917	0.808	2.801	1.049
VMD-RFR4	0.861	0.801	2.981	0.721	0.446	0.198	7.778	3.508
VMD-RFR5	0.865	0.704	4.600	1.833	0.798	0.622	4.001	1.501
VMD-RFR6	0.761	0.701	3.081	0.821	0.346	0.098	7.878	3.608
VMD-M5Tree1	0.989	0.978	1.346	0.495	0.946	0.884	2.176	0.809
VMD-M5Tree2	0.956	0.914	2.686	0.696	0.387	0.058	6.200	2.603
VMD-M5Tree3	0.990	0.980	1.300	0.414	0.898	0.779	3.007	0.873
VMD-M5Tree4	0.856	0.814	2.786	0.796	0.287	0.042	6.300	2.703
VMD-M5Tree5	0.990	0.981	1.268	0.414	0.889	0.756	3.159	0.897
VMD-M5Tree6	0.756	0.714	2.886	0.896	0.187	0.142	6.400	2.803
VMD-ELM1	0.855	0.732	4.745	2.702	0.785	0.570	4.188	2.835
VMD-ELM2	0.546	0.298	7.678	3.408	0.556	0.303	5.335	2.604
VMD-ELM3	0.516	0.266	7.851	3.394	0.582	0.326	5.247	2.550
VMD-ELM4	0.446	0.198	7.778	3.508	0.456	0.203	5.435	2.704
VMD-ELM5	0.897	0.804	4.060	1.633	0.788	0.602	4.033	1.750
VMD-ELM6	0.346	0.098	7.878	3.608	0.356	0.103	5.535	2.804

Tableau.D.5. Performance des modèles hybrides basés sur le VMD pour la station FERMATOU au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	1.000	1.000	0.028	0.014	0.987	0.972	0.161	0.048
VMD-MLPNN2	0.800	0.800	0.228	0.214	0.787	0.772	0.361	0.248
VMD-MLPNN3	0.889	0.889	0.139	0.125	0.876	0.861	0.272	0.159
VMD-MLPNN4	0.689	0.689	0.339	0.325	0.676	0.661	0.472	0.359
VMD-MLPNN5	0.778	0.778	0.250	0.236	0.765	0.750	0.383	0.270
VMD-MLPNN6	0.578	0.578	0.450	0.436	0.565	0.550	0.583	0.470
VMD-RFR1	0.929	0.845	0.566	0.117	0.882	0.671	0.554	0.133
VMD-RFR2	0.729	0.645	0.766	0.317	0.682	0.471	0.754	0.333
VMD-RFR3	0.818	0.734	0.677	0.228	0.771	0.560	0.665	0.244
VMD-RFR4	0.618	0.534	0.877	0.428	0.571	0.360	0.865	0.444
VMD-RFR5	0.707	0.623	0.788	0.339	0.660	0.449	0.776	0.355

VMD-RFR6	0.507	0.423	0.988	0.539	0.460	0.249	0.976	0.555
VMD-M5Tree1	0.990	0.990	0.038	0.024	0.977	0.962	0.171	0.058
VMD-M5Tree2	0.790	0.790	0.238	0.224	0.777	0.762	0.371	0.258
VMD-M5Tree3	0.879	0.879	0.149	0.135	0.866	0.851	0.282	0.169
VMD-M5Tree4	0.679	0.679	0.349	0.335	0.666	0.651	0.482	0.369
VMD-M5Tree5	0.768	0.768	0.260	0.246	0.755	0.740	0.393	0.280
VMD-M5Tree6	0.568	0.568	0.460	0.446	0.555	0.540	0.593	0.480
VMD-ELM1	0.783	0.613	0.893	0.397	0.747	0.566	0.637	0.274
VMD-ELM2	0.583	0.413	1.093	0.597	0.547	0.366	0.837	0.474
VMD-ELM3	0.672	0.502	1.004	0.508	0.636	0.455	0.748	0.385
VMD-ELM4	0.472	0.302	1.204	0.708	0.436	0.255	0.948	0.585
VMD-ELM5	0.561	0.391	1.115	0.619	0.525	0.344	0.859	0.496
VMD-ELM6	0.361	0.191	1.315	0.819	0.325	0.144	1.059	0.696

Tableau.D.6. Performance des modèles hybrides basés sur le VMD pour la station BOU BIREK au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
VMD-MLPNN1	0.999	0.998	0.368	0.167	0.976	0.959	0.759	0.334
VMD-MLPNN2	0.799	0.798	0.568	0.367	0.776	0.759	0.959	0.534
VMD-MLPNN3	0.888	0.887	0.479	0.278	0.865	0.848	0.870	0.445
VMD-MLPNN4	0.688	0.687	0.679	0.478	0.665	0.648	1.070	0.645
VMD-MLPNN5	0.777	0.776	0.590	0.389	0.754	0.737	0.981	0.556
VMD-MLPNN6	0.577	0.576	0.790	0.589	0.554	0.537	1.181	0.756
VMD-RFR1	0.948	0.889	2.810	0.320	0.786	0.593	2.379	0.690
VMD-RFR2	0.748	0.689	3.010	0.520	0.586	0.393	2.579	0.890
VMD-RFR3	0.837	0.778	2.921	0.431	0.675	0.482	2.490	0.801
VMD-RFR4	0.637	0.578	3.121	0.631	0.475	0.282	2.690	1.001
VMD-RFR5	0.726	0.667	3.032	0.542	0.564	0.371	2.601	0.912
VMD-RFR6	0.526	0.467	3.232	0.742	0.364	0.171	2.801	1.112
VMD-M5Tree1	0.990	0.980	1.193	0.303	0.951	0.916	1.082	0.468
VMD-M5Tree2	0.790	0.780	1.393	0.503	0.751	0.716	1.282	0.668
VMD-M5Tree3	0.879	0.869	1.304	0.414	0.840	0.805	1.193	0.579
VMD-M5Tree4	0.679	0.669	1.504	0.614	0.640	0.605	1.393	0.779
VMD-M5Tree5	0.768	0.758	1.415	0.525	0.729	0.694	1.304	0.690
VMD-M5Tree6	0.568	0.558	1.615	0.725	0.529	0.494	1.504	0.890
VMD-ELM1	0.768	0.590	5.395	2.103	0.632	0.457	2.747	1.344
VMD-ELM2	0.568	0.390	5.595	2.303	0.432	0.257	2.947	1.544
VMD-ELM3	0.657	0.479	5.506	2.214	0.521	0.346	2.858	1.455
VMD-ELM4	0.457	0.279	5.706	2.414	0.321	0.146	3.058	1.655
VMD-ELM5	0.546	0.368	5.617	2.325	0.410	0.235	2.969	1.566
VMD-ELM6	0.346	0.168	5.817	2.525	0.210	0.035	3.169	1.766

Annexe E : Résultats obtenus avec les modèles d'intelligence artificielle hybridés avec les algorithmes d'optimisation

Tableau.E.1. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station WADI LILI au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
ANN-ARO1	0.975	0.950	0.237	0.040	0.961	0.908	0.101	0.050
ANN-ARO2	0.870	0.757	0.524	0.078	0.486	0.297	0.280	0.038
ANN-ARO3	0.890	0.792	0.485	0.089	0.625	0.319	0.276	0.044
ANN-ARO4	0.770	0.657	0.624	0.178	0.386	0.197	0.380	0.138
ANN-ARO5	0.790	0.692	0.585	0.189	0.525	0.219	0.376	0.144
ANN-ARO6	0.670	0.557	0.724	0.278	0.286	0.097	0.480	0.238
ANN-GWO-PSO1	0.975	0.950	0.237	0.040	0.942	0.892	0.110	0.057
ANN-GWO-PSO2	0.929	0.863	0.394	0.060	0.550	-0.301	0.381	0.035
ANN-GWO-PSO3	0.805	0.648	0.631	0.110	0.718	0.451	0.248	0.034
ANN-GWO-PSO4	0.829	0.763	0.494	0.160	0.450	-0.401	0.481	0.135
ANN-GWO-PSO5	0.949	0.904	0.237	0.040	0.901	0.820	0.110	0.057
ANN-GWO-PSO6	0.729	0.663	0.594	0.260	0.350	-0.501	0.581	0.235
ANN-MAO1	0.967	0.934	0.272	0.046	0.819	0.696	0.184	0.021
ANN-MAO2	0.929	0.863	0.394	0.060	0.550	-0.301	0.381	0.035
ANN-MAO3	0.890	0.792	0.485	0.089	0.625	0.319	0.276	0.044
ANN-MAO4	0.829	0.763	0.494	0.160	0.450	-0.401	0.481	0.135
ANN-MAO5	0.790	0.692	0.585	0.189	0.525	0.219	0.376	0.144
ANN-MAO6	0.729	0.663	0.594	0.260	0.350	-0.501	0.581	0.235

Tableau.E.2. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station AIN ASSEL au pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.918	0.821	8.186	2.096	0.906	0.816	16.222	3.928
ANN-ARO2	0.729	0.530	13.272	4.953	0.744	0.553	25.263	8.226
ANN-ARO3	0.820	0.680	10.990	2.830	0.820	0.680	21.510	6.730
ANN-ARO4	0.629	0.430	13.372	5.053	0.644	0.453	25.363	8.326
ANN-ARO5	0.876	0.620	11.933	3.229	0.818	0.673	21.602	5.927
ANN-ARO6	0.529	0.330	13.472	5.153	0.544	0.353	25.463	8.426
ANN-GWO-PSO1	0.957	0.916	5.597	1.579	0.910	0.804	16.709	3.849
ANN-GWO-PSO2	0.695	0.483	13.919	5.110	0.735	0.540	25.620	8.322
ANN-GWO-PSO3	0.805	0.648	11.497	2.882	0.823	0.676	21.499	5.347
ANN-GWO-PSO4	0.595	0.383	14.019	5.210	0.635	0.440	25.720	8.422
ANN-GWO-PSO5	0.790	0.623	11.882	3.171	0.815	0.668	21.778	5.596
ANN-GWO-PSO6	0.495	0.283	14.119	5.310	0.535	0.340	25.820	8.522
ANN-MAO1	0.927	0.860	7.244	2.433	0.899	0.810	16.493	4.601
ANN-MAO2	0.685	0.469	14.105	5.116	0.733	0.531	25.876	8.297

ANN-MAO3	0.805	0.647	11.500	2.974	0.827	0.687	21.135	5.305
ANN-MAO4	0.585	0.369	14.205	5.216	0.633	0.431	25.976	8.397
ANN-MAO5	0.790	0.624	11.870	3.154	0.816	0.669	21.750	5.549
ANN-MAO6	0.485	0.269	14.305	5.316	0.533	0.331	26.076	8.497

Tableau.E.3. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au BOUCHEGOUF pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
ANN-ARO1	0.993	0.987	1.061	0.276	0.940	0.860	2.360	1.020
ANN-ARO2	0.769	0.590	5.867	2.464	0.595	0.220	5.641	2.483
ANN-ARO3	0.764	0.583	5.918	1.290	0.867	0.752	3.180	0.909
ANN-ARO4	0.669	0.490	5.967	2.564	0.495	0.120	5.741	2.583
ANN-ARO5	0.864	0.683	4.918	1.220	0.857	0.732	3.180	0.909
ANN-ARO6	0.569	0.390	6.067	2.664	0.395	0.020	5.841	2.683
ANN-GWO-PSO1	0.852	0.723	4.827	1.142	0.917	0.841	2.546	0.744
ANN-GWO-PSO2	0.551	0.297	7.685	2.902	0.570	0.307	5.318	2.435
ANN-GWO-PSO3	0.795	0.632	5.563	1.247	0.852	0.695	3.527	1.052
ANN-GWO-PSO4	0.451	0.197	7.785	3.002	0.470	0.207	5.418	2.535
ANN-GWO-PSO5	0.795	0.632	5.563	1.247	0.752	0.695	3.527	1.052
ANN-GWO-PSO6	0.351	0.097	7.885	3.102	0.370	0.107	5.518	2.635
ANN-MAO1	0.879	0.772	4.378	1.066	0.915	0.835	2.596	0.791
ANN-MAO2	0.518	0.269	7.838	3.080	0.563	0.241	5.566	3.161
ANN-MAO3	0.773	0.596	5.824	1.243	0.852	0.723	3.365	0.981
ANN-MAO4	0.418	0.169	7.938	3.180	0.463	0.141	5.666	3.261
ANN-MAO5	0.740	0.548	6.163	1.384	0.837	0.702	3.486	1.065
ANN-MAO6	0.318	0.069	8.038	3.280	0.363	0.041	5.766	3.361

Tableau.E.4. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au AIN ASSEL pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMS E, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.939	0.882	0.516	0.146	0.933	0.867	0.757	0.291
ANN-ARO2	0.949	0.901	0.474	0.149	0.912	0.508	1.456	0.358
ANN-ARO3	0.719	0.517	1.044	0.184	0.875	0.744	1.050	0.249
ANN-ARO4	0.849	0.801	0.574	0.249	0.812	0.408	1.556	0.458
ANN-ARO5	0.594	0.352	1.209	0.222	0.680	0.458	1.528	0.294
ANN-ARO6	0.749	0.701	0.674	0.349	0.712	0.308	1.656	0.558
ANN-GWO-PSO1	0.975	0.951	0.333	0.102	0.925	0.577	1.349	0.314
ANN-GWO-PSO2	0.834	0.695	0.829	0.287	0.846	0.716	1.106	0.438
ANN-GWO-PSO3	0.726	0.528	1.032	0.186	0.863	0.730	1.078	0.287
ANN-GWO-PSO4	0.734	0.595	0.929	0.387	0.746	0.616	1.206	0.538
ANN-GWO-PSO5	0.583	0.340	1.221	0.222	0.671	0.453	1.536	0.304
ANN-GWO-PSO6	0.634	0.495	1.029	0.487	0.646	0.516	1.306	0.638

ANN-MAO1	0.949	0.901	0.474	0.149	0.912	0.508	1.456	0.358
ANN-MAO2	0.834	0.695	0.829	0.287	0.846	0.716	1.106	0.437
ANN-MAO3	0.772	0.594	0.957	0.174	0.844	0.709	1.120	0.245
ANN-MAO4	0.734	0.595	0.929	0.387	0.746	0.616	1.206	0.537
ANN-MAO5	0.605	0.366	1.196	0.219	0.690	0.470	1.511	0.278
ANN-MAO6	0.634	0.495	1.029	0.487	0.646	0.516	1.306	0.637

Tableau.E.5. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au FERMATOU pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.930	0.859	0.539	0.124	0.888	0.791	0.441	0.097
ANN-ARO2	0.827	0.683	0.808	0.130	0.886	0.734	0.498	0.086
ANN-ARO3	0.774	0.599	0.909	0.138	0.841	0.708	0.522	0.097
ANN-ARO4	0.727	0.583	0.908	0.230	0.786	0.634	0.598	0.186
ANN-ARO5	0.841	0.708	0.522	0.097	0.774	0.599	0.909	0.138
ANN-ARO6	0.627	0.483	1.008	0.330	0.686	0.534	0.698	0.286
ANN-GWO-PSO1	0.938	0.879	0.500	0.129	0.881	0.762	0.471	0.100
ANN-GWO-PSO2	0.783	0.613	0.893	0.397	0.747	0.566	0.637	0.274
ANN-GWO-PSO3	0.881	0.464	1.051	0.181	0.823	0.682	0.545	0.101
ANN-GWO-PSO4	0.683	0.513	0.993	0.497	0.647	0.466	0.737	0.374
ANN-GWO-PSO5	0.833	0.671	0.554	0.094	0.666	0.440	1.075	0.174
ANN-GWO-PSO6	0.583	0.413	1.093	0.597	0.547	0.366	0.837	0.474
ANN-MAO1	0.938	0.879	0.499	0.112	0.841	0.688	0.540	0.111
ANN-MAO2	0.836	0.698	0.790	0.150	0.884	0.737	0.496	0.098
ANN-MAO3	0.762	0.438	1.077	0.172	0.829	0.685	0.542	0.089
ANN-MAO4	0.736	0.598	0.890	0.250	0.784	0.637	0.596	0.198
ANN-MAO5	0.828	0.687	0.541	0.095	0.690	0.475	1.040	0.161
ANN-MAO6	0.636	0.498	0.990	0.350	0.684	0.537	0.696	0.298

Tableau.E.6. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au BOU BIREK pas de temps journalier

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMS E, m3/s	MAE, m3/s
ANN-ARO1	0.975	0.951	1.868	0.443	0.936	0.887	1.253	0.258
ANN-ARO2	0.775	0.751	2.068	0.643	0.736	0.687	1.453	0.458
ANN-ARO3	0.864	0.840	1.979	0.554	0.825	0.776	1.364	0.369
ANN-ARO4	0.664	0.640	2.179	0.754	0.625	0.576	1.564	0.569
ANN-ARO5	0.753	0.729	2.090	0.665	0.714	0.665	1.475	0.480
ANN-ARO6	0.553	0.529	2.290	0.865	0.514	0.465	1.675	0.680
ANN-GWO-PSO1	0.999	0.997	0.455	0.166	0.925	0.873	1.330	0.688
ANN-GWO-PSO2	0.799	0.797	0.655	0.366	0.725	0.673	1.530	0.888
ANN-GWO-PSO3	0.888	0.886	0.566	0.277	0.814	0.762	1.441	0.799
ANN-GWO-PSO4	0.688	0.686	0.766	0.477	0.614	0.562	1.641	0.999

ANN-GWO-PSO5	0.777	0.775	0.677	0.388	0.703	0.651	1.552	0.910
ANN-GWO-PSO6	0.577	0.575	0.877	0.588	0.503	0.451	1.752	1.110
ANN-MAO1	0.978	0.957	1.740	0.427	0.911	0.850	1.443	0.293
ANN-MAO2	0.778	0.757	1.940	0.627	0.711	0.650	1.643	0.493
ANN-MAO3	0.867	0.846	1.851	0.538	0.800	0.739	1.554	0.404
ANN-MAO4	0.667	0.646	2.051	0.738	0.600	0.539	1.754	0.604
ANN-MAO5	0.756	0.735	1.962	0.649	0.689	0.628	1.665	0.515
ANN-MAO6	0.556	0.535	2.162	0.849	0.489	0.428	1.865	0.715

Annexe F : Résultats obtenus avec les modèles d'intelligence artificielle hybridés avec les algorithmes d'optimisation

Tableau.F.1. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station WADI LILI au pas de temps mensuel

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.977	0.953	0.029	0.005	0.952	0.891	0.054	0.009
ANN-ARO2	0.777	0.753	0.229	0.205	0.752	0.691	0.254	0.209
ANN-ARO3	0.866	0.842	0.140	0.116	0.841	0.780	0.165	0.120
ANN-ARO4	0.666	0.642	0.340	0.316	0.641	0.580	0.465	0.320
ANN-ARO5	0.755	0.731	0.251	0.227	0.730	0.669	0.276	0.231
ANN-ARO6	0.555	0.531	0.451	0.427	0.530	0.469	0.776	0.631
ANN-GWO-PSO1	0.958	0.919	0.039	0.006	0.923	0.822	0.068	0.012
ANN-GWO-PSO2	0.758	0.719	0.239	0.206	0.723	0.622	0.268	0.212
ANN-GWO-PSO3	0.847	0.808	0.150	0.117	0.812	0.711	0.179	0.123
ANN-GWO-PSO4	0.647	0.608	0.350	0.317	0.612	0.511	0.479	0.323
ANN-GWO-PSO5	0.736	0.697	0.261	0.228	0.701	0.600	0.290	0.234
ANN-GWO-PSO6	0.536	0.497	0.461	0.428	0.501	0.400	0.790	0.634
ANN-MAO1	0.973	0.947	0.036	0.006	0.911	0.830	0.041	0.008
ANN-MAO2	0.773	0.747	0.236	0.206	0.711	0.630	0.241	0.208
ANN-MAO3	0.862	0.836	0.147	0.117	0.800	0.719	0.152	0.119
ANN-MAO4	0.662	0.636	0.347	0.317	0.600	0.519	0.452	0.319
ANN-MAO5	0.751	0.725	0.258	0.228	0.689	0.608	0.263	0.230
ANN-MAO6	0.551	0.525	0.458	0.428	0.489	0.408	0.863	0.730

Tableau.F.2. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station FERAH au pas de temps mensuel

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.999	0.998	0.012	0.001	0.898	0.767	0.228	0.021
ANN-ARO2	0.799	0.798	0.212	0.201	0.698	0.567	0.428	0.221
ANN-ARO3	0.888	0.887	0.123	0.112	0.787	0.656	0.339	0.132
ANN-ARO4	0.688	0.687	0.323	0.312	0.587	0.456	0.639	0.332
ANN-ARO5	0.777	0.776	0.234	0.223	0.676	0.545	0.450	0.243
ANN-ARO6	0.577	0.576	0.434	0.423	0.476	0.345	0.950	0.643
ANN-GWO-PSO1	0.977	0.954	0.062	0.004	0.863	0.440	0.354	0.038
ANN-GWO-PSO2	0.777	0.754	0.262	0.204	0.663	0.240	0.554	0.238
ANN-GWO-PSO3	0.866	0.843	0.173	0.115	0.752	0.329	0.465	0.149
ANN-GWO-PSO4	0.666	0.643	0.373	0.315	0.552	0.129	0.765	0.349
ANN-GWO-PSO5	0.755	0.732	0.284	0.226	0.641	0.218	0.576	0.260
ANN-GWO-PSO6	0.555	0.532	0.484	0.426	0.441	0.018	1.076	0.660
ANN-MAO1	0.977	0.955	0.062	0.003	0.858	0.596	0.300	0.032
ANN-MAO2	0.777	0.755	0.262	0.203	0.658	0.396	0.500	0.232

ANN-MAO3	0.866	0.844	0.173	0.114	0.747	0.485	0.411	0.143
ANN-MAO4	0.666	0.644	0.373	0.314	0.547	0.285	0.711	0.343
ANN-MAO5	0.755	0.733	0.284	0.225	0.636	0.374	0.522	0.254
ANN-MAO6	0.555	0.533	0.484	0.425	0.436	0.174	1.022	0.654

Tableau.F.3. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au RN 25 pas de temps mensuel

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	0.981	0.951	0.054	0.003	0.944	0.714	0.135	0.012
ANN-ARO2	0.781	0.751	0.254	0.203	0.744	0.514	0.335	0.212
ANN-ARO3	0.870	0.840	0.165	0.114	0.833	0.603	0.246	0.123
ANN-ARO4	0.670	0.640	0.365	0.314	0.633	0.403	0.546	0.323
ANN-ARO5	0.759	0.729	0.276	0.225	0.722	0.492	0.357	0.234
ANN-ARO6	0.559	0.529	0.476	0.425	0.522	0.292	0.857	0.634
ANN-GWO-PSO1	0.943	0.880	0.085	0.005	0.942	0.786	0.117	0.012
ANN-GWO-PSO2	0.743	0.680	0.285	0.205	0.742	0.586	0.317	0.212
ANN-GWO-PSO3	0.832	0.769	0.196	0.116	0.831	0.675	0.228	0.123
ANN-GWO-PSO4	0.632	0.569	0.396	0.316	0.631	0.475	0.528	0.323
ANN-GWO-PSO5	0.721	0.658	0.307	0.227	0.720	0.564	0.339	0.234
ANN-GWO-PSO6	0.521	0.458	0.507	0.427	0.520	0.364	0.839	0.634
ANN-MAO1	0.987	0.976	0.038	0.002	0.899	0.696	0.139	0.015
ANN-MAO2	0.787	0.776	0.238	0.202	0.699	0.496	0.339	0.215
ANN-MAO3	0.876	0.865	0.149	0.113	0.788	0.585	0.250	0.126
ANN-MAO4	0.676	0.665	0.349	0.313	0.588	0.385	0.550	0.326
ANN-MAO5	0.765	0.754	0.260	0.224	0.677	0.474	0.361	0.237
ANN-MAO6	0.565	0.554	0.460	0.424	0.477	0.274	0.861	0.637

Tableau.F.4. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au AIN ASSEL pas de temps mensuel

Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	1.000	0.999	0.055	0.005	0.930	0.798	5.129	0.561
ANN-ARO2	0.800	0.799	0.255	0.205	0.730	0.598	5.329	0.761
ANN-ARO3	0.889	0.888	0.166	0.116	0.819	0.687	5.240	0.672
ANN-ARO4	0.689	0.688	0.366	0.316	0.619	0.487	5.540	0.872
ANN-ARO5	0.778	0.777	0.277	0.227	0.708	0.576	5.351	0.783
ANN-ARO6	0.578	0.577	0.477	0.427	0.508	0.376	5.851	1.183
ANN-GWO-PSO1	0.997	0.994	0.136	0.011	0.922	0.720	2.024	0.240
ANN-GWO-PSO2	0.797	0.794	0.336	0.211	0.722	0.520	2.224	0.440
ANN-GWO-PSO3	0.886	0.883	0.247	0.122	0.811	0.609	2.135	0.351
ANN-GWO-PSO4	0.686	0.683	0.447	0.322	0.611	0.409	2.435	0.551
ANN-GWO-PSO5	0.775	0.772	0.358	0.233	0.700	0.498	2.246	0.462
ANN-GWO-PSO6	0.575	0.572	0.558	0.433	0.500	0.298	2.746	0.862

ANN-MAO1	0.997	0.995	0.129	0.010	0.894	0.714	5.380	0.531
ANN-MAO2	0.797	0.795	0.329	0.210	0.694	0.514	5.580	0.731
ANN-MAO3	0.886	0.884	0.240	0.121	0.783	0.603	5.491	0.642
ANN-MAO4	0.686	0.684	0.440	0.321	0.583	0.403	5.791	0.842
ANN-MAO5	0.775	0.773	0.351	0.232	0.672	0.492	5.602	0.753
ANN-MAO6	0.575	0.573	0.551	0.432	0.472	0.292	6.102	1.153

Tableau.F.5. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au BOUCHEGOUF pas de temps mensuel

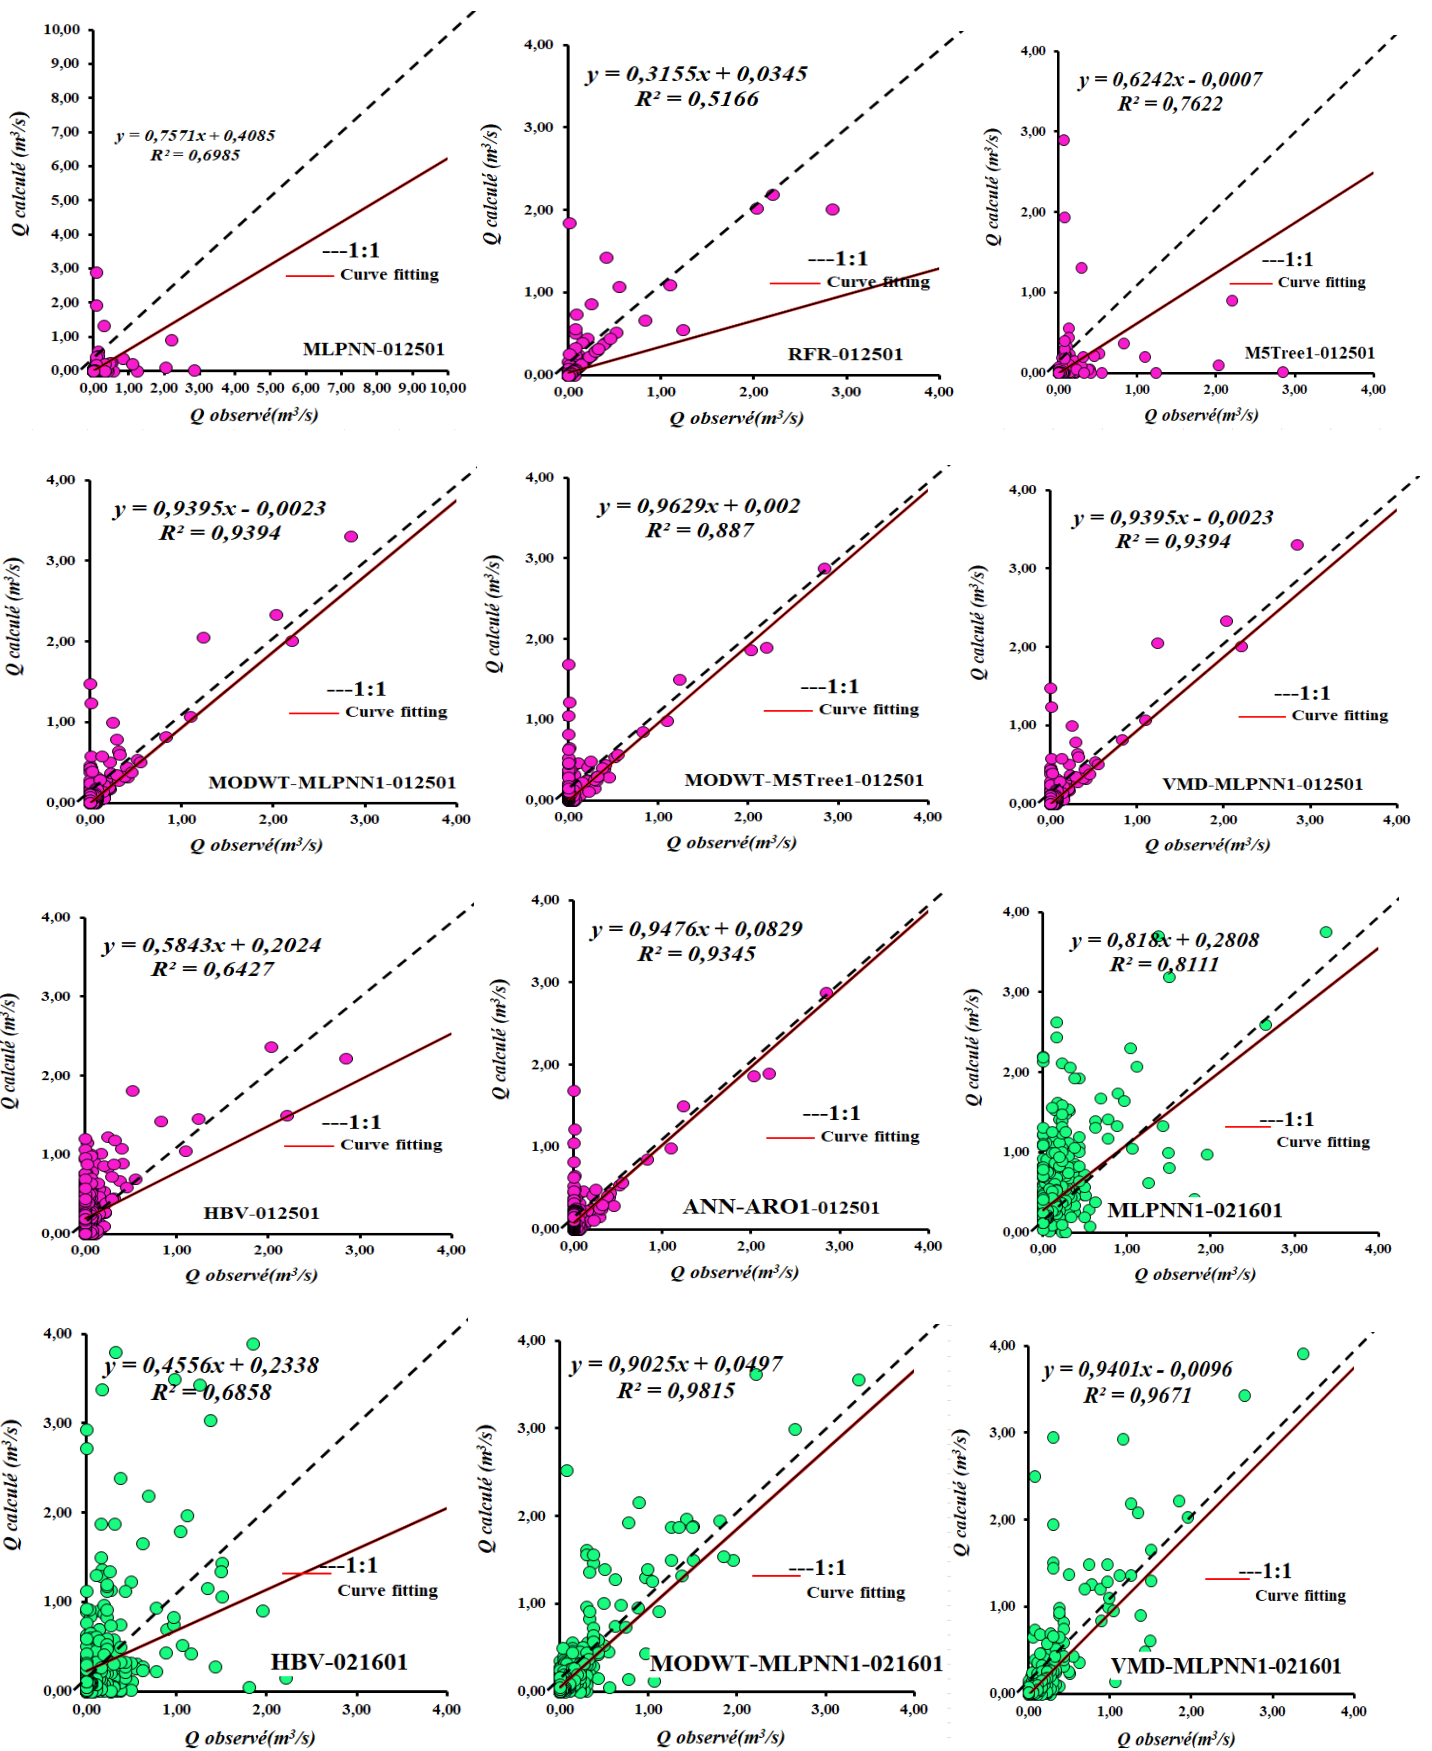
Modèles	Training				Validation			
	R	NSE	RMSE, m3/s	MAE, m3/s	R	NSE	RMSE, m3/s	MAE, m3/s
ANN-ARO1	1.000	1.000	0.006	0.000	0.925	0.903	0.221	0.021
ANN-ARO2	0.800	0.800	0.206	0.200	0.725	0.703	0.421	0.221
ANN-ARO3	0.889	0.889	0.117	0.111	0.814	0.792	0.332	0.132
ANN-ARO4	0.689	0.689	0.317	0.311	0.614	0.592	0.632	0.332
ANN-ARO5	0.778	0.778	0.228	0.222	0.703	0.681	0.443	0.243
ANN-ARO6	0.578	0.578	0.428	0.422	0.503	0.481	0.943	0.643
ANN-GWO-PSO1	0.998	1.000	0.013	0.001	0.910	0.793	0.322	0.025
ANN-GWO-PSO2	0.798	0.800	0.213	0.201	0.710	0.593	0.522	0.225
ANN-GWO-PSO3	0.887	0.889	0.124	0.112	0.799	0.682	0.433	0.136
ANN-GWO-PSO4	0.687	0.689	0.324	0.312	0.599	0.482	0.733	0.336
ANN-GWO-PSO5	0.776	0.778	0.235	0.223	0.688	0.571	0.544	0.247
ANN-GWO-PSO6	0.576	0.578	0.435	0.423	0.488	0.371	1.044	0.647
ANN-MAO1	0.994	0.998	0.026	0.001	0.904	0.751	0.354	0.027
ANN-MAO2	0.794	0.798	0.226	0.201	0.704	0.551	0.554	0.227
ANN-MAO3	0.883	0.887	0.137	0.112	0.793	0.640	0.465	0.138
ANN-MAO4	0.683	0.687	0.337	0.312	0.593	0.440	0.765	0.338
ANN-MAO5	0.772	0.776	0.248	0.223	0.682	0.529	0.576	0.249
ANN-MAO6	0.572	0.576	0.448	0.423	0.482	0.329	1.076	0.649

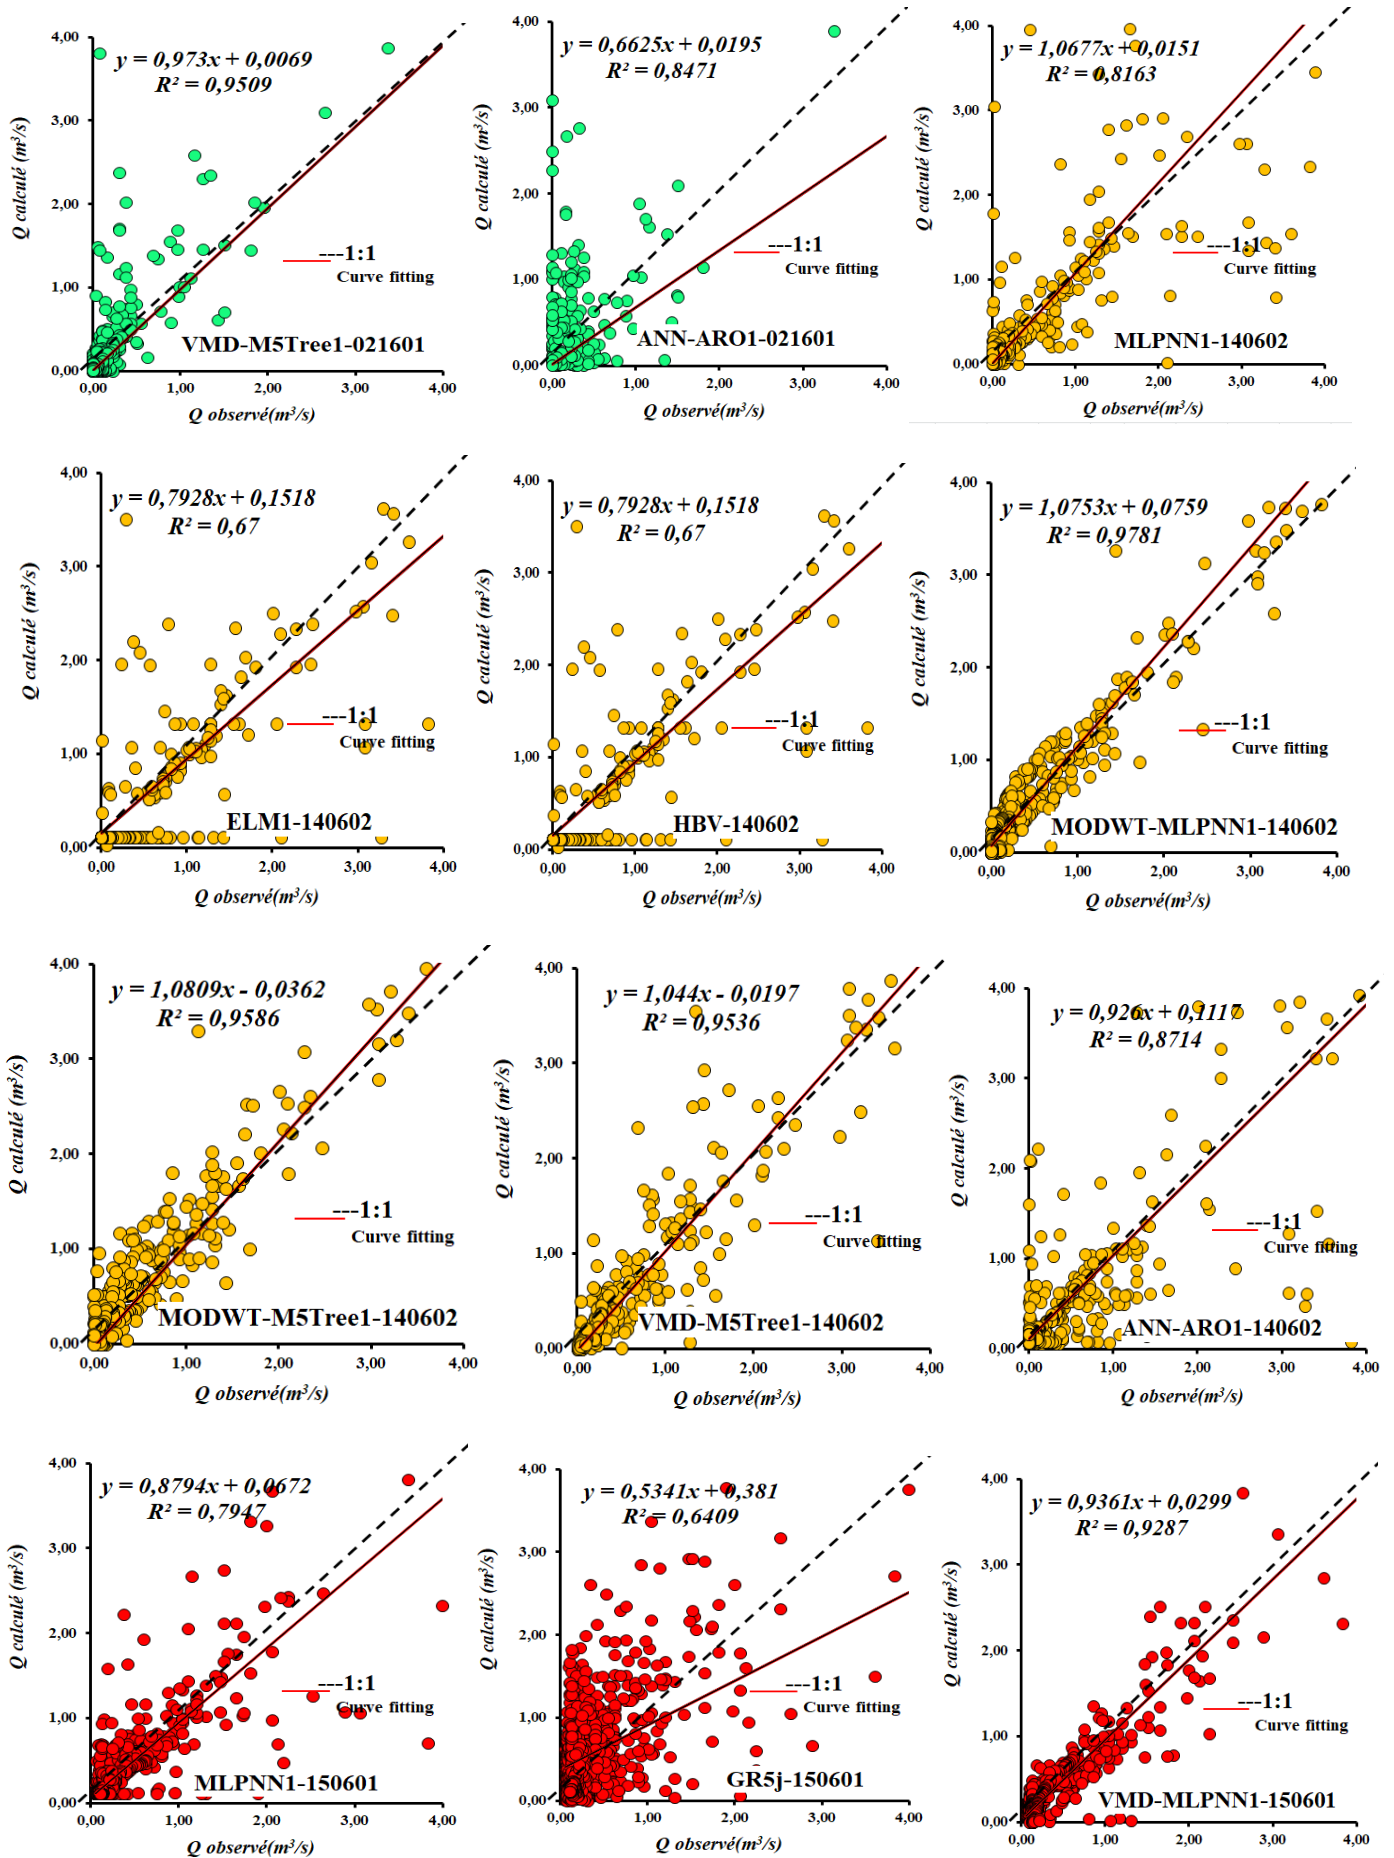
Tableau.F.6. Performances des différents modèles hybridés avec les algorithmes d'optimisation pour la station au AIN BERDA pas de temps mensuel

Modèles	Training				Validation			
	R	NSE	RMSE. m3/s	MAE. m3/s	R	NSE	RMSE. m3/s	MAE. m3/s
ANN-ARO1	0.999	0.993	0.007	0.000	0.961	0.961	0.178	0.016
ANN-ARO2	0.799	0.793	0.207	0.200	0.761	0.761	0.378	0.216
ANN-ARO3	0.888	0.882	0.118	0.111	0.850	0.850	0.289	0.127
ANN-ARO4	0.688	0.682	0.318	0.311	0.650	0.650	0.589	0.327
ANN-ARO5	0.777	0.771	0.229	0.222	0.739	0.739	0.400	0.238
ANN-ARO6	0.577	0.571	0.429	0.422	0.539	0.539	0.900	0.638
ANN-GWO-PSO1	0.999	0.993	0.007	0.000	0.925	0.930	0.238	0.018
ANN-GWO-PSO2	0.799	0.793	0.207	0.200	0.725	0.730	0.438	0.218
ANN-GWO-PSO3	0.888	0.882	0.118	0.111	0.814	0.819	0.349	0.129
ANN-GWO-PSO4	0.688	0.682	0.318	0.311	0.614	0.619	0.649	0.329
ANN-GWO-PSO5	0.777	0.771	0.229	0.222	0.703	0.708	0.460	0.240

ANN-GWO-PSO6	0.577	0.571	0.429	0.422	0.503	0.508	0.960	0.640
ANN-MAO1	0.999	0.995	0.007	0.000	0.897	0.854	0.344	0.032
ANN-MAO2	0.799	0.795	0.207	0.200	0.697	0.654	0.544	0.232
ANN-MAO3	0.888	0.884	0.118	0.111	0.786	0.743	0.455	0.143
ANN-MAO4	0.688	0.684	0.318	0.311	0.586	0.543	0.755	0.343
ANN-MAO5	0.777	0.773	0.229	0.222	0.675	0.632	0.566	0.254
ANN-MAO6	0.577	0.573	0.429	0.422	0.475	0.432	1.066	0.654

Annexe G : Résultats des critères graphiques





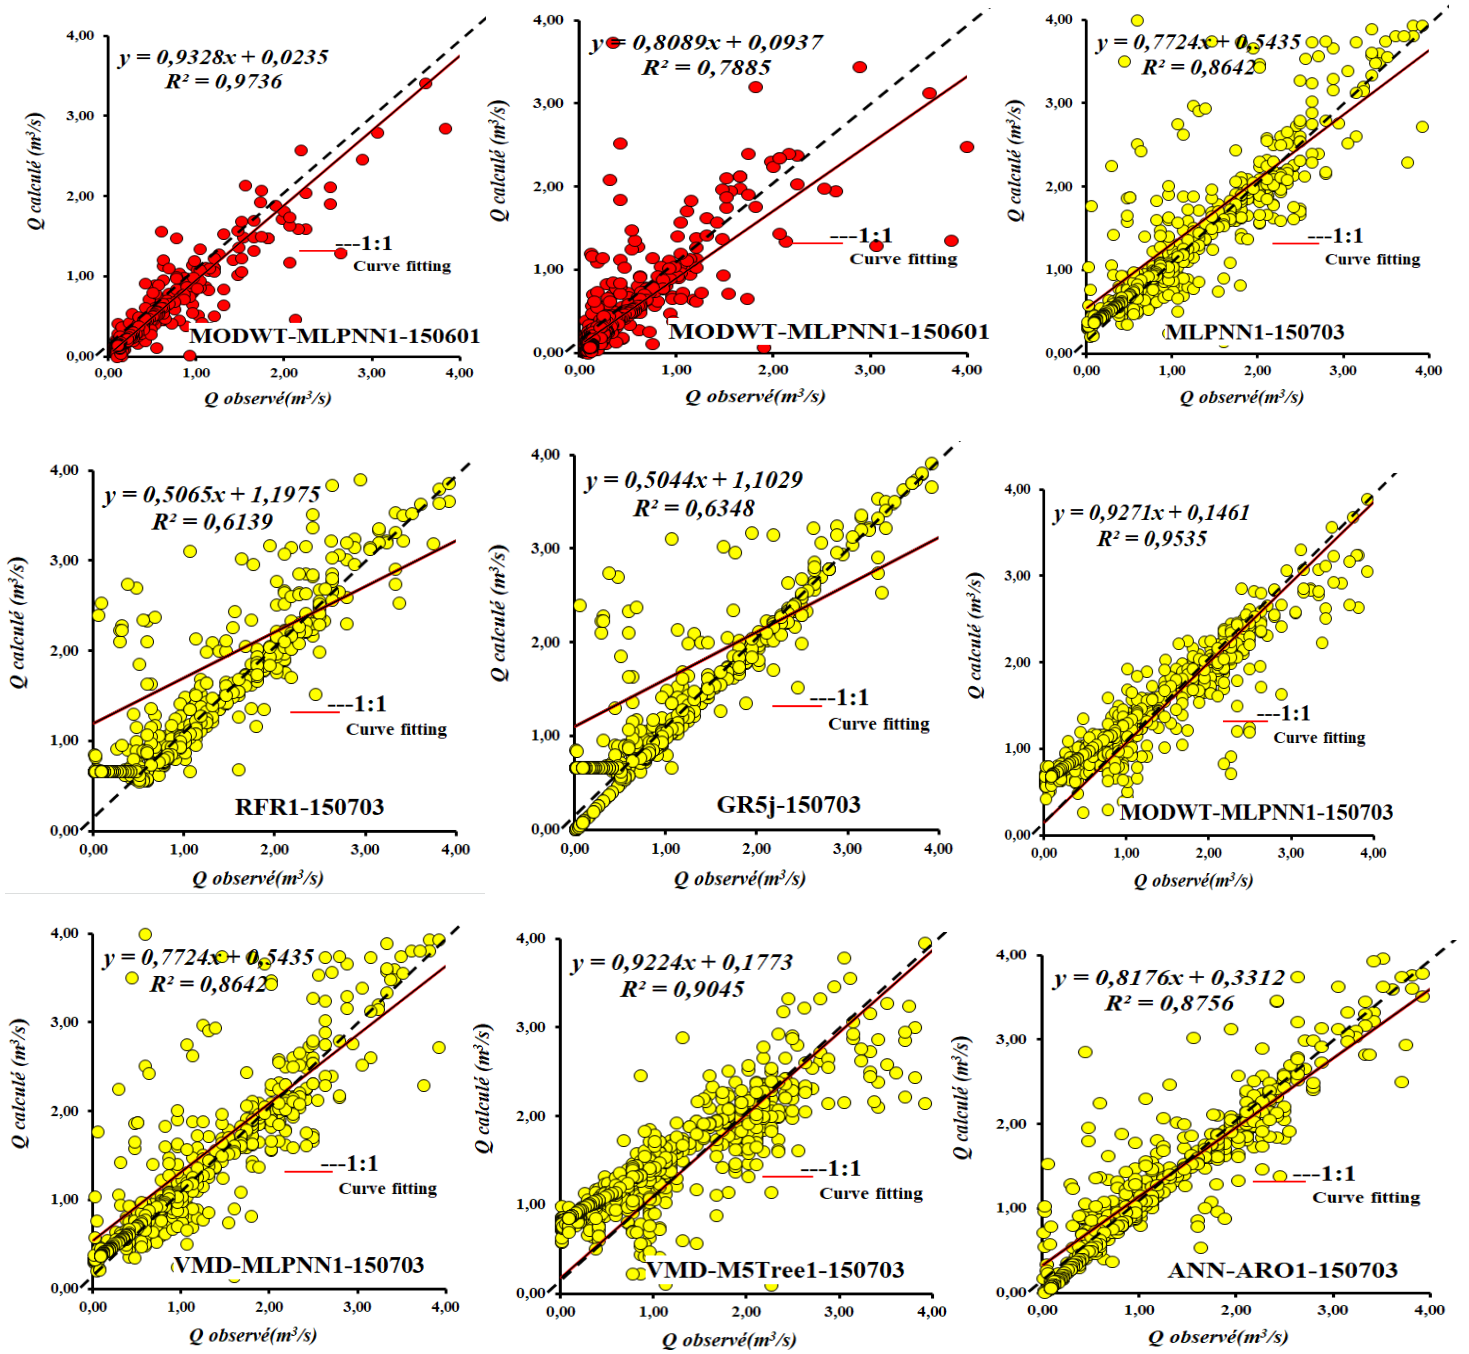
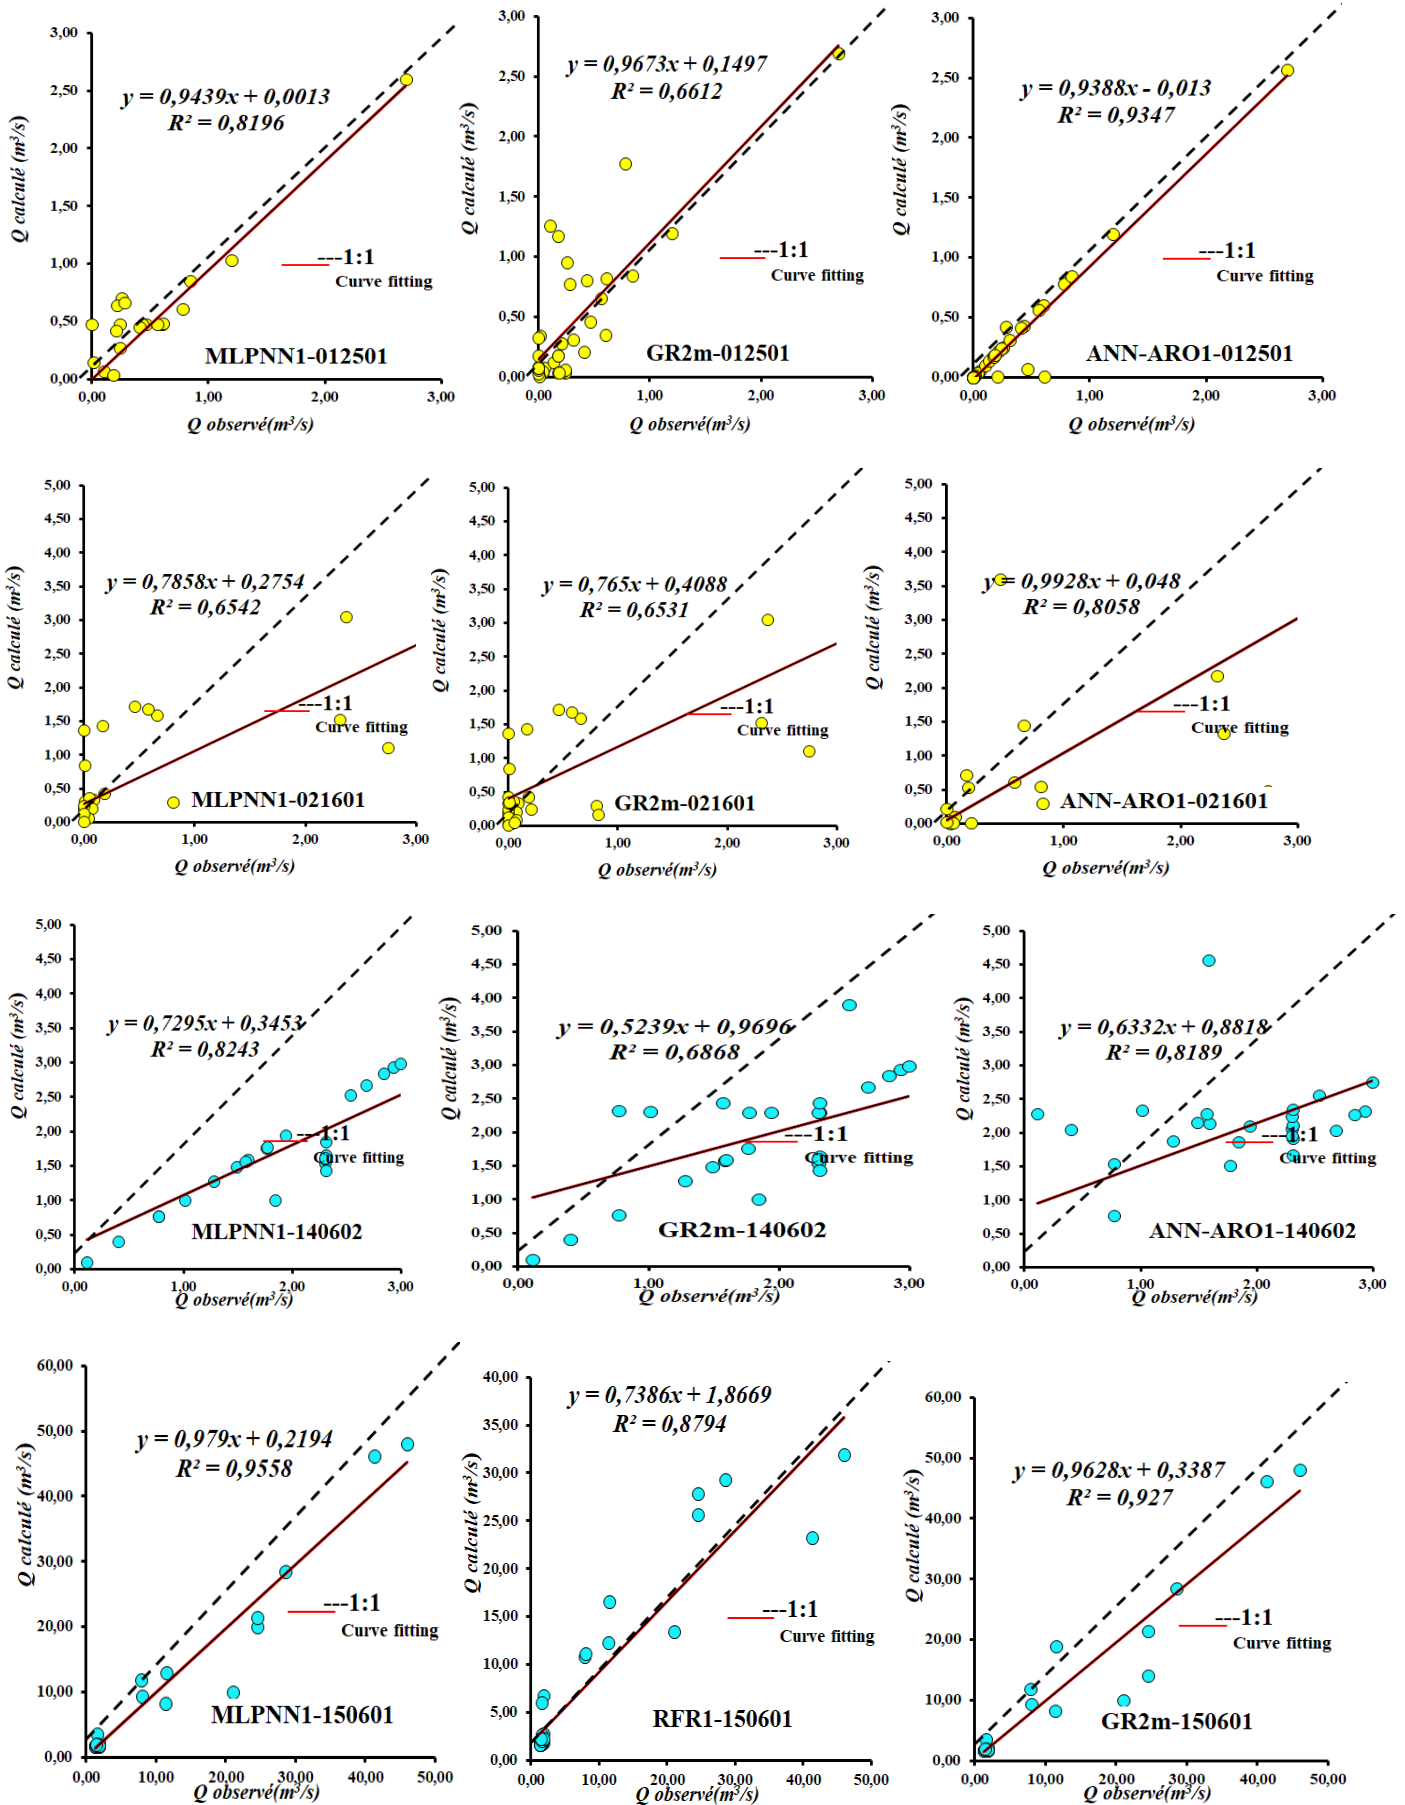


Figure G.1. Nuage de points entre les débits journaliers mesurés et calculés pour les meilleurs modèles dans la phase validation






Figure G.2. Nuage de points entre les débits mensuel mesurés et calculés pour les meilleurs modèles dans la phase validation

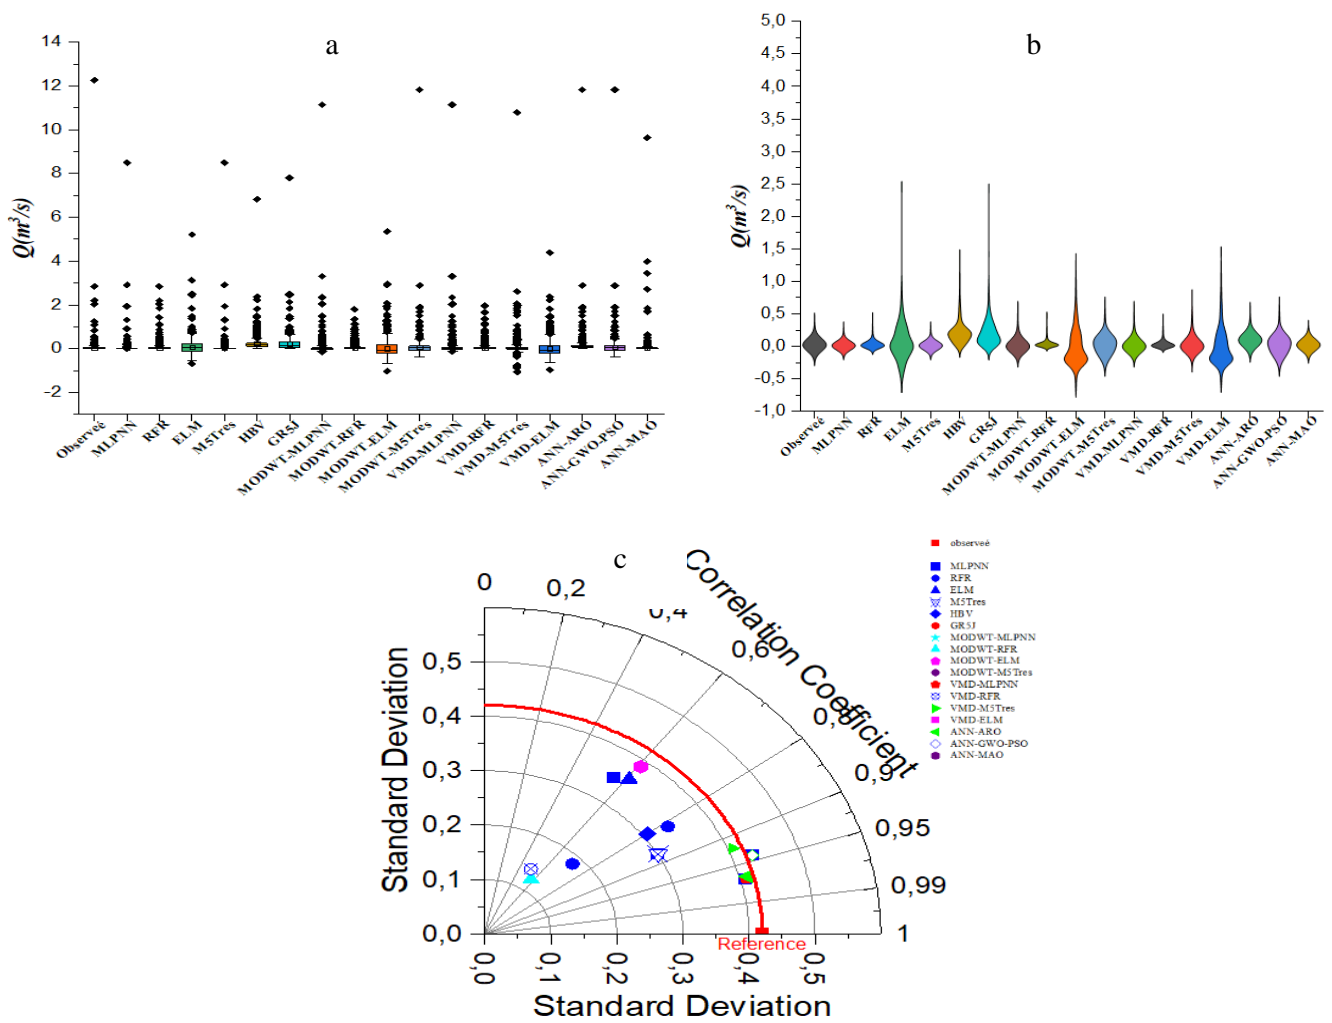


Figure G.3. Performances des meilleurs modèles au pas de temps journaliers en phase validation à la station WADI LILI : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

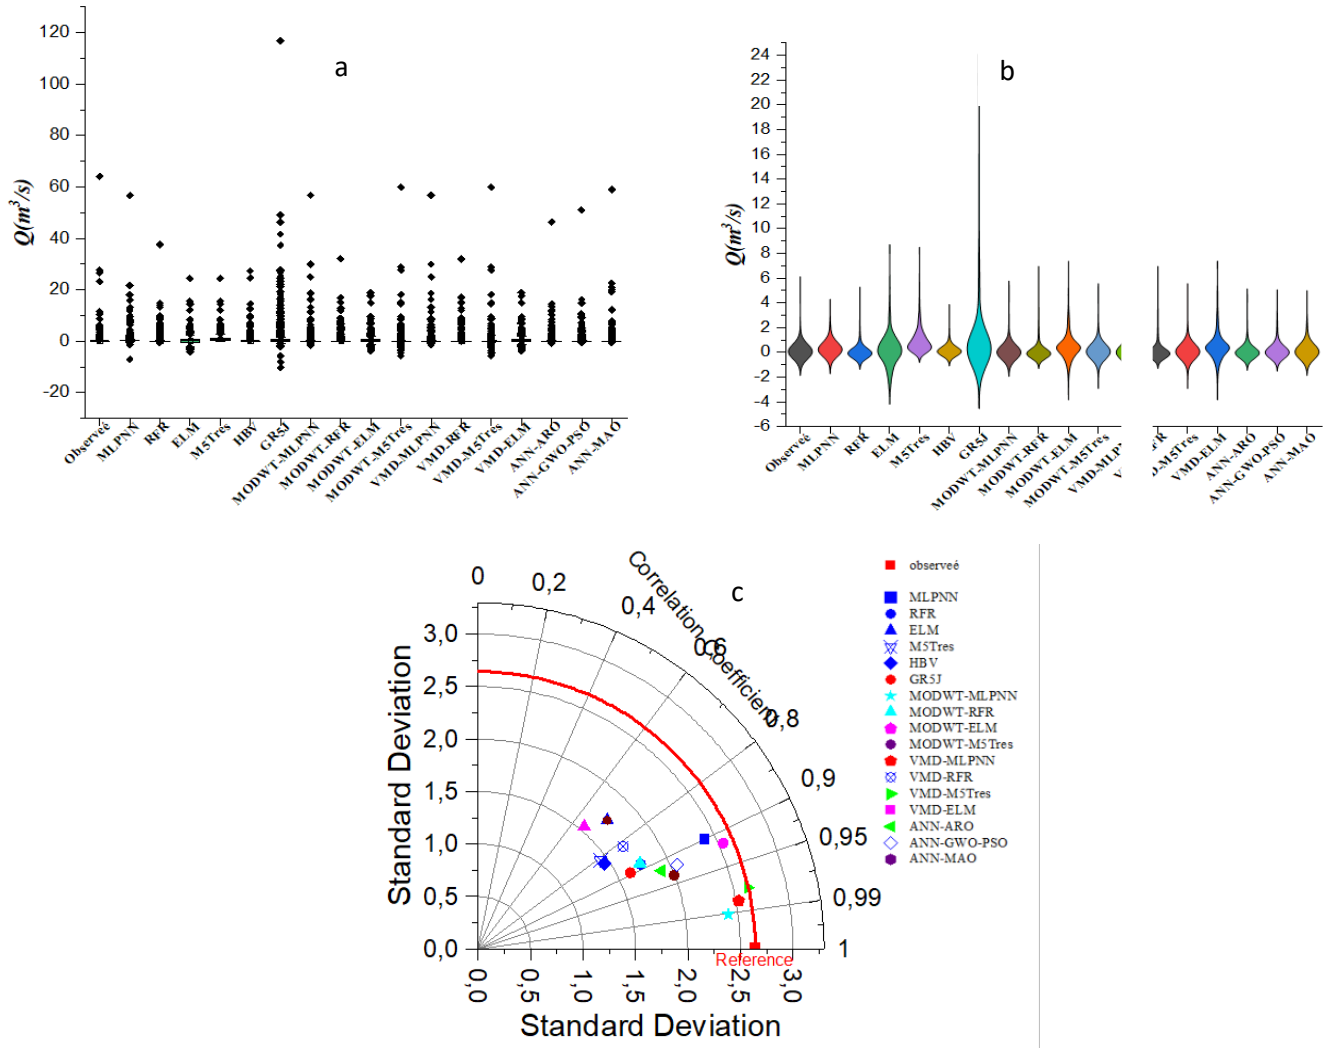


Figure G.4. Performances des meilleurs modèles au pas de temps journaliers en phase validation à la station FERAH : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

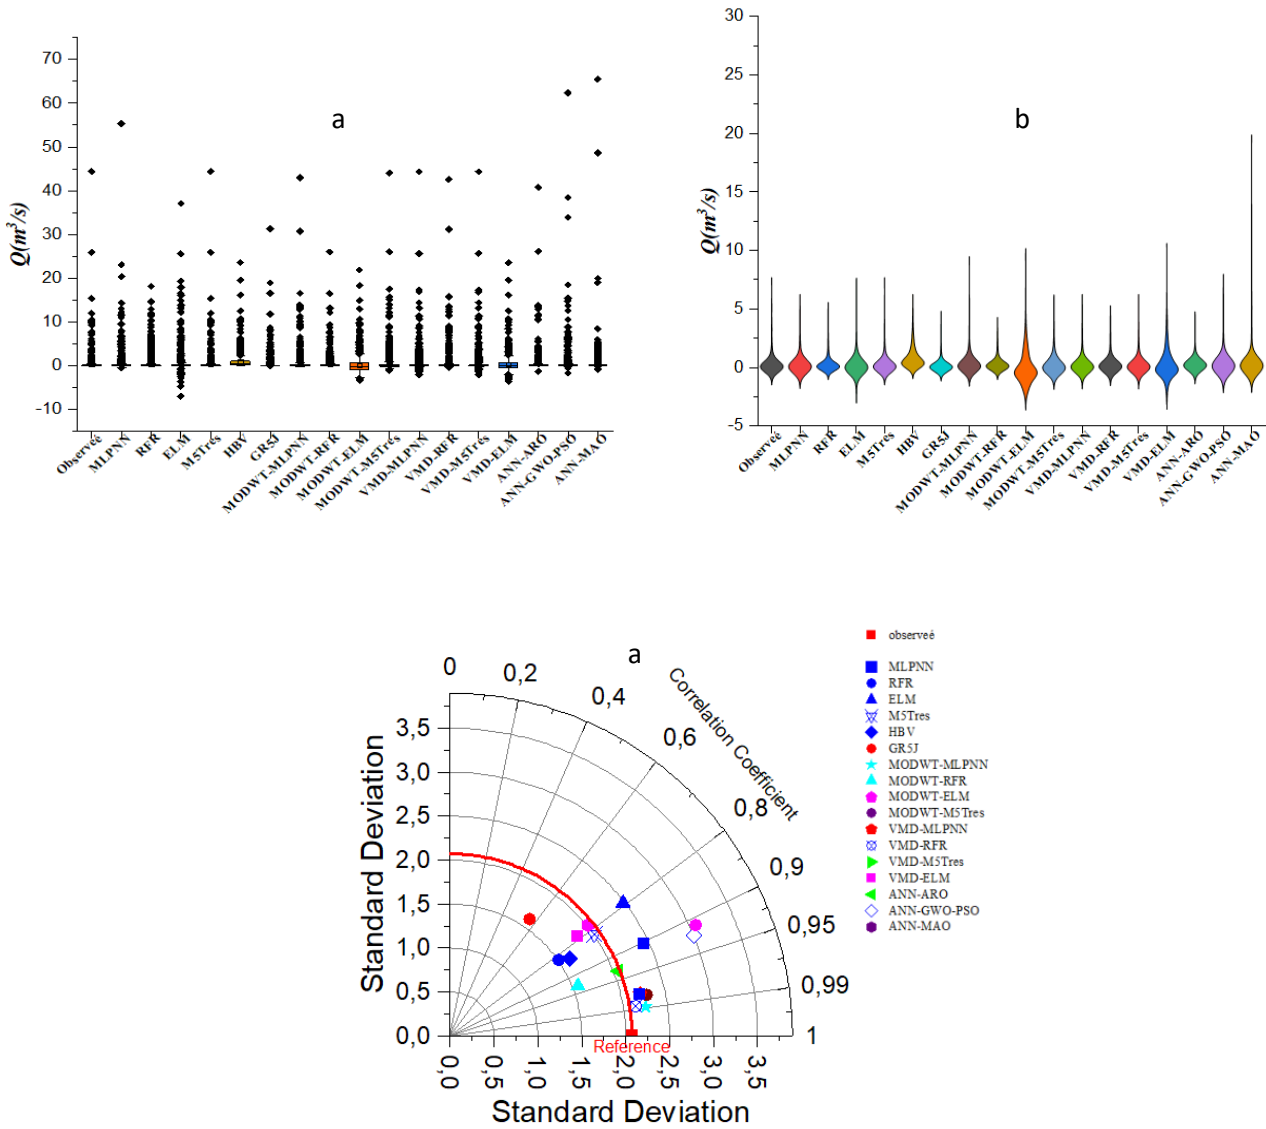


Figure G.5. Performances des meilleurs modèles au pas de temps journaliers en phase validation à la station AIN BERDA : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

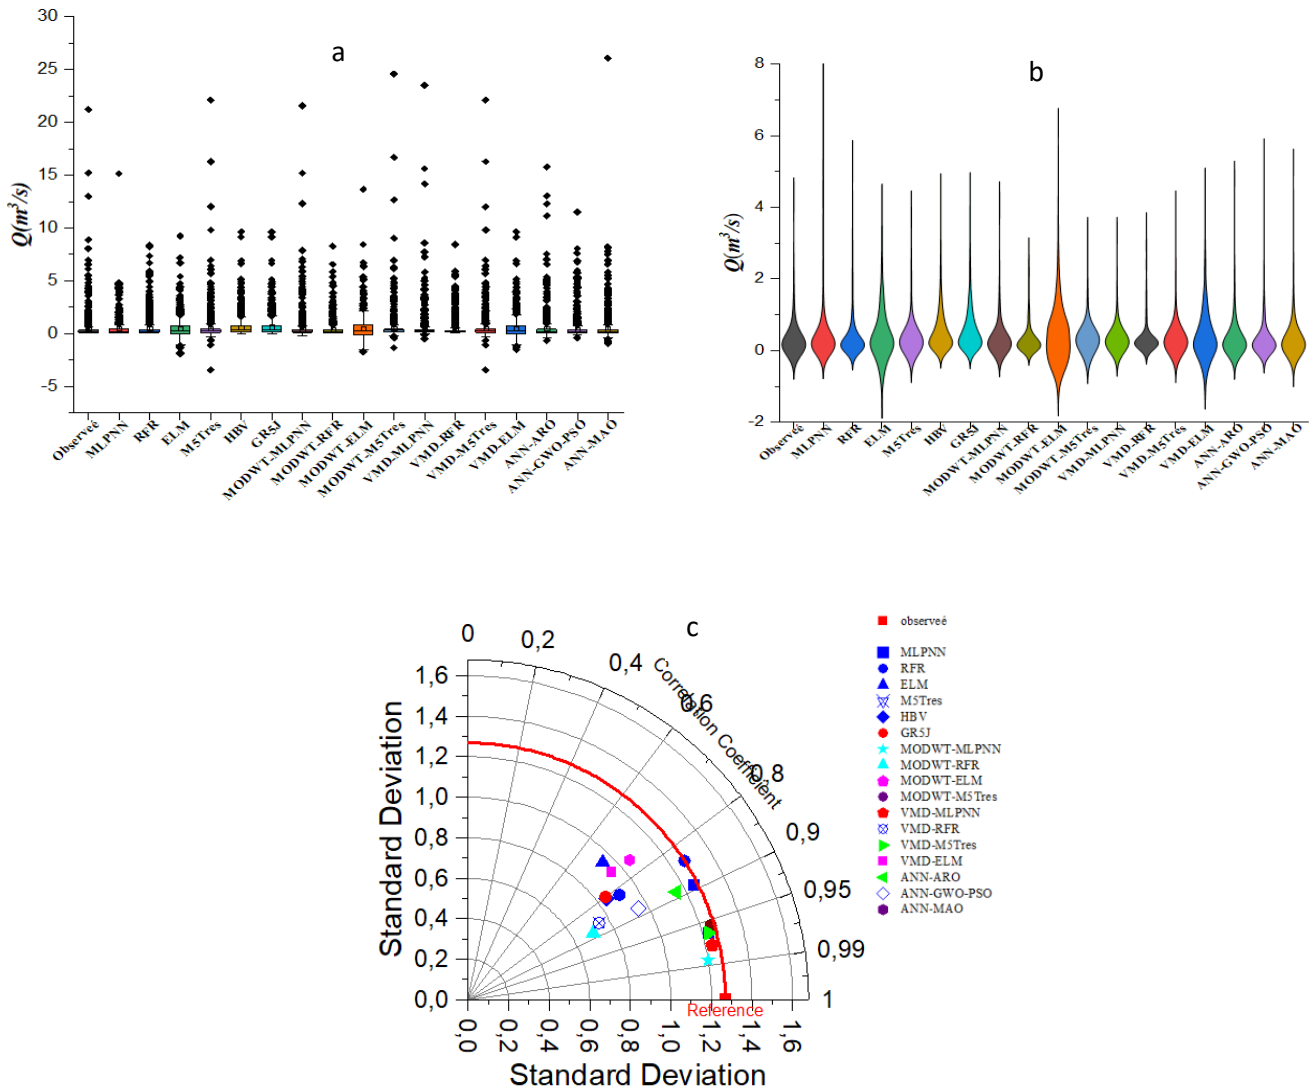


Figure G.6. Performances des meilleurs modèles au pas de temps journaliers en phase validation à la station FERMATOU : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

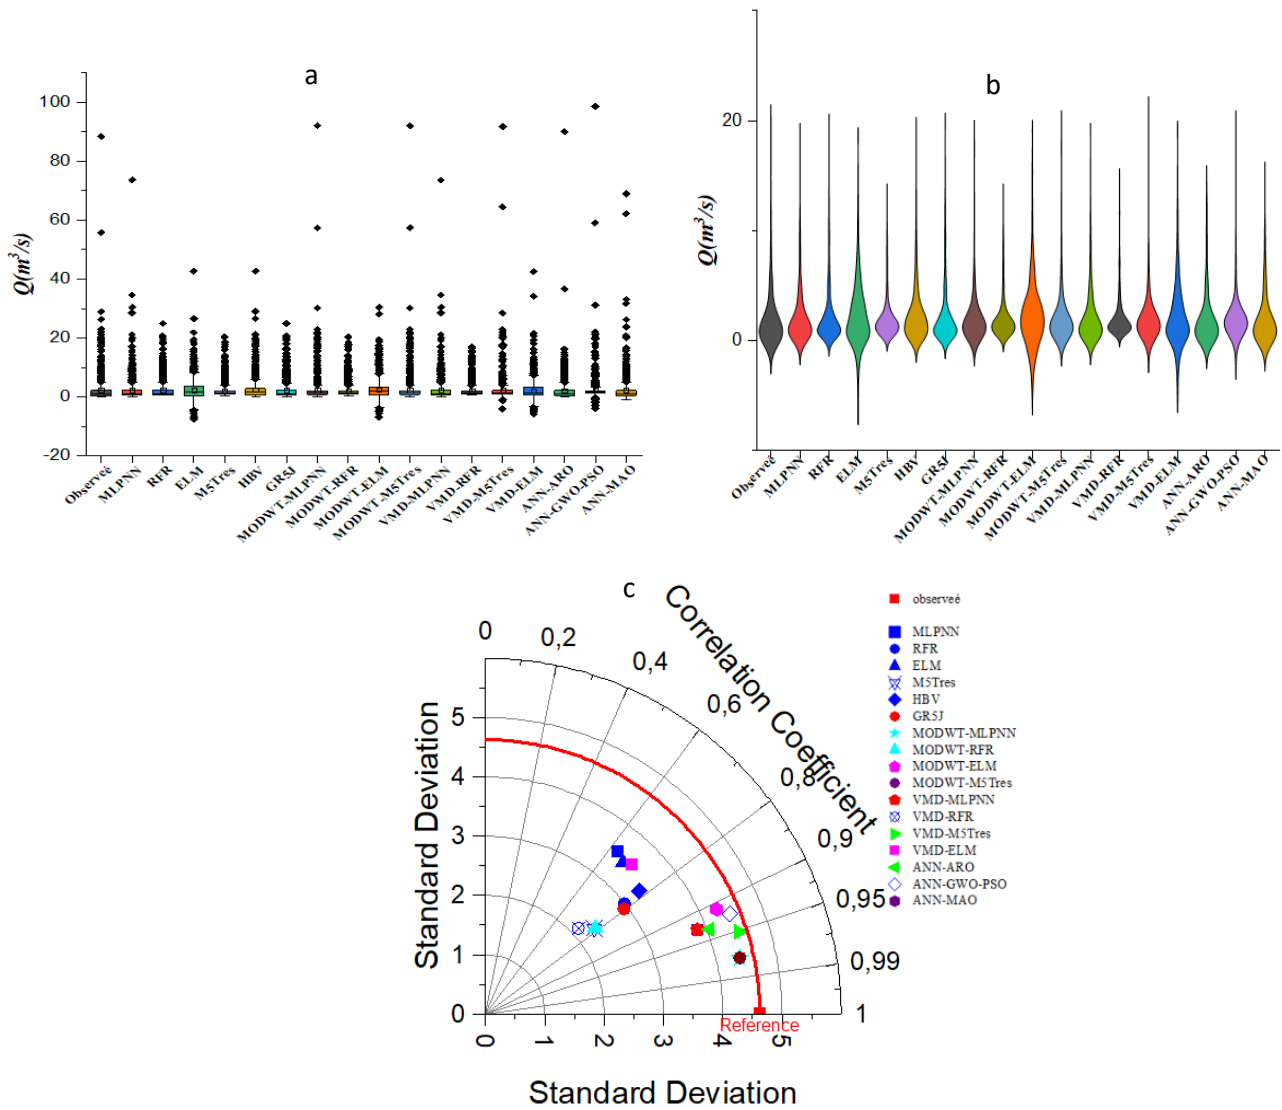


Figure G.7. Performances des meilleurs modèles au pas de temps journaliers en phase validation à la station BOU BRIK : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

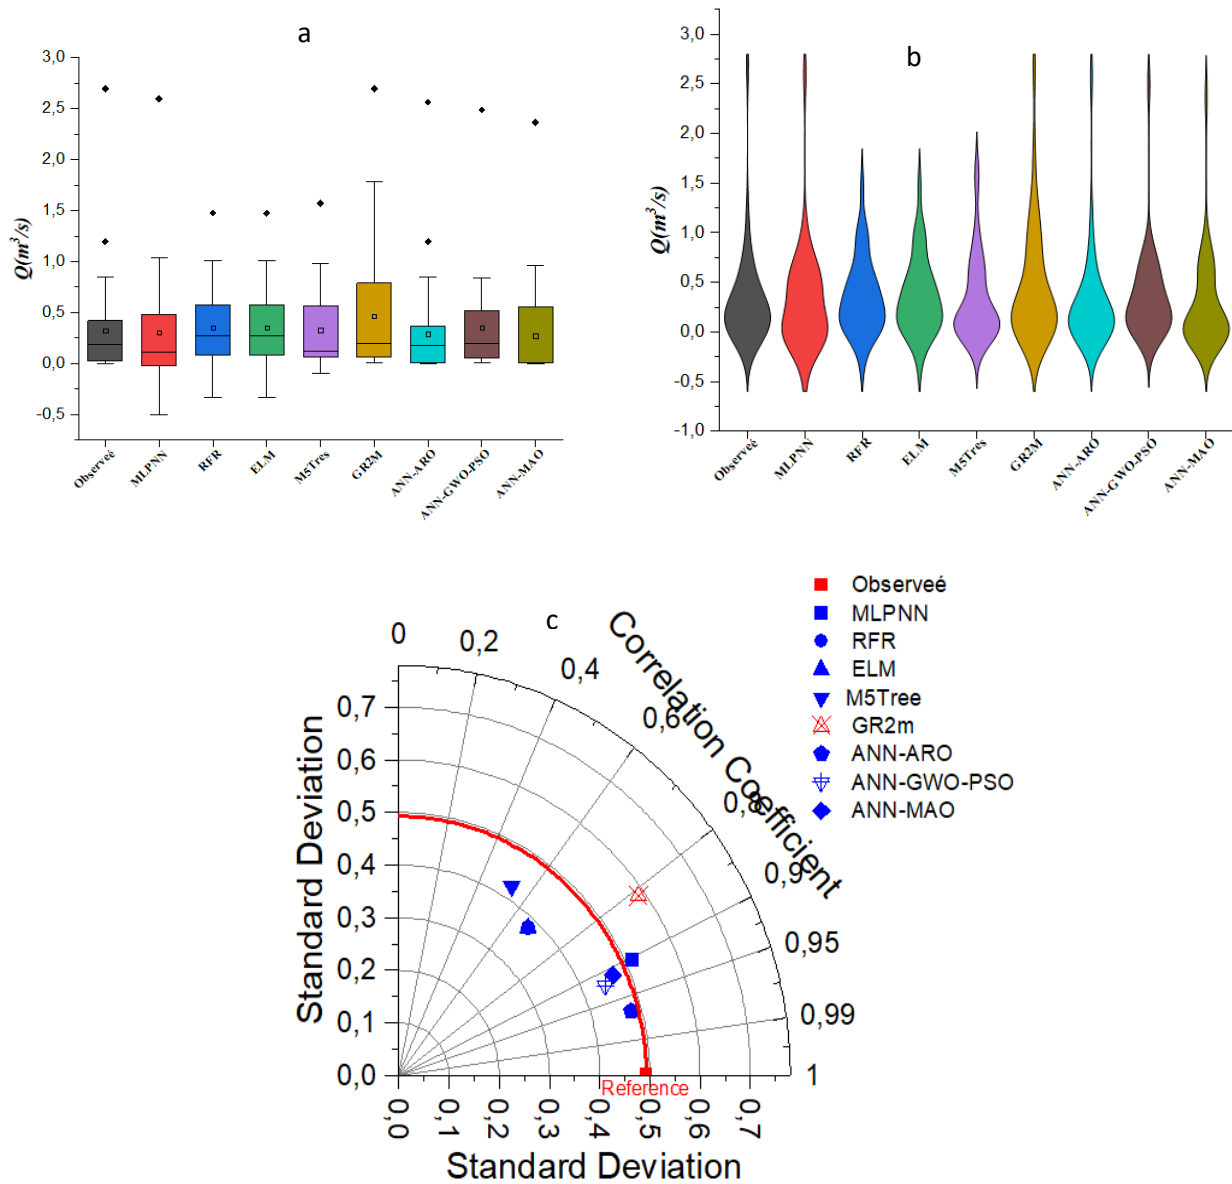


Figure G.8. Performances des meilleurs modèles au pas de temps mensuel en phase validation à la station WADI LILI : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

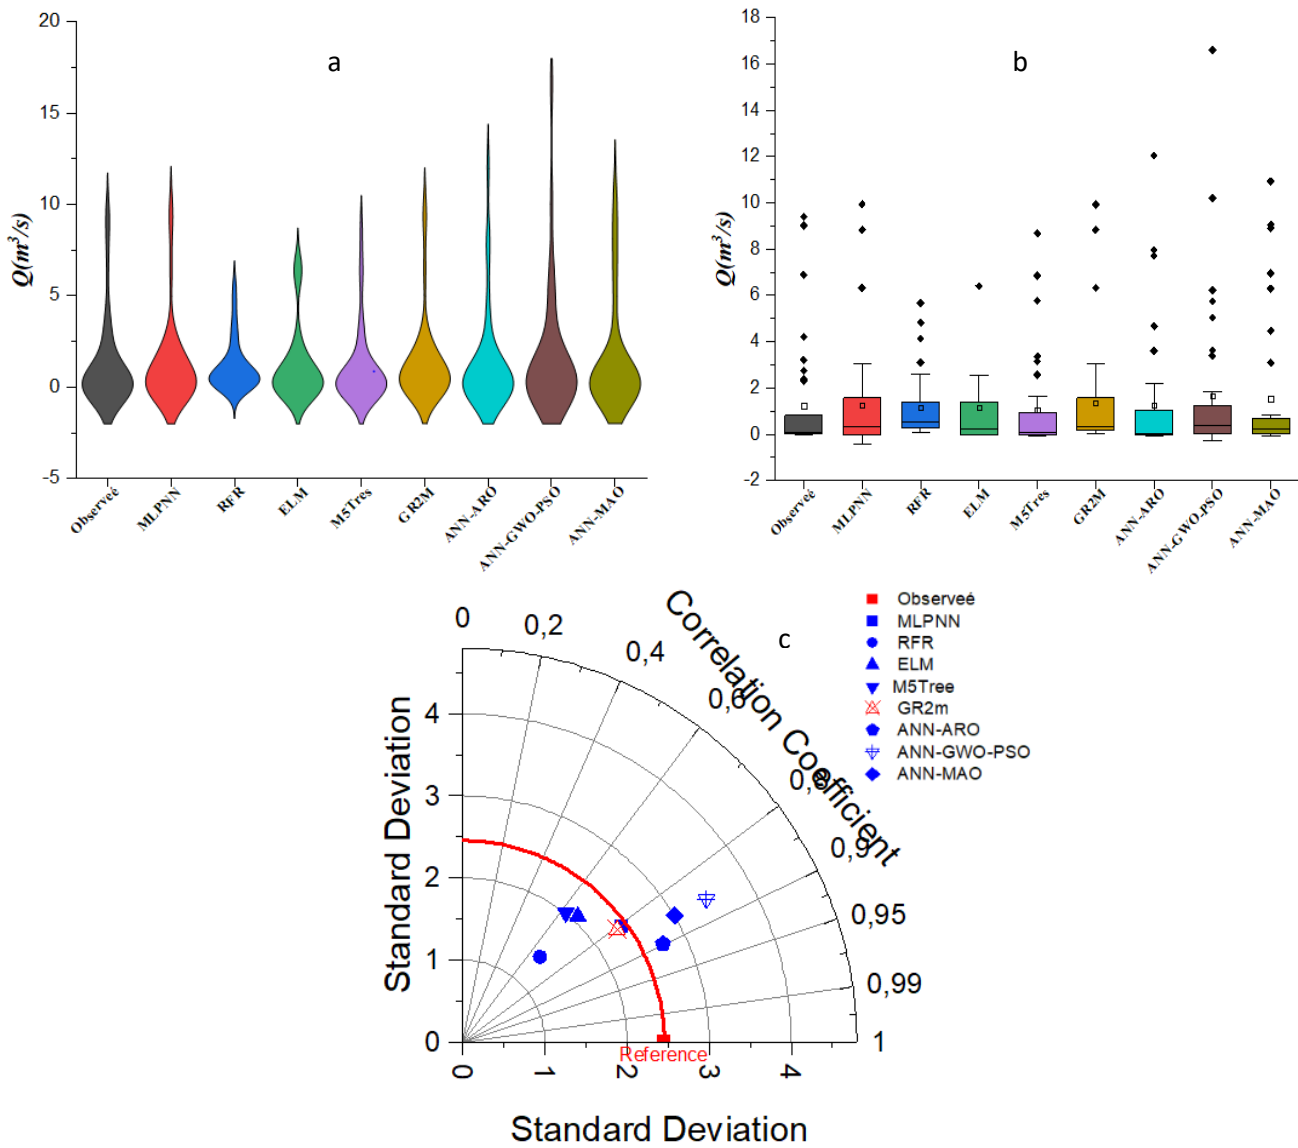


Figure G.9. Performances des meilleurs modèles au pas de temps mensuel en phase validation à la station FERAH : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

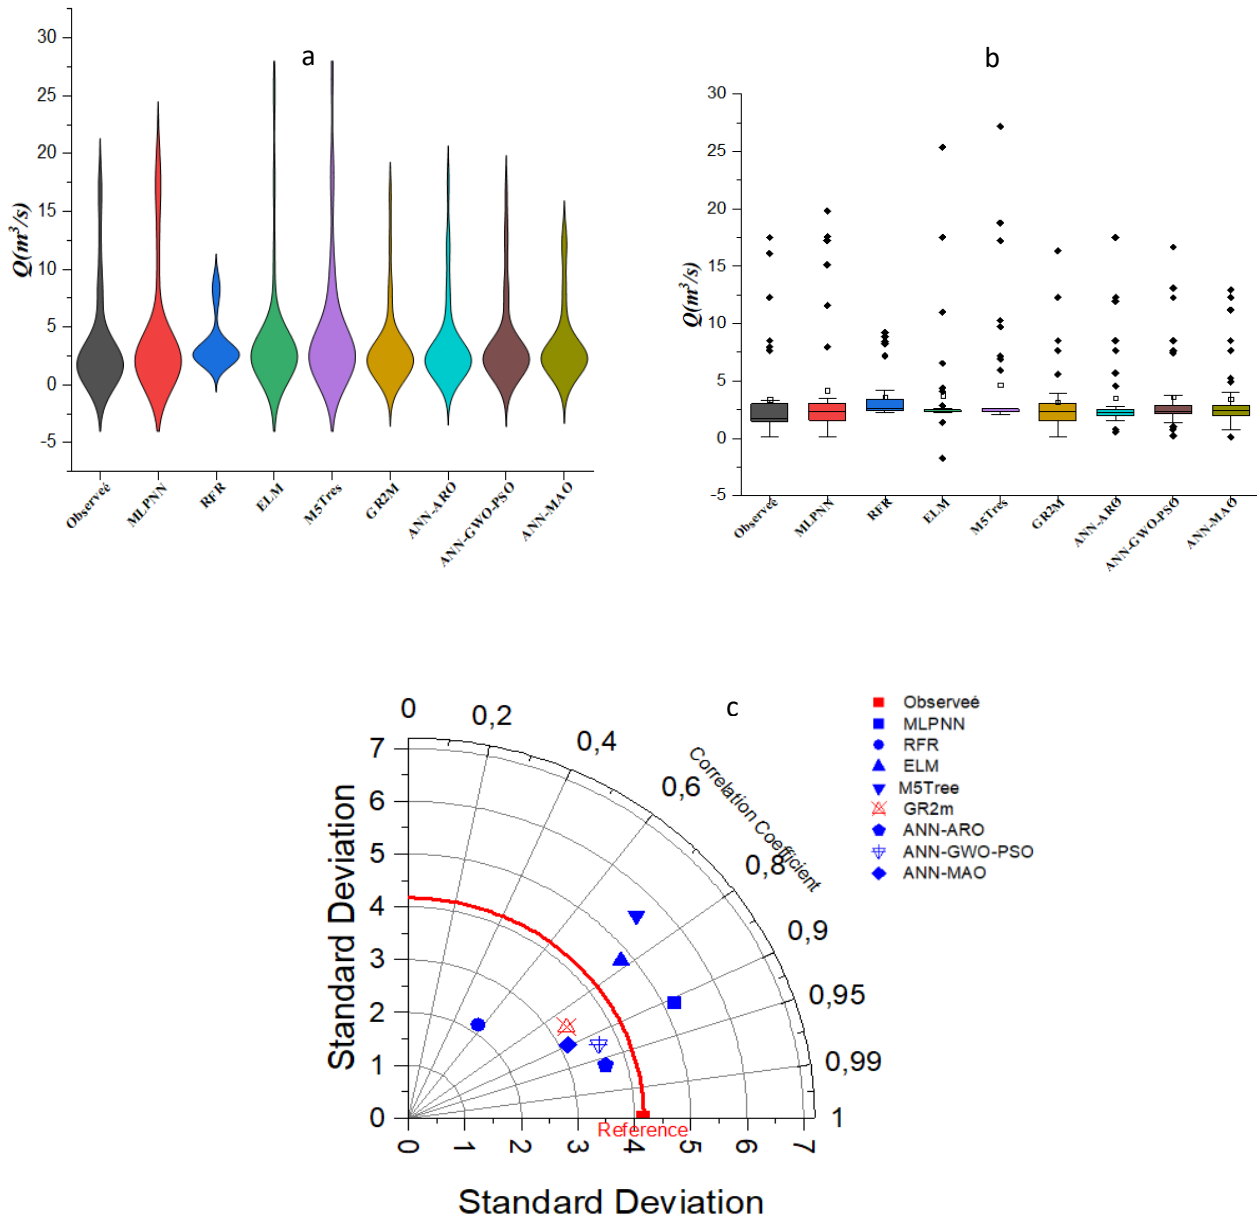


Figure G.10. Performances des meilleurs modèles au pas de temps mensuel en phase validation à la station AIN BERDA : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor

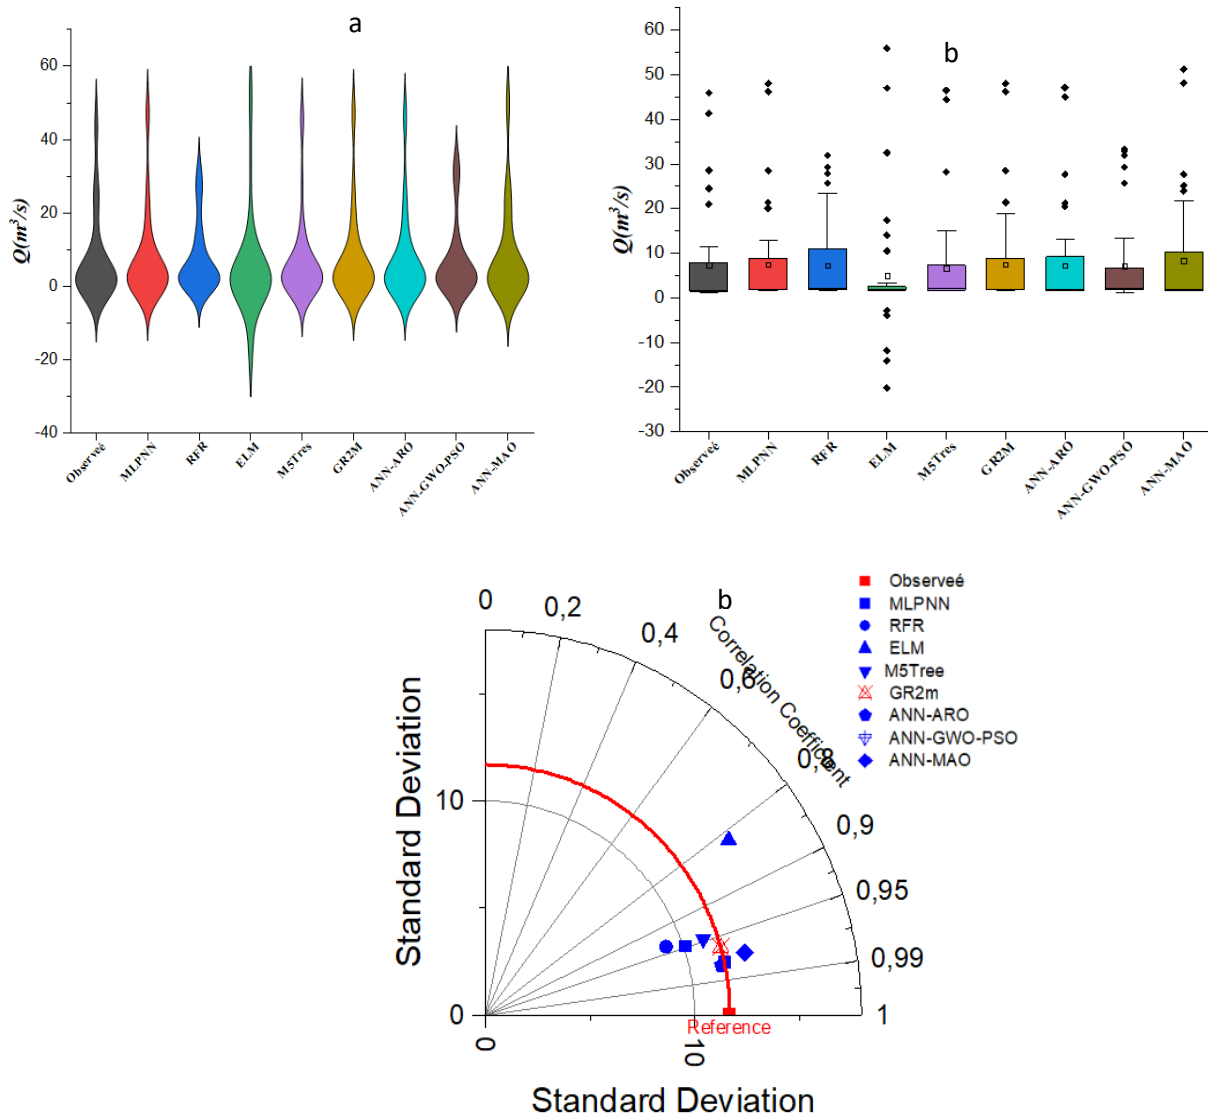


Figure G.11. Performances des meilleurs modèles au pas de temps mensuel en phase validation à la station FERMATOU : (a) Violin plot, (b) Boxplot et (c) Diagramme de Taylor

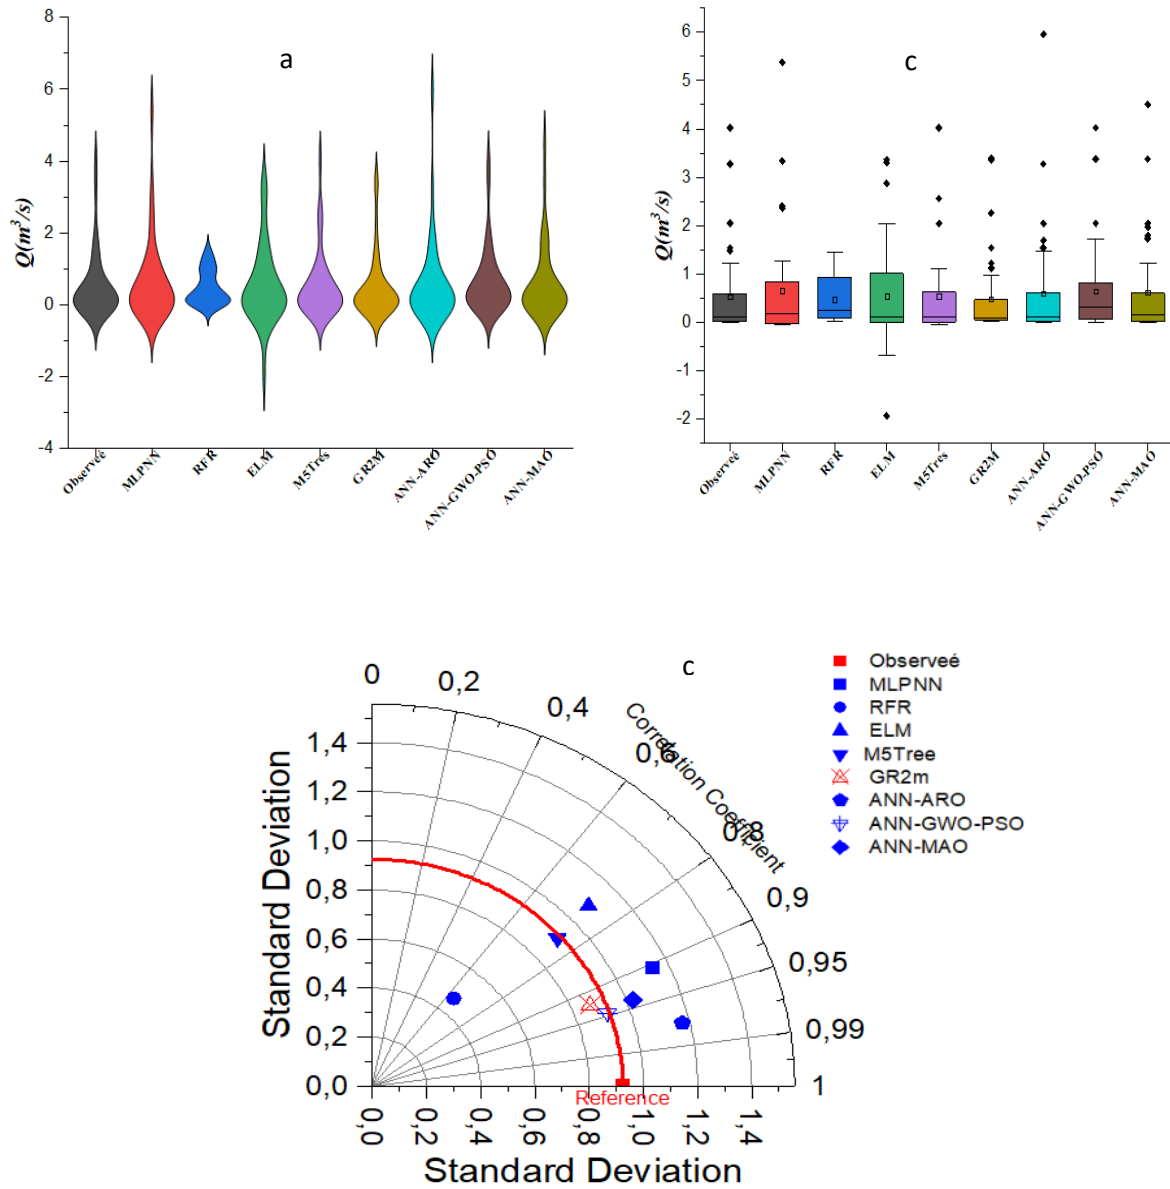


Figure G.12. Performances des meilleurs modèles au pas de temps mensuel en phase validation à la station BOU BRIK : (a) Boxplot, (b) Violin plot et (c) Diagramme de Taylor