الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement
Supérieur et de la Recherche Scientifique
Université 20 Août 1955 - SKIKDA -
Faculté des Sciences
Département D' Agronomie
N/réf : DSA/AGRO/2026

Skikda le : .....

Autorisation de Dépôt de Mémoire de Master

Je soussigné : **Pr. Heddam Salim** Président de Jury

Certifie que :

L'étudiant(e) : **Laib Abdelmalek**

Spécialité : **Aménagement Hydro-Agricole**

Intitulé : **Vers un modèle Pluie-Débit robuste et explicable : Intégration avancée de techniques de Machine Learning et de l'analyse SHAP dans le bassin versant de la Soummam.**

A apporté les corrections relatives à son travail de mémoire.

Président de Jury

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

Mémoire :

Présentée pour l'obtention du diplôme de Master (LMD)

SPÉCIALITÉ : AMÉNAGEMENT HYDRO-AGRICOLE

Thème :

Vers un modèle Pluie-Débit robuste et explicable : intégration avancée de technique de deep learning et de l'analyse SHAP dans le bassin versant de la Soummam

Présenté par :

- Abdelmalek LAIB

Membres de Jury:

Mr :HEDDAM Salim	(Prof)	**Président**	Université du 20 Août 1955 – Skikda
Mr : SADOUNE Abdelaziz	(MAA)	**Examinateur**	Université du 20 Août 1955 – Skikda
Mr : HEBAL Aziz	(Prof)	**Promoteur**	Université du 20 Août 1955 – Skikda
Mr : DAIF Noureddine	(MAB)	**Co-Promoteur**	Université du 20 Août 1955 – Skikda

Année universitaire : 2025-2026



DÉDICACE

● À mes chers **parents**, que Dieu les préserve, en témoignage de mon amour, de mon respect et de ma profonde gratitude pour tous les sacrifices qu'ils ont consentis pour mon éducation.

● À ma famille et à tous ceux qui ont cru en moi et m'ont soutenu durant mon parcours.

● Je dédie humblement ce travail.

Abdelmalek LAIB



REMERCIEMENTS

Avant toute chose, je rends grâce à **Allah**, le Très-Haut, le Tout-Puissant, dont les bienfaits innombrables m'ont accompagné tout au long de mon existence. Je Le remercie infiniment de m'avoir créé, guidé et honoré par les bienfaits de la foi, de la santé, de la raison et de la connaissance. Je Lui suis profondément reconnaissant de m'avoir accordé les capacités intellectuelles nécessaires pour poursuivre mes études, de m'avoir inspiré l'amour du savoir et de la recherche, de m'avoir facilité les chemins de l'apprentissage et de m'avoir permis de surmonter les difficultés rencontrées durant mon parcours universitaire.

Je Le remercie également pour toutes les opportunités qu'Il a mises sur mon chemin, pour les personnes bienveillantes qu'Il a placées à mes côtés, pour la patience, la persévérance et la détermination qu'Il m'a accordées lorsque les défis semblaient insurmontables. Sans Sa volonté, Sa guidance et Sa miséricorde, ce travail n'aurait jamais pu voir le jour. À Lui reviennent toute louange, toute gratitude et toute reconnaissance.

J'adresse ensuite mes plus sincères remerciements à mon encadreur, **Monsieur le Professeur HEBAL Aziz**, pour son accompagnement précieux tout au long de cette recherche. Je lui suis profondément reconnaissant pour sa disponibilité, ses orientations pertinentes, sa rigueur scientifique ainsi que pour ses remarques constructives qui ont largement contribué à l'amélioration de ce travail. Je tiens également à souligner ses remarquables qualités pédagogiques, sa maîtrise de l'enseignement et sa capacité à transmettre le savoir avec clarté, méthode et professionnalisme. Son expérience, son expertise scientifique et son dévouement envers ses étudiants ont constitué pour moi une véritable source d'inspiration et un modèle à suivre.

Je souhaite exprimer une gratitude toute particulière à **Monsieur le Docteur DAIF Noureddine**, Co-encadreur de ce travail, pour son soutien exceptionnel et son implication constante. Je le remercie sincèrement pour le temps qu'il m'a généreusement consacré, pour sa patience exemplaire, son écoute attentive et sa disponibilité permanente. Jamais avare de conseils, d'explications ou d'encouragements, il a toujours répondu à mes interrogations avec sérieux, calme, bienveillance et professionnalisme. Ses compétences scientifiques, ses excellentes qualités pédagogiques ainsi que son sens du partage ont grandement facilité ma progression et enrichi ma réflexion. Son accompagnement attentif, sa compréhension et son soutien continu à chaque étape de cette recherche ont été d'une valeur inestimable et resteront pour moi un souvenir particulièrement marquant de mon parcours universitaire.

J'adresse également mes sincères remerciements à **Monsieur le Professeur HEDDAM Salim** pour la qualité de son enseignement durant mon cursus de Master. Je lui suis reconnaissant pour sa disponibilité, sa volonté constante d'aider les étudiants ainsi que pour sa capacité à répondre à leurs questions avec clarté et professionnalisme. Les connaissances qu'il nous a transmises et les conseils qu'il nous a prodigués ont contribué de manière significative à notre formation académique.

Je tiens aussi à remercier **Monsieur le Docteur KHALED Merabet** pour la qualité de son enseignement dans la matière ayant contribué à la réalisation de ce mémoire. Je lui exprime ma gratitude pour les connaissances qu'il nous a transmises ainsi que pour son sérieux et son engagement dans la formation des étudiants.

Je souhaite également adresser mes remerciements à l'ensemble des enseignants du département qui ont contribué à ma formation universitaire. Chacun d'eux a participé, à sa manière, à l'acquisition des connaissances et des compétences qui m'ont permis de mener à bien ce travail.

Mes remerciements s'adressent également aux honorables membres du jury qui ont accepté d'évaluer ce mémoire. Je leur exprime ma profonde gratitude pour le temps qu'ils consacreront à son examen ainsi que pour leurs observations, remarques et recommandations qui contribueront sans aucun doute à l'enrichissement et à l'amélioration de ce travail.

Enfin, je tiens à exprimer ma sincère reconnaissance à ma famille, à mes amis et à toutes les personnes qui m'ont soutenu, encouragé et accompagné de près ou de loin tout au long de mon parcours universitaire. Leur confiance, leur soutien moral et leurs encouragements ont constitué une source permanente de motivation et de persévérance.

À toutes celles et à tous ceux qui ont contribué, de près ou de loin, à l'aboutissement de ce travail, j'adresse mes plus sincères remerciements et ma profonde gratitude.

Abdelmalek LAIB

Résumé

Cette étude porte sur la modélisation **pluie-débit journalière** dans un contexte méditerranéen semi-aride, à travers l'évaluation de plusieurs architectures de **deep learning** appliquées à deux sous-bassins du bassin de **la Soummam** (Algérie du Nord) : Fermatou et Bou Birek. L'objectif principal est d'analyser la capacité de ces modèles à reproduire les dynamiques hydrologiques dans des conditions marquées par une forte variabilité hydro-climatique et des données limitées.

Les séries journalières de précipitations et de débits couvrant la période **2002-2012** ont été exploitées afin de développer six modèles d'apprentissage profond : **LSTM, GRU, CNN, BiLSTM, BiGRU et CNN-LSTM**. Les variables d'entrée ont été définies à partir d'analyses statistiques préalables (**ACF, PACF et corrélations croisées**). Les performances ont été évaluées à l'aide de plusieurs indicateurs hydrologiques, notamment le coefficient de Nash-Sutcliffe **(NSE**), le coefficient de corrélation **R**, le **KGE** et le **RMSE**. Une analyse d'interprétabilité fondée sur la méthode **SHAP** a également été réalisée afin d'identifier l'influence relative des variables d'entrée.

Les résultats montrent que les architectures convolutionnelles et hybrides, en particulier le modèle **CNN-LSTM**, offrent les meilleures performances sur les deux stations étudiées, avec des valeurs de NSE proches de **0,88** en phase de validation. Les modèles récurrents classiques présentent des performances satisfaisantes mais globalement inférieures, tandis que les architectures bidirectionnelles n'apportent pas d'amélioration significative. L'analyse SHAP met en évidence des comportements hydrologiques différenciés entre les deux bassins, traduisant des réponses hydrologiques spécifiques selon les caractéristiques du milieu.

Cette recherche confirme **le potentiel des approches de deep learning** pour la **modélisation pluie-débit** en milieu semi-aride et souligne l'intérêt de l'intégration de méthodes d'interprétabilité pour une meilleure compréhension des mécanismes hydrologiques sous-jacents.

Mots-clés : Modélisation pluie-débit ; Deep learning ; CNN-LSTM ; Réseaux de neurones ; Hydrologie semi-aride ; Prévision des débits ; SHAP ; Bassin de la Soummam ; Algérie ; Séries temporelles hydrologiques.

الملخص

تتناول هذه الدراسة **نمذجة العلاقة بين الأمطار والتدفق اليومي** في سياق متوسطي شبه جاف، وذلك من خلال تقييم بنيات متعددة للتعلم العميق **(Deep Learning)** المطبقة على حوضين فرعيين من **حوض الصومام** (شمال الجزائر): **فرماطو** و**بو بيرك**. يكمن الهدف الرئيسي في تحليل قدرة هذه النماذج على محاكاة الديناميكيات الهيدرولوجية في ظل ظروف تتميز بتقلبات هيدرومناخية شديدة ومحدودية البيانات.

وقد تم استغلال السلاسل اليومية للتساقطات والتدفقات الممتدة من سنة **2002 إلى 2012** لتطوير ستة نماذج **للتعلم العميق**: **LSTM، GRU، CNN، BiLSTM، BiGRU** و**CNN-LSTM**. كما تم تحديد متغيرات المدخلات بناءً على تحليلات إحصائية مسبقة **(ACF، وPACF، والارتباطات المتبادلة)**. وقُيمت كفاءة النماذج بالاعتماد على عدة مؤشرات هيدرولوجية، لا سيما معامل "ناش-سوتكليف" **(NSE)**، معامل الارتباط **R**، مؤشر كفاءة "كلين-غوبتا" **(KGE)** والجذر التربيعي لمتوسط مربع الخطأ **(RMSE)**. بالإضافة إلى ذلك، جرى تنفيذ تحليل قابلية التفسير استنادًا إلى طريقة **SHAP** لتحديد التأثير النسبي لمتغيرات المدخلات.

تُظهر النتائج أن البنيات الالتفافية والهجينة، وتحديدًا نموذج **CNN-LSTM**، تقدم أفضل أداء في كلا المحطتين المدروستين، حيث اقتربت قيم معامل (NSE) **من 0.88** في مرحلة التحقق. وفي المقابل، أظهرت النماذج المتكررة الكلاسيكية أداءً مرضيًا ولكنه أدنى عمومًا، في حين لم تحقق البنيات ثنائية الاتجاه أي تحسن ملحوظ. كما يسلط تحليل **SHAP** الضوء على سلوكيات هيدرولوجية متباينة بين الحوضين، مما يعكس استجابات هيدرولوجية نوعية تختلف باختلاف خصائص البيئة المحلية.

تؤكد هذه الدراسة على **الإمكانات الواعدة لمقاربات التعلم العميق** في نمذجة الأمطار والتدفق في المناطق شبه الجافة، وتبرز أهمية دمج طرق قابلية التفسير لتحقيق فهم أفضل للآليات الهيدرولوجية الكامنة.

الكلمات المفتاحية: نمذجة الأمطار والتدفق؛ التعلم العميق؛ CNN-LSTM؛ الشبكات العصبونية؛ هيدرولوجيا المناطق شبه الجافة؛ التنبؤ بالتدفقات؛ SHAP؛ حوض الصومام؛ الجزائر؛ السلاسل الزمنية الهيدرولوجية.

Abstract

This study investigates **daily rainfall–runoff modeling** in a semi-arid Mediterranean context through the evaluation of several deep learning architectures applied to two sub-basins of the **Soummam** Basin in northern Algeria, namely Fermatou and Bou Birek. The main objective is to assess the ability of these models to reproduce hydrological dynamics under conditions characterized by high hydroclimatic variability and limited data availability.

Daily precipitation and streamflow data covering the period **2002–2012** were used to develop six deep learning models: **LSTM, GRU, CNN, BiLSTM, BiGRU**, and the hybrid **CNN-LSTM** model. Input variables were selected based on preliminary statistical analyses including autocorrelation **(ACF),** partial autocorrelation **(PACF),** and cross-correlation analyses. Model performance was evaluated using several hydrological metrics, including the Nash–Sutcliffe Efficiency **(NSE),** correlation coefficient **R**, Kling–Gupta Efficiency **(KGE)**, and Root Mean Square Error **(RMSE).** In addition, the SHAP interpretability approach was employed to identify the relative contribution of input variables.

The results indicate that convolutional and hybrid architectures, particularly the **CNN-LSTM** model, achieved the best performance for both study stations, with NSE values close to **0.88** during the validation phase. Conventional recurrent models provided satisfactory but comparatively lower performances, while bidirectional architectures did not yield significant improvements. **SHAP** analysis also revealed differences in hydrological behavior between the two basins, reflecting basin-specific hydrological responses related to local watershed characteristics.

This research confirms the **potential of deep learning approaches** for **rainfall–runoff modeling** in semi-arid environments and highlights the importance of integrating interpretability methods to improve the understanding of the underlying hydrological mechanisms.

Keywords: Rainfall-runoff modeling; Deep learning; CNN-LSTM, Neural networks; Semi-arid hydrology, Streamflow forecasting; SHAP, Soummam Basin, Algeria; Hydrological time series.

SOMMAIRE

Dédicace I

Remerciements II

Résumé III

Sommaire IV

Liste des figures XIII

Liste des tableaux XVI

Liste des abréviation XVII

Introduction générale 1

CHAPITRE I : GÉNÉRALITÉS SUR LA MODÉLISATION HYDROLOGIQUE

· I.1 Introduction 4

· I.2 Hydrologie : définition et champ d'étude 4

· I.2.1 Le cycle hydrologique 5

· I.2.2 Concept de bassin versant 6

· I.2.3 Processus hydrologiques de génération du ruissellement 7

· I.2.4 Variabilité spatio-temporelle et complexité des processus hydrologiques 8

· I.2.5 Données hydrologiques et limites de l'observation 8

. I.3 Modélisation hydrologique 9

. I.3.1 Généralités sur la modélisation hydrologique 10

. I.3.2 Composants d'un modèle hydrologique 11

. I.3.3 Étapes de développement d'un modèle hydrologique 11

. I.3.4 Classification des modèles pluie-débit 12

. I.3.4.1 Selon la nature de la variable 13

. I.3.4.1.1 Modèles stochastiques 13

. I.3.4.1.2 Modèles déterministes 13

. I.3.4.2 Selon le traitement de l'espace (Homogénéité du bassin) 14

. I.3.4.2.1 Modèles globaux 14

. I.3.4.2.2 Modèles semi-distribués 14

. I.3.4.2.3 Modèles distribués 14

. I.3.4.3 Selon le fondement théorique et approche de développement 15

. I.3.4.3.1 Modèles à base physique 15

. I.3.4.3.2 Modèles empiriques 15

. I.3.4.3.3 Modèles conceptuels 16

· I.4 Limites des modèles hydrologiques traditionnels 16

· I.5 Modèles d'intelligence artificielle appliqués à la modélisation hydrologique 17

· I.6 Conclusion 19

CHAPITRE II : REGION D'ETUDE ET DONNEES UTILISEES.

· II.1 Introduction 21

· II.2 Situation géographique 21

· II.3 Aperçu topographique 22

· II.4 Aspect climatique 22

· II.5 Végétation, couverture végétale et sols 23

· II.6 Caractéristiques générales du bassin de la Soummam 23

· II.6.1 Situation géographique 23

· II.6.2 Sous-bassins sélectionnés 24

· a) Sous-bassin de FERMATOU 25

· b) Sous-bassin de BOU BIREK 26

· II.6.3 Caractéristiques morphométriques des sous-bassins étudiés 27

· II.7 Données utilisées 28

· II.7.1 Collecte des données 28

· II.7.2 Stations sélectionnées 28

· II.7.3 Caractéristiques statistiques des séries 29

· II.8 Conclusion 32

CHAPITRE III : MATERIELS ET METHODES

· III.1 Introduction 33

· III.2 Étapes de mise en œuvre de l'étude 33

· III.3 Modèles d'intelligence artificielle appliqués à la prédiction du débit 35

· III.3.1 Réseau de neurones LSTM (Long Short-Term Memory) 36

· III.3.1.1 Architecture et mécanismes internes 36

· III.3.1.2 Avantages et inconvénients du modèle LSTM 37

· III.3.2 Réseau de neurones GRU (Gated Recurrent Unit) 37

· III.3.2.1 Architecture et mécanismes internes 38

· III.3.2.2 Avantages et inconvénients du modèle GRU 38

· III.3.3 Réseau de neurones convolutifs (CNN) 39

· III.3.3.1 Architecture et mécanismes internes 39

· III.3.3.2 Avantages et inconvénients du modèle CNN 40

· III.3.4 Modèle hybride CNN-LSTM 40

· III.3.4.1 Architecture et mécanismes internes 41

· III.3.4.2 Hybridation CNN-LSTM 42

· III.3.4.3 Avantages et inconvénients du modèle CNN-LSTM 42

· III.3.5 Réseau de neurones BiLSTM (Bidirectional Long Short-Term Memory) 42

· III.3.5.1 Architecture et mécanismes internes 43

· III.3.5.2 Avantages et inconvénients du modèle BiLSTM 43

· III.3.6 Réseau de neurones BiGRU (Bidirectional Gated Recurrent Unit) 44

· III.3.6.1 Architecture et mécanismes internes 44

· III.3.6.2 Avantages et inconvénients du modèle BiGRU 44

· III.3.7 Méthode d'interprétabilité SHAP 45

· III.3.7.1 Principe et mécanisme de fonctionnement 45

· III.3.7.2 Avantages et inconvénients de la méthode SHAP 46

· III.4 Évaluation des performances des modèles ……..…….. 47

· III.4.1 Critéres numériques (quantitatifs) ……..…… 47

· III.4.1.1 Coefficient de corrélation de Pearson ……..……..….. 47

· III.4.1.2 Coefficient d'efficacité de Nash-Sutcliffe (NSE) ……... 47

· III.4.1.3 Coefficient de Kling-Gupta (KGE) …… 48

· III.4.1.4 Erreur quadratique moyenne (RMSE) ……..... 48

· III.4.1.5 Erreur absolue moyenne (MAE) ……..…… 49

· III.4.1.6 Critère de sélection des modèles (CA) ……... 49

· III.5.2 Critères graphiques de visualisation des résultats …….…..... 50

· III.6 Outils et logiciels utilisés ……..…… 52

· III.7 Conclusion ……..……..……... 53

CHAPITRE IV : RÉSULTATS ET DISCUSSION

· IV.1 Introduction ……..…….. 54

· IV.2 Analyse et interprétation des résultats ……..…….. 54

· IV.3 Analyse comparative multi-critères des performances des modèles de deep learning ..60

· IV.4 Analyse de l'influence des variables explicatives sur les prédictions des modèles par l'approche SHAP ……..…… 66

· IV.5 Mise en perspective des résultats obtenus par rapport à la littérature scientifique ..…. 71

· IV.6 Conclusion …… 74

LISTE DES FIGURES

CHAPITER I : GÉNÉRALITÉS SUR LA MODÉLISATION HYDROLOGIQUE

· Figure I.1 – Cycle hydrologique et fonctionnement hydrologique du bassin versant ..…….. 6

· Figure I.2 – Complexité et non-linéarité des processus de transformation pluie-débit 8

· Figure I.3 – L'apprentissage dans la modélisation basée sur les données …… 10

· Figure I.4 – Étapes de la modélisation hydrologique ……..…….. 12

· Figure I.5 – Classification des modèles hydrologiques ……..……..…….. 16

· Figure I.6 – Modèles traditionnels et modernes …..... 19

CHAPITRE II : REGION D'ETUDE ET DONNEES UTILISEES.

· Figure II.1 – Situation géographique de la région d'étude …… 22

· Figure II.2 – Situation géographique du bassin versant de la Soummam en Algérie……. 24

· Figure II.3 – Carte du sous-bassin versant de FERMATOU …… 26

· Figure II.4 – Carte du sous-bassin versant de BOU BIREK ……..……..……... 27

· Figure II.5 – Boxplots des séries de précipitations et de débits des stations FERMATOU et BOU BIREK avec les principaux paramètres statistiques ……..…….. 30

· Figure II.6 – Matrices de corrélation entre les variables climatiques et hydrologiques pour les stations ……..……..……. 31

CHAPITRE III : MATERIELS ET METHODES

· Figure III.1 – Schéma de la démarche méthodologique pour la prédiction du débit journalier à l'aide de modèles d'intelligence artificielle ……..……..……... 35

· Figure III.2 – Structure interne d'une cellule LSTM (Long Short-Term Memory …….. 37

· Figure III.3 – Architecture interne d'une cellule GRU (Gated Recurrent Units …….. 39

· Figure III.4 – Architecture typique d'un réseau de neurones convolutif (CNN 1D) pour la modélisation de séries temporelles …… 40

· Figure III.5 – Architecture hybride CNN-LSTM intégrant l'extraction de caractéristiques et la modélisation temporelle …….. 42

· Figure III.6 – Illustration de l'architecture d'un réseau BiLSTM ……... 43

· Figure III.7 – Illustration de l'architecture d'un réseau BiGRU …… 45

· Figure III.8 – Illustration de l'architecture d'un SHAP …….... 46

· Figure III.9 – La démarche scientifique adoptée d'outils et logiciels ……... 52

CHAPITRE IV : RÉSULTATS ET DISCUSSION

· Figure IV.1 – Analyse de corrélation entre les débits observés et simulés à la station FERMATOU (scatterplot)…… 57

·Figure IV.2 – Analyse de corrélation entre les débits observés et simulés à la station BOU BIREK(scatterplot)…… 60

· Figure IV.3 – Distribution des performances des modèles de deep learning à l'aide des boxplots ……... 62

· Figure IV.4 – Distribution et densité des performances des modèles de deep learning (violin plot)…… 62

· Figure IV.5 – Courbes de variation des débits observés et simulés par les modèles de deep learning…….. 63

· Figure IV.6 – Diagramme de Taylor illustrant les performances des modèles de deep learning ……..…….. 64

· Figure IV.7 – Comparaison des performances des modèles de deep learning à l'aide d'un diagramme en barres…….……..…….. 64

· Figure IV.8 – Carte thermique des performances des modèles de deep learning selon les indicateurs statistiques……...……..... 65

· Figure IV.9 – Importance relative des variables d'entrée basée sur les valeurs SHAP pour les modèles de deep learning à la station FERMATOU (summary plot)……..…….. 67

· Figure IV.10 – Importance relative des variables d'entrée basée sur les valeurs SHAP pour les modèles de deep learning à la station BOU BIREK (summary plot)……...…..…… 68

· Figure IV.11 – Distribution des contributions des variables d'entrée aux prédictions des modèles(SHAP Pie Charts) à la station FERMATOU …… 69

· Figure IV.12 – Distribution des contributions des variables d'entrée aux prédictions des modèles (SHAP Pie Charts) à la station BOU BIREK…… 70

LISTE DES TABLEAUX

CHAPITER I : GÉNÉRALITÉS SUR LA MODÉLISATION HYDROLOGIQUE

· Tableau I.1 – Exemple de caractéristiques des modèles pluie-débit (Berthier, 2005) …….. 13

CHAPITRE II : REGION D'ETUDE ET DONNEES UTILISEES

· Tableau II.1 – Caractéristiques des bassins versants étudiés (Source ANRH, 2021) …… 28

· Tableau II.2 – Stations choisies dans cette étude (Sources : ANRH, 2021) ……..... 29

· Tableau II.3 – Les combinaisons d'entrées pour différents modèles ....…….…..... 32

CHAPITRE IV : RÉSULTATS ET DISCUSSION

. Tableau IV.1 – Évaluation numérique des modèles à la station FERMATOU ……. 55

· Tableau IV.2 – Évaluation numérique des modèles à la station BOU BIREK …… 57

· Tableau IV.3 – Résultats comparatifs des modèles de deep learning pour les stations FERMATOU et BOU BIREK ……. 61

LISTE DES ABRÉVIATIONS

ANFIS = Adaptive Neuro Fuzzy Inference System

ANN = Artificial Neural Networks (Réseaux de neurones artificiels)

ATHYS = Modèle hydrologique distribué

CNN = Convolutional Neural Networks (Réseaux de neurones convolutifs)

EDP = Équations aux Dérivées Partielles

ET = Évapotranspiration

GR = Modèle du Génie Rural

GRU = Gated Recurrent Unit

HEC-1 = Hydrologic Engineering Center model

HYDROTEL = Modèle hydrologique distribué

LSTM = Long Short-Term Memory

MAE = Mean Absolute Error (Erreur absolue moyenne)

NSE = Nash-Sutcliffe Efficiency (Coefficient d'efficacité de Nash-Sutcliffe)

PDM = Probability Distributed Moisture

R^2 = Coefficient de détermination

RF = Random Forests (Forêts aléatoires)

RMSE = Root Mean Square Error (Racine de l'erreur quadratique moyenne)

SHE = Système Hydrologique Européen

SIG = Système d'Information Géographique

SVM = Support Vector Machines (Machines à vecteurs de support)

SVR = Sector Vector Machine for Regression (Régression à vecteurs de support)

INTRODUCTION GENERALE

INTRODUCTION GENERALE

L'hydrologie est la science qui étudie le cycle de l'eau dans la nature, incluant les processus de précipitation, d'infiltration, de ruissellement et d'évaporation (Chow et al., 1988). Elle joue un rôle fondamental dans la compréhension du fonctionnement des bassins versants et dans la gestion des ressources en eau. Dans un contexte marqué par les changements climatiques, la variabilité hydrologique et l'augmentation des besoins en eau, l'étude des régimes hydrologiques devient essentielle pour la planification, la prévention des risques et la gestion durable des ressources hydriques.

Parmi les différentes problématiques hydrologiques, la modélisation des débits constitue un enjeu majeur. Elle permet de simuler le comportement des bassins versants et de prévoir les écoulements à partir de variables météorologiques, notamment les précipitations (Singh, 1995). La modélisation pluie-débit est ainsi largement utilisée dans des domaines tels que la gestion des crues, l'aménagement hydraulique, la production hydroélectrique et la gestion des sécheresses. Elle constitue un outil indispensable pour anticiper les événements extrêmes et optimiser l'exploitation des ressources en eau (Moriasi et al., 2007).

Cependant, la mesure directe des débits présente plusieurs contraintes. Les stations hydrométriques sont souvent limitées en nombre, leur maintenance est coûteuse, et les données peuvent être incomplètes ou entachées d'erreurs, notamment dans les régions semi-arides où les conditions hydrologiques sont complexes et fortement variables. De plus, certains bassins versants ne disposent pas de dispositifs de mesure fiables ou continus. Ces limitations rendent nécessaire le recours à des approches de modélisation permettant d'estimer les débits à partir d'autres variables plus accessibles, comme les précipitations (Di Baldassarre et al., 2017).

Dans ce contexte, la modélisation pluie-débit apparaît comme une solution pertinente pour pallier les insuffisances des données hydrométriques. Elle permet d'établir des relations entre les précipitations et les écoulements, en tenant compte des caractéristiques du bassin versant. Les approches traditionnelles, basées sur des modèles conceptuels ou physiques, ont longtemps été utilisées pour décrire ces processus. Toutefois, leur mise en œuvre nécessite souvent des hypothèses simplificatrices et une connaissance approfondie des paramètres du système, ce qui limite leur précision dans certains cas (Kratzert et al., 2018 ; Shen, 2018).

Avec l'évolution des technologies et l'essor de l'intelligence artificielle, de nouvelles approches de modélisation ont émergé, notamment les méthodes de *machine learning* et de *deep learning*. Ces techniques permettent de modéliser des relations complexes et non linéaires entre les variables d'entrée et de sortie, sans nécessiter une description explicite des processus physiques. Les architectures telles que les réseaux de neurones récurrents (LSTM, GRU) et convolutionnels (CNN) ont montré des performances prometteuses dans la modélisation hydrologique, en particulier pour la simulation des séries temporelles.

Malgré ces avancées, plusieurs défis subsistent, notamment en termes de robustesse des modèles, de généralisation et d'interprétabilité. En effet, les modèles de *deep learning* sont souvent considérés comme des « boîtes noires », ce qui limite leur acceptabilité dans les applications opérationnelles. Dans ce cadre, des méthodes d'explicabilité, telles que l'approche SHAP (*SHapley Additive exPlanations*), ont été développées afin d'analyser l'influence des variables d'entrée sur les prédictions et d'améliorer la compréhension du fonctionnement des modèles.

C'est dans ce contexte que s'inscrit le présent travail, qui vise à développer et évaluer des modèles de *deep learning* pour la modélisation des débits journaliers dans le bassin versant de la Soummam, situé au nord-centre de l'Algérie. Ce bassin présente des caractéristiques hydrologiques complexes, marquées par une forte variabilité des précipitations et des écoulements, ce qui en fait un cas d'étude pertinent pour tester l'efficacité des approches proposées.

L'originalité de ce travail réside dans l'application et la comparaison de plusieurs architectures de *deep learning*, notamment LSTM, GRU, CNN, ainsi que des modèles hybrides tels que CNN-LSTM, dans un contexte hydrologique réel. L'étude se base sur des données hydrométéorologiques observées, permettant d'évaluer les performances des modèles dans des conditions réalistes. Par ailleurs, l'intégration de l'approche SHAP constitue une contribution importante, en apportant une dimension interprétative aux résultats obtenus.

Les objectifs principaux de ce mémoire peuvent être résumés comme suit :

- Développer des modèles de *deep learning* pour la simulation des débits journaliers à partir des données de précipitation ;

- Comparer les performances des différentes architectures afin d'identifier les modèles les plus efficaces ;
- Analyser la capacité de généralisation des modèles dans différents scénarios ;
- Interpréter les résultats à l'aide de l'approche SHAP afin d'identifier les variables les plus influentes ;

Ainsi, ce travail vise à contribuer à l'amélioration des méthodes de modélisation hydrologique en proposant des approches performantes, robustes et interprétables, adaptées aux spécificités des bassins versants étudiés.

Le présent mémoire est structuré autour de quatre chapitres. Le premier chapitre présente un état de l'art de la modélisation hydrologique en mettant l'accent sur les principales approches et méthodes utilisées dans ce domaine. Le deuxième chapitre est consacré à la présentation de la région d'étude ainsi qu'aux données exploitées dans cette recherche. Le troisième chapitre décrit les matériels et méthodes adoptés, notamment les modèles utilisés et la démarche méthodologique suivie. Le quatrième chapitre expose les résultats obtenus et leur discussion. Enfin, ce travail se termine par une conclusion générale qui synthétise les principaux résultats et perspectives de l'étude.

CHAPITRE I

GENERALITE SUR LA MODELISATION HYDROLOGIQUE

CHAPITRE I : GENERALITE SUR LA MODELISATION HYDROLOGIQUE

I.1. Introduction

L'hydrologie constitue une discipline fondamentale pour la compréhension et la gestion des ressources en eau, en s'intéressant aux processus de circulation, de stockage et de transformation de l'eau au sein du système Terre–atmosphère (Brutsaert, 2005 ; Chow et al., 1988). Parmi les problématiques centrales de cette discipline, la relation pluie–débit occupe une place essentielle, notamment pour la prévision des crues, la gestion des ressources en eau et l'aménagement hydraulique (Beven, 2012 ; Dingman, 2015).

Cependant, la modélisation de cette relation demeure complexe en raison du caractère non linéaire et dynamique des processus hydrologiques, ainsi que des limites liées aux observations disponibles (Beven, 2001 ; Dingman, 2015). Pour répondre à cette complexité, plusieurs approches ont été développées, notamment les modèles empiriques, conceptuels et physiquement basés, chacun présentant des avantages et des limites en termes de représentation des processus hydrologiques. Plus récemment, les avancées en science des données ont favorisé l'émergence des méthodes basées sur l'apprentissage automatique et l'apprentissage profond, capables d'exploiter efficacement les données hydrométéorologiques et de modéliser des relations complexes entre les variables du système (Solomatine & Ostfeld, 2008 ; Kratzert et al., 2018).

Ainsi, ce chapitre présente les fondements de la modélisation hydrologique, les principales approches pluie–débit ainsi que l'émergence des méthodes modernes basées sur les données, qui constituent le cadre méthodologique de ce travail.

I.2. Définition et champ d'étude de l'hydrologie

L'hydrologie est la science qui étudie l'eau sur Terre, notamment sa distribution, son mouvement et sa qualité à la surface et dans le sous-sol (Brutsaert, 2005 ; Chow et al., 1988). Elle mobilise des notions issues de la météorologie, de la géologie et de la mécanique des fluides afin de comprendre et prévoir le comportement de l'eau. Cette discipline joue un rôle essentiel dans la gestion des ressources en eau, l'agriculture et la prévention des risques hydrologiques tels que les inondations et les sécheresses.

L'hydrologie repose sur une approche systémique fondée sur le cycle hydrologique, où l'eau circule continuellement entre l'atmosphère, les eaux de surface et les eaux souterraines (Brutsaert, 2005 ; Chow et al., 1988). Les échanges entre ces composantes permettent d'analyser les flux et les stocks d'eau au sein du système hydrologique.

Dans les études hydrologiques, le bassin versant est généralement considéré comme une unité de contrôle dans laquelle les relations entre les entrées, notamment les précipitations, et les sorties, telles que les débits, sont analysées à l'aide des principes de conservation de la masse et de l'énergie.

I.2.1. Le cycle hydrologique

Le cycle hydrologique décrit la circulation continue de l'eau au sein du système Terre–atmosphère. Sous l'effet de l'énergie solaire, l'eau s'évapore des océans, des sols et des surfaces continentales, puis se condense dans l'atmosphère avant de retomber sous forme de précipitations (Brutsaert, 2005 ; Chow et al., 1988).

Sur les continents, les précipitations se répartissent entre l'infiltration, le ruissellement de surface et l'évapotranspiration. L'eau infiltrée peut alimenter les nappes souterraines ou contribuer aux écoulements subsuperficiels, tandis que le ruissellement alimente les cours d'eau qui restituent finalement l'eau aux océans, assurant ainsi la continuité du cycle hydrologique (Figure I.1). À l'échelle d'un bassin versant, le bilan hydrique simplifié peut être exprimé par :

$$\mathbf{P = Q + ET + \Delta S} \qquad \mathbf{I.1}$$

Où : **P** représente les précipitations, **Q** le débit, **ET** l'évapotranspiration et **ΔS** la variation du stockage en eau.

Les principaux processus du cycle hydrologique — précipitation, infiltration, ruissellement et évapotranspiration — présentent une forte variabilité spatiale et temporelle, ce qui contribue à la complexité des systèmes hydrologiques.

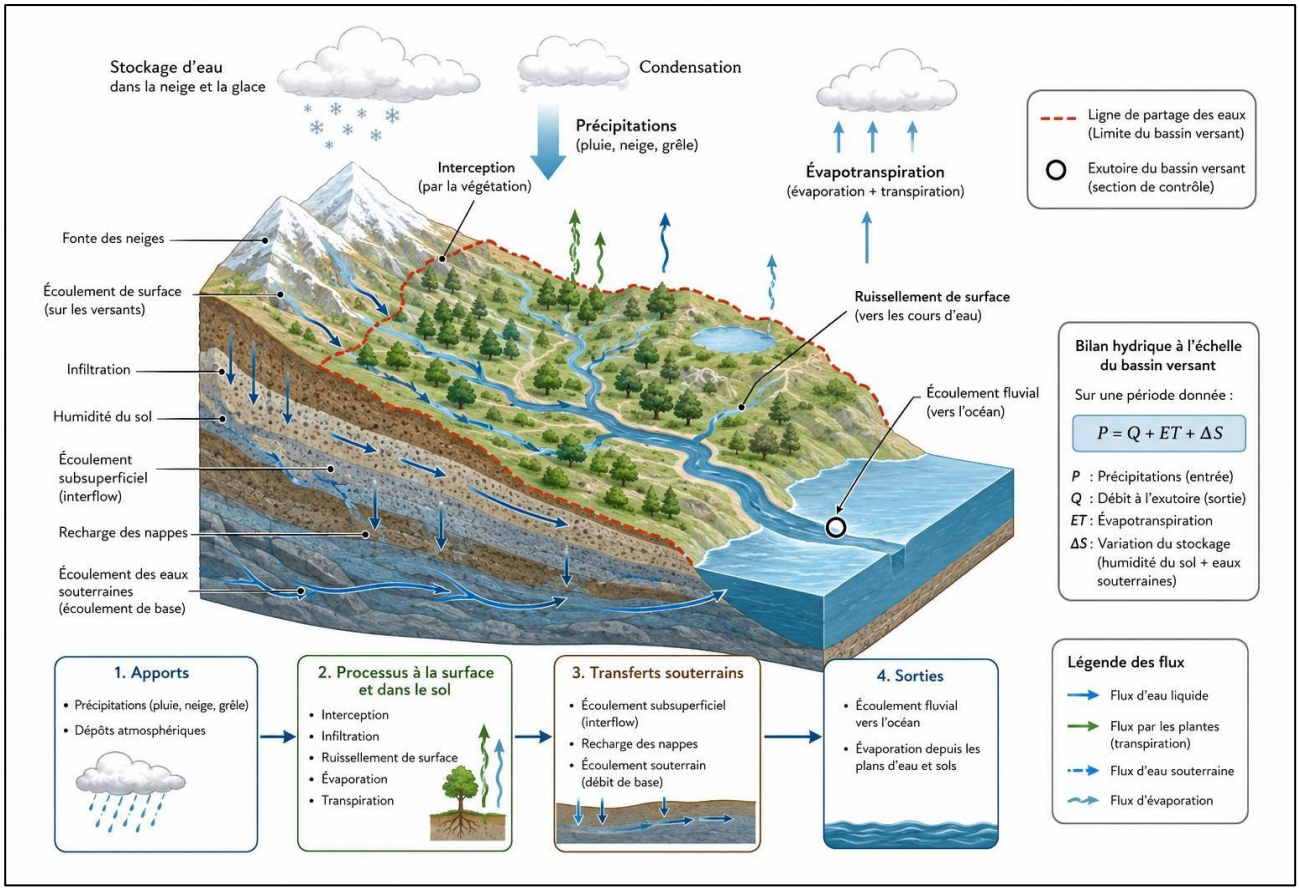


Figure I.1. Cycle hydrologique et fonctionnement hydrologique du bassin versant

I.2.2. Concept de bassin versant

Le bassin versant constitue l'unité spatiale fondamentale en hydrologie. Il correspond à une surface topographique délimitée par des lignes de partage des eaux, à l'intérieur de laquelle toutes les eaux précipitées convergent vers un même exutoire, tel qu'un oued, une rivière ou un lac (Chow et al., 1988). Ainsi, tout point situé à l'intérieur du bassin participe, directement ou indirectement, à l'alimentation du cours d'eau principal. Le fonctionnement hydrologique d'un bassin versant dépend principalement des précipitations, considérées comme les entrées du système, tandis que les écoulements à l'exutoire représentent les sorties. Entre ces deux composantes interviennent plusieurs processus hydrologiques, notamment l'infiltration, le ruissellement, l'évapotranspiration et le stockage temporaire de l'eau dans le sol ou les nappes souterraines.

L'étude des bassins versants permet de comprendre les mécanismes de transformation de la pluie en débit et constitue la base des analyses hydrologiques relatives à la prévision des

crues, à la gestion des ressources en eau, à la protection contre les inondations ainsi qu'à la modélisation pluie–débit. Afin de caractériser le comportement hydrologique d'un bassin versant, plusieurs paramètres morphométriques et physiographiques sont généralement utilisés. Ces paramètres permettent d'évaluer l'influence de la forme, du relief et du réseau hydrographique sur la réponse hydrologique du bassin.

Parmi les principaux critères de caractérisation figurent les indices de forme, tels que le coefficient de compacité de Gravelus et le facteur de forme, qui renseignent sur la géométrie du bassin et son aptitude à générer des écoulements rapides. Les indices de pente permettent d'évaluer l'influence du relief sur la vitesse du ruissellement et l'érosion des sols. La densité de drainage, définie comme le rapport entre la longueur totale du réseau hydrographique et la superficie du bassin, traduit le degré de développement du réseau d'écoulement. De même, le temps de concentration représente la durée nécessaire pour qu'une goutte d'eau issue du point le plus éloigné du bassin atteigne l'exutoire ; il constitue un paramètre essentiel dans l'analyse des crues et la modélisation hydrologique. L'ensemble de ces caractéristiques joue un rôle déterminant dans la compréhension du comportement hydrologique des bassins versants et dans l'élaboration des modèles de simulation hydrologique.

I.2.3. Processus hydrologiques de génération du ruissellement

La transformation des précipitations en débit résulte d'un ensemble de processus hydrologiques interdépendants contrôlés par les caractéristiques du bassin versant, telles que la perméabilité du sol, la couverture végétale et les conditions initiales d'humidité. Une partie des précipitations s'infiltre dans le sol et alimente les nappes souterraines, tandis qu'une autre contribue au ruissellement et à l'écoulement vers le réseau hydrographique. Le ruissellement peut être généré par excès d'infiltration lorsque l'intensité des précipitations dépasse la capacité d'infiltration du sol, ou par excès de saturation lorsque le sol est déjà saturé. D'autres processus, tels que l'écoulement subsuperficiel et le débit de base provenant des eaux souterraines, participent également à la réponse hydrologique du bassin versant.

L'interaction entre ces différents mécanismes confère au système hydrologique un comportement complexe, fortement dépendant des conditions hydrométéorologiques et des caractéristiques physiques du bassin (Beven, 2001 ; Dingman, 2015).

I.2.4. Variabilité spatio-temporelle et complexité des processus hydrologiques

Le fonctionnement hydrologique d'un bassin versant présente une forte variabilité spatiale et temporelle liée aux différences de topographie, de propriétés des sols, de couverture végétale et de conditions climatiques. Cette hétérogénéité influence directement la répartition des flux d'eau et les mécanismes de transformation des précipitations (Figure I.2).

Les processus hydrologiques présentent également un comportement fortement non linéaire. Des événements pluviométriques similaires peuvent produire des réponses hydrologiques différentes selon l'état initial du bassin versant, notamment l'humidité du sol et les interactions entre les processus internes.

Par conséquent, la relation pluie–débit constitue un système complexe et non linéaire, difficile à représenter par des formulations analytiques simples, ce qui représente un défi majeur pour la modélisation hydrologique (Beven, 2001 ; Dingman, 2015).

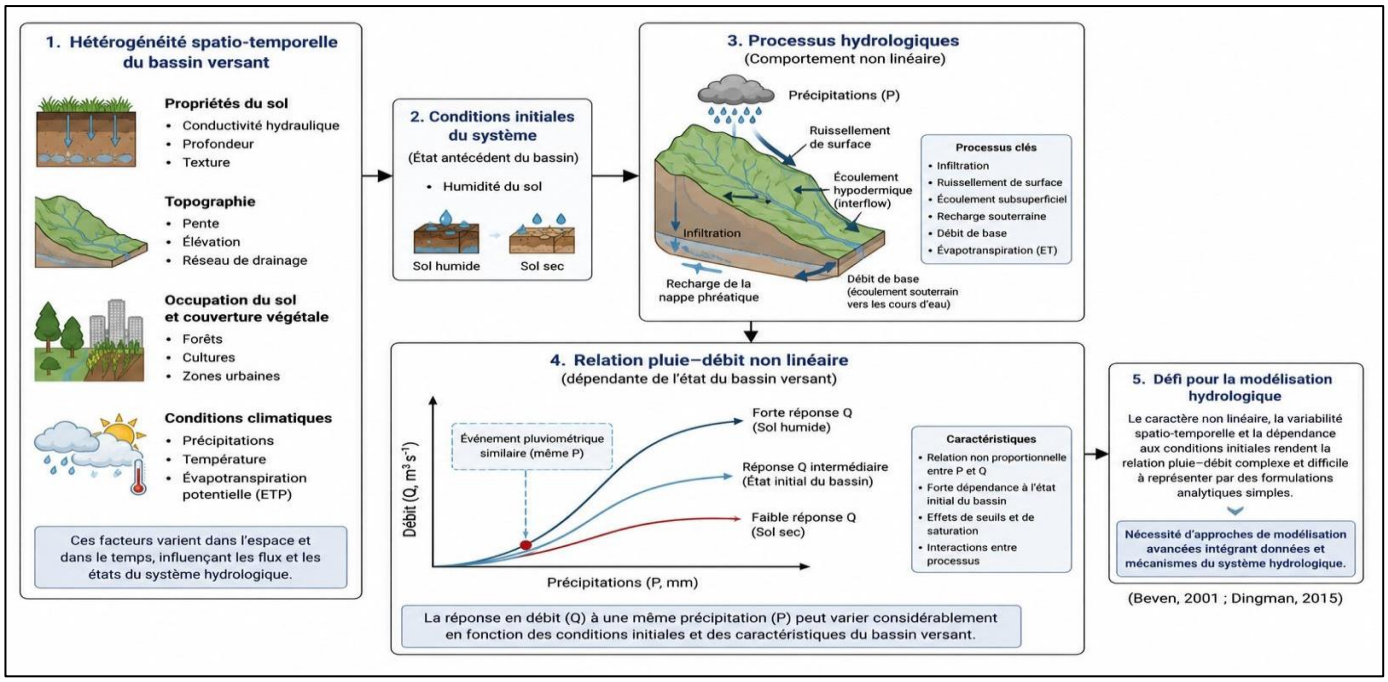


Figure I.2. Complexité et non-linéarité des processus de transformation pluie-débit

I.2.5. Données hydrologiques et limites de l'observation

L'étude des systèmes hydrologiques repose sur l'acquisition et l'analyse de données hydrométéorologiques permettant de décrire le fonctionnement du bassin versant ainsi que les

interactions entre ses différentes composantes. Les précipitations, généralement mesurées à l'aide de pluviomètres ou estimées par télédétection, représentent l'entrée principale du système hydrologique. Les débits observés aux stations hydrométriques constituent quant à eux la réponse intégrée du bassin versant aux événements pluviométriques. D'autres variables hydrologiques et climatiques, telles que l'évapotranspiration, la température, l'humidité du sol, les niveaux piézométriques ou encore les écoulements souterrains, contribuent à une meilleure compréhension des mécanismes de transfert et de stockage de l'eau au sein du bassin.

La qualité et la disponibilité des données hydrologiques jouent un rôle déterminant dans l'analyse et la modélisation des processus pluie–débit. Toutefois, les réseaux d'observation présentent souvent plusieurs limitations susceptibles d'affecter la fiabilité des analyses hydrologiques. Parmi les principales contraintes figurent l'insuffisance de la couverture spatiale des stations de mesure, particulièrement dans les régions montagneuses ou semi-arides, les discontinuités et lacunes des séries chronologiques, ainsi que les erreurs liées aux instruments de mesure et aux conditions d'observation. De plus, certaines composantes du cycle hydrologique, notamment l'évapotranspiration réelle, l'humidité profonde du sol ou les flux souterrains, demeurent difficiles à mesurer directement et nécessitent le recours à des méthodes d'estimation ou à des approches indirectes.

À ces difficultés s'ajoutent la forte variabilité spatiale et temporelle des précipitations ainsi que le caractère complexe et non linéaire des processus hydrologiques, rendant la compréhension et la prévision des écoulements particulièrement délicates (Beven, 2001 ; Dingman, 2015). Dans ce contexte, la modélisation hydrologique apparaît comme un outil indispensable pour représenter de manière simplifiée mais cohérente le comportement des bassins versants. Elle permet de relier les données d'entrée, principalement les précipitations et les variables climatiques, aux sorties observées telles que les débits, afin de simuler le fonctionnement hydrologique du bassin et d'améliorer la prévision des ressources en eau et des événements extrêmes.

I.3. Modélisation hydrologique

La modélisation hydrologique constitue un outil fondamental pour l'étude et la compréhension des processus liés au cycle de l'eau au sein des bassins versants. Elle permet de représenter de manière simplifiée le comportement d'un système hydrologique afin de simuler ou prévoir les écoulements à partir des variables climatiques et hydrologiques

observées (Beven, 2012 ; Chow et al., 1988). Les modèles hydrologiques sont largement utilisés dans plusieurs domaines, notamment la prévision des crues, la gestion des ressources en eau, l'analyse des impacts climatiques ainsi que l'évaluation des risques hydrologiques.

I.3.1. Généralités sur la modélisation hydrologique

La modélisation hydrologique repose sur la représentation mathématique des relations entre les entrées et les sorties d'un bassin versant. Les précipitations constituent généralement les principales variables d'entrée, tandis que les débits observés à l'exutoire représentent les sorties du système (Figure I.3) (Dingman, 2015). Entre ces deux composantes interviennent plusieurs processus hydrologiques, tels que l'infiltration, le ruissellement, l'évapotranspiration et le stockage de l'eau dans le sol.

L'objectif principal de la modélisation hydrologique est de reproduire le comportement réel du bassin versant afin d'améliorer la compréhension des mécanismes hydrologiques et de faciliter la prévision des écoulements. Selon les objectifs de l'étude et la disponibilité des données, différents types de modèles hydrologiques peuvent être utilisés (Beven, 2012).

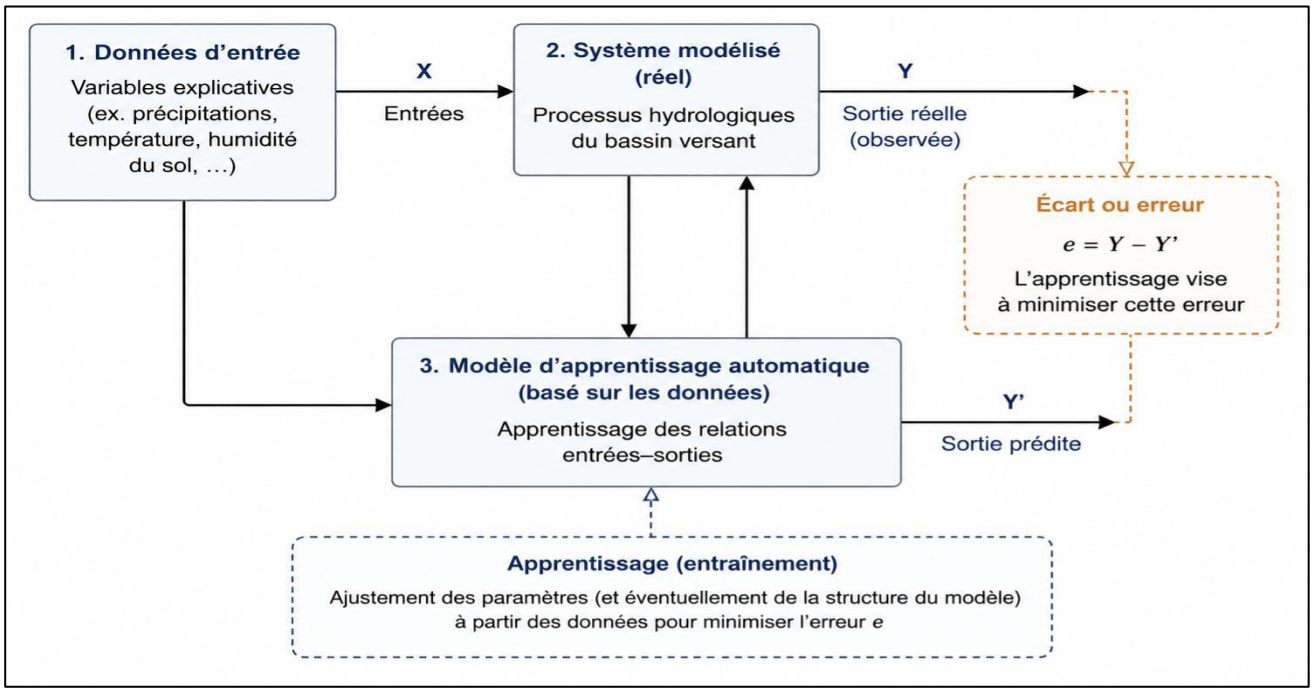


Figure I.3. L'apprentissage dans la modélisation basée sur les données

I.3.2. Composants d'un modèle hydrologique

Un modèle hydrologique est généralement constitué de plusieurs composantes permettant de représenter le fonctionnement du bassin versant. Les variables d'entrée regroupent principalement les données climatiques et hydrométéorologiques, telles que les précipitations, la température et l'évapotranspiration potentielle. Ces données servent à alimenter le modèle et à décrire les conditions hydrologiques du système.

Les paramètres du modèle correspondent aux coefficients utilisés pour représenter certains processus hydrologiques. Ces paramètres peuvent être déterminés à partir des caractéristiques physiques du bassin versant ou ajustés lors de la phase de calibration. Les variables d'état représentent quant à elles les conditions internes du système, comme l'humidité du sol ou le stockage souterrain. Enfin, les variables de sortie correspondent généralement aux débits simulés ou aux niveaux d'eau calculés par le modèle (Chow et al., 1988).

I.3.3. Étapes de développement d'un modèle hydrologique

Le développement d'un modèle hydrologique suit généralement plusieurs étapes successives. La première étape consiste à collecter et prétraiter les données hydrométéorologiques nécessaires à la modélisation. Cette phase comprend le contrôle de qualité des données, le traitement des valeurs manquantes ainsi que la normalisation ou la standardisation des séries temporelles.

La deuxième étape correspond à la calibration ou à l'entraînement du modèle. Dans le cas des approches basées sur les données et l'intelligence artificielle, cette phase vise à ajuster les paramètres internes du modèle afin de minimiser les erreurs entre les valeurs simulées et les observations réelles. Les données sont généralement divisées en plusieurs ensembles : un ensemble d'apprentissage (training set) utilisé pour entraîner le modèle, un ensemble de validation (validation set) permettant d'ajuster les hyperparamètres, et un ensemble de test (test set) destiné à évaluer les performances finales du modèle (Solomatine & Ostfeld, 2008).

La dernière étape concerne l'évaluation des performances du modèle à l'aide de critères statistiques et hydrologiques tels que le coefficient de Nash–Sutcliffe (NSE), la racine de l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) ou encore le

coefficient de détermination (R^2). Ces indicateurs permettent de mesurer la capacité du modèle à reproduire correctement les débits observés (Figure I.4).

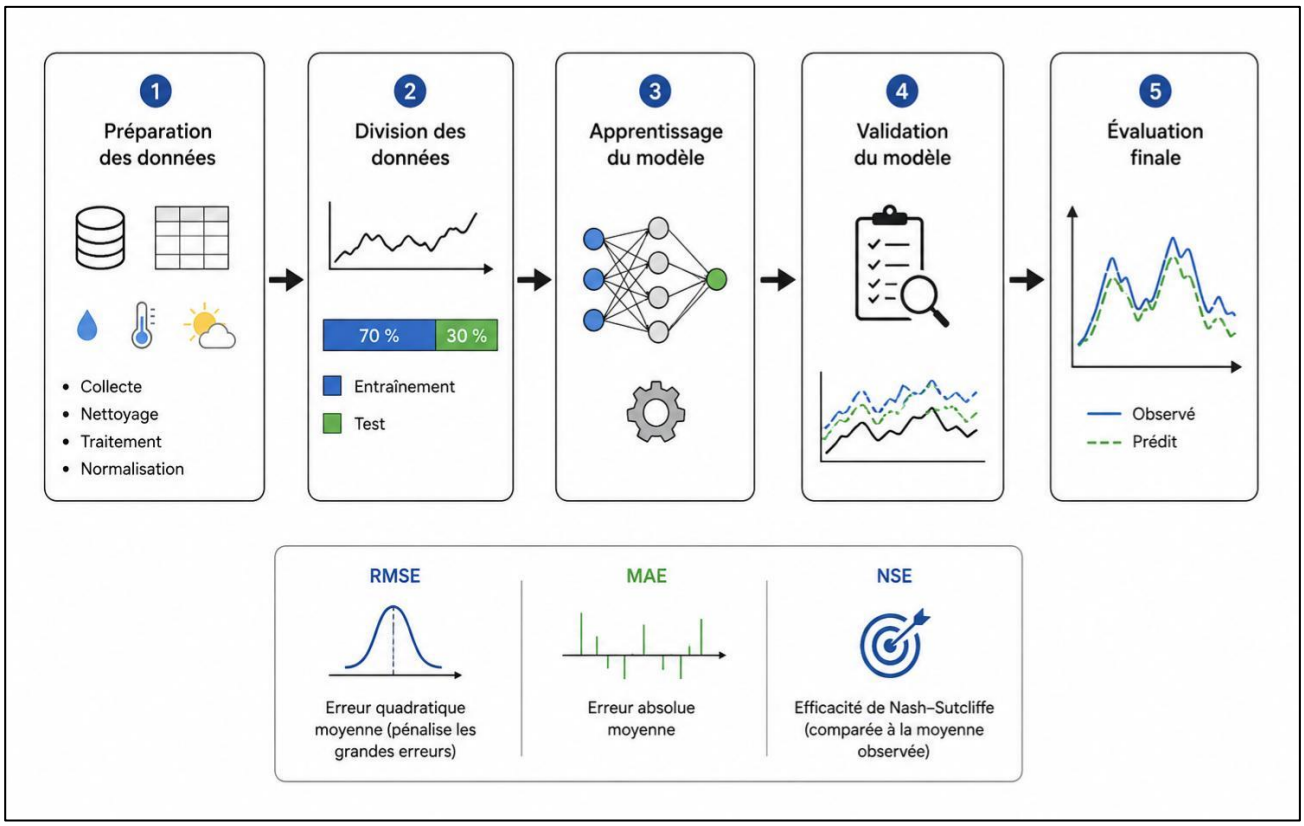


Figure I.4. Étapes de la modélisation hydrologique

I.3.4. 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. Perrin (2002) disait qu'il existe presque autant de classifications que d'hydrologues (Figure I.5). Le tableau suivant propose une classification de différents types de modèles selon leurs caractéristiques, en s'appuyant sur les travaux : d'Ambroise (1998), Andrassian (2002), Clarke (1973), Oudin (2004) et Perrin (2000).

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

Caractéristiques	Type de modèle
Selon la nature de la variable	Modèles déterministes (variables non aléatoires) Modèles stochastiques (variables aléatoires)
Traitement de l'espace (Homogénéité du bassin)	Modèles globales Modèles semi-distribués Modèles spatiales
Fondamentale théorique et approche de développement	Modèles empiriques Modèles conceptuels Modèles à base physique

I.3.4.1. Selon la nature de la variable

I.3.4.1.1. 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 Génèrent 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.3.4.1.2. Modèles déterministes

Un modèle est dit déterministe si aucune de ses grandeurs n'est considère 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.3.4.2. Selon le traitement de l'espace (Homogénéité du bassin)

I.3.4.2.1. 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.3.4.2.2. 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 (Refsgaard, 1997). 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.3.4.2.3. 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.3.4.3. 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.3.4.3.1 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.3.4.3.2. 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 boite 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.3.4.3.3 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.

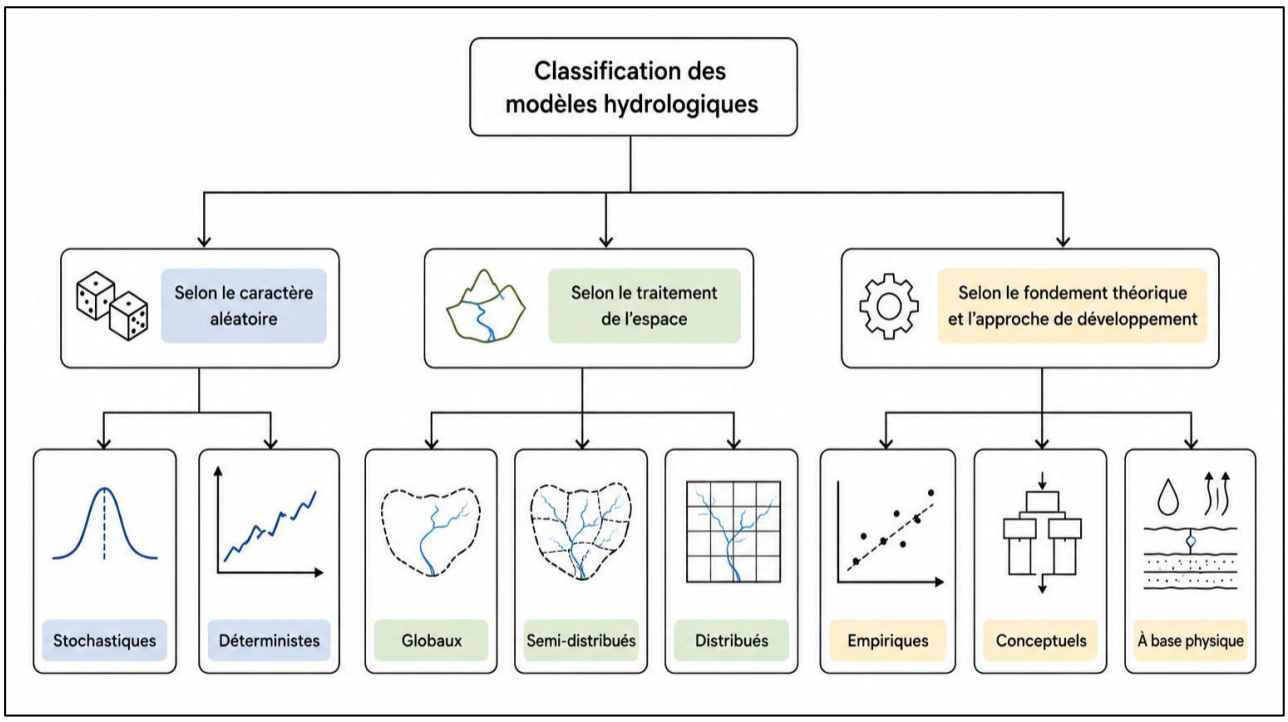


Figure I.5. Classification des modèles hydrologiques

I.5. Limites des modèles hydrologiques traditionnels

Malgré leur large utilisation dans la simulation pluie–débit et la gestion des ressources en eau, les modèles hydrologiques traditionnels, qu'ils soient conceptuels ou physiquement basés, présentent plusieurs limites importantes. Ces modèles reposent généralement sur des hypothèses simplificatrices nécessaires à la représentation des processus hydrologiques, ce qui peut réduire leur capacité à reproduire fidèlement la complexité réelle des bassins versants (Beven, 2012 ; Dingman, 2015). En particulier, les modèles conceptuels considèrent souvent

des relations simplifiées entre les précipitations, l'infiltration et le ruissellement, tout en supposant une homogénéité spatiale des caractéristiques du bassin versant.

Par ailleurs, la calibration des modèles hydrologiques traditionnels demeure une étape délicate en raison du phénomène d'équifinalité (*equifinality*), selon lequel plusieurs combinaisons de paramètres peuvent produire des résultats similaires pour un même bassin versant (Beven, 2001). Cette situation traduit l'incertitude associée à la représentation des processus hydrologiques et limite parfois la capacité des modèles à être transférés vers d'autres conditions climatiques ou hydrologiques.

Les besoins importants en données constituent également une contrainte majeure. Les modèles physiquement distribués nécessitent des informations détaillées sur les propriétés des sols, la topographie, l'occupation du sol et les caractéristiques climatiques, ainsi qu'une puissance de calcul souvent élevée. De plus, la forte non-linéarité des processus hydrologiques rend difficile la représentation précise des événements extrêmes, tels que les crues exceptionnelles ou les périodes de sécheresse prolongée (Solomatine & Ostfeld, 2008 ; Frame et al., 2022).

Ainsi, malgré les progrès réalisés dans le développement des modèles hydrologiques classiques, leurs limites ont favorisé l'émergence de nouvelles approches basées sur l'exploitation des données et les techniques d'intelligence artificielle.

I.6. Modèles d'intelligence artificielle appliqués à la modélisation hydrologique

Au cours des dernières décennies, les techniques d'intelligence artificielle ont connu un développement considérable dans le domaine de la modélisation hydrologique. Contrairement aux modèles hydrologiques traditionnels, les approches basées sur l'intelligence artificielle cherchent principalement à apprendre les relations entre les variables hydrométéorologiques à partir des données observées, sans nécessiter une représentation physique explicite des processus internes du bassin versant (Solomatine & Ostfeld, 2008).

Les premières applications ont principalement utilisé des méthodes de *Machine Learning* telles que les réseaux de neurones artificiels (*Artificial Neural Networks*), les machines à vecteurs de support (*Support Vector Machines*) et les forêts aléatoires (*Random Forests*). Ces modèles ont montré une grande capacité à représenter les relations non linéaires complexes

entre les précipitations et les débits, notamment dans les applications de prévision pluie–débit et de gestion des ressources en eau (Abrahart et al., 2012 ; Nourani et al., 2018).

Plus récemment, les approches de *Deep Learning* se sont imposées comme des outils particulièrement performants pour l'analyse des séries temporelles hydrologiques. Les réseaux récurrents de type *Long Short-Term Memory* (LSTM) et *Gated Recurrent Unit* (GRU) sont largement utilisés en raison de leur aptitude à capturer les dépendances temporelles longues caractéristiques des systèmes hydrologiques (Hochreiter & Schmidhuber, 1997 ; Kratzert et al., 2018). D'autres architectures, telles que les réseaux de neurones convolutionnels (*Convolutional Neural Networks,* CNN), ont également montré des résultats prometteurs dans l'exploitation des structures spatiales des données hydrologiques.

De nombreuses études récentes ont démontré que les modèles d'intelligence artificielle peuvent atteindre, voire dépasser, les performances des modèles hydrologiques traditionnels en matière de simulation pluie–débit et de prévision hydrologique (Kratzert et al., 2019 ; Nearing et al., 2021). Les recherches actuelles s'orientent également vers des approches hybrides combinant les connaissances physiques hydrologiques et les techniques de deep learning afin d'améliorer la robustesse, la généralisabilité et l'interprétabilité des modèles (Frame et al., 2022).

Ainsi, les modèles d'intelligence artificielle représentent aujourd'hui une orientation majeure de la modélisation hydrologique moderne et constituent des outils particulièrement adaptés à l'étude des systèmes hydrologiques complexes et non linéaires.

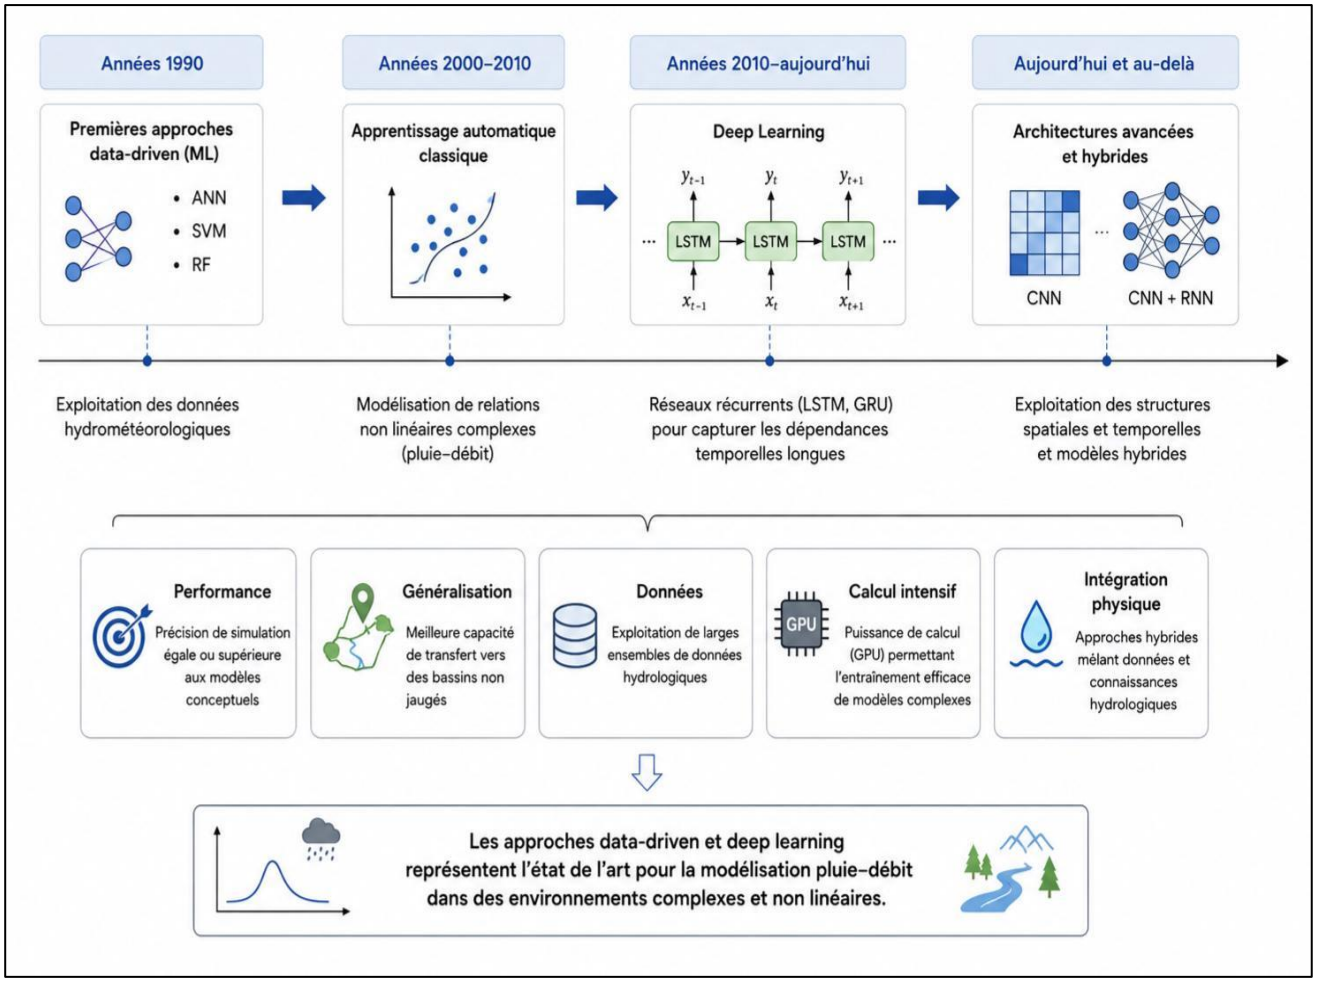


Figure I.6. Model traditionnels et moderne

I.7. Conclusion

Ce chapitre a présenté les fondements théoriques de l'hydrologie et de la modélisation pluie–débit, en mettant en évidence la complexité des processus hydrologiques et la forte variabilité spatio-temporelle qui caractérise les bassins versants. Les principales approches de modélisation ont été abordées, depuis les modèles traditionnels ; empiriques, conceptuels et physiquement fondés jusqu'aux approches modernes basées sur les données.

L'étude bibliographique a mise en évidence, l'évolution récente des méthodes d'apprentissage automatique et de deep learning qui a profondément transformé la modélisation hydrologique, en offrant des outils capables de représenter des relations non linéaires complexes à partir des données hydrométéorologiques. Parmi ces approches, les architectures de réseaux neuronaux récurrents, notamment les modèles LSTM, occupent aujourd'hui une place importante dans la prévision pluie–débit.

Ainsi, les approches data-driven apparaissent comme des outils prometteurs pour améliorer la prévision hydrologique et compléter les méthodes traditionnelles, particulièrement dans les contextes caractérisés par une forte complexité des systèmes hydrologiques et une disponibilité croissante des données.

.

CHAPITRE II

REGION D'ETUDE ET DONNEES UTILISEES

CHAPITRE II : REGION D'ETUDE ET DONNEES UTILISEES

II .1 Introduction

Ce chapitre présente la région d'étude ainsi que les données utilisées dans le cadre de cette recherche. Il décrit les principales caractéristiques géographiques, climatiques et hydrologiques du nord de l'Algérie et du bassin versant de la Soummam, ainsi que les stations hydrométriques étudiées. Les différentes données hydrométéorologiques exploitées, leurs sources et les étapes de traitement et de prétraitement appliquées avant la phase de modélisation sont également présentées.

II.2 Situation géographique

Le bassin versant de la Soummam, objet de cette étude, est situé dans le nord de l'Algérie (Figure II.1), une région caractérisée par une importante diversité géographique, climatique et hydrologique. Notre étude se base sur la partie nord de l'Algérie comprise entre les longitudes « 2° et 9° » Est et les latitudes « 33° et 37° » Nord, couvrant une superficie d'environ 365 000 km². Cette région s'étend sur près de 1200 km le long du littoral méditerranéen. Elle est limitée au nord par la mer Méditerranée, à l'ouest par le Maroc, à l'est par la Tunisie et au sud par les flancs nord de l'Atlas saharien. Le nord algérien est dominé par un climat méditerranéen marqué par des hivers humides et des étés chauds et secs, avec une forte influence du relief et des chaînes montagneuses de l'Atlas tellien sur la répartition spatiale des précipitations et des écoulements hydrologiques.

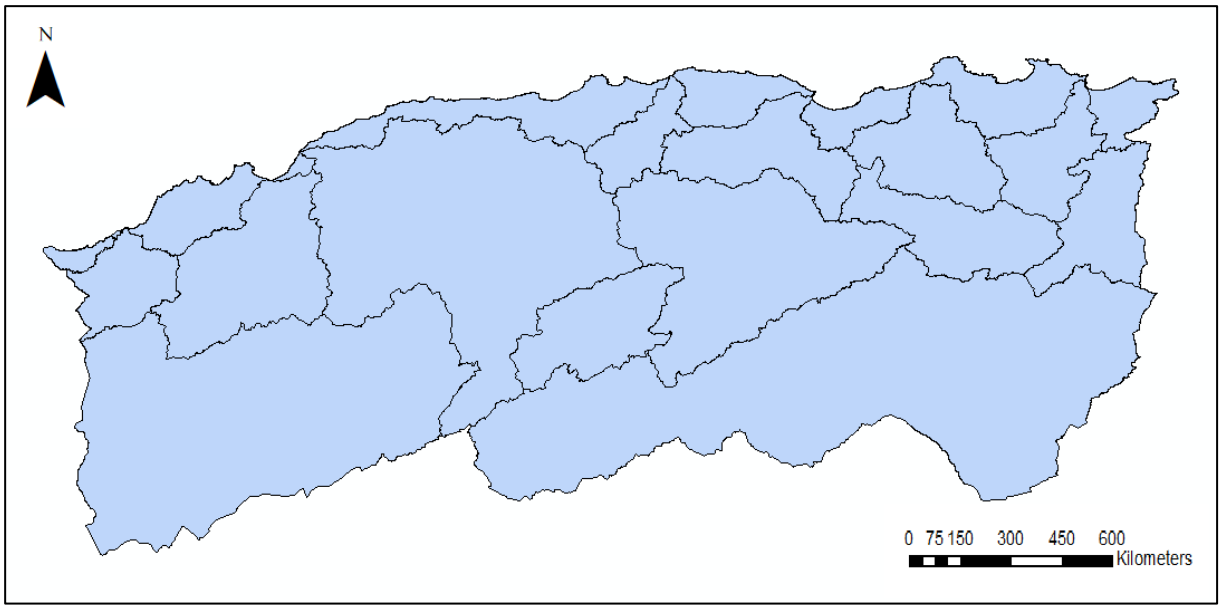


Figure II.1. Situation géographique de la région d'étude dans le nord algérien

II.3 Aperçu topographique

Le relief du nord algérien résulte de l'évolution géologique et de l'action de l'érosion durant plusieurs périodes géologiques. Cette région est généralement subdivisée en trois grands ensembles morphologiques : le Tell au nord, les Hauts Plateaux au centre et l'Atlas saharien au sud. Le Tell constitue une bande côtière étroite, s'étendant sur environ 1200 km le long du littoral méditerranéen, caractérisée par des plaines fertiles, des vallées et des chaînes montagneuses appartenant à l'Atlas tellien. Les Hauts Plateaux représentent une vaste zone semi-aride composée de plaines et de dépressions internes appelées « chotts », tandis que l'Atlas saharien forme une barrière montagneuse marquant la transition vers le Sahara. Cette diversité topographique influence fortement la répartition des précipitations, les écoulements hydrologiques et la dynamique des bassins versants dans le nord de l'Algérie (Bellout, 2015).

II.4 Aspect climatique

Le climat du nord de l'Algérie est principalement de type méditerranéen avec une influence continentale liée au relief et à l'altitude. Il se caractérise par des hivers humides et relativement froids ainsi que des étés chauds et secs. La saison sèche estivale varie généralement de trois à six mois selon les régions. Les précipitations sont plus importantes dans les zones côtières et montagneuses et diminuent progressivement vers les Hauts Plateaux et les régions intérieures. Le climat du nord algérien est fortement influencé par la mer Méditerranée,

les chaînes montagneuses de l'Atlas tellien ainsi que les masses d'air humides provenant du nord et du nord-ouest. Selon Meddi et Toumi (2015), les perturbations atmosphériques d'origine méditerranéenne jouent un rôle majeur dans la distribution des précipitations sur le nord algérien.

II.5 Végétation, couverture végétale et sols

La végétation du nord algérien est caractérisée par une grande diversité liée aux variations climatiques et topographiques. Les zones humides et montagneuses présentent principalement des formations forestières composées de chênes, de pins et de maquis méditerranéens, tandis que les zones semi-arides sont dominées par une végétation steppique plus clairsemée. Dans plusieurs régions, les plaines alluviales sont largement exploitées pour l'agriculture, notamment les cultures céréalières, les oliveraies et les vergers. Les sols reflètent également l'influence du climat, du relief et de la nature géologique des terrains. On distingue principalement des sols calcaires et des sols non calcaires, incluant des sols podzoliques présents dans les régions humides du nord de l'Algérie. La dégradation du couvert végétal observée dans certaines zones est principalement liée aux incendies, au surpâturage et à l'expansion des activités agricoles, ce qui accentue les phénomènes d'érosion et de ruissellement (Duchaufour, 1975).

II.6 Caractéristiques générales du bassin de la Soummam

II.6.1 Situation géographique

Le bassin versant de la Soummam est localisé dans la partie nord de l'Algérie et constitue l'un des principaux bassins hydrographiques du nord algérien. Il couvre une superficie d'environ 9125 km² et s'étend entre les méridiens 3°38' et 5°38' Est et les parallèles 35°45' et 36°45' Nord (Figure I.2). Le bassin débouche sur la mer Méditerranée au niveau du golfe de Béjaïa et présente une position stratégique entre les zones littorales humides et les régions intérieures semi-arides.

Le bassin de la Soummam est limité au nord par les chaînes montagneuses du Djurdjura et leurs prolongements vers la Méditerranée, au sud par les contreforts du Hodna, à l'est par les chaînes des Babors et les hauts plateaux de Sétif, et à l'ouest par le plateau de Bouira. Cette configuration géographique confère au bassin une grande diversité morphologique et climatique influençant directement le comportement hydrologique de la région.

Le réseau hydrographique du bassin est très développé et structuré autour de l'oued Soummam, principal cours d'eau du bassin, formé par la confluence de l'oued Sahel à l'ouest et de l'oued Boussellam à l'est. Ces deux oueds se rejoignent au niveau de la région d'Akbou avant de se jeter dans la Méditerranée. Le bassin compte plusieurs sous-bassins et un réseau hydrographique dense totalisant environ 726 km de cours d'eau.

Par ailleurs, le bassin versant de la Soummam possède d'importantes potentialités hydriques, aussi bien en eaux superficielles qu'en eaux souterraines. Selon l'Agence des Bassins Hydrographiques (ABH), les ressources en eau du bassin sont estimées à près de 837 Hm³, dont 684 Hm³ d'eaux superficielles et 153 Hm³ d'eaux souterraines, ce qui souligne l'importance stratégique de cette région pour les activités agricoles et le développement socio-économique du nord algérien.

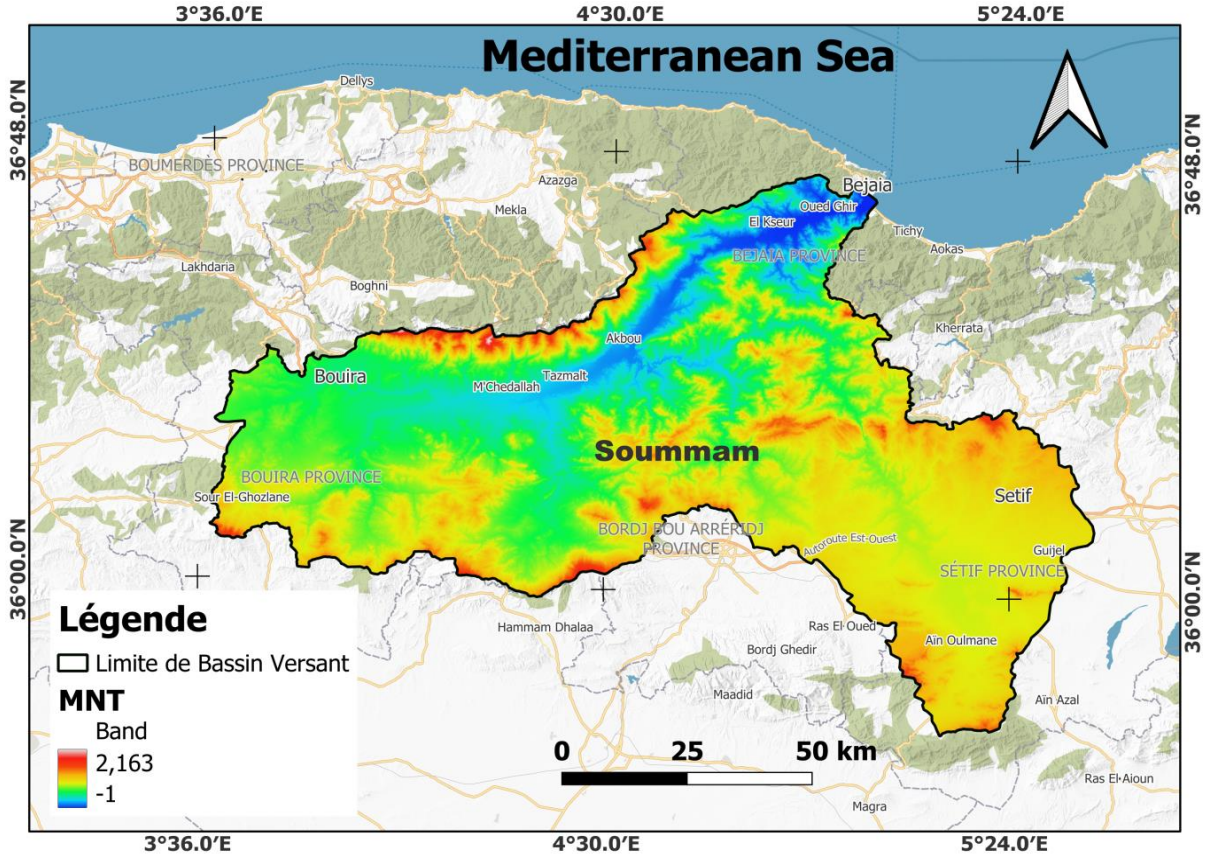


Figure I.2. Situation géographique du bassin versant de la Soummam en Algérie

II.6.2 Sous-bassins sélectionnés

Dans le cadre de cette étude, deux sous-bassins versants appartenant au bassin de la Soummam ont été sélectionnés afin d'analyser la relation pluie-débit et d'évaluer les performances des modèles de deep learning appliqués à la prévision hydrologique. Le choix

des stations de FERMATOU et BOU BIREK repose principalement sur la disponibilité et la qualité des données hydrométéorologiques, ainsi que sur leur importance hydrologique au sein du bassin du Bou Sellam. Ces deux stations présentent des caractéristiques physiographiques et climatiques différentes, permettant ainsi d'évaluer la robustesse des modèles dans des contextes hydrologiques variés.

a) Sous-bassin de FERMATOU

Le sous-bassin de FERMATOU appartient au bassin versant du Bou Sellam et correspond à la station hydrométrique codée 150601. Il est localisé dans la partie nord-est du bassin de la Soummam, au niveau de la wilaya de Sétif. Ce sous-bassin présente une altitude variant entre environ 846 m et 1701 m, avec un relief relativement montagneux dominé par des zones de moyenne altitude. Le réseau hydrographique y est influencé principalement par les précipitations saisonnières méditerranéennes, ce qui engendre une forte variabilité des écoulements durant les périodes humides. La station de FERMATOU occupe une position stratégique pour le suivi hydrologique de l'oued Bou Sellam et constitue une zone importante pour l'analyse pluie-débit dans le bassin de la Soummam (Figure I.3).

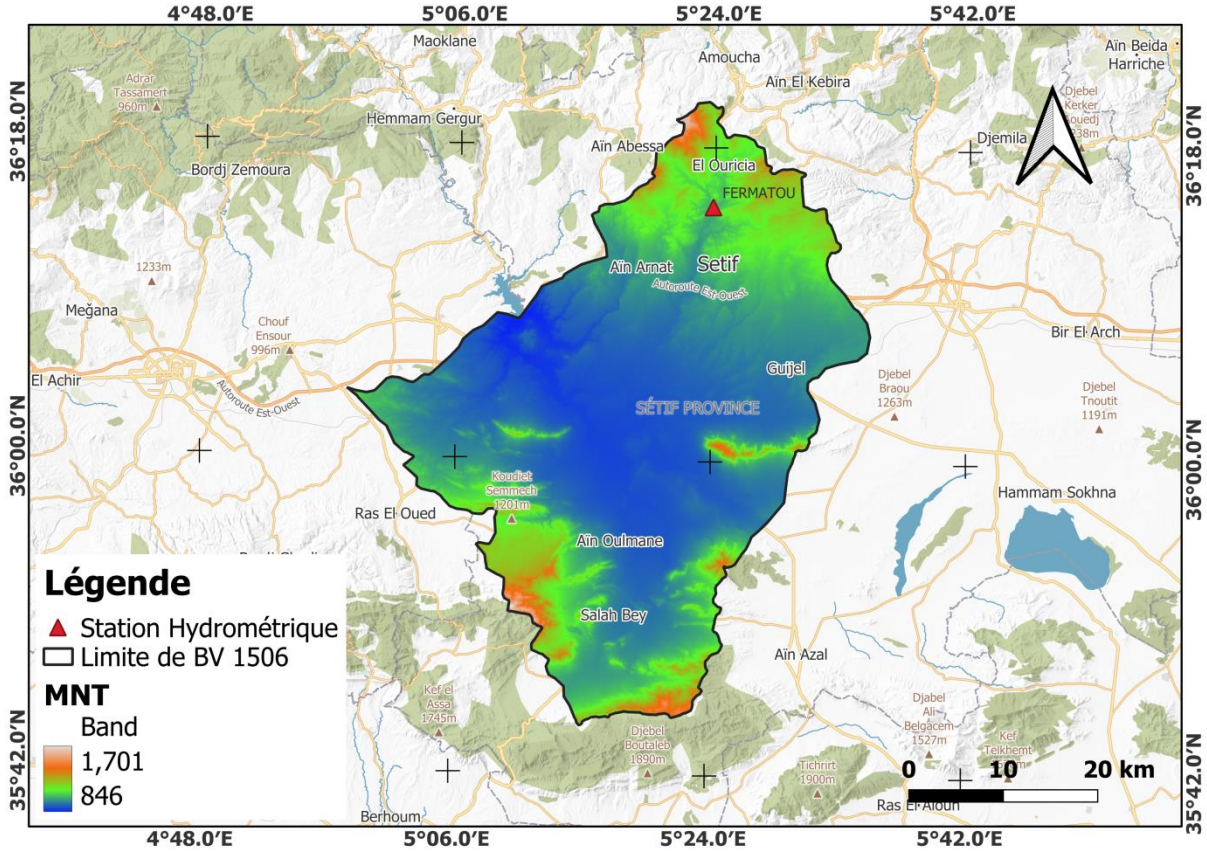


Figure II.3. Carte du sous-bassin versant de FERMATOU

b) Sous-bassin de BOU BIREK

Le sous-bassin de BOU BIREK, associé à la station hydrométrique codée 150703, est également situé dans le bassin du Bou Sellam, au nord-est du bassin versant de la Soummam. Ce sous-bassin se caractérise par un relief plus contrasté, avec des altitudes comprises entre environ 289 m et 1689 m. Il présente une topographie variée dominée par des zones montagneuses et des vallées relativement encaissées influençant directement les écoulements de surface. La station de BOU BIREK est localisée dans une région hydrologiquement active où les précipitations et les caractéristiques morphologiques jouent un rôle important dans la dynamique des débits observés. Ce sous-bassin représente ainsi une zone d'étude pertinente pour l'évaluation des modèles hydrologiques développés dans cette recherche (Figure II.4).

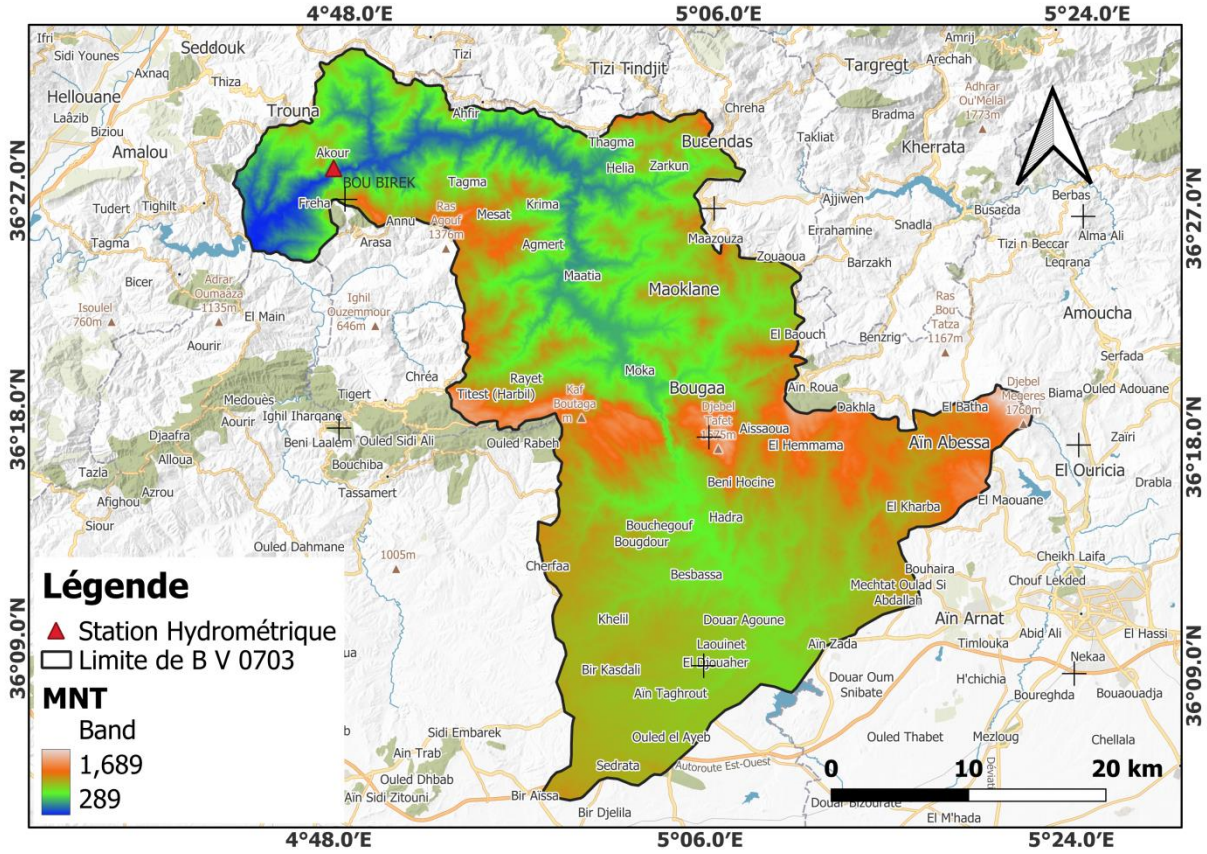

4°48.0'E
5°06.0'E
5°24.0'E
36°27.0'N
36°18.0'N
36°09.0'N
Légende
Station Hydrométrique
Limite de B V 0703
MNT
Band
1,689
289
0
10
20 km
BOU BIREK
Trouna
Hellouane
Amalou
Seddouk
Tizi Tindjit
Targregt
Kherrata
Bucendas
Maaouklane
Bougaa
Aïn Abessa
El Ouricia
Amoucha
Aïn Arnat
Ain Taghrout
Bir Kasdali
Ouled Dahmane
Tassamert
Bouchiba
Ouled Rabeh
Ouled Sidi Ali
Beni Laalem
Tigert
Chréa
Titest (Harbil)
Aïn Roua
Aïssaoua
El Hemmama
Beni Hocine
El Kharba
Hadra
Bouchegouf
Bougdour
Besbassa
Cherfaa
Khelil
Douar Agoune
Laouinet
Aïn Zada
Timlouka
Douar Oum Snibate
Ouled el Ayeb
Sedrata
Bir Aïssa
Bir Djelila
Ouled Thabet
Mezloug
Chellala
Boureghda
Bouaouadja
Nekaa
H'chichia
Abid Ali
El Hassi
Cheikh Laifa
Chouf Lekded
Bouhaira
Mechtat Oulad Si Abdallah
El Maouane
Drabla
Zairi
Serfada
Ouled Adouane
Biama
Djebel Megeres 1760m
El Batha
Dakhla
Ain Roua
Benzrig
El Baouch
Zouaoua
Barzakh
Maazouza
Errahamine
Snadla
Ajiwen
Busaada
Berbas
Alma Ali
Tizi n Beccar
Leqrana
Takliat
Bradma
Chreha
Thagma
Helia
Zarkun
Akour
Tagma
Krima
Mesat
Agmert
Maatia
Arasa
Annu
Frèha
Ras Agouf 1376m
Tudert
Tighilt
Bicer
Adrar Oumaaza 1135m
El Main
Aourir
Ighil Ouzemmour 646m
Isoulel 760m
Ighil Iharqane
Djaafra
Alloua
Tazla
Afighou
Azrou
Siour
Medouès
Ouled Brahim
Ouled Ali Ben Ali
Ouled Ali Ben Ali
Ouled Ali Ben Ali

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

Sous-bassin	Code station	Oued	S (km^2)	P (km)	Ic	L (km)	Hmoy (m)	Dd (km/km^2)	Ct
FERMATOU	150601	Bou Sellam	105	60	1.09	18	1205	2.94	18
BOU BIREK	150703	Bou Sellam	2960	250	1.28	144	1100	—	—

II.7 Données utilisées

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.

II.7.1 Collecte des données

Dans le cadre de cette étude, trois types principaux de données ont été collectés : hydrométriques et pluviométriques, toutes enregistrées à une résolution journalière, afin de permettre la modélisation du débit journalier en lien avec les précipitations.

La phase de collecte et de traitement des données constitue l'une des étapes les plus délicates et exigeantes en hydrologie. Les données hydrométriques exploitées proviennent de la banque de données de l'Agence Nationale des Ressources Hydrauliques (ANRH), dont les enregistrements sont organisés selon l'année hydrologique, allant du 1er septembre au 31 août. La sélection des stations hydrométriques et pluviométriques utilisées dans ce travail repose sur des critères stricts de qualité, d'homogénéité et de disponibilité des séries sur des périodes récentes et communes. Le traitement initial des séries nécessite un travail de mise en forme et d'harmonisation, souvent long et complexe, compte tenu de la diversité et de la structure des bases de données informatisées de l'ANRH.

La plupart des séries disponibles sont incomplètes, parfois de courte durée, et présentent des lacunes ou des valeurs aberrantes. Un traitement statistique préalable s'avère donc indispensable pour le comblement des données manquantes, la détection des valeurs anormales et l'homogénéisation des séries, en vue d'assurer la fiabilité des résultats de modélisation.

II.7.2 Stations sélectionnées

À l'issue d'un processus rigoureux de traitement et de validation des données, incluant notamment le comblement des lacunes et la vérification de la cohérence temporelle, un ensemble de stations a été retenu pour cette étude. Ces stations sont répertoriées dans le tableau Pour assurer une couverture spatiale et fonctionnelle optimale au sein de chaque sous-bassin étudié, deux types de stations ont été sélectionnés :

- Une station pluviométrique,
- Une station hydrométrique,

Cette configuration permet de disposer, pour chaque secteur, de l'ensemble des paramètres nécessaires à la modélisation pluie-débit à l'échelle journalière.

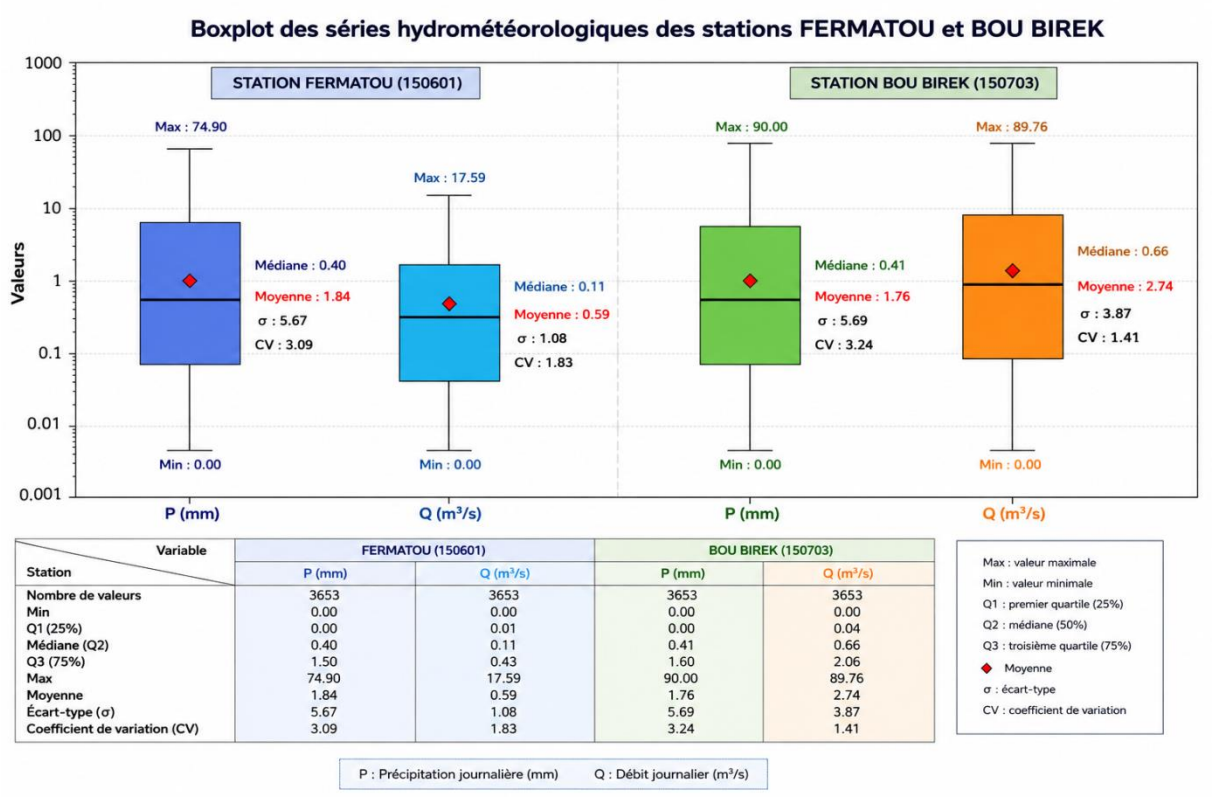
Tableau II.2 : **Stations choisies dans cette étude *(Sources : ANRH, 2021)***

Nom de la station hydrométrique	Code station hydrométrique	Station pluviométrique	Période d'étude
FERMATOU	150601	150601	2002–2012
BOU BIREK	150703	150710	2002–2012

II.7.3 Caractéristiques statistiques des séries

L'analyse statistique descriptive des séries hydrométéorologiques constitue une étape importante dans l'étude des données avant la phase de modélisation. Elle permet d'évaluer la variabilité, la dispersion ainsi que le comportement général des précipitations et des débits observés au niveau des stations étudiées. Les principaux paramètres statistiques retenus dans cette étude sont la moyenne, le minimum, le maximum, l'écart-type ainsi que le coefficient de variation. Ces indicateurs permettent de mieux comprendre la dynamique hydrologique des sous-bassins étudiés et d'identifier la variabilité des séries temporelles utilisées dans la modélisation pluie-débit.

La figure II.5 représentent les caractéristiques statistiques des séries collectées pas de temps journalier.



Variable / Station	FERMATOU (150601) P (mm)	FERMATOU (150601) Q (m³/s)	BOU BIREK (150703) P (mm)	BOU BIREK (150703) Q (m³/s)
Nombre de valeurs	3653	3653	3653	3653
Min	0.00	0.00	0.00	0.00
Q1 (25%)	0.00	0.01	0.00	0.04
Médiane (Q2)	0.40	0.11	0.41	0.66
Q3 (75%)	1.50	0.43	1.60	2.06
Max	74.90	17.59	90.00	89.76
Moyenne	1.84	0.59	1.76	2.74
Écart-type (σ)	5.67	1.08	5.69	3.87
Coefficient de variation (CV)	3.09	1.83	3.24	1.41

Figure II.5. Boxplots des séries de précipitations et de débits des stations FERMATOU et BOU BIREK avec les principaux paramètres statistiques

Les résultats montrent une forte variabilité des séries hydrométéorologiques au niveau des deux stations étudiées. Les coefficients de variation élevés observés pour les précipitations traduisent l'irrégularité temporelle des épisodes pluvieux caractéristiques des régions méditerranéennes semi-arides. Par ailleurs, les débits enregistrés à la station de BOU BIREK présentent des valeurs maximales plus importantes que celles observées à FERMATOU, ce qui reflète l'influence des caractéristiques morphologiques et hydrologiques propres à chaque sous-bassin.

La sélection des variables d'entrée pertinentes pour la modélisation pluie-débit repose en grande partie sur l'analyse des relations temporelles entre les variables climatiques (pluie, évapotranspiration) et la variable cible (débit). Pour ce faire, trois outils statistiques ont été mobilisés : l'auto-corrélation (ACF), l'auto-corrélation partielle (PACF) et la corrélation croisée (XCF ou CCF).

- ACF (Auto-Correlation Function) : Elle mesure la corrélation entre une variable et ses propres valeurs passées. Elle permet d'identifier les lags (décalages temporels) les plus influents dans une série temporelle, comme les valeurs passées du débit pouvant expliquer sa valeur actuelle.
- PACF (Partial Auto-Correlation Function) : Elle complète l'ACF en évaluant la corrélation entre une variable et ses *lags* en éliminant l'effet des *lags* intermédiaires. Cela aide à repérer les valeurs vraiment indépendantes qui ont un impact direct sur la variable cible.
- XCF ou CCF (Cross-Correlation Function) : Elle mesure la corrélation entre deux séries temporelles décalées dans le temps. Cette fonction est utilisée pour évaluer la relation entre les précipitations et le débit observé à différentes échelles de temps. Elle permet ainsi de déterminer combien de jours après une pluie (par exemple) un effet sur le débit est observé.

Grâce à ces analyses, les décalages temporels optimaux ont été identifiés pour chaque variable, ce qui permet de construire une structure d'entrée efficace pour le modèle. Typiquement, les valeurs de pluie, de débit aux temps t-1, t-2 et t-3 ont montré une influence significative sur le débit journalier, et ont donc été retenues comme variables d'entrée.

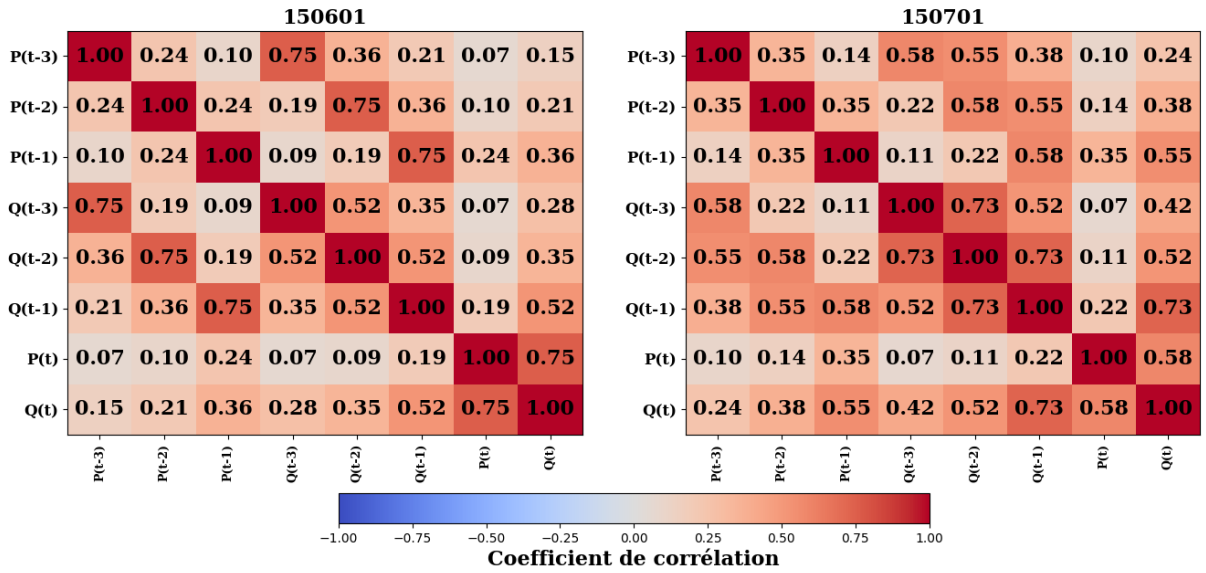


Figure II.6. Matrices de corrélation entre les variables climatiques et hydrologiques pour les stations

Tableau II.3 : Les combinaisons entrées pour différents modèles

Combinaison d'entrée	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), P(t)	Q(t)
P(t)	Q(t)

II.8 Conclusion

Ce chapitre a présenté les principales caractéristiques physiques et hydrologiques du bassin de la soummam, ainsi que les sous-bassins retenus pour l'étude. Il a également décrit le processus de collecte, de traitement et de sélection des données nécessaires à la modélisation. Enfin, les variables d'entrée ont été choisies à l'aide d'analyses statistiques (ACF, PACF, XCF), en vue d'une modélisation efficace dans le chapitre suivant.

CHAPITRE III

MATERIALS ET METHODES

CHAPITRE III : MATERIELS ET METHODES

III.1 Introduction

Ce chapitre décrit la méthodologie adoptée pour la mise en œuvre des modèles d'intelligence artificielle (LSTM, CNN, GRU, LSTM-CNN, BiLSTM, BiGRU) appliqués à la prédiction du débit journalier. La démarche repose sur une série d'étapes allant de la collecte et la préparation des données à la modélisation, et de l'évaluation des performances des modèles à leur interprétation, notamment à l'aide de la méthode SHAP (Shapley Additive exPlanations). Elle intègre également des outils d'analyse statistique visant à optimiser le choix des variables d'entrée.

III.2 Étapes de mise en œuvre des modèles

La méthodologie adoptée dans cette étude repose sur une succession d'étapes logiques et complémentaires visant à développer des modèles performants de prédiction du débit journalier à partir de variables hydrométéorologiques. Le travail a débuté par la collecte des données issues de deux stations hydrométriques situées dans le bassin versant de la Soummam, incluant les précipitations et les débits journaliers (Figure III.1).

Ces données ont fait l'objet d'un prétraitement rigoureux, comprenant la gestion des valeurs manquantes, la normalisation via la méthode Min-Max Scaling, ainsi que leur division en deux ensembles distincts : un ensemble d'entraînement 70% et un ensemble de validation 30%. Par la suite, une analyse statistique préliminaire a été réalisée à l'aide des fonctions d'autocorrélation (ACF), d'autocorrélation partielle (PACF) et de corrélation croisée (XCF), dans le but d'identifier les retards temporels optimaux à intégrer comme variables d'entrée dans les modèles.

La phase de modélisation consiste en la conception, l'entraînement et la validation de six architectures d'apprentissage profond, à savoir : les réseaux LSTM, GRU, leurs variantes bidirectionnelles (BiLSTM et BiGRU), les réseaux convolutifs (CNN), ainsi qu'un modèle hybride de type LSTM-CNN. Ces modèles ont été implémentés en Python à l'aide des bibliothèques Keras et TensorFlow, avec un ajustement des hyperparamètres basé sur les performances observées sur l'ensemble de validation.

Enfin, les performances des modèles ont été évaluées et comparées à l'aide de plusieurs indicateurs statistiques, notamment la racine de l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE), le coefficient de corrélation (R), l'indice de Nash-Sutcliffe (NSE), ainsi que le coefficient (CA). Une analyse interprétable basée sur la méthode SHAP (SHapley Additive exPlanations) a également été réalisée afin d'évaluer l'influence des variables d'entrée sur les prédictions des modèles. Cette analyse a permis d'apprécier la précision, la robustesse et la capacité des modèles à produire des prévisions fiables, contribuant ainsi à une meilleure compréhension et gestion des ressources en eau.

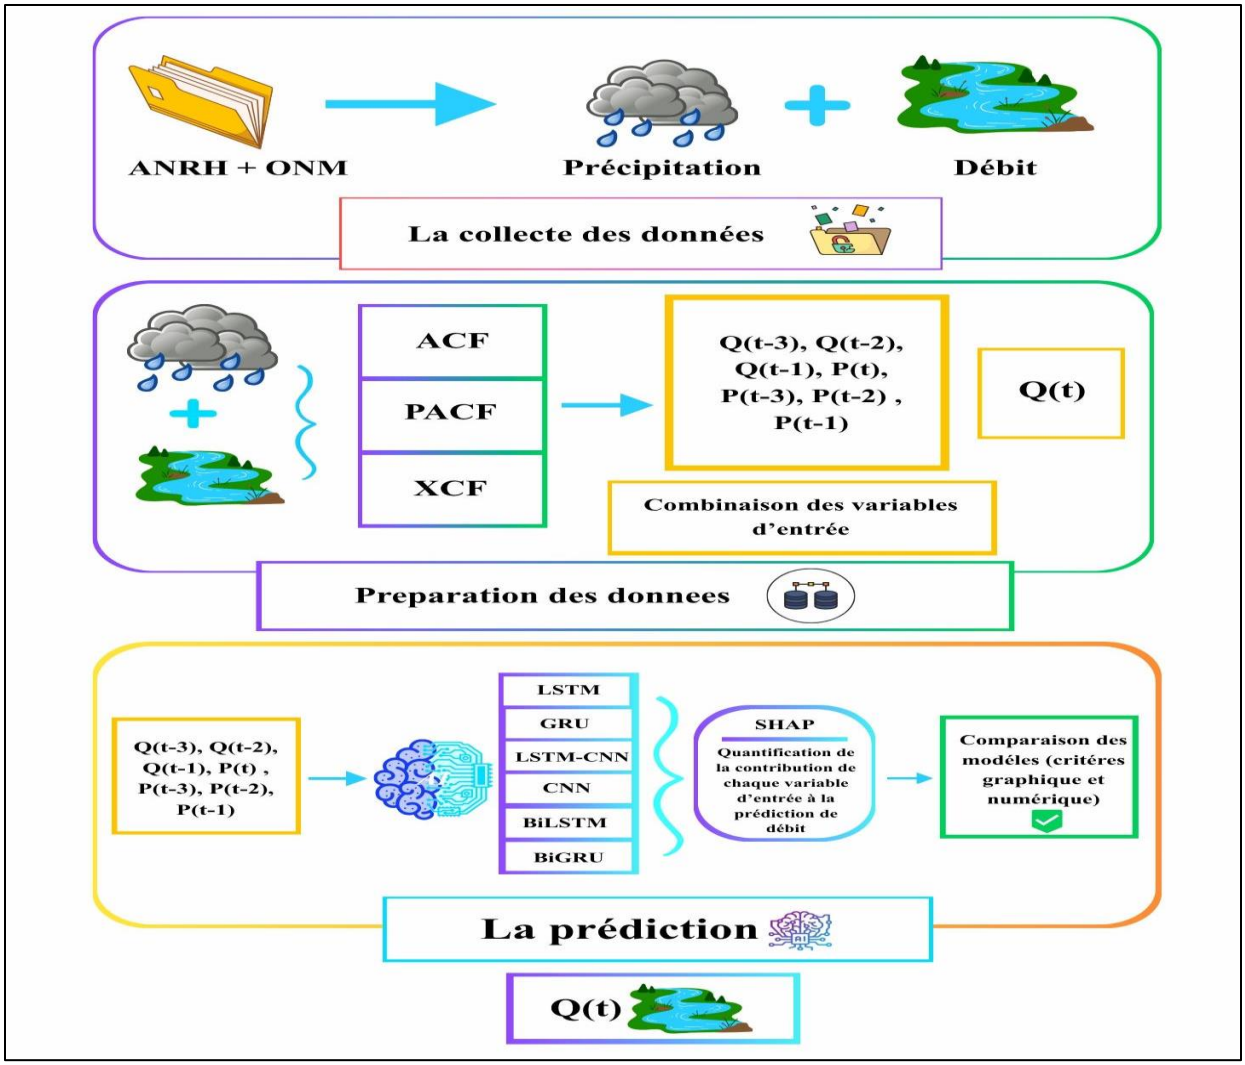


Figure III.1. Schéma de la démarche méthodologique pour la prédiction du débit journalier à l'aide de modèles d'intelligence artificielle

III.3 Modèles d'intelligence artificielle choisis dans cette étude pour la prédiction du débit

Dans le cadre de cette étude, plusieurs modèles d'apprentissage profond ont été utilisés afin de modéliser les relations complexes et non linéaires entre les variables hydrométéorologiques, notamment les précipitations et les débits journaliers. Les architectures retenues comprennent les réseaux de neurones récurrents de type LSTM et GRU, leurs variantes bidirectionnelles (BiLSTM et BiGRU), ainsi que les réseaux de neurones convolutifs (CNN) et un modèle hybride LSTM-CNN.

Ces modèles, issus des avancées récentes en intelligence artificielle, présentent des capacités complémentaires pour l'analyse des séries temporelles hydrologiques, notamment en ce qui concerne la capture des dépendances temporelles et des structures locales des données. Leur comparaison a pour objectif d'identifier l'approche la plus performante pour la prédiction du débit journalier dans un contexte semi-aride, caractérisé par une forte variabilité climatique et une disponibilité limitée des données, tout en intégrant une analyse interprétable basée sur la méthode SHAP (SHapley Additive exPlanations) afin de mieux comprendre l'influence des variables d'entrée sur les prédictions.

III.3.1 Réseau de neurones LSTM (Long Short-Term Memory)

Les réseaux de neurones récurrents classiques (RNN) souffrent du problème de disparition ou d'explosion du gradient lors de l'apprentissage de dépendances à long terme (Hochreiter, 1991, cité dans Hochreiter & Schmidhuber, 1997). Pour y remédier, Hochreiter et Schmidhuber (1997) ont proposé l'architecture **LSTM**, fondée sur une mémoire interne capable de conserver l'information sur de longues séquences temporelles.

Grâce à cette capacité, les **LSTM** sont particulièrement adaptés à la modélisation des processus hydrologiques, caractérisés par des dynamiques non linéaires et des effets de mémoire du bassin versant (Kratzert et al., 2019 ; Shen & Lawson, 2021).

III.3.1.1. Architecture et mécanismes internes

La cellule LSTM est structurée autour d'un **état cellulaire tCtCt,** assurant un flux continu d'information dans le temps (Figure III.2**)**.

Sa mise à jour est contrôlée par trois portes principales (Hochreiter & Schmidhuber, 1997) :

- **Porte d'oubli** : sélectionne les informations à conserver ou supprimer de Ct−1C_{t-1}Ct−1 .
- **Porte d'entrée** : intègre les nouvelles informations via une combinaison sigmoïde– *tanh*
- **Porte de sortie** : génère l'état caché hth_tht à partir de l'état cellulaire

Cette structure permet de capturer des relations temporelles complexes et des décalages hydrologiques, tels que le temps de réponse d'un bassin versant (Lees et al., 2022). En modélisation pluie-débit, les entrées incluent généralement les précipitations, la température et l'évapotranspiration, tandis que la sortie correspond au débit futur.

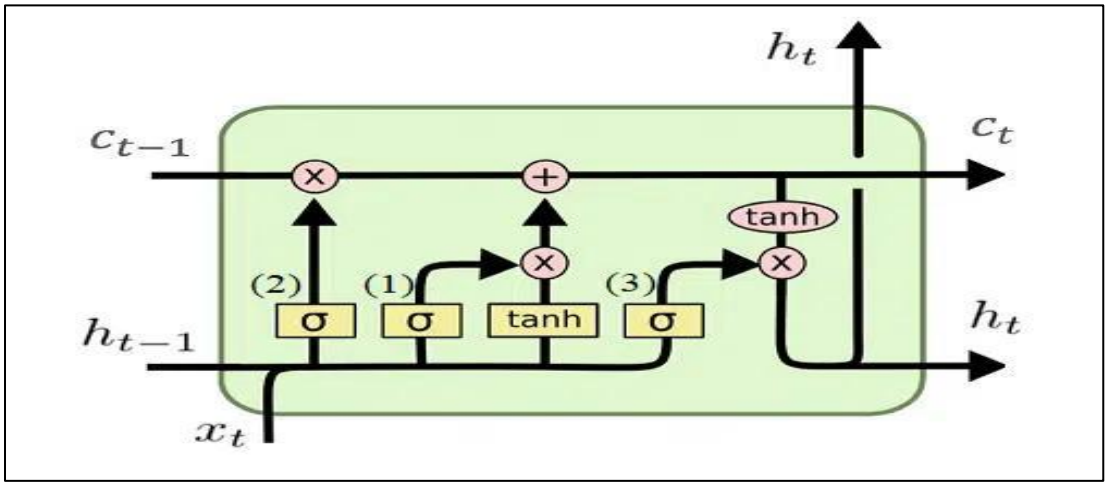


Figure III.2. Structure interne d'une cellule LSTM (Fangming Xue et al., 2026)

III.3.1.2. Avantages et inconvénients du modèle LSTM

Le LSTM se distingue par sa capacité à modéliser des dépendances temporelles longues et des relations non linéaires complexes, ce qui lui permet de surpasser de nombreux modèles hydrologiques traditionnels (Kratzert et al., 2019 ; Shen & Lawson, 2021). Par exemple, Kratzert et al. (2019) rapportent un NSE médian de 0,69, supérieur à celui du modèle SAC-SMA, tandis que ses états internes corrèlent avec des variables physiques comme l'humidité du sol (Lees et al., 2022). Toutefois, ces modèles nécessitent des volumes de données importants et présentent un coût computationnel élevé, étant souvent plus lents que les GRU ou les CNN (Weißenborn et al., 2025). De plus, leur caractère de « boîte noire » limite leur interprétabilité et peut conduire à des corrélations non physiques, ce qui pose des enjeux de robustesse face aux conditions climatiques variables (Bayati et al., 2025)

III.3.2 Réseau de neurones GRU (Gated Recurrent Unit)

Les GRU ont été introduites par Cho et al. (2014) comme une alternative simplifiée aux LSTM, tout en conservant leur capacité à atténuer le problème de disparition du gradient. Initialement développées pour la traduction automatique, elles ont été rapidement adoptées en

hydrologie, où elles présentent des performances comparables, voire supérieures, aux LSTM dans certains cas (Waqas & Humphries, 2024 ; Weißenborn et al., 2025).

Grâce à leur structure allégée, les GRU offrent un compromis efficace entre complexité et capacité d'apprentissage des dépendances temporelles, ce qui les rend adaptées à la modélisation pluie-débit.

III.3.2.1 Architecture et mécanismes internes

L'architecture des GRU repose sur un état caché unique ht contrairement au LSTM qui distingue état cellulaire et état caché. Elle est contrôlée par deux portes principales (Cho et al., 2014) :

- Porte de mise à jour (*update gate*) : régule la part d'information passée à conserver et des nouvelles informations à intégrer
- Porte de réinitialisation (*reset gate***)** : contrôle l'influence de l'état précédent et permet de s'adapter aux variations rapides

Cette simplification réduit le nombre de paramètres d'environ 25 %, améliorant l'efficacité computationnelle et la vitesse d'apprentissage (Waqas & Humphries, 2024). En modélisation pluie-débit, les entrées sont similaires à celles des LSTM, tandis que la sortie correspond au débit simulé (Figure III.3).

III.3.2.2 Avantages et inconvénients du modèle GRU

Le GRU se distingue par sa simplicité et son efficacité computationnelle, permettant des temps d'apprentissage plus rapides tout en conservant des performances proches des LSTM (Weißenborn et al., 2025). Par exemple, Weißenborn et al. (2025) montrent qu'il est nettement plus rapide, avec des écarts de performance inférieurs à 3,9 %. Il est également adapté aux contextes de données limitées grâce à une bonne capacité de généralisation (Waqas & Humphries, 2024), et peut surpasser le LSTM à certaines échelles temporelles, notamment pour des prévisions à moyen terme (Farfán Durán & Cea, 2024). Toutefois, sa structure simplifiée peut limiter la modélisation de dépendances très longues, où le LSTM reste plus performant. Comme les autres modèles profonds, il demeure peu interprétable et sensible aux conditions d'entraînement.

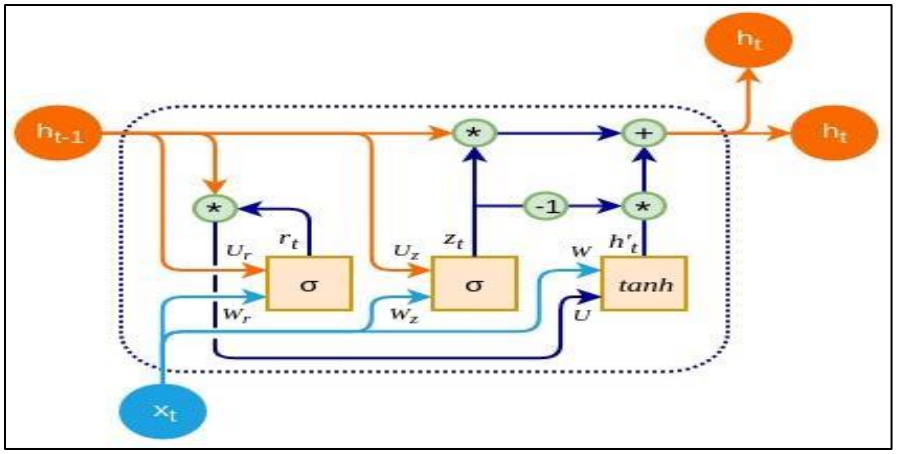


Figure III.3. Architecture interne d'une cellule GRU (Jianghua Liu et al., 2025)

III.3.3 Réseau de neurones convolutifs (CNN)

Les **CNN** ont été initialement développés pour le traitement des images (LeCun et al., 1989), avant de connaître un essor majeur en vision par ordinateur (Krizhevsky et al., 2012). Ils ont ensuite été adaptés aux séries temporelles, notamment en hydrologie, grâce à leur capacité à extraire automatiquement des caractéristiques locales pertinentes (Shen, 2018).

Dans la modélisation pluie-débit, les **CNN** permettent d'identifier des motifs temporels dans les précipitations et autres variables hydrométéorologiques, constituant ainsi une alternative efficace aux approches récurrentes pour la capture de dépendances locales.

III.3.3.1 Architecture et mécanismes internes

Contrairement aux réseaux récurrents, les CNN reposent sur des filtres convolutifs qui glissent le long de l'entrée pour détecter des motifs locaux, avec un partage des poids réduisant le nombre de paramètres (Kiranyaz et al., 2019). Dans les séries temporelles hydrologiques, on utilise principalement des convolutions 1D, où les filtres opèrent sur l'axe temporel pour produire des cartes de caractéristiques (Figure III.4).

Une architecture typique comprend (Shen, 2018 ; Kiranyaz et al., 2019) :

- Couche de convolution 1D : extraction de caractéristiques locales à partir de filtres (2 à 7 pas de temps)

- Fonction d'activation : généralement *ReLU*
- Couche de pooling (optionnelle) : réduction de la dimension temporelle
- Couches fully connected : transformation en sortie prédictive
- Couche de sortie : estimation du débit

Cette structure permet de capturer efficacement des motifs hydrologiques locaux, comme les événements de pluie intense.

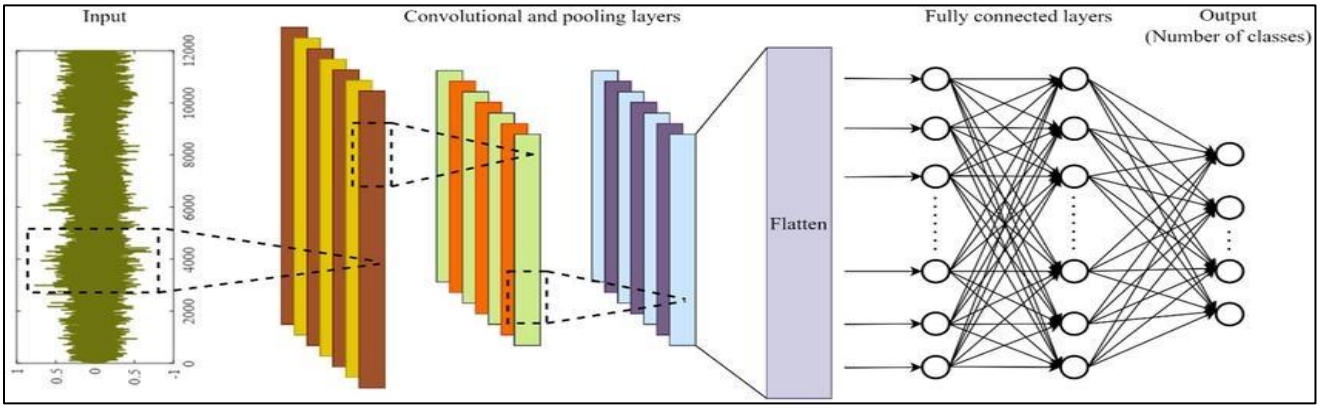


Figure III.4. Architecture typique d'un réseau de neurones convolutif (CNN 1D) pour modélisation de séries temporelles (Viet-Linh Tran et al., 2023)

III.3.3.2 Avantages et inconvénients du modèle CNN

Les CNN offrent une forte efficacité computationnelle grâce à l'absence de récurrence et à leur parallélisation, permettant des temps d'entraînement réduits tout en maintenant des performances proches des LSTM et GRU (Weißenborn et al., 2025 ; Zhao et al., 2019). Ils sont particulièrement adaptés à la détection de motifs locaux, notamment pour la prévision des crues rapides (Ghimire et al., 2021). Cependant, leur principale limite réside dans leur difficulté à capturer des dépendances temporelles longues, importantes pour certains processus hydrologiques (Kiranyaz et al., 2019 ; Shen, 2018). L'augmentation de la profondeur ou de la taille des filtres peut atténuer cette limite, mais augmente le risque de surapprentissage.

III.3.4 Modèle hybride CNN–LSTM

Le modèle CNN–LSTM est une architecture hybride combinant les réseaux de neurones convolutifs (CNN) et les réseaux récurrents de type LSTM, afin de tirer parti de leurs capacités

complémentaires. Les CNN permettent d'extraire des caractéristiques locales pertinentes à partir des séries temporelles, tandis que les LSTM sont capables de modéliser les dépendances temporelles à long terme (Kim & Cho, 2019).

Cette combinaison est particulièrement adaptée à la modélisation pluie-débit, où les processus hydrologiques présentent à la fois des dynamiques rapides liées aux événements pluviométriques et des effets de mémoire du bassin versant.

III.3.4.1 Architecture et mécanismes internes

L'architecture **CNN–LSTM** repose généralement sur une succession de couches convolutionnelles et récurrentes. Les couches de convolution 1D sont utilisées en entrée pour extraire des motifs locaux à partir des variables hydro-climatiques, avec un partage des poids réduisant le nombre de paramètres (Kim & Cho, 2019). Les caractéristiques extraites sont ensuite transmises à des couches LSTM, qui modélisent les dépendances temporelles à long terme (Figure III.5).

Une architecture typique comprend :

- Couches de convolution 1D (extraction des caractéristiques locales),
- Couches de pooling et de dropout (réduction et régularisation),
- Couches LSTM (modélisation temporelle),
- Couches fully connected et couche de sortie (prédiction du débit).

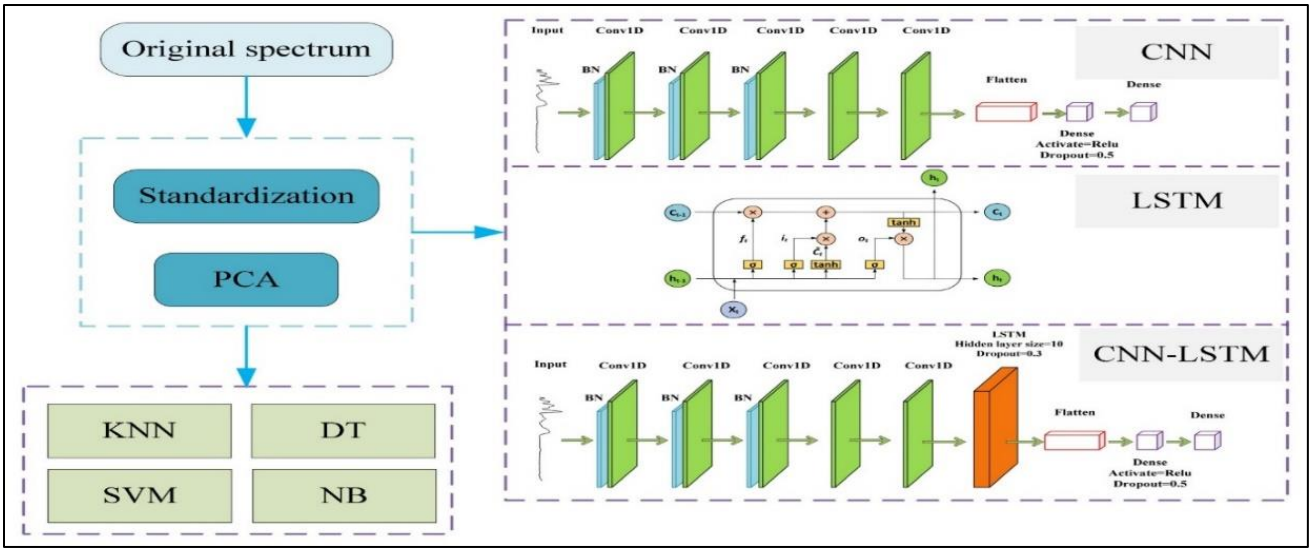


Figure III.5. Architecture hybride CNN-LSTM intégrant l'extraction de caractéristiques et la modélisation temporelle (Zhou et al., 2023)

III.3.4.2 Avantages et inconvénients du modèle CNN–LSTM

Le modèle CNN–LSTM combine les avantages des CNN et des LSTM, permettant une meilleure capture des motifs locaux et des dépendances temporelles, ce qui améliore les performances prédictives par rapport aux modèles individuels (Khosravi et al., 2022). Il est particulièrement efficace pour des séries hydrologiques complexes intégrant des dynamiques multi-échelles. Toutefois, cette hybridation augmente la complexité du modèle, le nombre paramètres et le temps d'entraînement, tout en nécessitant une calibration rigoureuse pour éviter le surapprentissage (Kim & Cho, 2019).

III.3.5 Réseau de neurones BiLSTM (Bidirectional Long Short-Term Memory)

Le BiLSTM est une extension du LSTM proposée par Schuster et Paliwal (1997), permettant de traiter les séquences temporelles dans les deux sens : du passé vers le futur et du futur vers le passé. Cette architecture combine deux réseaux LSTM indépendants, dont les sorties sont fusionnées à chaque pas de temps afin d'exploiter simultanément le contexte passé et futur.

En hydrologie, cette approche permet une meilleure représentation des dynamiques pluie-débit, en intégrant à la fois les conditions antérieures du bassin et l'évolution future de la séquence (Subramaniyam et al., 2025).

III.3.5.1. Architecture et mécanismes internes

Le BiLSTM repose sur deux couches LSTM parallèles :

- une couche **forward** produisant un état caché basé sur les informations passées,
- une couche **backward** produisant un état caché basé sur les informations futures.

Les deux représentations sont ensuite combinées, généralement par concaténation : $ht = [ht; ht]$ (Schuster & Paliwal, 1997).

Cette architecture permet de capturer des dépendances temporelles plus riches et de mieux modéliser les décalages hydrologiques, tels que l'alignement des pics de crue. Toutefois, elle double approximativement le nombre de paramètres par rapport à un LSTM classique (Figure III.6).

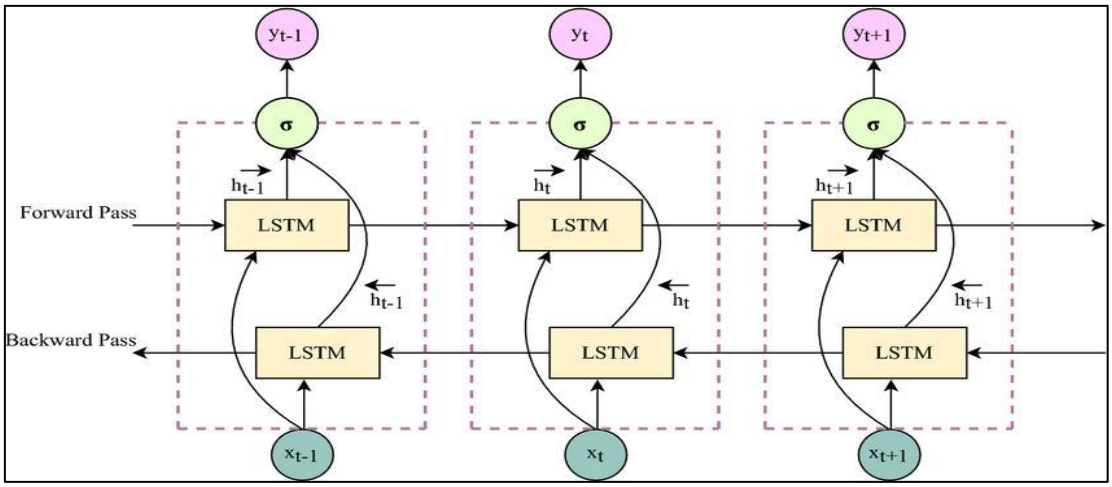


Figure III.6. Illustration de l'architecture d'un réseau BiLSTM (Ruiru Daniel., 2024)

III.3.5.2 Avantages et inconvénients du modèle BiLSTM

Le BiLSTM améliore la capture du contexte temporel en exploitant les informations passées et futures, ce qui peut augmenter significativement la précision des prévisions pluie-débit et réduire les problèmes de décalage temporel (Subramaniyam et al., 2025). Il est particulièrement efficace pour l'alignement des pics de crue et les prévisions à horizon étendu. Cependant, cette architecture est plus coûteuse en calcul et nécessite davantage de données pour l'apprentissage. De plus, son

utilisation reste limitée pour les applications en temps réel, car elle requiert l'accès à l'ensemble de la séquence, y compris les données futures.

III.3.6 Réseau de neurones BiGRU (Bidirectional Gated Recurrent Unit)

Le BiGRU est une extension du GRU basée sur le principe de bidirectionnalité introduit par Schuster et Paliwal (1997). Contrairement au GRU classique, qui traite les séquences du passé vers le futur, le BiGRU combine deux couches GRU : une couche forward et une couche backward, permettant d'exploiter simultanément les informations passées et futures.

En hydrologie, cette architecture améliore la modélisation des relations pluie-débit en intégrant un contexte temporel complet, ce qui est particulièrement utile pour des phénomènes complexes tels que les crues et les phases de décrue.

III.3.6.1 Architecture et mécanismes internes

Le **BiGRU** repose sur deux réseaux GRU parallèles :

- une couche **forward** traitant la séquence dans l'ordre chronologique,
- une couche **backward** traitant la séquence en sens inverse.

Les états cachés issus des deux directions sont ensuite combinés, généralement par concaténation, afin de produire une représentation enrichie à chaque pas de temps (Schuster & Paliwal, 1997).

Cette structure permet de capturer à la fois les dépendances temporelles passées et futures, améliorant ainsi la compréhension des dynamiques hydrologiques. Toutefois, elle entraîne une augmentation du nombre de paramètres et du coût computationnel par rapport au GRU unidirectionnel (Figure III.7).

III.3.6.2. Avantages et inconvénients du modèle BiGRU

Le **BiGRU** offre une meilleure représentation du contexte temporel en combinant les informations passées et futures, ce qui améliore les performances de prédiction du débit, notamment pour des horizons multiples et des séries complexes (Mena, 2024). Il présente

également une efficacité computationnelle supérieure au BiLSTM grâce à une architecture plus légère, avec moins de paramètres à entraîner. Cependant, comme le BiLSTM, il nécessite l'accès à l'ensemble de la séquence, ce qui limite son utilisation pour les prévisions en temps réel.

De plus, l'augmentation de la complexité du modèle peut accroître le risque de surapprentissage et nécessite une calibration rigoureuse.

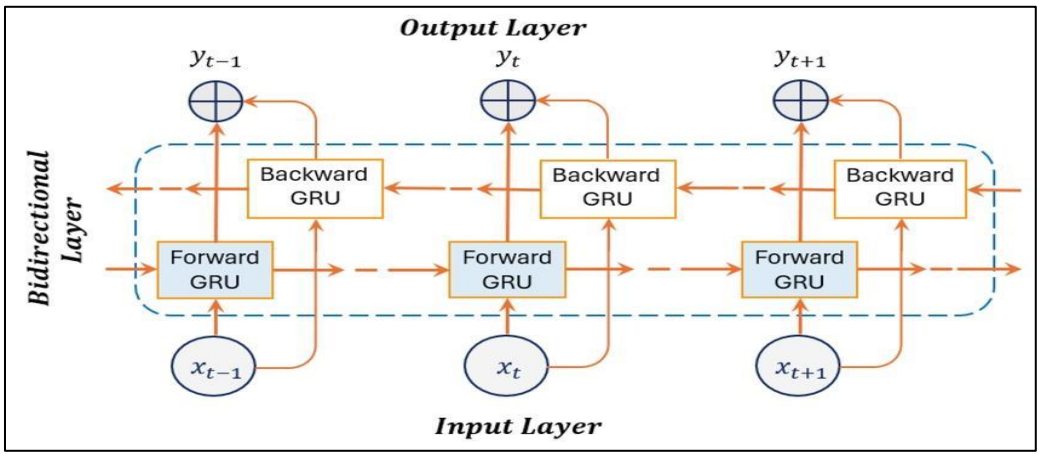


Figure III.7. Illustration de l'architecture d'un réseau BiGRU (Esam Mahdi et al., 2025)

III.4. Méthode d'interprétabilité SHAP (SHapley Additive exPlanations)

La méthode SHAP est une approche d'interprétabilité des modèles d'apprentissage automatique basée sur la théorie des jeux coopératifs (Lundberg & Lee, 2017). Elle permet d'expliquer les prédictions d'un modèle en attribuant à chaque variable d'entrée une contribution quantitative à la sortie.

Dans le contexte hydrologique, SHAP est largement utilisée pour interpréter les modèles de deep learning, notamment les LSTM et les architectures hybrides, en identifiant l'influence des variables hydrométéorologiques (précipitations, température, évapotranspiration) sur les débits simulés.

III.4.1. Principe et mécanisme de fonctionnement

La méthode **SHAP** repose sur les **valeurs de Shapley**, issues de la théorie des jeux, qui mesurent la contribution moyenne marginale d'une variable à la prédiction du modèle (Lundberg

& Lee, 2017). Chaque prédiction est décomposée comme la somme des contributions individuelles des variables, garantissant une interprétation cohérente et additive (Figure III.8).

Formellement, la prédiction d'un modèle peut être exprimée comme :

$$f(x) = \phi 0 + i = 1 \sum n \phi i \qquad \textbf{III.1}$$

où $n\phi$ représente la contribution de la variable iii, et $\phi 0$ a valeur de base du modèle.

Cette approche permet d'analyser à la fois : l'importance globale des variables, et leur influence locale sur chaque prédiction.

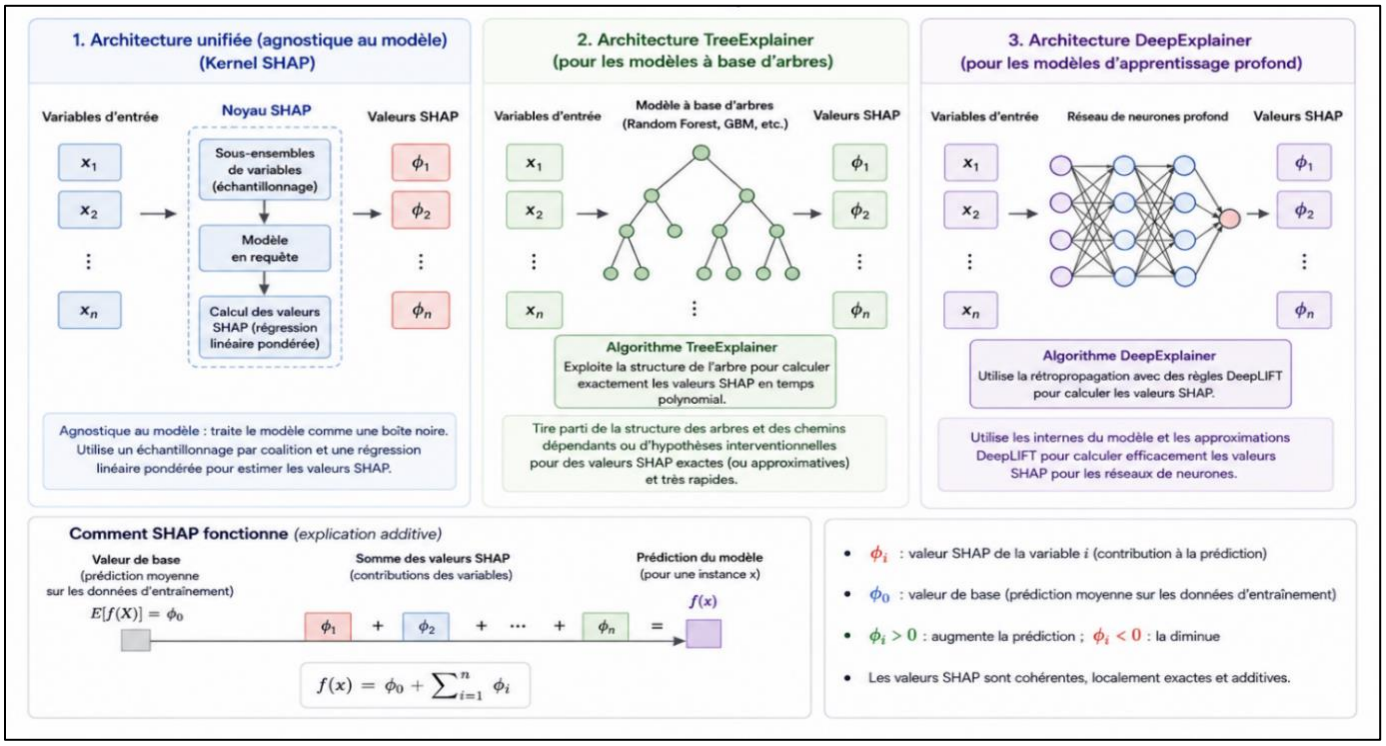


Figure III.8. Illustration de l'architecture d'un SHAP

III.4.2. Avantages et inconvénients de la méthode SHAP

La méthode **SHAP** présente l'avantage d'offrir une interprétation à la fois globale et locale des modèles, tout en reposant sur des fondements théoriques solides garantissant la cohérence des explications (Lundberg & Lee, 2017). Elle est particulièrement utile pour analyser des modèles complexes tels que les réseaux de neurones, en mettant en évidence l'influence relative des variables hydrologiques. Toutefois, son principal inconvénient réside dans son coût

computationnel élevé, notamment pour les modèles profonds et les grands ensembles de données. De plus, l'interprétation des résultats peut devenir complexe lorsque le nombre de variables est important, et les explications restent dépendantes du modèle utilisé.

III.5. Évaluation des performances des modèles

L'évaluation des performances des modèles de prévision constitue une étape essentielle pour juger de leur précision, de leur robustesse et de leur capacité de généralisation. Dans le cadre de cette étude, deux catégories complémentaires de critères ont été mobilisées : les indicateurs numériques (quantitatifs) et les représentations graphiques (visuelles). Ces outils permettent d'avoir une lecture complète des résultats obtenus, en alliant rigueur statistique et interprétation visuelle.

III.5.1. Critères numériques (quantitatifs)

III.5.1.1. Coefficient de corrélation (R)

Est un indicateur statistique qui mesure le degré de relation linéaire entre les débits simulés et observés. Il permet d'évaluer la capacité du modèle à reproduire la dynamique temporelle et les tendances des séries hydrologiques (Moriasi et al., 2007)

$$\boldsymbol{R} = \frac{\sum_{i=1}^{n}(\mathbf{xi}-\mathbf{x}^{-})(\mathbf{yi}-\mathbf{y}^{-})}{\sqrt{\sum_{i=1}^{n}(\mathbf{xi}-\mathbf{x}^{-})^{2}}\sqrt{\sum_{i=1}^{n}(\mathbf{yi}-\mathbf{y}^{-})^{2}}} \qquad \textbf{III.2}$$

Interprétation : le coefficient R varie entre (-1) et 1, où une valeur proche de 1 indique une forte corrélation positive et une bonne reproduction des variations temporelles. En pratique, ($R > 0.8$) traduit une très bonne performance, ($0.6 < R \leq 0.8$) une performance acceptable, tandis que ($R \leq 0.6$) indique une corrélation faible entre les valeurs simulées et observées.

III.5.1.2. Coefficient d'efficacité de Nash–Sutcliffe (NSE)

Est un indicateur largement utilisé en hydrologie pour évaluer la performance des modèles en comparant les erreurs de simulation à la variabilité des observations (Nash & Sutcliffe, 1970).

Il mesure la capacité du modèle à reproduire les débits observés en se basant sur les écarts quadratiques entre valeurs simulées et observées.

$$\boldsymbol{NSE = 1 - \frac{\sum_{i=1}^{n}(Qobs,i - Qsim,i)}{\sum_{i=1}^{n}(Qobs,i - \bar{Q}obs,i)}} \qquad \textbf{III.3}$$

Interprétation : le **NSE** varie de $-\infty$ à 1, avec une valeur optimale de 1 indiquant une concordance parfaite. En pratique, (NSE > 0.75) traduit une très bonne performance, $(0.5 < \text{NSE} \leq 0.75)$ une performance satisfaisante, tandis que $(\text{NSE} \leq 0.5)$ indique une faible capacité du modèle à reproduire les observations.

III.5.1.3. Coefficient de Kling–Gupta (KGE)

Est un indicateur de performance hydrologique introduit pour fournir une évaluation plus équilibrée que le NSE en intégrant simultanément trois composantes : la corrélation (R), le biais (rapport des moyennes) et la variabilité (rapport des écarts-types) (Gupta et al., 2009). Il mesure ainsi la capacité du modèle à reproduire à la fois la dynamique, le volume et la dispersion des débits simulés.

$$\boldsymbol{KGE = 1 - \sqrt{(r-1)^2 + (\alpha - 1)^2 + (\beta - 1)^2}} \qquad \textbf{III.4}$$

Interprétation : KGE varie de $-\infty$ à 1, avec une valeur optimale de 1 correspondant à une concordance parfaite. En pratique, (KGE > 0.75) indique une très bonne performance, $(0.5 < \text{KGE} \leq 0.75)$une performance satisfaisante, tandis que $(\text{KGE} \leq 0.5)$reflète des limitations importantes du modèle.

III.5.1.4. L'erreur quadratique moyenne (RMSE)

Est un indicateur statistique qui mesure l'écart global entre les débits simulés et observés en donnant un poids plus important aux erreurs élevées en raison de leur mise au carré (Chai & Draxler, 2014). Elle permet d'évaluer la précision du modèle, notamment sa capacité à reproduire les valeurs extrêmes et les pics de débit.

$$\boldsymbol{RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Qsim,i - Qobs,i)^2}} \qquad \textbf{III.5}$$

Interprétation : le RMSE est toujours positif et sa valeur optimale est 0, indiquant une concordance parfaite. Plus le RMSE est faible, meilleure est la performance du modèle ; à l'inverse, des valeurs élevées traduisent des écarts importants entre simulations et observations. Son interprétation dépend toutefois de l'échelle des données étudiées.

III.5.1.5. L'erreur absolue moyenne (MAE)

Est un indicateur statistique qui mesure la moyenne des écarts absolus entre les débits simulés et observés, sans accentuer les grandes erreurs (Hyndman & Koehler, 2006). Elle fournit une estimation directe et robuste de l'erreur moyenne du modèle, moins sensible aux valeurs extrêmes que le RMSE.

$$\boldsymbol{MAE = \frac{1}{n}\sum_{i=1}^{n}|Qsim,i - Qobs,i|} \qquad \textbf{III.6}$$

Interprétation : le MAE est toujours positif et sa valeur optimale est 0, indiquant une concordance parfaite. Plus le MAE est faible, meilleure est la performance du modèle ; des valeurs élevées traduisent une erreur moyenne importante entre simulations et observations. Son interprétation reste dépendante de l'échelle des données.

III.5.1.6. Critère de sélection des modèles CA (*Critère d'Acceptabilité* ou *Comparative Assessment*)

En complément des indicateurs classiques d'évaluation des performances, certains travaux récents ont proposé des critères synthétiques visant à faciliter la sélection du modèle optimal parmi plusieurs alternatives. Dans ce cadre, le critère noté **CA** (*Critère d'Acceptabilité* ou *Comparative Assessment*) a été utilisé dans certaines études pour établir un classement global des modèles en combinant plusieurs indicateurs de performance (Adnan et al., 2019).

Le principe de ce critère repose sur une approche comparative, dans laquelle les modèles sont évalués simultanément selon plusieurs métriques statistiques telles que le RMSE, le MAE, le coefficient de corrélation (R) et l'indice de Nash–Sutcliffe (NSE). Chaque modèle est alors classé en fonction de ses performances relatives pour chaque indicateur, permettant ainsi d'obtenir une vision globale de sa robustesse.

Contrairement aux indicateurs classiques qui évaluent un aspect spécifique de la performance, le critère CA vise à fournir une évaluation synthétique en intégrant plusieurs dimensions, notamment la précision, la variabilité et la corrélation. Cette approche permet de réduire les biais liés à l'utilisation d'un seul indicateur et facilite la prise de décision dans le choix du modèle le plus performant.

$$\boldsymbol{CA = 0.33 \times \left(RMSE + MAE + (1 - R^2)\right)} \qquad \textbf{III.7}$$

Interprétation:

Le critère **CA** ne possède pas de valeur absolue universelle, mais s'interprète de manière relative. Le modèle présentant les meilleures performances globales (par exemple, les plus faibles erreurs et les plus fortes corrélations) est considéré comme le plus approprié. Ainsi, ce critère est utilisé comme un outil d'aide à la décision pour identifier le modèle offrant le meilleur compromis entre précision et robustesse.

III.5.2. Critères graphiques de visualisation des résultats

En complément des indicateurs numériques, plusieurs représentations graphiques ont été mobilisées afin d'analyser visuellement les performances des modèles et de mieux interpréter leurs comportements. Le nuage de points (*scatter plot*) permet de comparer directement les valeurs observées et prédites à travers une ligne de référence $\boldsymbol{y = xy = xy = x}$, utile pour détecter les biais systématiques ou les écarts importants.

Les *box plots* et *violin plots* ont été utilisés pour illustrer la distribution des erreurs ou des valeurs simulées par chaque modèle, en mettant en évidence la dispersion, la symétrie ou la présence de valeurs aberrantes. Les courbes de variation temporelle permettent de suivre l'évolution conjointe des débits simulés et observés au fil du temps, offrant une vue directe sur la capacité du modèle à reproduire les dynamiques hydrologiques, notamment lors des crues ou des étiages.

Le *barplot* a servi à comparer visuellement les scores des différents indicateurs de performance (NSE, RMSE, KGE, etc.) entre les modèles, facilitant l'identification du modèle le plus performant selon chaque critère. La carte thermique (*heatmap*) a été utilisée pour synthétiser

les résultats sous forme matricielle, en représentant les performances de chaque modèle selon les stations ou les variables, ce qui facilite une analyse croisée des résultats.

Enfin, le diagramme de Taylor offre une visualisation synthétique très utile en hydrologie, combinant dans un seul graphique le coefficient de corrélation, l'écart-type et l'erreur quadratique normalisée, permettant une comparaison simultanée et intuitive de l'ensemble des modèles testés.

En complément de ces outils, une analyse interprétable basée sur SHAP (SHapley Additive exPlanations) a été utilisée afin d'expliquer l'importance des variables d'entrée dans les prédictions des modèles d'apprentissage profond. Les graphiques SHAP, notamment les *summary plots* et les pie charts SHAP, permettent de quantifier et de représenter visuellement la contribution relative de chaque variable (par exemple les précipitations et les débits retardés) dans les décisions du modèle. Le diagramme circulaire SHAP met en évidence la part d'influence de chaque variable sous forme de proportions, facilitant ainsi une interprétation globale et intuitive des mécanismes internes du modèle.

L'utilisation combinée de ces outils graphiques et interprétables vient ainsi enrichir l'évaluation globale, en confirmant ou en nuançant les résultats numériques par des tendances visuelles et explicatives claires.

III.6. Outils et logiciels utilisés

La réalisation de ce travail s'est appuyée sur une combinaison de logiciels et d'environnements de développement, choisis en fonction des besoins spécifiques liés à la gestion, au traitement, à la modélisation et à la visualisation des données hydrologiques (Figure III.9). Pour la programmation et le développement des modèles d'intelligence artificielle (LSTM, GRU, CNN et leurs variantes bidirectionnelles et hybrides), le langage Python a été utilisé en raison de sa flexibilité, de sa richesse en bibliothèques scientifiques et de son large usage dans le domaine de l'apprentissage automatique. Les principales bibliothèques mobilisées comprennent NumPy et Pandas pour la manipulation et le traitement des données, Matplotlib et Seaborn pour la visualisation graphique, Scikit-learn pour les opérations de prétraitement et l'évaluation statistique, ainsi que TensorFlow/Keras pour la conception, l'entraînement et l'optimisation des réseaux de neurones. Pour l'organisation et la structuration initiale des données hydrométéorologiques (précipitations et débits), des traitements préliminaires ont été réalisés à l'aide de Microsoft Excel**,** notamment pour la gestion des séries chronologiques, la détection des valeurs manquantes et l'analyse statistique descriptive de base.

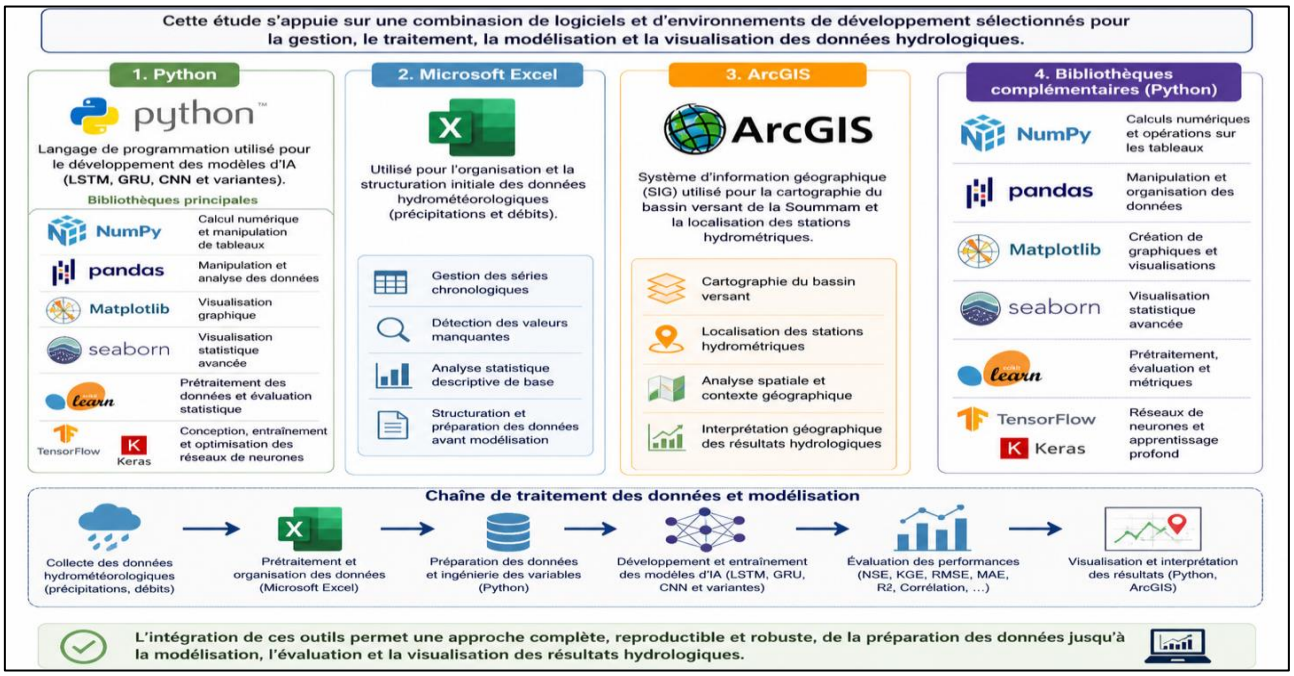


Figure III.9. La démarche scientifique adoptée d'outils et logiciels

La cartographie du bassin versant de la Soummam ainsi que la localisation des stations hydrométriques ont été réalisées à l'aide du logiciel ArcGIS**,** un système d'information

géographique (SIG) permettant la production de cartes précises et adaptées aux besoins de l'étude. Cet outil a joué un rôle essentiel dans la compréhension du contexte spatial et dans l'interprétation géographique des résultats hydrologiques obtenus. L'ensemble de ces outils a permis de construire une chaîne de traitement complète et cohérente, allant de la collecte et la préparation des données jusqu'à la modélisation, l'évaluation des performances et la visualisation des résultats, garantissant ainsi la reproductibilité et la robustesse de la démarche scientifique adoptée.

III .7. Conclusion

Ce chapitre a permis d'établir un cadre méthodologique rigoureux pour la modélisation de la relation pluie-débit dans le bassin de la Soummam. L'intégration de prétraitements statistiques adaptés et d'architectures d'apprentissage profond (LSTM, GRU, CNN et leurs variantes) constitue une base solide pour capturer la dynamique non linéaire des écoulements. Cette structuration méthodologique, renforcée par des outils d'interprétabilité tels que la méthode SHAP, garantit non seulement la fiabilité des prédictions, mais permet également une meilleure compréhension des mécanismes hydrologiques, qui seront analysés et discutés dans le chapitre suivant.

CHAPITRE IV

RESULTATS ET DISCUSSION

CHAPITRE IV : RESULTATS ET DISCUSSION

IV.1 Introduction

Ce chapitre est consacré à la présentation et à l'analyse des résultats obtenus lors de l'exécution de différents modèles de *deep learning*. Il est structuré en quatre parties principales. La première porte sur l'interprétation des résultats obtenus pour chaque station, tandis que la deuxième est dédiée à une analyse comparative des performances des modèles. La troisième partie concerne l'interprétation des modèles à l'aide de l'approche SHAP, permettant l'analyse de l'influence des variables d'entrée. Enfin, une comparaison avec les résultats, tirés de la littérature, est présentée afin de situer les performances obtenues dans un contexte scientifique plus large.

IV.2 Analyse et interprétation des résultats

Cette section présente et analyse, les résultats obtenus à partir de l'application de différents modèles de *deep learning*, pour la modélisation des débits journaliers au niveau de deux stations hydrométriques situées dans le bassin de la Soummam, au nord-centre de l'Algérie. Les modèles développés, à savoir : LSTM, GRU, CNN, BiLSTM, BiGRU ainsi que l'architecture hybride CNN-LSTM, ont été évalués afin de comparer leurs performances et leurs capacités à reproduire la dynamique hydrologique du bassin.

L'évaluation des modèles repose sur une combinaison de critères de validation numériques et graphiques. Les critères numériques permettent de quantifier la précision des prédictions à travers différents indicateurs statistiques, tandis que les critères graphiques offrent une visualisation comparative entre les débits observés et simulés, facilitant ainsi l'analyse du comportement des modèles face aux variations hydrologiques. Par ailleurs, l'interprétation des résultats s'appuie sur l'approche SHAP (SHapley Additive exPlanations), permettant d'analyser l'influence des variables d'entrée sur les prédictions des modèles et d'améliorer leur interprétabilité. Cette approche contribue à une meilleure compréhension des mécanismes régissant la modélisation des débits journaliers. Dans ce cadre, une analyse comparative détaillée est réalisée pour les deux stations étudiées dans le bassin de la Soummam, suivie d'une discussion approfondie mettant en évidence les performances relatives des modèles, leurs limites ainsi que leur pertinence dans le contexte hydrologique de la région étudiée.

Les tableaux IV.1 et IV.2 présentent les résultats numériques obtenus pour les différents modèles de *deep learning* appliqués aux deux stations étudiées dans le bassin de la Soummam. Ces résultats sont évalués selon les phases d'apprentissage (training) et de validation, permettant ainsi d'analyser à la fois la capacité d'ajustement des modèles aux données d'entraînement et leur aptitude à généraliser sur des données non utilisées lors de l'apprentissage. Cette double évaluation offre une vision globale des performances des modèles et facilite leur comparaison dans les deux contextes d'analyse

Tableau IV.1. Évaluation numérique des modèles à la station FERMATOU

Model	R	NSE	MAE	RMSE	KGE	CA	R	NSE	MAE	RMSE	KGE	CA
LSTM1	0.927	0.846	0.158	0.460	0.781	0.250	0.908	0.820	0.138	0.413	0.894	0.240
GRU1	0.946	0.865	0.176	0.479	0.799	0.269	0.926	0.843	0.145	0.386	0.884	0.222
CNN1	0.965	0.932	0.119	0.307	0.943	0.163	0.938	0.879	0.131	0.339	0.933	0.195
CNN-LSTM1	0.960	0.909	0.137	0.353	0.834	0.188	0.941	0.884	0.139	0.359	0.896	0.208
BiLSTM1	0.979	0.928	0.156	0.372	0.853	0.206	0.919	0.817	0.184	0.417	0.837	0.250
BiGRU1	0.980	0.947	0.174	0.390	0.872	0.225	0.917	0.835	0.179	0.396	0.820	0.243
LSTM2	0.829	0.676	0.251	0.668	0.667	0.406	0.868	0.748	0.215	0.490	0.823	0.314
GRU2	0.831	0.694	0.269	0.687	0.686	0.425	0.853	0.697	0.234	0.537	0.779	0.344
CNN2	0.891	0.788	0.239	0.541	0.864	0.325	0.836	0.602	0.254	0.615	0.730	0.386
CNN-LSTM2	0.859	0.734	0.251	0.605	0.795	0.369	0.861	0.696	0.235	0.537	0.801	0.340
BiLSTM2	0.861	0.752	0.269	0.624	0.814	0.388	0.872	0.745	0.241	0.492	0.795	0.321
BiGRU2	0.863	0.771	0.288	0.643	0.832	0.406	0.867	0.745	0.246	0.492	0.745	0.325
LSTM3	0.904	0.809	0.176	0.512	0.784	0.287	0.927	0.853	0.155	0.374	0.896	0.221
GRU3	0.906	0.828	0.195	0.531	0.803	0.306	0.918	0.818	0.180	0.416	0.860	0.248
CNN3	0.941	0.884	0.151	0.399	0.901	0.220	0.914	0.811	0.154	0.424	0.856	0.245
CNN-LSTM3	0.917	0.836	0.170	0.475	0.825	0.265	0.919	0.835	0.168	0.396	0.875	0.237
BiLSTM3	0.919	0.855	0.188	0.494	0.843	0.284	0.923	0.847	0.197	0.381	0.862	0.239
BiGRU3	0.921	0.873	0.207	0.512	0.862	0.302	0.899	0.797	0.186	0.439	0.899	0.270
LSTM4	0.406	0.157	0.515	1.078	0.106	0.801	0.386	0.143	0.515	0.902	0.180	0.749
GRU4	0.408	0.176	0.534	1.096	0.125	0.820	0.390	0.136	0.482	0.906	0.217	0.738
CNN4	0.574	0.310	0.460	0.975	0.305	0.695	0.360	0.050	0.479	0.950	0.262	0.759
CNN-LSTM4	0.618	0.361	0.437	0.938	0.368	0.658	0.364	0.029	0.464	0.960	0.278	0.756
BiLSTM4	0.620	0.379	0.456	0.957	0.386	0.677	0.374	0.138	0.499	0.905	0.143	0.747
BiGRU4	0.622	0.398	0.474	0.975	0.405	0.695	0.328	0.075	0.520	0.937	0.165	0.775
LSTM5	0.535	0.279	0.426	0.997	0.285	0.705	0.534	0.284	0.418	0.825	0.325	0.646
GRU5	0.537	0.297	0.444	1.015	0.304	0.723	0.531	0.272	0.384	0.831	0.335	0.638
CNN5	0.649	0.402	0.365	0.907	0.430	0.611	0.503	0.220	0.377	0.861	0.338	0.655
CNN-LSTM5	0.658	0.416	0.358	0.897	0.465	0.601	0.491	0.184	0.380	0.880	0.368	0.666
BiLSTM5	0.660	0.434	0.376	0.916	0.484	0.620	0.497	0.243	0.432	0.848	0.303	0.671
BiGRU5	0.662	0.453	0.395	0.934	0.502	0.638	0.486	0.215	0.435	0.864	0.365	0.681
LSTM6	0.780	0.603	0.262	0.739	0.641	0.460	0.870	0.755	0.207	0.483	0.818	0.308
GRU6	0.782	0.622	0.280	0.758	0.659	0.478	0.870	0.755	0.193	0.482	0.786	0.303
CNN6	0.781	0.602	0.274	0.740	0.727	0.464	0.868	0.724	0.228	0.512	0.819	0.325

CNN-LSTM6	0.780	0.601	0.270	0.741	0.706	0.463	0.869	0.734	0.219	0.503	0.843	0.319
BiLSTM6	0.781	0.620	0.288	0.760	0.725	0.482	0.864	0.721	0.298	0.515	0.661	0.352
BiGRU6	0.783	0.638	0.307	0.778	0.743	0.500	0.854	0.709	0.306	0.526	0.666	0.364

L'analyse des résultats de validation dans le tableau IV.1 à la station FERMATOU, met en évidence des différences claires entre les modèles de *deep learning* en termes de performance et de capacité de généralisation. Les indicateurs statistiques montrent que les performances varient selon les scénarios, ce qui permet d'identifier les modèles les plus adaptés à la modélisation des débits journaliers. Le modèle CNN-LSTM se distingue globalement comme le plus performant, en particulier dans le scénario 1 où CNN-LSTM1 présente des résultats très satisfaisants avec des valeurs élevées de R (0.941), NSE (0.884) et KGE (0.896), associées à de faibles erreurs (MAE = 0.139 ; RMSE = 0.359). Ces résultats traduisent une excellente capacité du modèle à reproduire les débits observés et à capturer la dynamique hydrologique. La combinaison des couches convolutionnelles et récurrentes permet ainsi d'extraire efficacement à la fois les caractéristiques locales et les dépendances temporelles des données.

Le modèle CNN1 présente également de très bonnes performances (NSE = 0.879 ; KGE = 0.933 ; RMSE = 0.339), proches de celles du CNN-LSTM, mais légèrement inférieures en termes de capacité globale de généralisation. Les modèles récurrents classiques, notamment GRU1 et LSTM1, affichent des performances satisfaisantes (NSE = 0.843 et 0.820), mais avec des erreurs plus élevées, ce qui indique une précision moindre. Les modèles bidirectionnels (BiLSTM1 et BiGRU1) présentent des résultats comparables, sans amélioration notable, malgré leur complexité plus importante. Dans les scénarios 2 et 3, les performances des modèles restent globalement acceptables, avec des valeurs de NSE comprises entre 0.60 et 0.85. Le modèle CNN-LSTM conserve des performances stables, ce qui confirme sa robustesse face aux variations des données d'entrée. Les modèles CNN et LSTM suivent la même tendance, mais avec une légère variabilité selon les scénarios. En revanche, les scénarios 4 et 5 montrent une dégradation importante des performances pour l'ensemble des modèles, avec des valeurs de NSE faibles (souvent inférieures à 0.30) et des erreurs élevées. Cela traduit une difficulté générale des modèles à reproduire les débits dans ces conditions, probablement liée à une insuffisance des variables d'entrée ou à une complexité hydrologique plus importante. Le scénario 6 présente une amélioration des performances avec des NSE compris entre 0.70 et 0.75 pour plusieurs modèles, dont CNN-LSTM6, indiquant une capacité correcte de généralisation. Toutefois, les performances restent inférieures à celles observées dans le scénario 1.

Dans l'ensemble, les résultats de validation à la station FERMATOU montrent que le modèle CNN-LSTM est le plus performant, grâce à sa capacité à combiner efficacement les avantages des architectures convolutionnelles et récurrentes. Les modèles CNN et GRU/LSTM offrent également des performances satisfaisantes, mais restent légèrement en retrait. Ces résultats confirment l'intérêt des modèles hybrides pour la modélisation des débits journaliers (Figure IV.1).

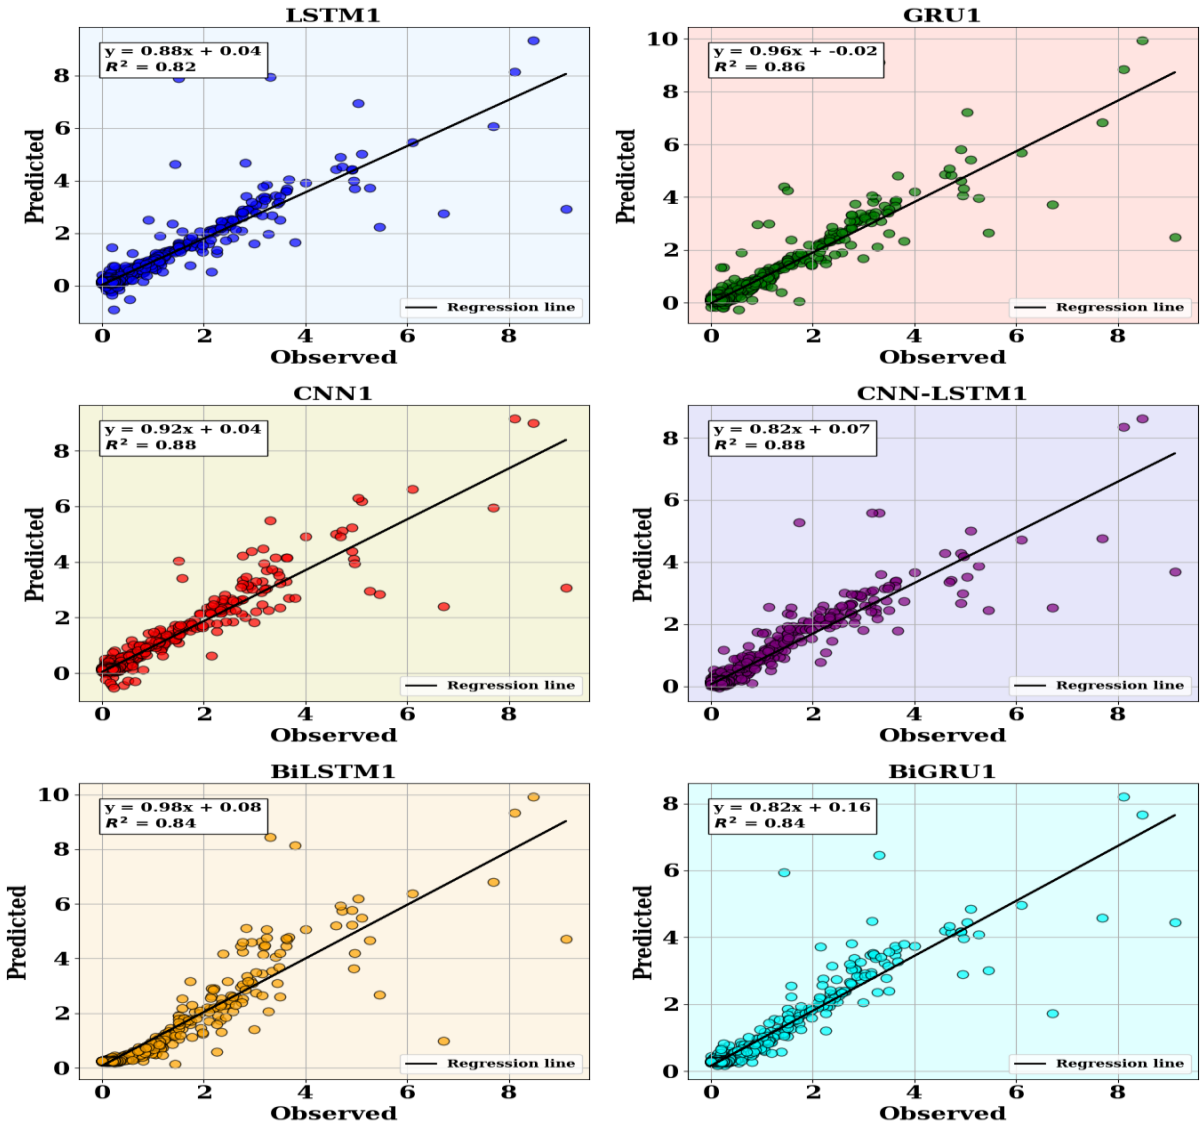


Figure IV.1. Analyse de corrélation entre les débits observés et simulés à la station FERMATOU (scatter plot)

Tableau IV.2. Évaluation numérique des modèles à la station BOU BIREK

Model	R	NSE	MAE	RMSE	KGE	CA	R	NSE	MAE	RMSE	KGE	CA
LSTM1	0.937	0.847	0.906	1.692	0.752	0.321	0.925	0.800	0.775	1.098	0.675	0.363
GRU1	0.941	0.837	0.916	1.618	0.752	0.321	0.928	0.832	0.650	1.004	0.747	0.325
CNN1	0.976	0.946	0.507	1.008	0.893	0.179	0.937	0.870	0.438	0.884	0.855	0.263
CNN-LSTM1	0.983	0.929	0.529	1.149	0.841	0.199	0.943	0.865	0.426	0.902	0.855	0.267

BiLSTM1	0.976	0.946	0.507	1.008	0.893	0.179	0.919	0.808	0.703	1.075	0.714	0.351
BiGRU1	0.973	0.929	0.529	1.149	0.841	0.199	0.916	0.811	0.685	1.067	0.735	0.348
LSTM2	0.797	0.590	1.717	2.767	0.537	0.605	0.725	0.438	1.440	1.839	0.473	0.710
CNN2	0.844	0.695	1.641	2.386	0.675	0.531	0.716	0.472	1.325	1.783	0.458	0.685
CNN2	0.844	0.695	1.641	2.386	0.675	0.531	0.721	0.436	1.423	1.842	0.492	0.709
CNN-LSTM2	0.837	0.700	1.670	2.369	0.765	0.536	0.719	0.445	1.415	1.827	0.470	0.706
BiLSTM2	0.844	0.695	1.641	2.386	0.675	0.531	0.707	0.473	1.333	1.781	0.498	0.690
BiGRU2	0.837	0.700	1.670	2.369	0.765	0.536	0.711	0.435	1.429	1.844	0.413	0.715
LSTM3	0.856	0.719	1.689	2.388	0.784	0.555	0.879	0.748	0.789	1.231	0.736	0.415
GRU3	0.888	0.782	0.947	2.016	0.778	0.390	0.891	0.770	0.746	1.177	0.758	0.392
CNN3	0.936	0.855	0.579	1.647	0.782	0.282	0.920	0.835	0.443	0.997	0.859	0.293
CNN-LSTM3	0.962	0.913	0.560	1.276	0.847	0.223	0.918	0.837	0.452	0.990	0.878	0.295
BiLSTM3	0.936	0.855	0.579	1.647	0.782	0.282	0.833	0.688	0.880	1.369	0.715	0.480
BiGRU3	0.955	0.874	0.598	1.666	0.801	0.301	0.874	0.737	0.814	1.258	0.775	0.427
LSTM4	0.675	0.415	2.049	3.305	0.395	0.759	0.449	0.150	1.652	2.262	0.307	0.924
GRU4	0.694	0.434	2.068	3.324	0.414	0.778	0.453	0.172	1.707	2.233	0.179	0.927
CNN4	0.724	0.480	2.049	3.118	0.451	0.716	0.450	0.182	1.648	2.219	0.247	0.916
CNN-LSTM4	0.717	0.464	2.029	3.165	0.431	0.723	0.449	0.187	1.631	2.212	0.240	0.912
BiLSTM4	0.736	0.483	2.048	3.184	0.450	0.742	0.423	0.179	1.565	2.223	0.183	0.911
BiGRU4	0.755	0.502	2.067	3.203	0.469	0.761	0.442	0.164	1.704	2.243	0.181	0.932
LSTM5	0.761	0.550	1.163	2.899	0.533	0.579	0.714	0.510	0.890	1.717	0.607	0.602
GRU5	0.866	0.704	0.933	2.353	0.623	0.438	0.725	0.525	0.901	1.691	0.598	0.594
CNN5	0.859	0.709	0.916	2.330	0.658	0.438	0.696	0.423	0.728	1.863	0.677	0.608
CNN-LSTM5	0.866	0.704	0.933	2.353	0.623	0.438	0.742	0.546	0.768	1.652	0.667	0.557
BiLSTM5	0.885	0.723	0.952	2.372	0.642	0.457	0.649	0.407	1.264	1.889	0.483	0.723
BiGRU5	0.866	0.704	0.933	2.353	0.623	0.438	0.690	0.460	0.911	1.802	0.638	0.631
LSTM6	0.577	0.324	1.935	3.555	0.363	0.815	0.671	0.479	0.930	1.821	0.657	0.650
GRU6	0.596	0.343	1.954	3.574	0.382	0.834	0.653	0.323	1.572	2.019	0.428	0.795
CNN6	0.615	0.362	1.973	3.593	0.401	0.853	0.650	0.350	1.489	1.977	0.490	0.775
CNN-LSTM6	0.590	0.336	1.925	3.524	0.365	0.805	0.642	0.338	1.489	1.996	0.492	0.782
BiLSTM6	0.578	0.324	1.926	3.555	0.361	0.814	0.634	0.307	1.580	2.043	0.383	0.808
BiGRU6	0.597	0.343	1.945	3.574	0.380	0.833	0.633	0.310	1.568	2.038	0.388	0.806

L'analyse des résultats de validation présentés dans le tableaux IV.2 à la station BOU BIREK met en évidence des variations importantes des performances des modèles de *deep learning* selon les scénarios. Globalement, les modèles montrent des niveaux de précision différents, permettant d'identifier les architectures les plus adaptées à la modélisation des débits journaliers dans ce contexte hydrologique. Dans le scénario 1, les meilleures performances sont obtenues par les modèles CNN1 et CNN-LSTM1. Le modèle CNN1 présente un NSE de 0.870, un KGE de 0.855 et une faible erreur (RMSE = 0.884), tandis que CNN-LSTM1 affiche des performances très proches avec un NSE de 0.865, un KGE de 0.855 et un RMSE de 0.902. Ces résultats indiquent une excellente capacité des deux modèles à reproduire les débits observés. Les modèles récurrents GRU1 et LSTM1 présentent également de bonnes performances (NSE

= 0.832 et 0.800), mais avec des erreurs légèrement plus élevées, traduisant une précision inférieure. Les modèles bidirectionnels restent en retrait, sans amélioration notable.

Dans le scénario 2, une baisse significative des performances est observée pour l'ensemble des modèles. Les valeurs de NSE deviennent faibles (entre 0.43 et 0.47), accompagnées d'erreurs élevées (RMSE ≈ 1.78–1.84), indiquant une difficulté des modèles à reproduire les débits. Aucun modèle ne se distingue clairement, ce qui suggère une sensibilité importante à la qualité des données d'entrée. Le scénario 3 montre une nette amélioration des performances. Le modèle CNN-LSTM3 se distingue avec un NSE de 0.837 et un KGE de 0.878, ainsi qu'une erreur réduite (RMSE = 0.990), confirmant sa capacité à bien modéliser les débits. Le modèle CNN3 présente également de bonnes performances (NSE = 0.835 ; KGE = 0.859), tandis que les modèles LSTM3 et GRU3 restent légèrement en retrait. Les modèles bidirectionnels montrent des performances variables, mais sans surpasser les modèles principaux. Dans le scénario 4, les performances des modèles sont très faibles. Les valeurs de NSE sont proches de zéro (souvent inférieures à 0.20), avec des erreurs élevées (RMSE > 2.20), indiquant une incapacité générale des modèles à reproduire les débits observés. Cette situation reflète probablement une inadéquation des variables d'entrée ou une complexité hydrologique difficile à capturer. Le scénario 5 présente également des performances limitées, avec des NSE généralement inférieurs à 0.55. Les modèles CNN-LSTM5 et GRU5 montrent des résultats légèrement meilleurs (NSE ≈ 0.54–0.55), mais les erreurs restent relativement élevées. Les modèles bidirectionnels affichent des performances plus faibles, confirmant leur manque d'efficacité dans ce scénario. Enfin, dans le scénario 6, les performances restent modérées. Les modèles LSTM6 et CNN-LSTM6 présentent des NSE compris entre 0.33 et 0.48, avec des erreurs relativement élevées. Les modèles CNN et GRU montrent des résultats similaires, sans qu'un modèle ne se distingue clairement. Cela indique une capacité limitée de généralisation dans ce scénario.

Dans l'ensemble, les résultats de validation à la station BOU BIREK montrent que les modèles CNN et CNN-LSTM offrent les meilleures performances, notamment dans les scénarios 1 et 3. Les modèles récurrents (LSTM et GRU) présentent des performances acceptables mais inférieures, tandis que les modèles bidirectionnels n'apportent pas d'amélioration significative. Comme pour la station FERMATOU, les performances des modèles dépendent fortement du scénario, ce qui souligne l'importance du choix des variables d'entrée et des conditions de modélisation dans la simulation des débits journaliers (Figure IV.2).

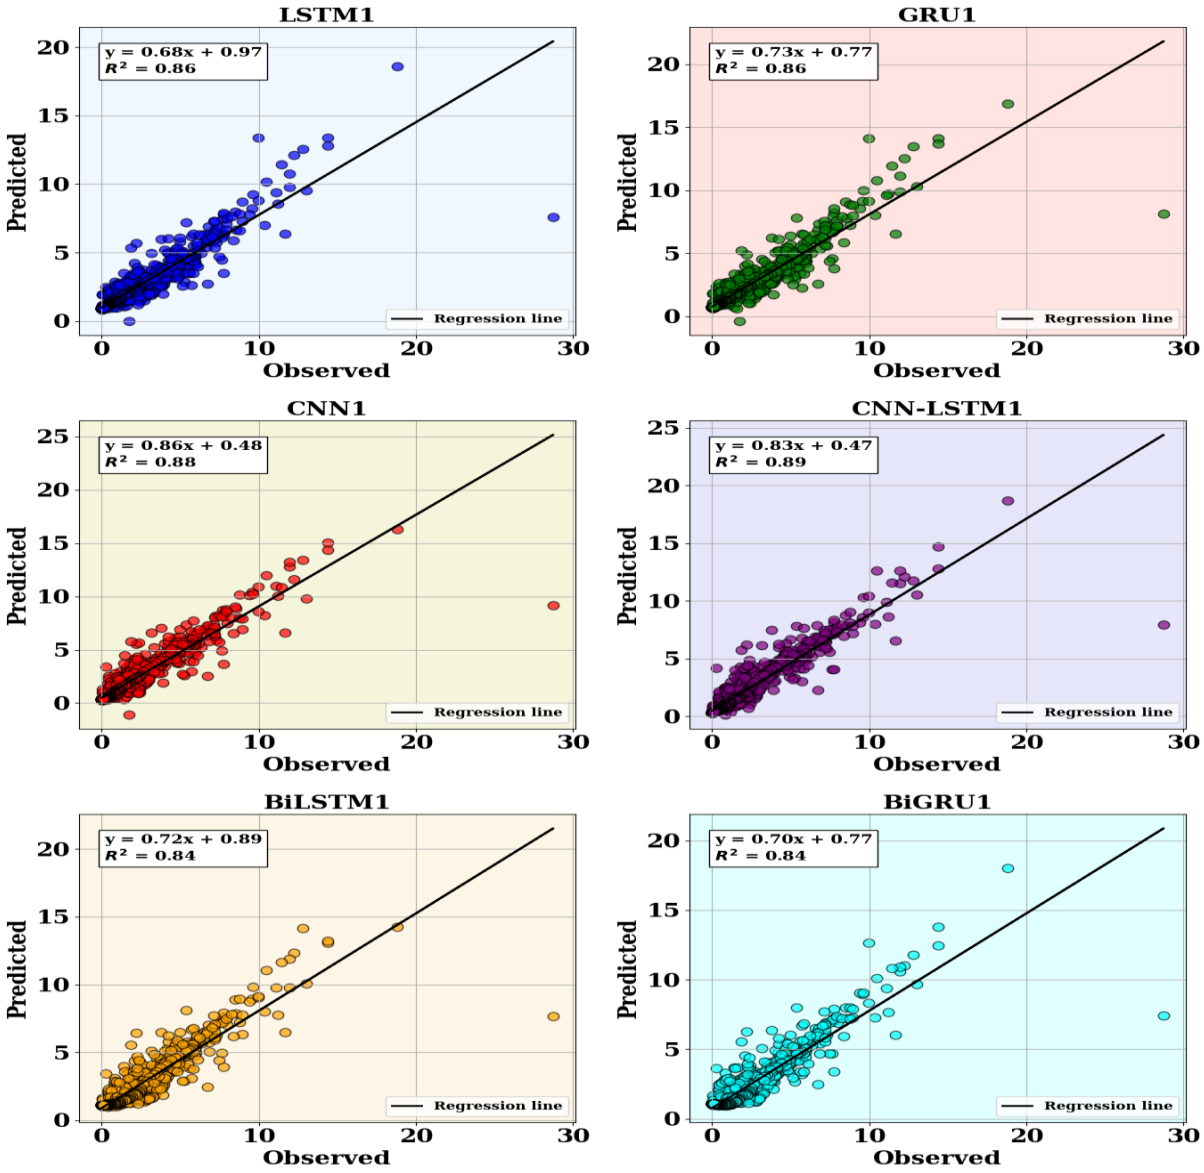


Figure IV.2 : **Analyse de corrélation entre les débits observés et simulés à la station BOU BIREK (scatter plot)**

IV. 3 Analyse comparative multicritères des performances des modèles de *deep learning*

Dans cette section, une analyse comparative des performances des différents modèles de *deep learning* est réalisée afin d'identifier le modèle le plus performant pour la modélisation des débits journaliers. Cette analyse se base sur les résultats obtenus pour le premier scénario, considéré comme le plus représentatif en termes de qualité de simulation.

À cet effet, un tableau récapitulatif des indicateurs statistiques (R, NSE, MAE, RMSE, KGE et CA) est présenté, accompagné d'une analyse graphique incluant des outils tels que le diagramme de Taylor, les *boxplots* et les *violin* plots. Ces représentations permettent d'évaluer

de manière approfondie la précision, la dispersion et la robustesse des modèles, facilitant ainsi leur comparaison globale.

Tableau IV.3. Résultats comparatifs des modèles de *deep learning* pour les stations FERMATOU et BOU BIREK

		Apprentissage						Validation					
Station	**Model**	**R**	**NSE**	**MAE**	**RMSE**	**KGE**	**CA**	**R**	**NSE**	**MAE**	**RMSE**	**KGE**	**CA**
FERMATOU	**CNN1**	0.965	0.932	0.119	0.307	0.943	0.163	0.938	0.879	0.131	0.339	0.933	0.195
	CNN-LSTM1	0.96	0.909	0.137	0.353	0.834	0.188	0.941	0.884	0.139	0.359	0.896	0.208
	GRU1	0.946	0.865	0.176	0.479	0.799	0.269	0.926	0.843	0.145	0.386	0.884	0.222
	BiLSTM1	0.979	0.928	0.156	0.372	0.853	0.206	0.919	0.817	0.184	0.417	0.837	0.25
	BiGRU1	0.98	0.947	0.174	0.39	0.872	0.225	0.917	0.835	0.179	0.396	0.82	0.243
	LSTM1	0.927	0.846	0.158	0.46	0.781	0.25	0.908	0.82	0.138	0.413	0.894	0.24
BOU BIREK	**CNN-LSTM1**	0.983	0.929	0.529	1.149	0.841	0.199	0.943	0.865	0.426	0.902	0.855	0.267
	CNN1	0.976	0.946	0.507	1.008	0.893	0.179	0.937	0.870	0.438	0.884	0.855	0.263
	GRU1	0.941	0.837	0.916	1.618	0.752	0.321	0.928	0.832	0.65	1.004	0.747	0.325
	LSTM1	0.937	0.847	0.906	1.692	0.752	0.321	0.925	0.8	0.775	1.098	0.675	0.363
	BiLSTM1	0.976	0.946	0.507	1.008	0.893	0.179	0.919	0.808	0.703	1.075	0.714	0.351
	BiGRU1	0.973	0.929	0.529	1.149	0.841	0.199	0.916	0.811	0.685	1.067	0.735	0.348

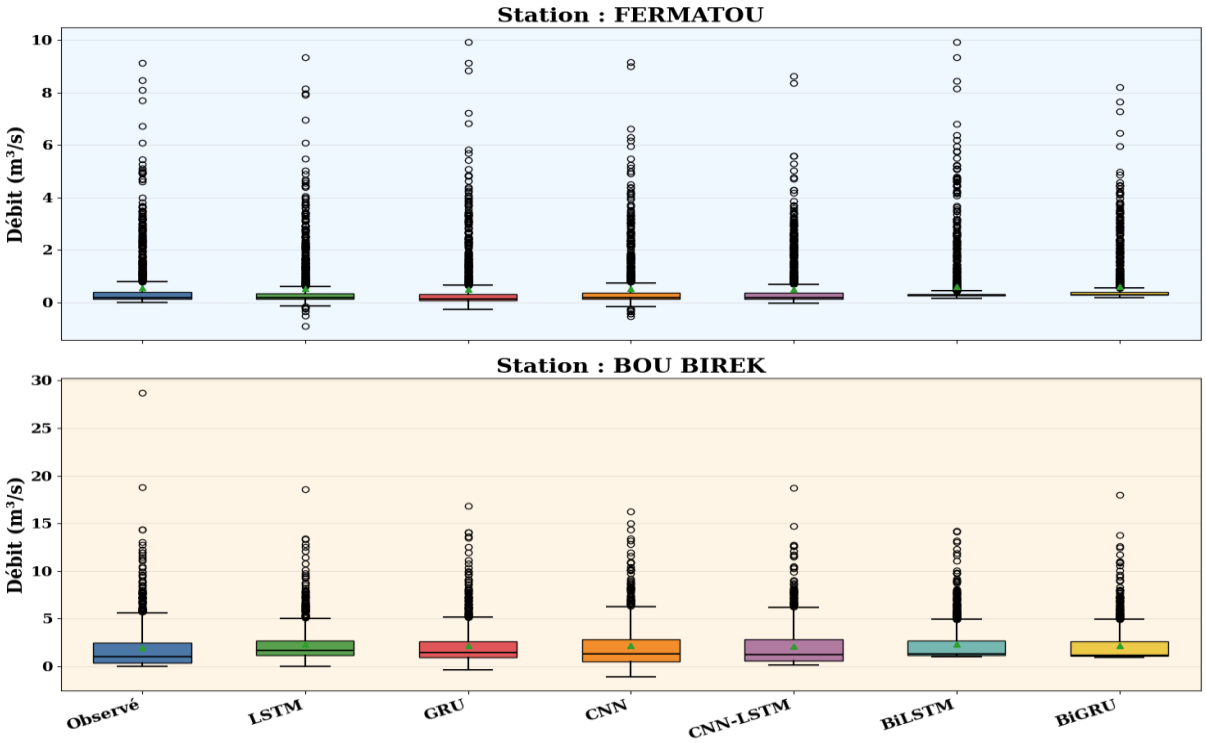


Figure IV.3. Distribution des performances des modèles de *deep learning* à l'aide des *boxplots*

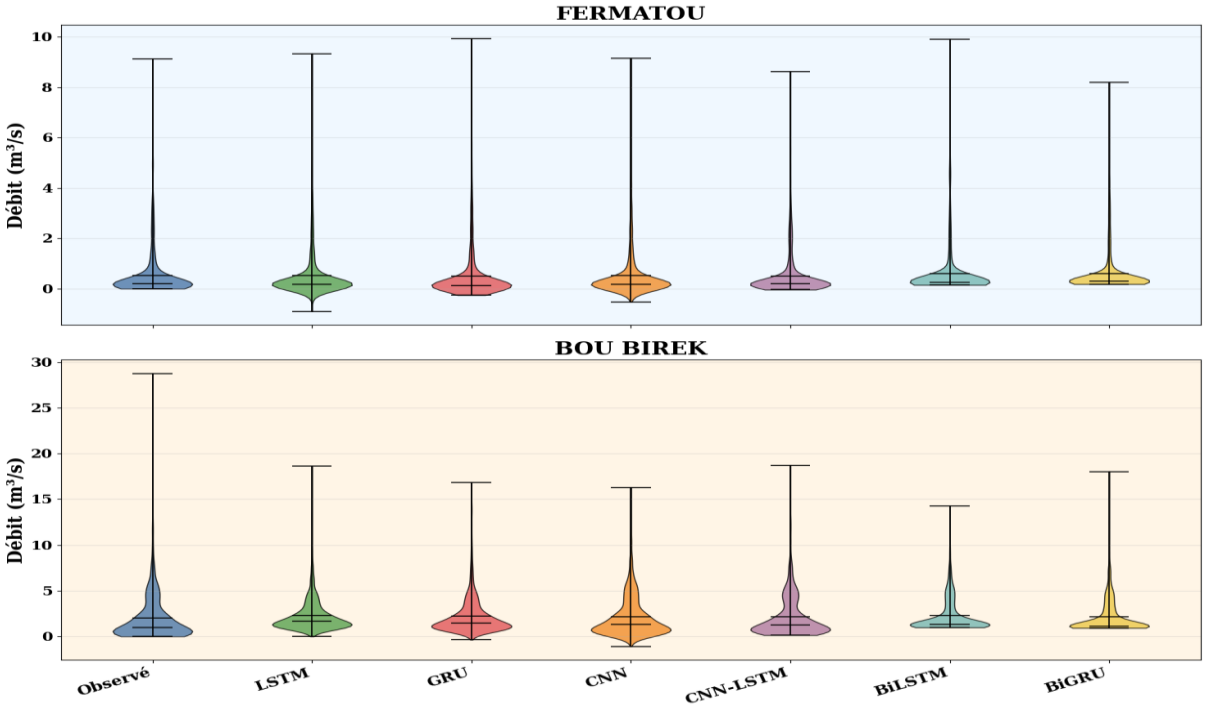


Figure IV.4. Distribution et densité des performances des modèles de *deep learning (violin plot*)

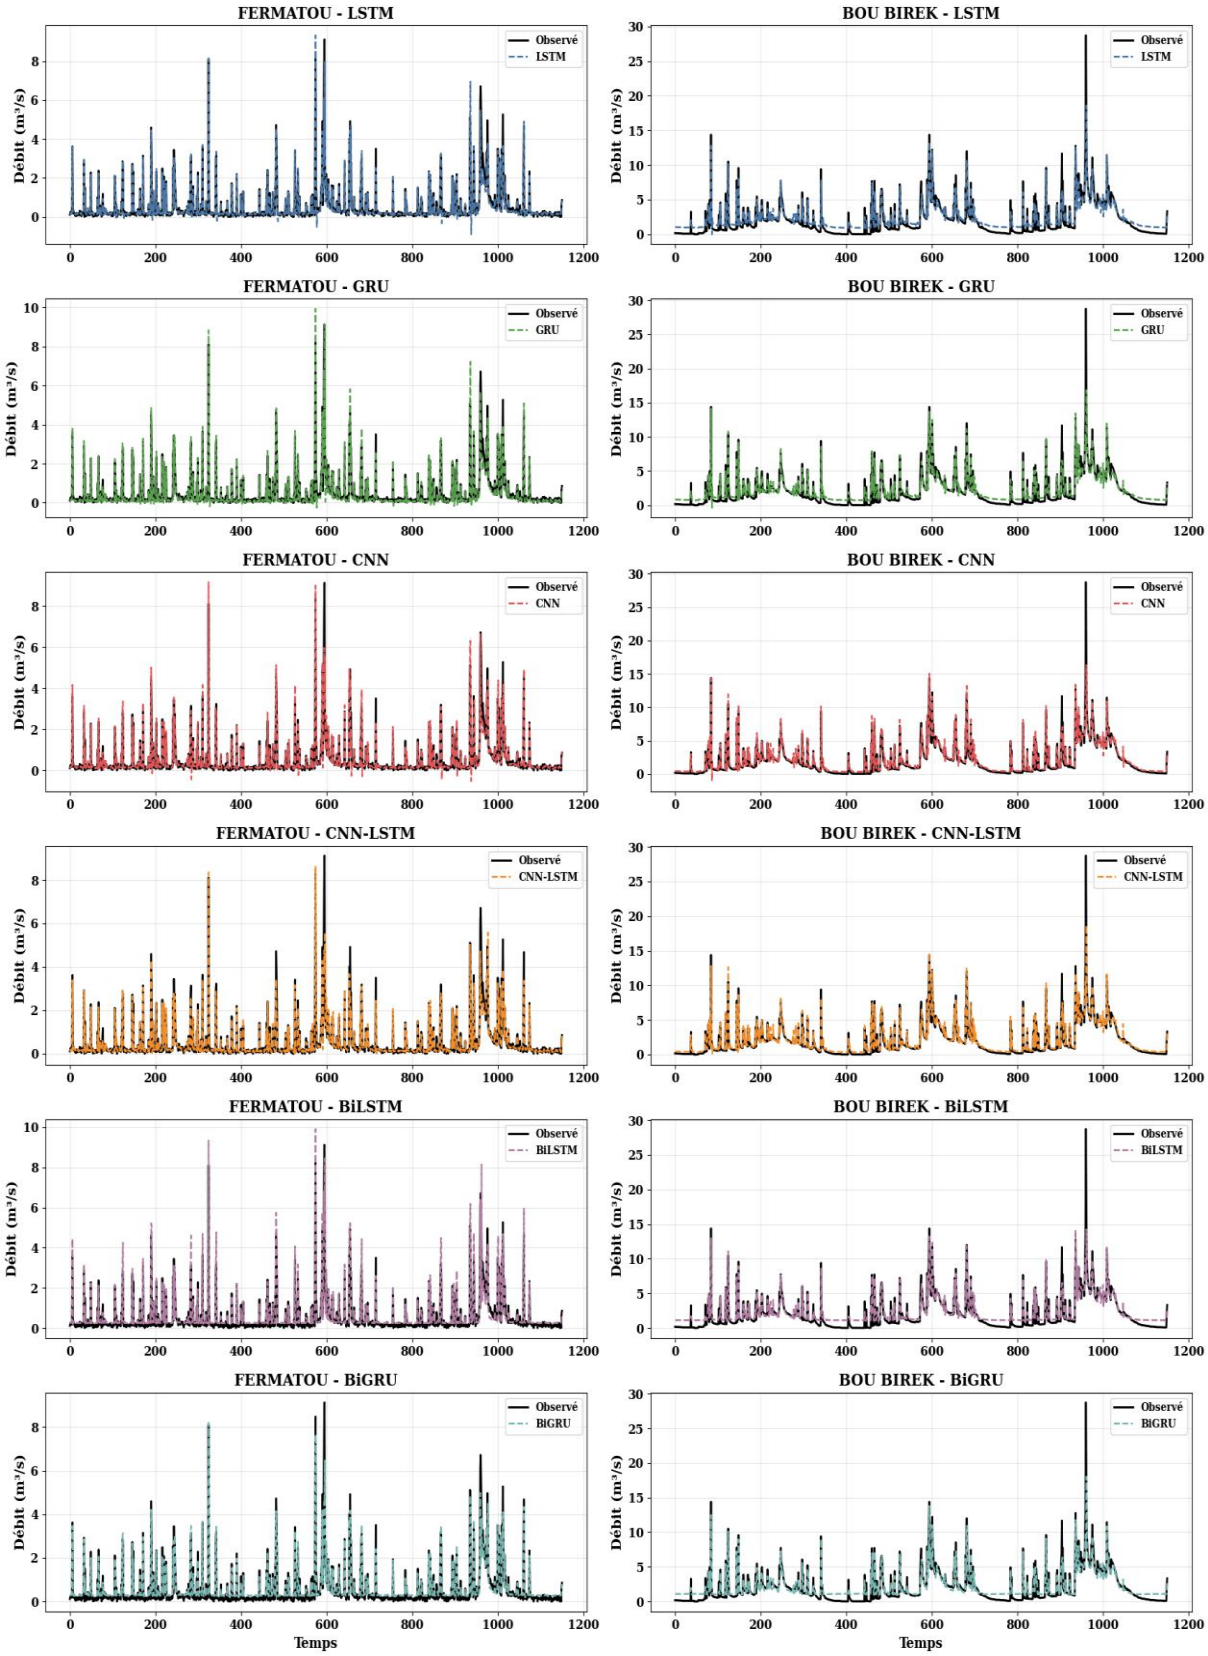


Figure IV.5. Courbes de variation des débits observés et simulés par les modèles de *deep learning*

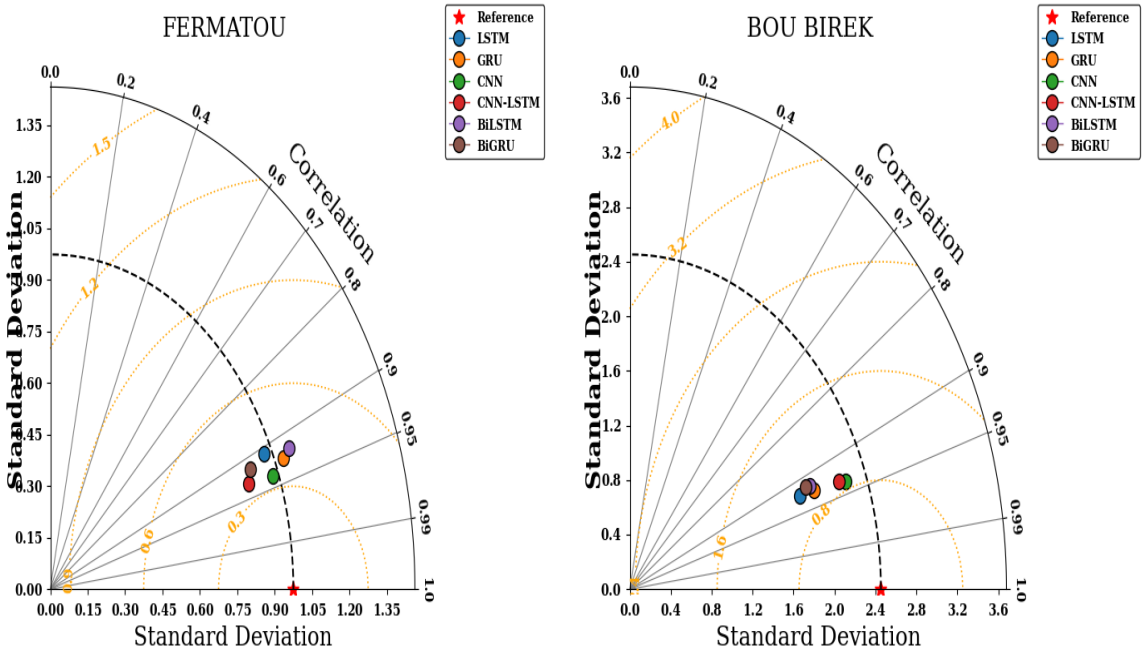


Figure IV.6. Diagramme de Taylor illustrant les performances des modèles de *deep learning*

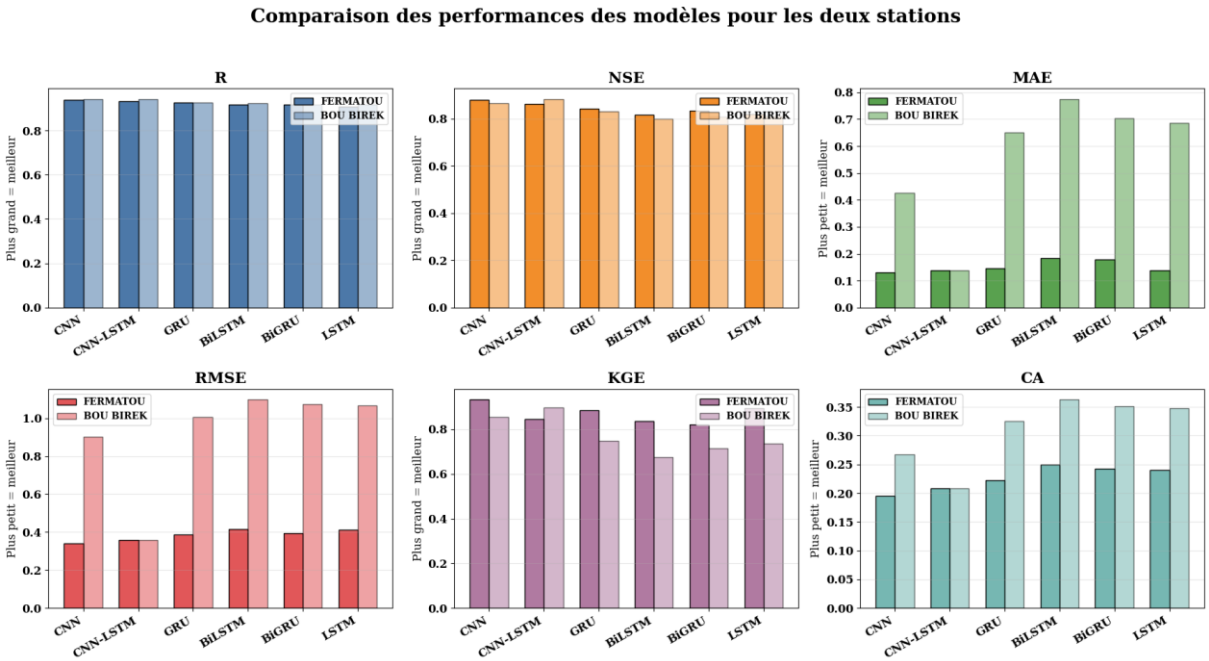


Figure IV.7. Comparaison des performances des modèles de *deep learning* à l'aide d'un diagramme en barres

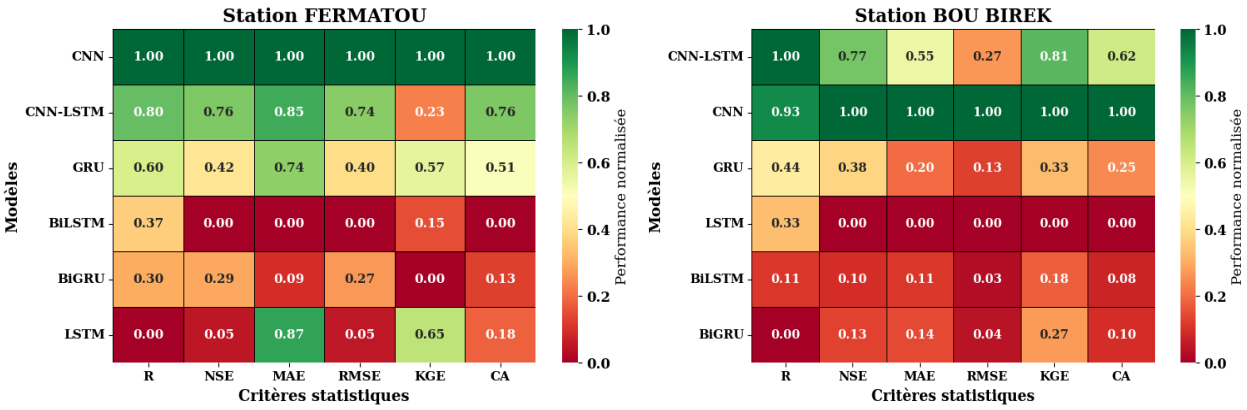


Figure IV.8. Carte thermique des performances des modèles de *deep learning* selon les indicateurs statistiques

L'analyse du tableau récapitulatif des résultats de validation (Tableau IV.3) met en évidence que les modèles CNN et CNN-LSTM présentent globalement les meilleures performances pour les deux stations. À la station FERMATOU, le modèle CNN1 se distingue par un KGE très élevé (0,933) et une faible erreur RMSE (0,339), tandis que le CNN-LSTM1 affiche le meilleur NSE (0,884) avec des erreurs également faibles, confirmant la robustesse de l'approche hybride. À la station BOU BIREK, ces deux modèles dominent également, avec des indicateurs supérieurs aux autres architectures. Les modèles récurrents classiques (LSTM et GRU) présentent des performances acceptables mais inférieures, tandis que les modèles bidirectionnels (BiLSTM et BiGRU) n'apportent pas d'amélioration significative malgré leur complexité. Globalement, le tableau IV.3 met en évidence une supériorité des architectures convolutionnelles, en particulier du modèle hybride CNN-LSTM.

L'interprétation des figures confirme ces résultats. Les diagrammes en barres et les heatmaps montrent clairement la dominance des modèles CNN et CNN-LSTM sur la majorité des indicateurs, traduisant une meilleure précision et une plus grande stabilité (Figures IV.7 et IV.8). Les boxplots et les violin plots indiquent que ces modèles reproduisent mieux la distribution des débits observés, avec une dispersion plus faible et une meilleure cohérence globale, contrairement aux autres modèles qui présentent une variabilité plus importante (Figures IV.3 et IV.4). Les courbes de variation temporelle (Figure IV.5) montrent que les modèles CNN et CNN-LSTM suivent plus fidèlement les fluctuations des débits, en capturant les tendances générales et une grande partie des pics. Enfin, le diagramme de Taylor (Figure IV.6) confirme que ces modèles sont les plus proches du point de référence, avec des corrélations élevées et une bonne reproduction de la variabilité des données.

Dans l'ensemble, la combinaison des résultats numériques et des analyses graphiques permet de conclure que les modèles CNN et CNN-LSTM sont les plus performants pour la modélisation des débits journaliers aux stations FERMATOU et BOU BIREK. Le modèle CNN-LSTM apparaît particulièrement pertinent grâce à sa capacité à intégrer à la fois les caractéristiques spatiales et les dépendances temporelles des données. Les autres modèles présentent des performances correctes mais restent globalement en retrait. Ces résultats confirment l'intérêt des approches hybrides en modélisation hydrologique et soulignent l'importance du choix de l'architecture pour améliorer la qualité des simulations.

IV. 4 Analyse de l'influence des variables explicatives sur les prédictions des modèles par l'approche SHAP

Dans cette partie, l'approche **SHAP** (SHapley Additive exPlanations) est utilisée afin d'interpréter les modèles de *deep learning* et d'analyser l'influence des variables d'entrée sur les prédictions des débits journaliers. Cette méthode permet d'évaluer la contribution de chaque variable explicative, offrant ainsi une meilleure compréhension du fonctionnement interne des modèles. L'analyse est réalisée en se basant uniquement sur les résultats du scénario 1, correspondant aux meilleures performances obtenues pour les deux stations. À cet effet, quatre figures sont présentées : deux pour la station FERMATOU et deux pour la station BOU BIREK. Ces représentations permettent d'identifier les variables les plus influentes et d'examiner leur impact sur les prédictions des modèles dans les deux contextes hydrologiques étudiés.

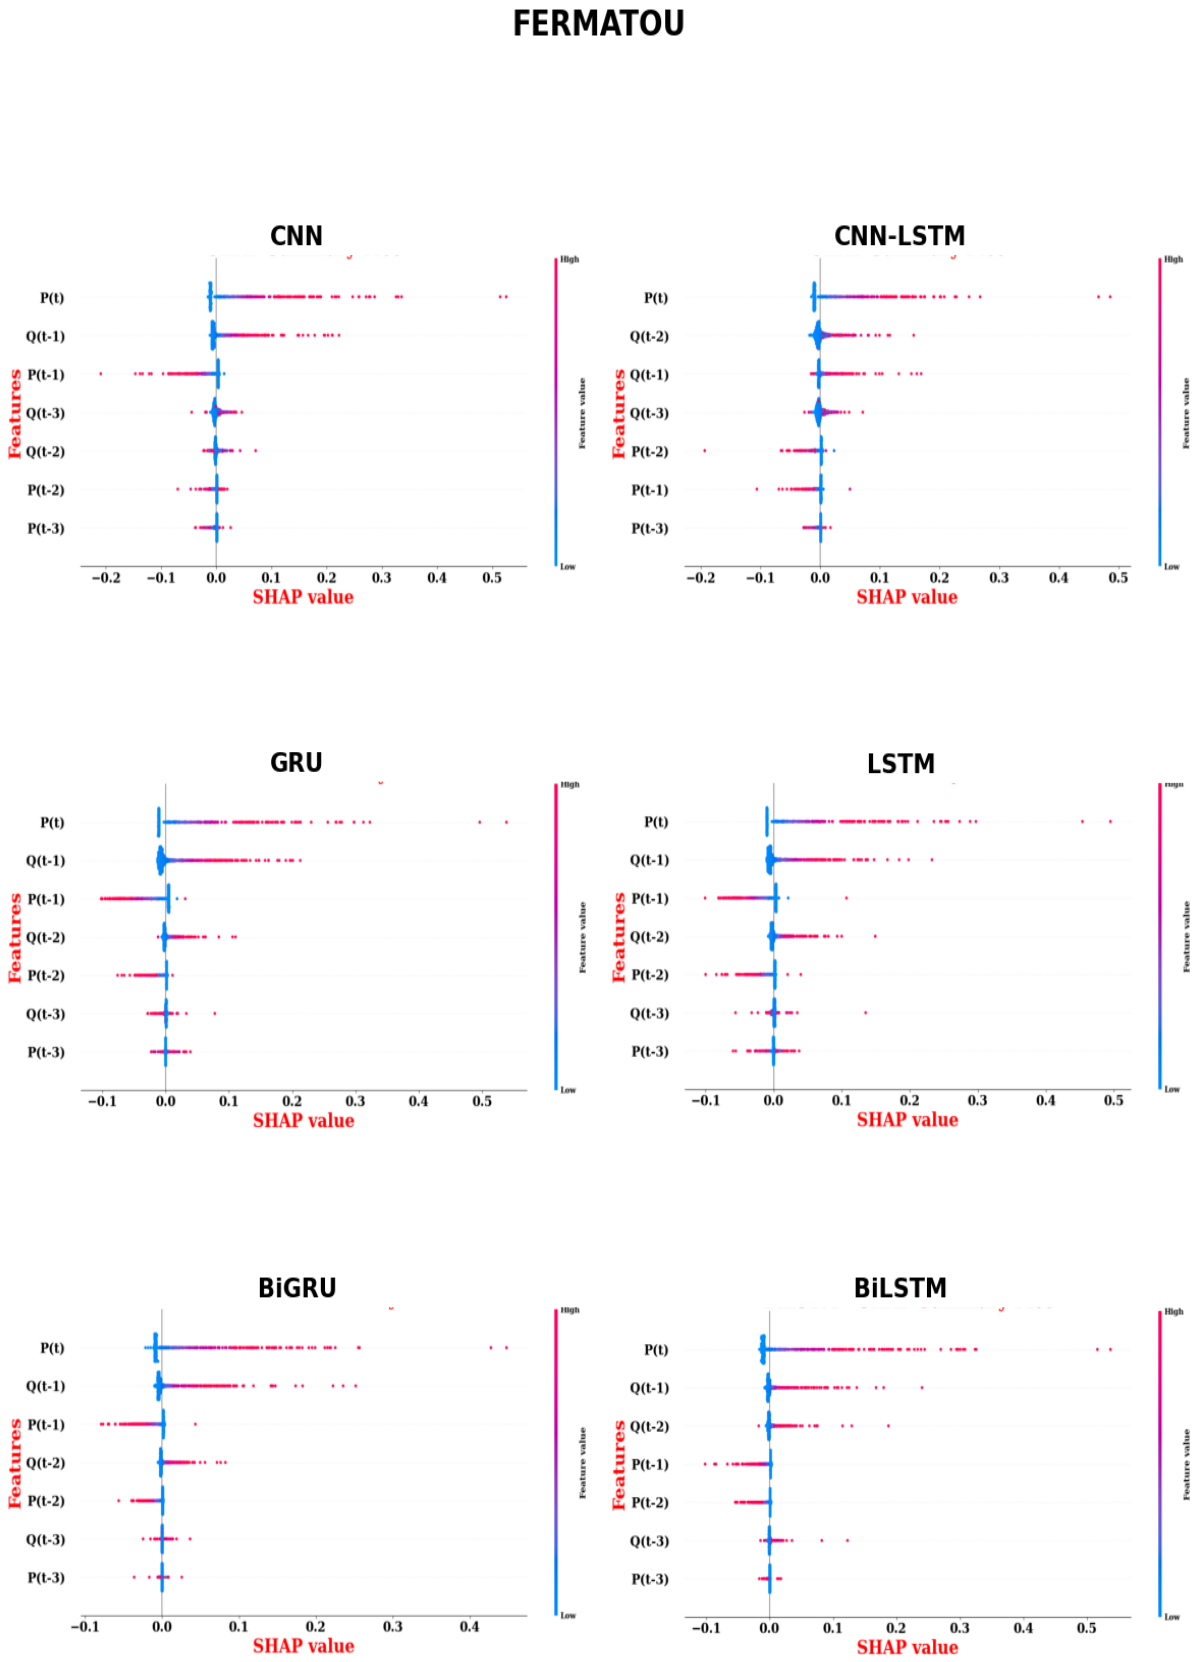


Figure IV.9. Importance relative des variables d'entrée basée sur les valeurs SHAP pour les modèles de *deep learning* à la station FERMATOU **(**summary plot)

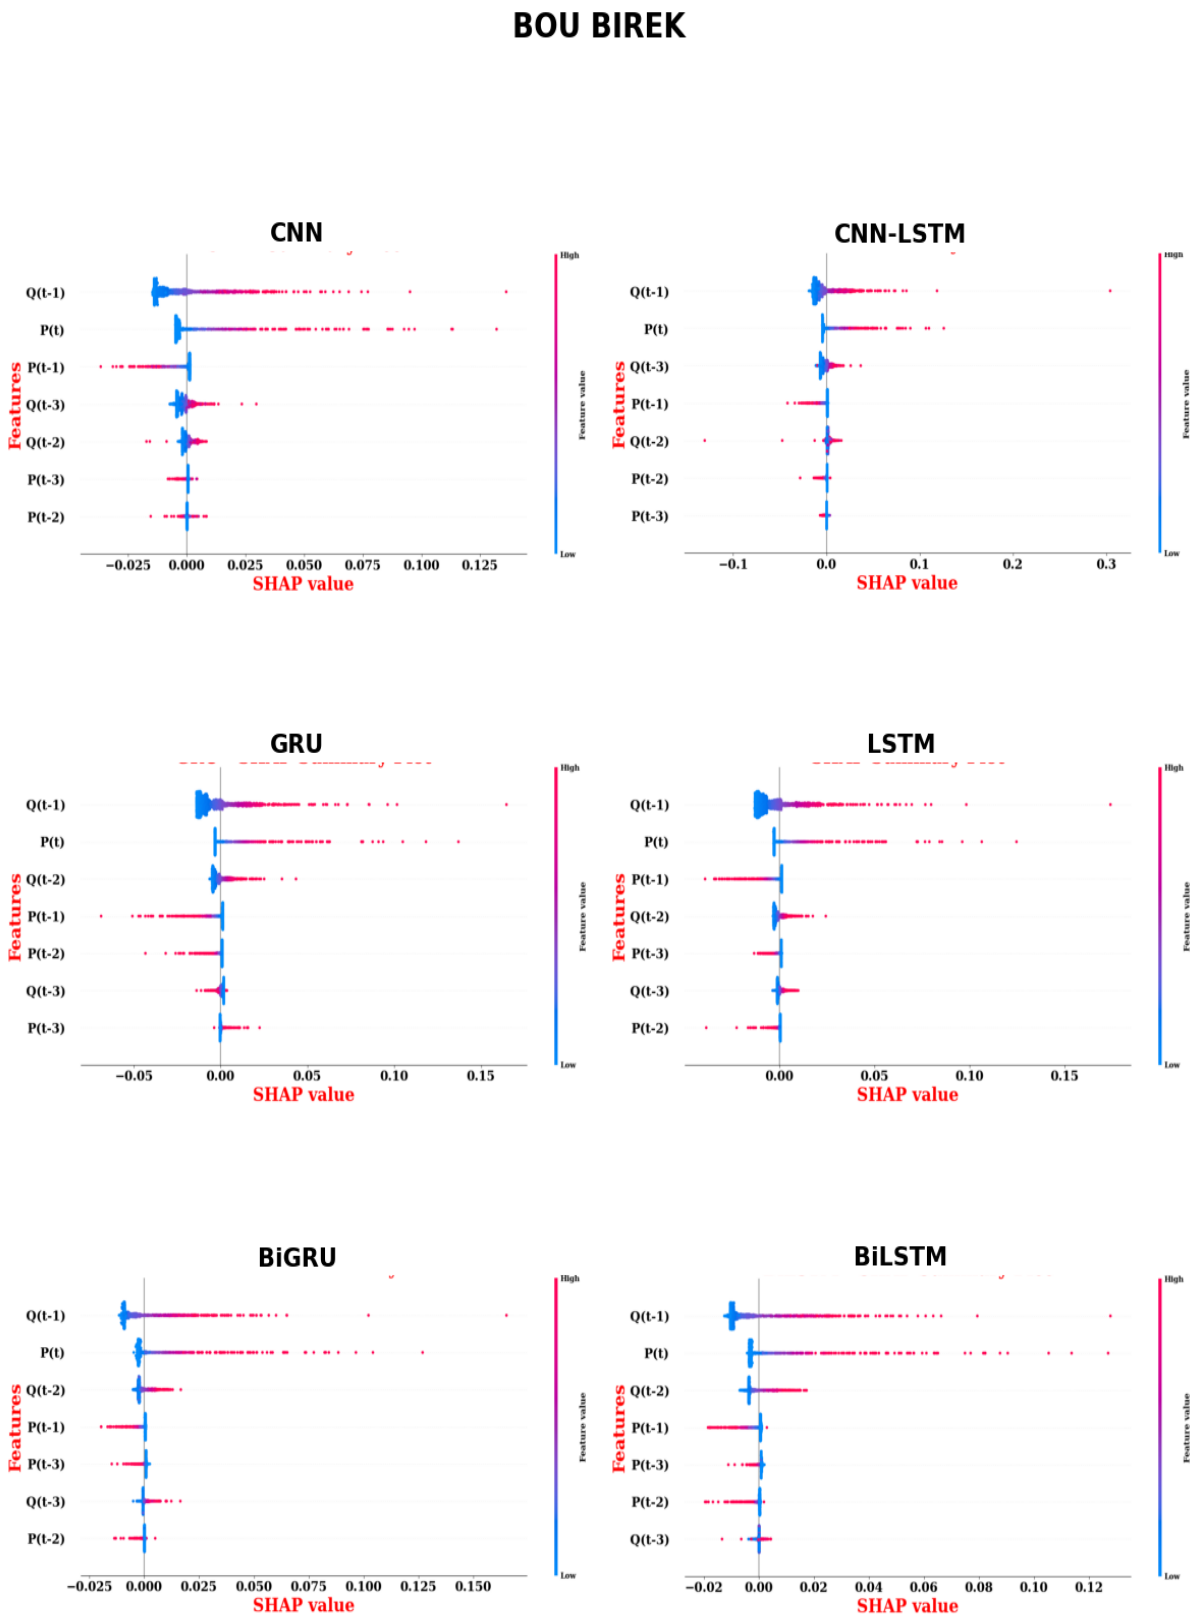


Figure IV.10. Importance relative des variables d'entrée basée sur les valeurs SHAP pour les modèles de *deep learning* à la station BOU BIREK ***(summary plot)***

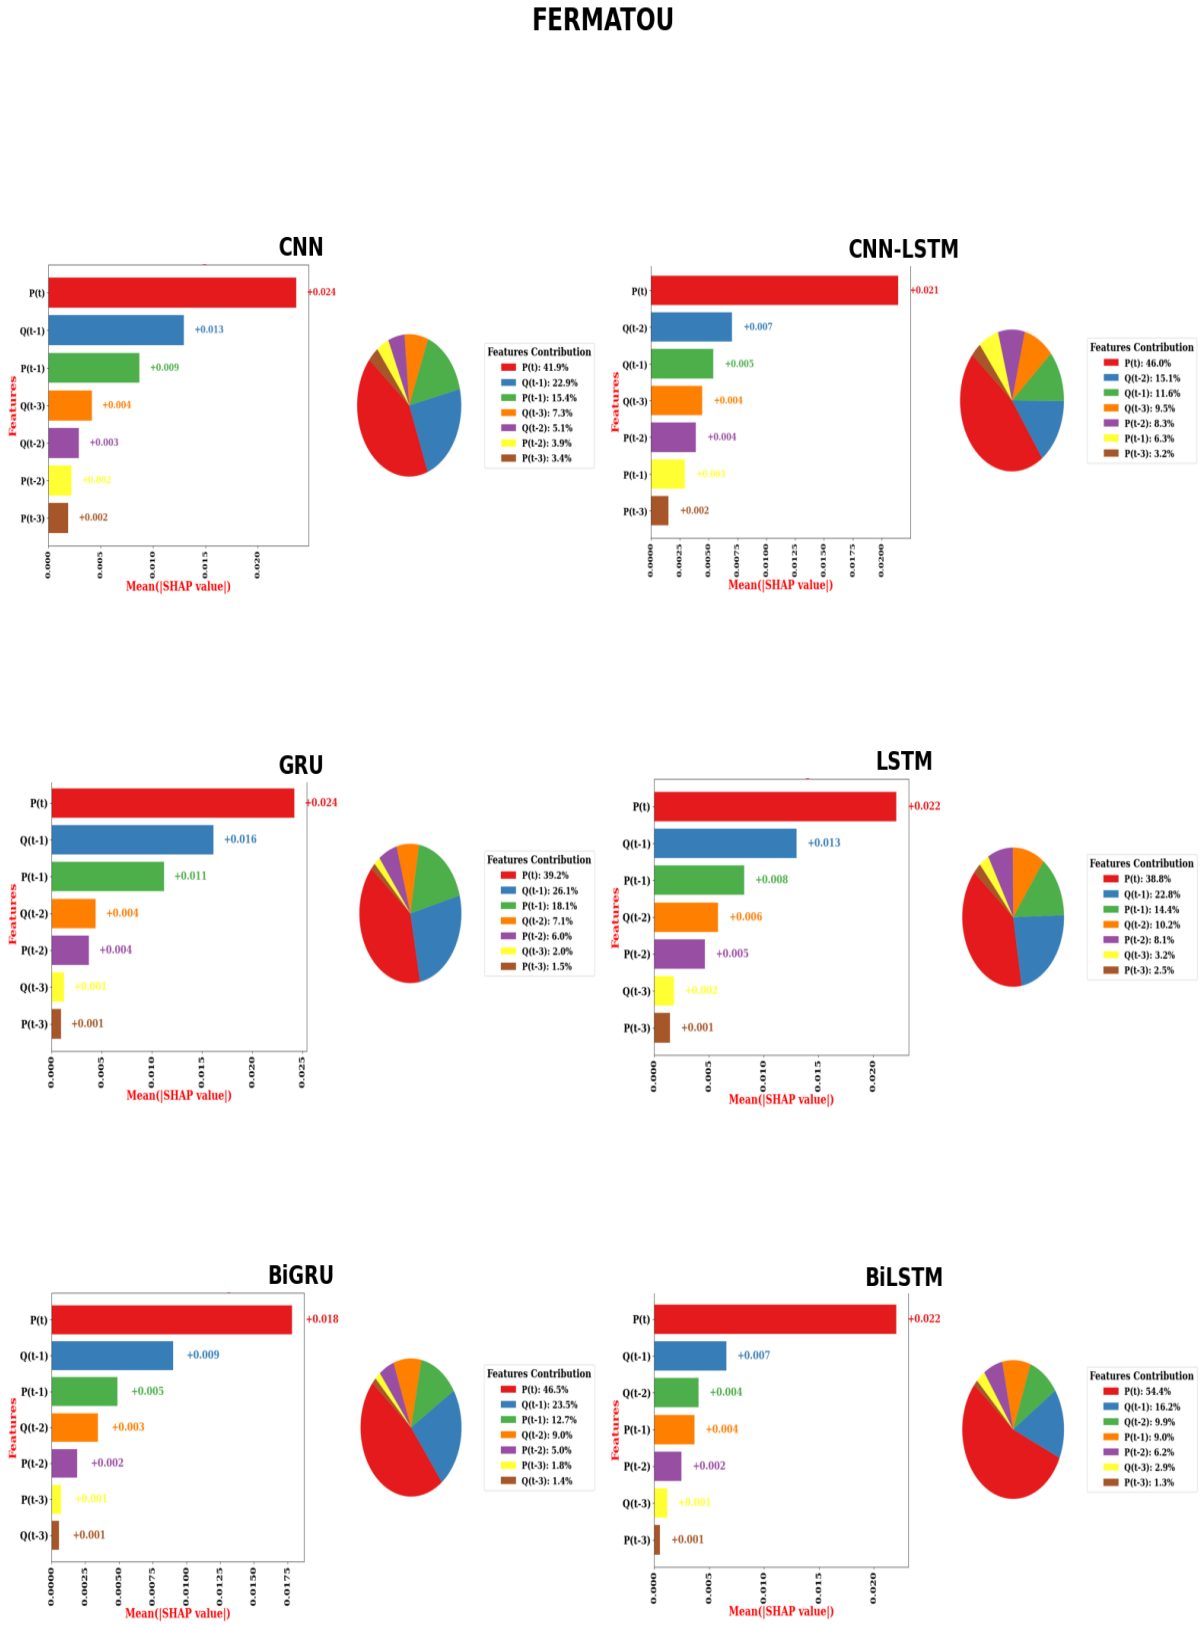


Figure IV.11. Distribution des contributions des variables d'entrée aux prédictions des modèles (SHAP Pie Charts) à la station FERMATOU

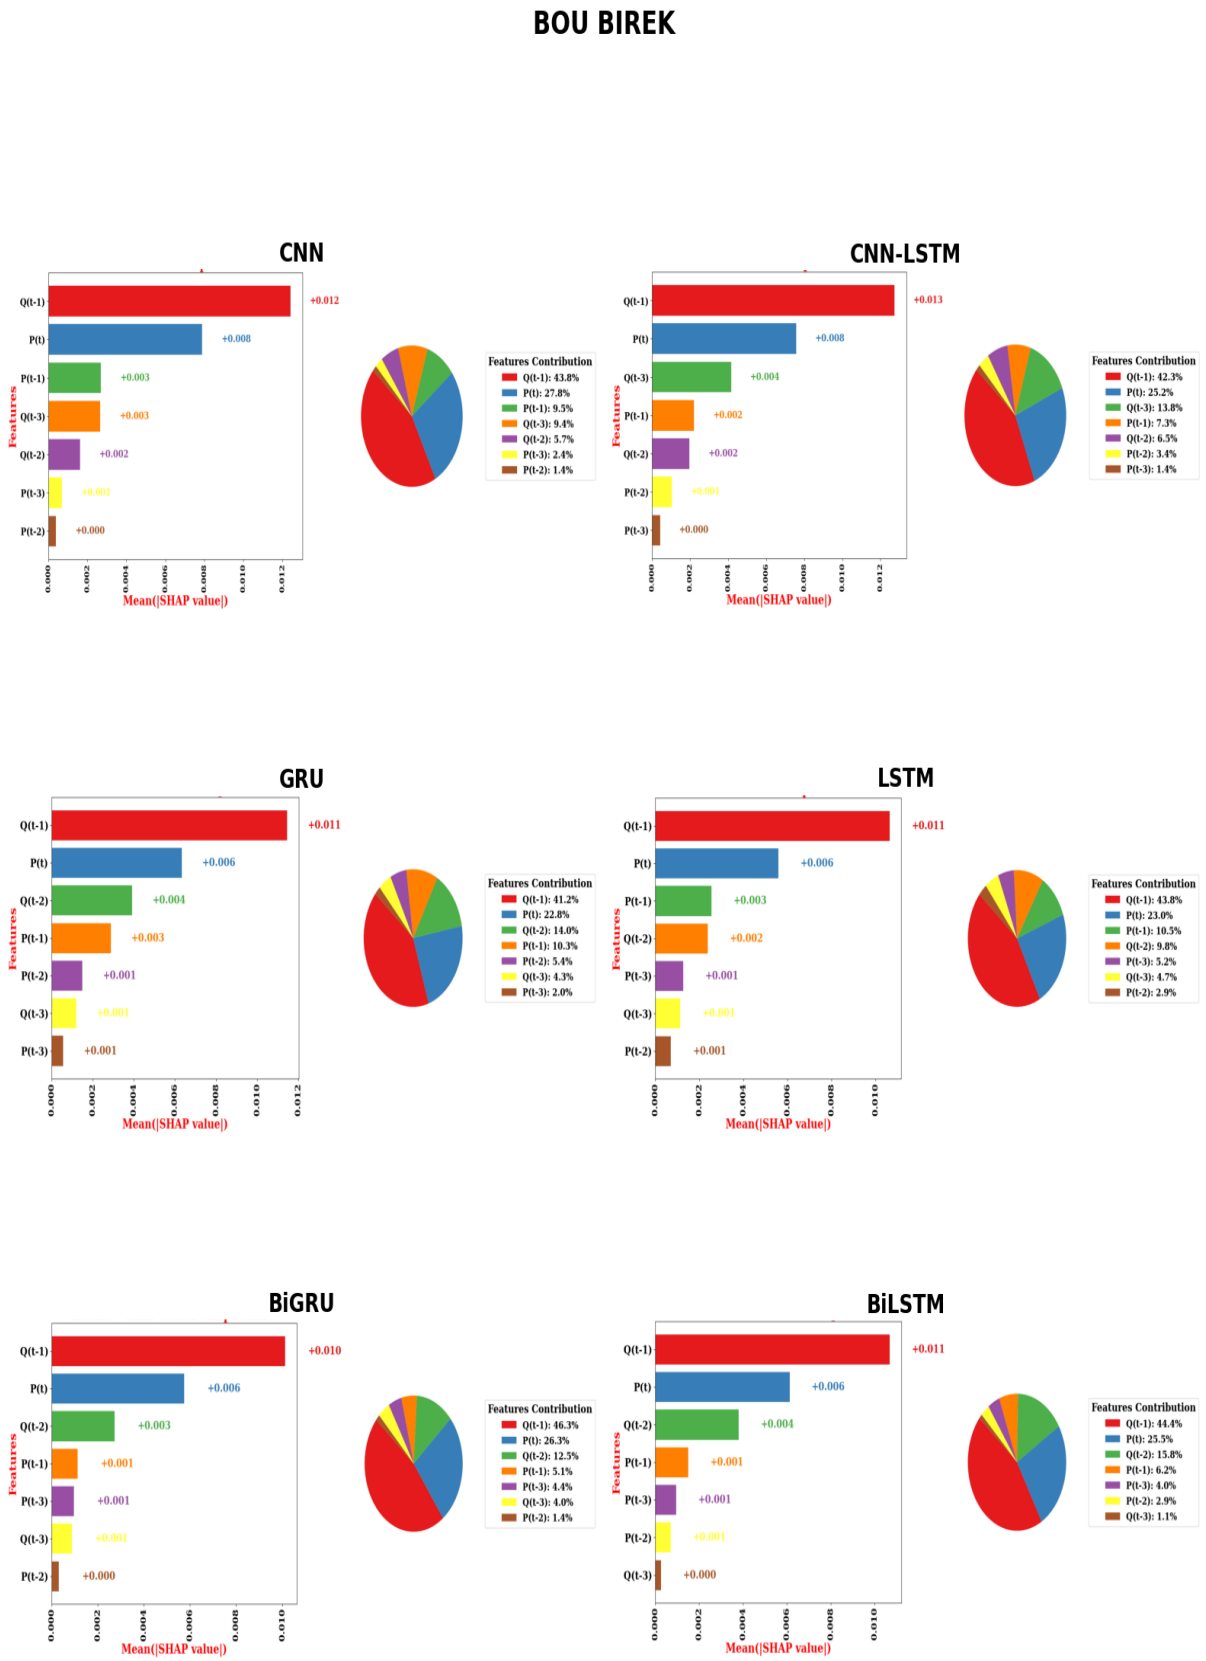


Figure IV.12. Distribution des contributions des variables d'entrée aux prédictions des modèles (SHAP **Pie Charts**) à la station BOU BIREK

L'analyse des figures **SHAP** permet de mieux comprendre l'influence des variables d'entrée sur les prédictions des modèles de *deep learning* pour les deux stations étudiées. Les résultats montrent que l'importance des variables n'est pas uniforme, mais dépend fortement des caractéristiques hydrologiques spécifiques à chaque station.

À la station FERMATOU, les résultats révèlent que les précipitations actuelles, **P(t),** joue le rôle dominant dans la modélisation pour l'ensemble des modèles avec des contributions allant de 38,8 % à 54,4 % (Figure IV.11). Cette importance élevée indique une forte réactivité immédiate du système aux événements pluviométriques, les débits passés tels que **Q(t-1)** viennent en seconde position (Figure IV.9).

En revanche, à la station BOU BIREK, les variables liées aux débits passés, en particulier **Q(t-1)**, sont prédominantes avec des contributions atteignant 41,2 % à 46,3 %. Les variables de précipitation, notamment **P(t),** présentent une contribution significative (22,8 % à 27,8 %), mais restent inférieures à celle des débits antérieurs (Figure IV.12). Cette prédominance des débits passés à BOU BIREK traduit une plus forte dépendance temporelle et un effet de mémoire hydrologique plus marqué du bassin.

Les graphiques de type *summary plot* confirment ces observations en montrant la distribution des valeurs **SHAP**. Les variables les plus importantes présentent une dispersion plus large, indiquant un impact plus variable sur les prédictions. Les valeurs élevées des variables (représentées en rouge) sont généralement associées à une augmentation des débits simulés, ce qui est cohérent avec le comportement hydrologique attendu.

Globalement, ces influences distinctes sont particulièrement bien capturées par les modèles comme le CNN-LSTM, ce qui montre que ce type d'architecture est capable d'intégrer efficacement et d'adapter les effets combinés des précipitations et des conditions hydrologiques antérieures selon le contexte spécifique du bassin étudié. Dans l'ensemble, les résultats SHAP confirment que les modèles les plus performants, notamment CNN et CNN-LSTM, exploitent efficacement les variables les plus pertinentes. Cette analyse permet ainsi de valider la cohérence physique des modèles tout en améliorant leur interprétabilité.

IV. 5 Mise en perspective des résultats obtenus par rapport à la littérature scientifique

Dans cette partie, les résultats obtenus à partir des modèles de *deep learning* sont confrontés à ceux existants dans la littérature scientifique. Cette démarche vise à évaluer la

cohérence des performances observées avec celles rapportées dans des études similaires, notamment en ce qui concerne l'efficacité des différentes architectures dans la modélisation des débits journaliers. Elle permet également de situer la contribution de ce travail par rapport aux recherches antérieures, en mettant en évidence les points de convergence ainsi que les éventuelles divergences liées aux caractéristiques hydrologiques des bassins étudiés et aux données utilisées.

Dans une perspective de positionnement scientifique rigoureux, les performances obtenues dans le bassin versant de la Soummam s'inscrivent dans un cadre comparatif riche, tant à l'échelle nationale qu'internationale. Cette analyse permet d'évaluer la pertinence des architectures développées au regard de l'état de l'art actuel.

À l'échelle nationale, les travaux de Daif (2024), réalisés notamment sur des stations du bassin de la Soummam, montrent que les modèles d'intelligence artificielle classiques tels que le MLPNN atteignent des performances modérées (NSE ≈ 0,789 à FERMATOU et ≈ 0,872 à BOU BIREK). En revanche, l'intégration de techniques de décomposition du signal comme la Variational Mode Decomposition (VMD) permet d'atteindre des performances nettement supérieures (NSE ≈ 0,972 et ≈ 0,959). En comparaison, les modèles développés dans cette étude, notamment CNN1 (NSE ≈ 0,879) et CNN-LSTM1 (NSE ≈ 0,884), surpassent clairement les approches d'IA simples, tout en restant légèrement inférieurs aux modèles hybrides fortement optimisés. Cela met en évidence un compromis pertinent entre performance et simplicité méthodologique.

Cette tendance est cohérente avec les résultats de Tikhamarine (2021) dans le bassin de la Seybouse, où les modèles classiques (MLP, SVR) présentent des performances satisfaisantes (NSE ≈ 0,88–0,90), tandis que les approches hybrides intégrant des ondelettes et des algorithmes d'optimisation (W-MLP, LSSVR-SCA) atteignent des performances plus élevées (NSE ≈ 0,954–0,971). Ces résultats confirment que la décomposition fréquentielle améliore la capacité des modèles à représenter les dynamiques multi-échelles du ruissellement. Dans le même contexte, Bouna et al. (2025) montrent que les modèles de deep learning appliqués à des données satellitaires en Algérie présentent généralement des performances plus modestes (NSE > 0,60), inférieures à celles obtenues dans cette étude, soulignant ainsi l'importance de la qualité et de la représentativité des données d'entrée.

Par ailleurs, Zerouali et al. (2025), à travers un modèle hybride RFE-CNN-GRU appliqué au bassin du Cheliff, rapportent des performances relativement limitées (R ≈ 0,88 ; RMSE ≈

3,61), comparées aux résultats obtenus dans ce travail (R ≈ 0,93 ; RMSE ≈ 0,339–0,884). Cela suggère que l'augmentation de la complexité algorithmique n'implique pas nécessairement une amélioration systématique des performances, notamment en présence de données bruitées ou peu représentatives.

À l'échelle internationale, les travaux de Liu et al. (2026) montrent que les modèles de *deep learning* classiques (CNN, LSTM, GRU) peuvent atteindre des performances très élevées (NSE ≈ 0,973–0,976), tandis que les architectures hybrides intégrant des données multi-sources dépassent parfois 0,98. Toutefois, ces résultats sont généralement obtenus dans des bassins bien instrumentés et caractérisés par des régimes hydrologiques plus réguliers, ce qui limite leur comparabilité directe avec le contexte semi-aride et non stationnaire du bassin de la Soummam. Cette influence du contexte est également soulignée par Kapoor et Chandra (2026), qui rapportent des performances nettement plus faibles dans des bassins arides (NSE ≈ 0,589–0,665), confirmant que les résultats obtenus dans cette étude (NSE ≈ 0,87) peuvent être considérés comme élevés dans des conditions hydrologiques complexes.

De plus, Xie et al. (2026) montrent que l'intégration de techniques avancées de décomposition combinées à des architectures optimisées (APSO-VMD-STA-GRU) permet d'atteindre des performances exceptionnelles (NSE > 0,99), bien supérieures à celles des modèles simples. Toutefois, ces approches soulèvent des questions liées au sur-ajustement et à la transférabilité des modèles. Dans une approche complémentaire, Li et al. (2024) mettent en évidence l'intérêt de l'intégration de contraintes physiques dans les modèles de *deep learning*, améliorant la cohérence hydrologique des prédictions (NSE ≈ 0,70), bien que ces performances restent inférieures à celles obtenues dans ce travail. Par ailleurs, Ouyang et al. (2025) montrent que des techniques telles que le transfert d'apprentissage peuvent constituer une alternative efficace pour améliorer les performances dans des contextes à données limitées. Enfin, les travaux de Gharehbaghi, Heddam et al. (2026) confirment la valeur ajoutée de l'hybridation ; ils démontrent notamment que le couplage de couches convolutionnelles et récurrentes (ex. BiRNN-CNN) améliore non seulement la stabilité des prévisions, mais surtout la capacité du modèle à capturer les valeurs extrêmes (les pics) dans des séries temporelles complexes. Toutefois, cette précision accrue s'obtient au prix d'une augmentation significative de la complexité et d'une diminution de l'interprétabilité.

Dans ce contexte global, les résultats obtenus dans cette étude apparaissent comme robustes et scientifiquement cohérents. Les modèles développés, en particulier les architectures

CNN et CNN-LSTM, présentent des performances élevées, comparables à celles rapportées dans plusieurs travaux récents. Bien que certaines approches fortement hybridées puissent atteindre des niveaux de précision légèrement supérieurs, les résultats obtenus ici restent très satisfaisants compte tenu de l'utilisation de données hydrologiques réelles, souvent caractérisées par leur variabilité et leur bruit.

Ce positionnement met en évidence l'intérêt d'une approche basée sur des architectures efficaces et relativement simples, capables de fournir des résultats fiables tout en conservant une bonne capacité de généralisation. De plus, l'intégration de l'approche SHAP permet d'apporter une dimension interprétative essentielle, en assurant une cohérence entre les prédictions des modèles et les processus hydrologiques sous-jacents. Ainsi, cette étude montre que la performance d'un modèle hydrologique ne dépend pas uniquement de sa complexité, mais également de sa capacité à exploiter efficacement les données disponibles, à rester robuste face aux incertitudes, et à produire des résultats interprétables et cohérents avec le fonctionnement réel du bassin versant.

IV. 5 Conclusion

En conclusion, ce chapitre a permis d'évaluer et d'analyser les performances des différents modèles de *deep learning* appliqués à la modélisation des débits journaliers au niveau des stations FERMATOU et BOU BIREK. Les résultats ont montré la supériorité des modèles CNN et CNN-LSTM, capables de reproduire efficacement la dynamique hydrologique du bassin. L'analyse comparative, appuyée par des indicateurs statistiques et des outils graphiques, a confirmé la robustesse de ces modèles. Par ailleurs, l'approche SHAP a apporté une meilleure compréhension du rôle des variables d'entrée, renforçant ainsi l'interprétabilité des résultats. Enfin, la comparaison avec la littérature a permis de situer ce travail dans un cadre scientifique cohérent, mettant en évidence un bon compromis entre performance, robustesse et interprétation des modèles.

CONCLUSION GENERALE

CONCLUSION GENERALE

Ce travail a porté sur l'application des techniques de deep learning à la modélisation pluie–débit dans le bassin versant de la Soummam, situé dans le nord de l'Algérie. L'objectif principal de cette étude était d'évaluer la capacité de différentes architectures de deep learning à reproduire les débits journaliers observés au niveau des stations hydrométriques de FERMATOU et de BOU BIREK. Pour cela, plusieurs modèles ont été développés et comparés, notamment les modèles LSTM, GRU, CNN, BiLSTM, BiGRU ainsi que l'architecture hybride CNN-LSTM. Le travail, a également inclus une phase de prétraitement des données hydrométéorologiques, ainsi qu'une analyse d'interprétabilité basée sur l'approche SHAP afin de mieux comprendre l'influence des variables d'entrée sur les prédictions des modèles.

Les résultats obtenus ont montré que les modèles convolutionnels et hybrides présentent globalement les meilleures performances pour la simulation des débits journaliers. Au niveau de la station de FERMATOU, les modèles CNN1 et CNN-LSTM1 ont fourni les meilleurs résultats de validation avec des valeurs élevées des indicateurs statistiques R, NSE et KGE, traduisant ainsi une bonne capacité à reproduire la dynamique hydrologique du bassin. Le modèle CNN1 a particulièrement présenté les erreurs de prédiction les plus faibles, tandis que le modèle CNN-LSTM1 a montré une meilleure stabilité dans la représentation des écoulements journaliers.

Concernant la station de BOU BIREK, les résultats ont également confirmé la supériorité des modèles CNN et CNN-LSTM par rapport aux architectures récurrentes classiques. Malgré la forte variabilité hydrologique observée dans ce sous-bassin, ces modèles ont réussi à mieux capter les relations non linéaires entre les précipitations et les débits observés. Les analyses statistiques et graphiques réalisées ont montré une bonne concordance entre les débits simulés et les débits observés.

L'analyse comparative des modèles a également permis de mettre en évidence l'importance des variables temporelles et des débits retardés dans la prévision hydrologique. Les matrices de corrélation ainsi que l'analyse SHAP ont confirmé que les variables liées à la pluie et même de débit antérieurs constituent les paramètres les plus influents dans les prédictions réalisées par les modèles. L'intégration de l'approche SHAP représente ainsi un

apport important dans ce travail puisqu'elle améliore l'interprétabilité des modèles et facilite la compréhension des mécanismes hydrologiques du bassin versant étudié.

Enfin, plusieurs perspectives peuvent être envisagées pour approfondir ce travail. Il serait intéressant d'intégrer d'autres variables hydro-climatiques telles que la température, l'humidité du sol ou l'évapotranspiration afin d'améliorer davantage les performances des modèles. L'utilisation de données satellitaires et climatiques à haute résolution, pourrait également contribuer à une meilleure précision des simulations hydrologiques. De plus, le développement de nouvelles architectures hybrides plus avancées, ainsi que l'application de ces approches à d'autres bassins versants algériens, constituent des perspectives prometteuses pour de futurs travaux dans le domaine de la modélisation hydrologique par intelligence artificielle.

Références bibliographiques

1. Abrahart, R. J., Anctil, F., Coulibaly, P., Dawson, C. W., Mount, N. J., See, L. M., Shamseldin, A. Y., Solomatine, D. P., Toth, E., & Wilby, R. L. (2012). Two decades of anarchy ? Emerging themes and outstanding challenges for neural network river forecasting. Progress in Physical Geography, 36(4), 480–513. https://doi.org/10.1177/0309133312444943

2. Adnan, R. M., Liang, Z., Trajkovic, S., Zounemat-Kermani, M., Li, B., & Kisi, O. (2019). Daily streamflow prediction using optimally pruned extreme learning machine. Journal of Hydrology, 577, 123981. https://doi.org/10.1016/j.jhydrol.2019.123981

3. Agence Nationale des Ressources Hydrauliques. (2021). Données hydrométriques et pluviométriques du bassin versant de la Soummam [Base de données]. ANRH, Alger.

4. Alam, M. S., et al. (2025). Sentiment analysis in social media : How data science impacts public opinion knowledge integrates natural language processing (NLP) with artificial intelligence (AI). American Journal of Scholarly Research and Innovation, 4(1), 63–100. https://doi.org/10.63125/r3sq6p80

5. Ambroise, B. (1999). Genèse des débits dans les petits bassins versants ruraux en milieu tempéré : 2. Modélisation systémique et dynamique. Revue des Sciences de l'Eau, 12, 123–153. https://doi.org/10.7202/705346ar

6. Andréassian, V. (2002). Impact de l'évolution du couvert forestier sur le comportement hydrologique des bassins versants (Thèse de doctorat). Université Pierre et Marie Curie (Paris VI), France.

7. Bayati, A., Ameli, A. A., & Razavi, S. (2025). Evaluating the functional realism of deep learning rainfall-runoff models using catchment hydrology principles. Water Resources Research, 61, e2025WR040076. https://doi.org/10.1029/2025WR040076

8. Bellout, M. (2015). Étude de la répartition fréquentielle et annuelle des débits des cours d'eau de l'Algérie du Nord. Mémoire de Magister, Département de Génie Civil et Hydraulique, Université Kasdi Merbah Ouargla, Algérie.

9. Berthier, C. H. (2005). Quantification des incertitudes des débits calculés par un modèle pluie-débit empirique. Université Paris Sud XI, Paris.

10. Beven, K. J. (2001). How far can we go in distributed hydrological modelling ? Hydrology and Earth System Sciences, 5(1), 1–12. https://doi.org/10.5194/hess-5-1-2001

11. Beven, K. J. (2012). Rainfall-runoff modelling : The primer (2nd ed.). Wiley-Blackwell.

12. Brutsaert, W. (2005). Hydrology : An introduction. Cambridge University Press.

13. Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE) ? Arguments against avoiding RMSE in the literature. Geoscientific Model Development, 7(3), 1247–1250. https://doi.org/10.5194/gmd-7-1247-2014

14. Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP) (pp. 1724–1734). Association for Computational Linguistics. https://doi.org/10.3115/v1/D14-1179

15. Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). Applied hydrology. McGraw-Hill.

16. Clarke, R. T. (1973). Mathematical models in hydrology (FAO Irrigation and Drainage Paper No. 19). Food and Agriculture Organization of the United Nations.

17. Daif, N. (2025). Test de plusieurs modèles pluie-débit à différents pas de temps : Cas du Nord algérien (Thèse de doctorat, Université 20 Août 1955 de Skikda).

18. Daniel, R., Jouandeau, N., & Odhiambo, D. (2024). LSTM versus transformers : A practical comparison and combination of deep learning models for trading financial instruments. HAL Open Science. https://hal.science/hal-05487901

19. Dingman, S. L. (2015). Physical hydrology (3rd ed.). Waveland Press.

20. Duchaufour, P. (1975). Pédologie : Pédogenèse et classification (Vol. 1). Masson.

21. Duchaufour, P. (1975). Précis de pédologie. Paris, France : Masson.

22. Edijatno, & Michel, C. (1989). Un modèle pluie-débit journalier à trois paramètres. La Houille Blanche, 2, 113–122. https://doi.org/10.1051/lhb/1989007

23. Farfán-Durán, J. F., & Cea, L. (2024). Streamflow forecasting with deep learning models : A side-by-side comparison in Northwest Spain. Earth Science Informatics. https://doi.org/10.1007/s12145-024-01454-9

24. Frame, J. M., Kratzert, F., Klotz, D., Gauch, M., Shalev, G., Gilon, O., & Nearing, G. S. (2022). Deep learning rainfall-runoff predictions of extreme events. Hydrology and Earth System Sciences, 26(13), 3377–3392. https://doi.org/10.5194/hess-26-3377-2022

25. Gharehbaghi, A., Heddam, S., Mehdizadeh, S., & Kim, S. (2026). A comparative evaluation of deep learning and machine learning models for river suspended sediment concentration forecasting. Water Resources Management, 40, 15. https://doi.org/10.1007/s11269-025-04401-5

26. Ghimire, S., Yaseen, Z. M., Farooque, A. A., Deo, R. C., Zhang, J., & Tao, X. (2021). Streamflow prediction using an integrated methodology based on convolutional neural network and long short-term memory networks. Scientific Reports, 11, Article 16751. https://doi.org/10.1038/s41598-021-96751-4

27. 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 en Génie Civil, Institut National des Sciences Appliquées de Lyon (INSA Lyon).

28. Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria : Implications for improving hydrological modelling. Journal of Hydrology, 377(1–2), 80–91. https://doi.org/10.1016/j.jhydrol.2009.08.003

29. 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, École Nationale Polytechnique).

30. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

31. Hydrologic Engineering Center. (1998). HEC-1 flood hydrograph package : User's manual (Version 4.1). U.S. Army Corps of Engineers.

32. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. International Journal of Forecasting, 22(4), 679–688. https://doi.org/10.1016/j.ijforecast.2006.03.001

33. 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. https://doi.org/10.3923/jest.2012.249.261

34. Kapoor, A., & Chandra, R. (2026). QDeepGR4J : Quantile-based ensemble of deep learning and GR4J hybrid rainfall-runoff models for extreme flow prediction with uncertainty quantification. Journal of Hydrology, 664(Part B), 134434. https://doi.org/10.1016/j.jhydrol.2025.134434

35. Khosravi, K., Golkarian, A., & Tiefenbacher, J. P. (2022). Using optimized deep learning to predict daily streamflow : A comparison to common machine learning algorithms. Water Resources Management, 36, 699–716. https://doi.org/10.1007/s11269-021-03051-7

36. Kim, T. Y., & Cho, S. B. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. Energy, 182, 72–81. https://doi.org/10.1016/j.energy.2019.05.230

37. Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications : A survey. Mechanical Systems and Signal Processing, 151, 107398. https://doi.org/10.1016/j.ymssp.2020.107398

38. Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall-runoff modelling using long short-term memory (LSTM) networks. Hydrology and Earth System Sciences, 22(11), 6005–6022. https://doi.org/10.5194/hess-22-6005-2018

39. Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. (2019). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. Hydrology and Earth System Sciences, 23(12), 5089–5110. https://doi.org/10.5194/hess-23-5089-2019

40. Kratzert, F., Herrnegger, M., Klotz, D., Hochreiter, S., & Klambauer, G. (2019). NeuralHydrology – Interpreting LSTMs in hydrology. In W. Samek, G. Montavon, A. Vedaldi, L. K. Hansen, & K.-R. Müller (Eds.), Explainable AI : Interpreting, explaining and visualizing deep learning (pp. 347–362). Springer. https://doi.org/10.1007/978-3-030-28954-6_19

41. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In F. Pereira, L. Bottou, C. Burges, & K. Q. Weinberger (Eds.), Advances in Neural Information Processing Systems (Vol. 25, pp. 1097–1105). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45-Paper.pdf

42. Le Clerc, S. (2004). Revisiter la notion de scénario hydrologique de référence pour la caractérisation des inondations (Thèse de doctorat). Université Joseph Fourier, Grenoble.

43. LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. Neural Computation, 1(4), 541–551. https://doi.org/10.1162/neco.1989.1.4.541

44. Lees, T., Reece, S., Kratzert, F., Klotz, D., Gauch, M., De Bruijn, J., Kumar Sahu, R., Greve, P., Slater, L., & Dadson, S. J. (2022). Hydrological concept formation inside long short-term memory (LSTM) networks. Hydrology and Earth System Sciences, 26(12), 3079–3101. https://doi.org/10.5194/hess-26-3079-2022

45. Li, H., Zhang, C., Chu, W., Shen, D., & Li, R. (2024). A process-driven deep learning hydrological model for daily rainfall-runoff simulation. Journal of Hydrology, 637, 131434. https://doi.org/10.1016/j.jhydrol.2024.131434

46. Liu, J., Gu, C., Wang, J., Dong, Y., & Huang, S. (2025). AI-assisted monitoring and prediction of structural displacements in large-scale hydropower facilities. Water, 17(20), 2996. https://doi.org/10.3390/w17202996

47. Liu, W., Mo, L., Li, X., Xiao, W., Huang, H., & Zhang, Y. (2026). A hybrid deep learning rainfall-runoff forecasting model incorporating spatiotemporal information from multi-source data. Expert Systems with Applications, 298(Part D), 129974. https://doi.org/10.1016/j.eswa.2025.129974

48. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), Advances in Neural Information Processing Systems (Vol. 30).

49. Maftei, C. (2002). Étude concernant les écoulements superficiels (Thèse de doctorat). Université Ovidius, Constanța.

50. Mahdi, E., Martin-Barreiro, C., & Cabezas, X. (2025). A novel hybrid approach using an attention-based transformer + GRU model for predicting cryptocurrency prices. Mathematics, 13(9), 1484. https://doi.org/10.3390/math13091484

51. Meddi, M., & Toumi, S. (2015). Incertitude des données pluviométriques en Algérie du Nord et impact sur l'estimation des quantiles des pluies journalières maximales annuelles. Larhyss Journal, 23, 213–229.

52. Meddi, M., & Toumi, S. (2015). Spatial variability and cartography of maximum annual daily rainfall under different return periods in Northern Algeria. Journal of Water and Land Development.

53. Mena, N. B. (2024). Application of SA-Conv1D-BiGRU model for streamflow prediction in southern Ethiopia. Hydrology Research, 55(9), 936–957. https://doi.org/10.2166/nh.2024.074

54. 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

55. Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. Transactions of the ASABE, 50(3), 885–900. https://doi.org/10.13031/2013.23153

56. Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I : A discussion of principles. Journal of Hydrology, 10(3), 282–290. https://doi.org/10.1016/0022-1694(70)90255-6

57. Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., & Gupta, H. V. (2021). What role does hydrological science play in the age of machine learning ? Water Resources Research, 57(3), e2020WR028091. https://doi.org/10.1029/2020WR028091

58. Nourani, V., Andalib, G., Sadikoglu, F., & Sharghi, E. (2018). Cascade-based multi-scale AI approach for modeling rainfall-runoff process. Hydrology Research, 49(4), 1191–1207. https://doi.org/10.2166/nh.2017.045

59. Oudin, L. (2004). Recherche d'un modèle d'évapotranspiration potentielle pertinent comme entrée d'un modèle pluie-débit global (Thèse de doctorat). ENGREF, Paris.

60. Oudin, L., Andréassian, V., Perrin, C., & Anctil, F. (2004). Locating the sources of low-pass behavior within rainfall-runoff models. Water Resources Research, 40(11), W11101. https://doi.org/10.1029/2004WR003291

61. Ouyang, W., Zhang, C., Ye, L., Zhang, H., Meng, Z., & Chu, J. (2025). Dive into transfer-learning for daily rainfall-runoff modeling in data-limited basins. Journal of Hydrology, 133063. https://doi.org/10.1016/j.jhydrol.2025.133063

62. 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.

63. Perrin, C. (2000). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative (Thèse de doctorat). Institut National Polytechnique de Grenoble.

64. Refsgaard, J. C. (1997). Parameterisation, calibration and validation of distributed hydrological models. Journal of Hydrology, 198(1–4), 69–97. https://doi.org/10.1016/S0022-1694(96)03329-X

65. Sanikhani, H., Deo, R. C., Yaseen, Z. M., Eray, O., & Kisi, O. (2018). Non-tuned data intelligent model for soil temperature estimation : A new approach. Geoderma, 330, 52–64. https://doi.org/10.1016/j.geoderma.2018.05.030

66. Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. IEEE Transactions on Signal Processing, 45(11), 2673–2681. https://doi.org/10.1109/78.650093

67. Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. Water Resources Research, 54(11), 8558–8593. https://doi.org/10.1029/2018WR022643

68. Shen, C., & Lawson, K. (2021). Applications of deep learning in hydrology. In G. Camps-Valls, D. Tuia, X. X. Zhu, & M. Reichstein (Eds.), Deep learning for the earth sciences : A

comprehensive approach to remote sensing, climate science and geosciences (pp. 285–297). Wiley. https://doi.org/10.1002/9781119646181.ch19

69. Solomatine, D. P., & Ostfeld, A. (2008). Data-driven modelling : Some past experiences and new approaches. Journal of Hydroinformatics, 10(1), 3–22. https://doi.org/10.2166/hydro.2008.015

70. Subramaniyam, C., Amaguchi, H., & Imamura, Y. (2025). Real-time flood runoff prediction for a small-to-medium-scale urban river watershed using a bidirectional long short-term memory model (BiLSTM). Journal of JSCE, 12(2), 24-27025. https://www.jstage.jst.go.jp/article/journalofjsce/12/2/12_24-27025/_article

71. Tikhamarine, Y. (2021). Prévision des débits journaliers et mensuels par les modèles de l'intelligence artificielle (Thèse de doctorat, Université des Sciences et de la Technologie Houari Boumediene).

72. Tran, V.-L., Cuong, V. T., & Nguyen, T.-Q. (2023). One-dimensional convolutional neural network for damage detection of structures using time series data. Asian Journal of Civil Engineering, 25(1), 1–34. https://doi.org/10.1007/s42107-023-00816-w

73. Vaze, J., Jordan, P., Beecham, R., Frost, A., & Summerell, G. (2011). Guidelines for rainfall-runoff modelling : Towards best practice model application. eWater Cooperative Research Centre.

74. Waqas, M., & Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. MethodsX, 13, 102946. https://doi.org/10.1016/j.mex.2024.102946

75. Weißenborn, M., Breuer, L., & Houska, T. (2025). Neural networks in catchment hydrology : A comparative study of different algorithms in an ensemble of ungauged basins in Germany. Hydrology and Earth System Sciences, 29, 5131–5164. https://doi.org/10.5194/hess-29-5131-2025

76. Xie, X., Huang, G., Wang, S., Wang, F., & Xie, S. (2025). Interpretable deep learning for dynamic rainfall-runoff prediction : Integrating adaptive signal decomposition and spatiotemporal feature extraction. Journal of Environmental Management, 398, 128444. https://doi.org/10.1016/j.jenvman.2025.128444

77. Zerouali, B., Santos, C. A. G., Alodah, A., Abda, Z., Nahas, F., Bailek, N., & Youssef, Y. M. (2025). Next-generation runoff prediction : Merging RFE, SHAP insights, and satellite data with innovative deep learning techniques. Journal of Hydrology : Regional Studies, 62, 102870. https ://doi.org/10.1016/j.ejrh.2025.102870Références bibliographiques

1. Abrahart, R. J., Anctil, F., Coulibaly, P., Dawson, C. W., Mount, N. J., See, L. M., Shamseldin, A. Y., Solomatine, D. P., Toth, E., & Wilby, R. L. (2012). Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting. Progress in Physical Geography, 36(4), 480–513. https://doi.org/10.1177/0309133312444943

2. Adnan, R. M., Liang, Z., Trajkovic, S., Zounemat-Kermani, M., Li, B., & Kisi, O. (2019). Daily streamflow prediction using optimally pruned extreme learning machine. Journal of Hydrology, 577, 123981. https://doi.org/10.1016/j.jhydrol.2019.123981

3. Agence Nationale des Ressources Hydrauliques. (2021). Données hydrométriques et pluviométriques du bassin versant de la Soummam [Base de données]. ANRH, Alger.

4. Alam, M. S., et al. (2025). Sentiment analysis in social media: How data science impacts public opinion knowledge integrates natural language processing (NLP) with artificial intelligence (AI). American Journal of Scholarly Research and Innovation, 4(1), 63–100. https://doi.org/10.63125/r3sq6p80

5. Ambroise, B. (1999). Genèse des débits dans les petits bassins versants ruraux en milieu tempéré : 2. Modélisation systémique et dynamique. Revue des Sciences de l'Eau, 12, 123–153. https://doi.org/10.7202/705346ar

6. Andréassian, V. (2002). Impact de l'évolution du couvert forestier sur le comportement hydrologique des bassins versants (Thèse de doctorat). Université Pierre et Marie Curie (Paris VI), France.

7. Bayati, A., Ameli, A. A., & Razavi, S. (2025). Evaluating the functional realism of deep learning rainfall-runoff models using catchment hydrology principles. Water Resources Research, 61, e2025WR040076. https://doi.org/10.1029/2025WR040076

8. Berthier, C. H. (2005). Quantification des incertitudes des débits calculés par un modèle pluie-débit empirique. Université Paris Sud XI, Paris.

9. Beven, K. J. (2001). How far can we go in distributed hydrological modelling? Hydrology and Earth System Sciences, 5(1), 1–12. https://doi.org/10.5194/hess-5-1-2001

10. Beven, K. J. (2012). Rainfall-runoff modelling: The primer (2nd ed.). Wiley-Blackwell.

11. Brutsaert, W. (2005). Hydrology: An introduction. Cambridge University Press.

12. Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. Geoscientific Model Development, 7(3), 1247–1250. https://doi.org/10.5194/gmd-7-1247-2014

13. Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP) (pp. 1724–1734). Association for Computational Linguistics. https://doi.org/10.3115/v1/D14-1179

14. Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). Applied hydrology. McGraw-Hill.

15. Clarke, R. T. (1973). Mathematical models in hydrology (FAO Irrigation and Drainage Paper No. 19). Food and Agriculture Organization of the United Nations.

16. Daif, N. (2025). Test de plusieurs modèles pluie-débit à différents pas de temps : Cas du Nord algérien (Thèse de doctorat, Université 20 Août 1955 de Skikda).

17. Daniel, R., Jouandeau, N., & Odhiambo, D. (2024). LSTM versus transformers: A practical comparison and combination of deep learning models for trading financial instruments. HAL Open Science. https://hal.science/hal-05487901

18. Dingman, S. L. (2015). Physical hydrology (3rd ed.). Waveland Press.

19. Duchaufour, P. (1975). Pédologie : Pédogenèse et classification (Vol. 1). Masson.

20. Edijatno, & Michel, C. (1989). Un modèle pluie-débit journalier à trois paramètres. La Houille Blanche, 2, 113–122. https://doi.org/10.1051/lhb/1989007

21. Farfán-Durán, J. F., & Cea, L. (2024). Streamflow forecasting with deep learning models: A side-by-side comparison in Northwest Spain. Earth Science Informatics. https://doi.org/10.1007/s12145-024-01454-9

22. Frame, J. M., Kratzert, F., Klotz, D., Gauch, M., Shalev, G., Gilon, O., & Nearing, G. S. (2022). Deep learning rainfall-runoff predictions of extreme events. Hydrology and Earth System Sciences, 26(13), 3377–3392. https://doi.org/10.5194/hess-26-3377-2022

23. Gharehbaghi, A., Heddam, S., Mehdizadeh, S., & Kim, S. (2026). A comparative evaluation of deep learning and machine learning models for river suspended sediment concentration forecasting. Water Resources Management, 40, 15. https://doi.org/10.1007/s11269-025-04401-5

24. Ghimire, S., Yaseen, Z. M., Farooque, A. A., Deo, R. C., Zhang, J., & Tao, X. (2021). Streamflow prediction using an integrated methodology based on convolutional neural network and long short-term memory networks. Scientific Reports, 11, Article 16751. https://doi.org/10.1038/s41598-021-96751-4

25. 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 en Génie Civil, Institut National des Sciences Appliquées de Lyon (INSA Lyon).

26. Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. Journal of Hydrology, 377(1–2), 80–91. https://doi.org/10.1016/j.jhydrol.2009.08.003

27. 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, École Nationale Polytechnique).

28. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

29. Hydrologic Engineering Center. (1998). HEC-1 flood hydrograph package: User's manual (Version 4.1). U.S. Army Corps of Engineers.

30. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. International Journal of Forecasting, 22(4), 679–688. https://doi.org/10.1016/j.ijforecast.2006.03.001

31. 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. https://doi.org/10.3923/jest.2012.249.261

32. Kapoor, A., & Chandra, R. (2026). QDeepGR4J: Quantile-based ensemble of deep learning and GR4J hybrid rainfall-runoff models for extreme flow prediction with uncertainty

quantification. Journal of Hydrology, 664(Part B), 134434. https://doi.org/10.1016/j.jhydrol.2025.134434

33. Khosravi, K., Golkarian, A., & Tiefenbacher, J. P. (2022). Using optimized deep learning to predict daily streamflow: A comparison to common machine learning algorithms. Water Resources Management, 36, 699–716. https://doi.org/10.1007/s11269-021-03051-7

34. Kim, T. Y., & Cho, S. B. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. Energy, 182, 72–81. https://doi.org/10.1016/j.energy.2019.05.230

35. Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. Mechanical Systems and Signal Processing, 151, 107398. https://doi.org/10.1016/j.ymssp.2020.107398

36. Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall-runoff modelling using long short-term memory (LSTM) networks. Hydrology and Earth System Sciences, 22(11), 6005–6022. https://doi.org/10.5194/hess-22-6005-2018

37. Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. (2019). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. Hydrology and Earth System Sciences, 23(12), 5089–5110. https://doi.org/10.5194/hess-23-5089-2019

38. Kratzert, F., Herrnegger, M., Klotz, D., Hochreiter, S., & Klambauer, G. (2019). NeuralHydrology – Interpreting LSTMs in hydrology. In W. Samek, G. Montavon, A. Vedaldi, L. K. Hansen, & K.-R. Müller (Eds.), Explainable AI: Interpreting, explaining and visualizing deep learning (pp. 347–362). Springer. https://doi.org/10.1007/978-3-030-28954-6_19

39. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In F. Pereira, L. Bottou, C. Burges, & K. Q. Weinberger (Eds.), Advances in Neural Information Processing Systems (Vol. 25, pp. 1097–1105). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45-Paper.pdf

40. Le Clerc, S. (2004). Revisiter la notion de scénario hydrologique de référence pour la caractérisation des inondations (Thèse de doctorat). Université Joseph Fourier, Grenoble.

41. LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. Neural Computation, 1(4), 541–551. https://doi.org/10.1162/neco.1989.1.4.541

42. Lees, T., Reece, S., Kratzert, F., Klotz, D., Gauch, M., De Bruijn, J., Kumar Sahu, R., Greve, P., Slater, L., & Dadson, S. J. (2022). Hydrological concept formation inside long short-term memory (LSTM) networks. Hydrology and Earth System Sciences, 26(12), 3079–3101. https://doi.org/10.5194/hess-26-3079-2022

43. Li, H., Zhang, C., Chu, W., Shen, D., & Li, R. (2024). A process-driven deep learning hydrological model for daily rainfall-runoff simulation. Journal of Hydrology, 637, 131434. https://doi.org/10.1016/j.jhydrol.2024.131434

44. Liu, J., Gu, C., Wang, J., Dong, Y., & Huang, S. (2025). AI-assisted monitoring and prediction of structural displacements in large-scale hydropower facilities. Water, 17(20), 2996. https://doi.org/10.3390/w17202996

45. Liu, W., Mo, L., Li, X., Xiao, W., Huang, H., & Zhang, Y. (2026). A hybrid deep learning rainfall-runoff forecasting model incorporating spatiotemporal information from multi-source data. Expert Systems with Applications, 298(Part D), 129974. https://doi.org/10.1016/j.eswa.2025.129974

46. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), Advances in Neural Information Processing Systems (Vol. 30).

47. Maftei, C. (2002). Étude concernant les écoulements superficiels (Thèse de doctorat). Université Ovidius, Constanța.

48. Mahdi, E., Martin-Barreiro, C., & Cabezas, X. (2025). A novel hybrid approach using an attention-based transformer + GRU model for predicting cryptocurrency prices. Mathematics, 13(9), 1484. https://doi.org/10.3390/math13091484

49. Meddi, M., & Toumi, S. (2015). Incertitude des données pluviométriques en Algérie du Nord et impact sur l'estimation des quantiles des pluies journalières maximales annuelles. Larhyss Journal, 23, 213–229.

50. Mena, N. B. (2024). Application of SA-Conv1D-BiGRU model for streamflow prediction in southern Ethiopia. Hydrology Research, 55(9), 936–957. https://doi.org/10.2166/nh.2024.074

51. 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

52. Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. Transactions of the ASABE, 50(3), 885–900. https://doi.org/10.13031/2013.23153

53. Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I: A discussion of principles. Journal of Hydrology, 10(3), 282–290. https://doi.org/10.1016/0022-1694(70)90255-6

54. Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., & Gupta, H. V. (2021). What role does hydrological science play in the age of machine learning? Water Resources Research, 57(3), e2020WR028091. https://doi.org/10.1029/2020WR028091

55. Nourani, V., Andalib, G., Sadikoglu, F., & Sharghi, E. (2018). Cascade-based multi-scale AI approach for modeling rainfall-runoff process. Hydrology Research, 49(4), 1191–1207. https://doi.org/10.2166/nh.2017.045

56. Oudin, L. (2004). Recherche d'un modèle d'évapotranspiration potentielle pertinent comme entrée d'un modèle pluie-débit global (Thèse de doctorat). ENGREF, Paris.

57. Oudin, L., Andréassian, V., Perrin, C., & Anctil, F. (2004). Locating the sources of low-pass behavior within rainfall-runoff models. Water Resources Research, 40(11), W11101. https://doi.org/10.1029/2004WR003291

58. Ouyang, W., Zhang, C., Ye, L., Zhang, H., Meng, Z., & Chu, J. (2025). Dive into transfer-learning for daily rainfall-runoff modeling in data-limited basins. Journal of Hydrology, 133063. https://doi.org/10.1016/j.jhydrol.2025.133063

59. 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.

60. Perrin, C. (2000). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative (Thèse de doctorat). Institut National Polytechnique de Grenoble.

61. Refsgaard, J. C. (1997). Parameterisation, calibration and validation of distributed hydrological models. Journal of Hydrology, 198(1–4), 69–97. https://doi.org/10.1016/S0022-1694(96)03329-X

62. Sanikhani, H., Deo, R. C., Yaseen, Z. M., Eray, O., & Kisi, O. (2018). Non-tuned data intelligent model for soil temperature estimation: A new approach. Geoderma, 330, 52–64. https://doi.org/10.1016/j.geoderma.2018.05.030

63. Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. IEEE Transactions on Signal Processing, 45(11), 2673–2681. https://doi.org/10.1109/78.650093

64. Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. Water Resources Research, 54(11), 8558–8593. https://doi.org/10.1029/2018WR022643

65. Shen, C., & Lawson, K. (2021). Applications of deep learning in hydrology. In G. Camps-Valls, D. Tuia, X. X. Zhu, & M. Reichstein (Eds.), Deep learning for the earth sciences: A comprehensive approach to remote sensing, climate science and geosciences (pp. 285–297). Wiley. https://doi.org/10.1002/9781119646181.ch19

66. Solomatine, D. P., & Ostfeld, A. (2008). Data-driven modelling: Some past experiences and new approaches. Journal of Hydroinformatics, 10(1), 3–22. https://doi.org/10.2166/hydro.2008.015

67. Subramaniyam, C., Amaguchi, H., & Imamura, Y. (2025). Real-time flood runoff prediction for a small-to-medium-scale urban river watershed using a bidirectional long short-term memory model (BiLSTM). Journal of JSCE, 12(2), 24-27025. https://www.jstage.jst.go.jp/article/journalofjsce/12/2/12_24-27025/_article

68. Tikhamarine, Y. (2021). Prévision des débits journaliers et mensuels par les modèles de l'intelligence artificielle (Thèse de doctorat, Université des Sciences et de la Technologie Houari Boumediene).

69. Tran, V.-L., Cuong, V. T., & Nguyen, T.-Q. (2023). One-dimensional convolutional neural network for damage detection of structures using time series data. Asian Journal of Civil Engineering, 25(1), 1–34. https://doi.org/10.1007/s42107-023-00816-w

70. Vaze, J., Jordan, P., Beecham, R., Frost, A., & Summerell, G. (2011). Guidelines for rainfall-runoff modelling: Towards best practice model application. eWater Cooperative Research Centre.

71. Waqas, M., & Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. MethodsX, 13, 102946. https://doi.org/10.1016/j.mex.2024.102946

72. Weißenborn, M., Breuer, L., & Houska, T. (2025). Neural networks in catchment hydrology: A comparative study of different algorithms in an ensemble of ungauged basins in Germany. Hydrology and Earth System Sciences, 29, 5131–5164. https://doi.org/10.5194/hess-29-5131-2025

73. Xie, X., Huang, G., Wang, S., Wang, F., & Xie, S. (2025). Interpretable deep learning for dynamic rainfall-runoff prediction: Integrating adaptive signal decomposition and spatiotemporal feature extraction. Journal of Environmental Management, 398, 128444. https://doi.org/10.1016/j.jenvman.2025.128444

74. Zerouali, B., Santos, C. A. G., Alodah, A., Abda, Z., Nahas, F., Bailek, N., & Youssef, Y. M. (2025). Next-generation runoff prediction: Merging RFE, SHAP insights, and satellite data with innovative deep learning techniques. Journal of Hydrology: Regional Studies, 62, 102870. https://doi.org/10.1016/j.ejrh.2025.102870