



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Faculté des sciences et sciences appliquées

Université Larbi Ben M'Hidi. Oum-El-Bouaghi

Département : Hydraulique

Thèse présentée en vue de l'obtention du diplôme de doctorat en 3ème cycle LMD

Option : hydraulique urbaine

N° d'ordre :

Sujet :

Modélisation pluie-débit et débits de crues en milieu semi-aride par différentes méthodes statistiques et modèles hydrologiques. Etude de cas

Par : Yamina AOULMI

Présentée est soutenue publiquement le 11/04/2022

DEVANT LES MEMBRES DU JURY:

<u>Nom et Prénom</u>	<u>Grade</u>	<u>Qualité</u>	<u>Université</u>
DJEDDOU Messaoud	Pr	Président	Oum El Bouaghi
MAROUF Nadir	Pr	Rapporteur	Oum El Bouaghi
AMIRECHE Mohamed	MCB	Co-Rapporteur	Oum El Bouaghi
SEKIOU Fateh	MCA	Examineur	Oum El Bouaghi
HOUICHI Larbi	Pr	Examineur	Batna II
BOUTAGHANE Hamouda	MCA	Examineur	Annaba

Remerciement

Je tiens tout d'abord à remercier Dieu, le tout-puissant, de m'avoir donné la volonté et la patience pour mener à bien ce modeste travail.

Je tiens à exprimer mes vifs remerciements à mes deux encadrateurs Mr. Nadir Marouf et Mr. Mohamed Amireche pour leurs appuis, leurs orientations et leurs conseils judicieux durant toute la période du projet.

Je tiens à remercier également les membres du jury pour l'honneur qu'ils m'ont fait en acceptant de juger et d'évaluer mon travail ainsi que tous les enseignants qui ont contribué à ma formation depuis le début.

Enfin, tous mes remerciements vont à ma famille et mes amis qui ont été nombreux à m'aider et à m'encourager.

Dédicaces

Tous les mots ne sauraient exprimer la gratitude, l'amour, le respect, la reconnaissance, c'est tout simplement que : Je dédie cette thèse de doctorat à :

A Ma tendre Mère « SOURAYA » : Tu représentes pour moi la source de tendresse et l'exemple de dévouement qui n'a pas cessé de m'encourager. Tu as fait plus qu'une mère puisse faire pour que ses enfants suivent le bon chemin dans leur vie et leurs études.

A Mon très cher Père « DJAMEL » : Aucune dédicace ne saurait exprimer l'amour, l'estime, le dévouement et le respect que j'ai toujours pour vous. Rien au monde ne vaut les efforts fournis jour et nuit pour mon éducation et mon bien être. Ce travail et le fruit de tes sacrifices que tu as consentis pour mon éducation et ma formation le long de ces années.

A Mes chers frères "ABDERREZAK" et "SOFIANE", les mots ne suffisent pas à exprimer l'attachement, l'amour et l'affection que je porte pour vous deux. Mes anges gardiens et mes fidèles compagnons dans les moments les plus délicats de cette vie mystérieuse. Je vous dédie ce travail avec tous mes vœux de bonheur, de santé et de réussite.

A tous mes enseignants depuis mes premières années d'études.

A mes chères amies AMIRA et HDJER,

A tous ceux qui me sont chers et que j'ai omis de citer.

« Yamina »

ملخص

يمكن أن يوفر تطوير نماذج موثوقة للسيول المائية معلومات مفيدة لتخطيط موارد المياه وإدارتها. في سياق البساطة ، تتميز النمذجة بواسطة نموذج الهندسة الزراعية (GR) ، وهو نموذج GR4j (نموذج الهندسة الزراعية مع 4 معلمات يومية) بميزة تتطلب فقط سلسلة من بيانات الأرصاد الجوية (المطر ، ETP) والقياس الهيدرومتري (التدفق) في خطوات الوقت اليومي. أصبح استخدام الشبكة العصبية الاصطناعية (RNA) لتبني مثل هذه النماذج والتنبؤ بالتغيرات في التدفق شائعاً بين العديد من علماء الهيدرولوجيا لفترة طويلة. جذب دمج مناهج التحسين الارشادية الحديثة مع RNA لزيادة أدائها الكثير من الاهتمام. من ناحية أخرى ، جذبت الشبكة العصبية التلافيفية للتعلم العميق (CNN) مؤخرًا اهتمامًا ملحوظًا من الباحثين ، تمامًا مثل RNA ، يؤدي دمجها مع مناهج التحسين الارشادية إلى تحسين كفاءتها.

يهدف هذا العمل البحثي أولاً إلى محاكاة تحويل هطول الأمطار إلى تدفق يومي في حوض سيبوس الواقع في منطقة شبه قاحلة في الجزائر ، باستخدام النموذج المفاهيمي GR4J. دفعتنا النتائج الضعيفة التي حصلت عليها هذه النماذج إلى تغيير محور التطبيق إلى نماذج الصندوق الأسود ، ولا سيما RNA ، في البداية. بالإضافة إلى ذلك ، اختبر جدوى استخدام RNA مع أربعة تكوينات للمدخلات لنمذجة التدفقات اليومية دائماً في نفس الحوض. الأول RNA I_P يأخذ بعين الاعتبار إلا هطول الأمطار فقط كمتغير إدخال. يعتبر الثاني RNA II_{P,Vv}, RNA II_{P,HUM}, RNA II_{P,ETP}, RNA II_{P,T} متغيراً ثانياً مع هطول الأمطار (التبخّر ، نتح الحرارة ، الرطوبة أو سرعة الرياح) في إدخال النموذج. يجمع الثالث RNA III_{P,T,HUM} بين درجة الحرارة والرطوبة وهطول الأمطار. يتكون الأخير RNA V_{P,ETP,T,HUM,Vv} من تجميع مختلف معلمات الأرصاد الجوية مع هطول الأمطار كمتغير إدخال. تم تصميم نماذج RNA للحوض بأكمله بنفس التكوينات على النحو المحدد أعلاه. تم توفير محاكاة أفضل للتدفق بواسطة RNA II_{P,T} و RNA II_{P,Vv} لمحطتي Medjez-Amar II و Bordj-Sabath ، على التوالي. إلا أن ، تطبيق RNA V_{P,ETP,T,HUM,Vv} للمحطات الأخرى وأيضاً للحوض بالكامل يعكس استراتيجية لمحاكاة التدفق ويظهر تحسناً في دقة التنبؤ مقارنة بالتكوينات الأخرى. تعمل التكوينات الأربعة للنماذج العصبية بشكل أفضل من نموذج GR4j لمحطات الدراسة الست.

بعد ذلك ، التحقق من كفاءة دمج نماذج RNA مع خوارزميات metaheuristic ؛ الخوارزميات الجينية GA ، تحسين حشد الجسيمات PSO ، خوارزمية اليراع FFA و خوارزمية تحسين سرب الجسيمات المحسنة IPSO ، أيضاً لنمذجة التدفق اليومي ، حيث تم تشكيل مدخلات النماذج من هطول الأمطار والتدفقات السابقة. كشفت نتائج التحليل في جميع محطات الدراسة أن نموذج RNA-IPSO يتفوق على أداء RNA-GA و RNA-PSO و RNA-FFA في تقدير التدفق. لذلك ، تعد الخوارزمية الهجينة IPSO هي أفضل تقنية لتحسين قدرة RNA في نمذجة التدفق اليومي.

أخيراً ، فحص الشبكة العصبية التلافيفية ذات التعلم العميق (CNN) وشبكة محسنة باستخدام خوارزمية إمبيرالية تنافسية (ICA) وتحسين الذئب الرمادي (GWO) للتنبؤ بالتدفق الساعي على نطاقات متعددة ، تتراوح من 100 كيلومتر مربع إلى أكثر من 6000 كيلومتر مربع في منطقة الدراسة. تم استخدام مجموعة بيانات إعادة تحليل الغلاف الجوي ، ERA5 بدقة 31 كم التي تم إنشاؤها بواسطة المركز الأوروبي للتنبؤات الجوية متوسطة المدى ، ومؤشرات تقلب المناخ ورصد التدفق في الموقع في نمذجة تدفق الفيضانات. تم استخدام تحليل المكون الرئيسي لتحديد أهم متغيرات المدخلات. كشفت النتائج في محطات الدراسة الست أن النماذج ذات المؤشرات المناخية تعمل بشكل أفضل ، خاصة في التنبؤ بالتدفقات الشديدة في الأحواض مع مناطق الصرف بين 200 كيلومتر مربع و 2000 كيلومتر مربع ، مقارنة بالنماذج التي تحتوي على بيانات الغلاف الجوي فقط كمدخلات. تفوق نموذج CNN-GWO على CNN-ICA والنموذج المستقل في التنبؤ بالتدفق مع NSE محسن حتى 0.99.

كلمات مفتاحية : حوض Seybouse ، التدفق ، تدفق الفيضانات ، النموذج المفاهيمي GR4J ، الشبكات العصبية الاصطناعية (RNA) ، الخوارزميات الجينية (GA) ، تحسين سرب الجسيمات (PSO) ، خوارزمية اليراع (FFA) ، الجسيمات المحسنة لتحسين سرب الجسيمات (IPSO) ، الشبكة العصبية التلافيفية (CNN) ، الخوارزمية الإميرالية التنافسية (ICA) ، تحسين الذئب الرمادي (GWO).

Résumé

Le développement de modèles pluie-débit fiables peut offrir des informations utiles pour la planification et la gestion des ressources en eau. Dans un contexte de simplicité, la modélisation par un modèle Génie Rural (GR), qui est le modèle GR4j (modèle du Génie Rural à 4 paramètres Journalier) a l'avantage de n'exiger que des séries de données météorologiques (pluie, ETP) et hydrométrique (débit) au pas de temps journalier. L'utilisation du réseau de neurones artificiels (RNA) pour adopter de tels modèles et prévoir les changements dans le débit est devenue populaire parmi de nombreux hydrologues depuis longtemps. L'intégration d'approches d'optimisation heuristiques modernes avec RNA pour augmenter ses performances, a attiré beaucoup d'attention. D'un autre côté, un apprentissage en profondeur d'un réseau de neurones convolutifs (CNN) a récemment suscité un intérêt remarquable de la part des chercheurs, et tout comme RNA, son intégration avec des outils heuristiques améliore davantage son efficacité.

Ce travail de recherche vise en premier lieu, de simuler la transformation de la pluie en débit journalier dans le bassin de la Seybouse situé dans une région semi-aride en Algérie, en utilisant le modèle conceptuel GR4J. Les mauvais résultats obtenus par ces modèles, nous incitent à changer l'axe d'application vers les modèles boîte noire notamment les RNA dans un premier temps. Par ailleurs, tester la faisabilité d'utilisation de RNA avec quatre configurations d'entrée pour modéliser toujours les débits journaliers dans le même bassin. La 1^{er} RNA I_P ne considère que les précipitations comme variable d'entrée. La 2^e RNA $II_{P,ETP}$, RNA $II_{P,T}$, RNA $II_{P,HUM}$, RNA $II_{P,VV}$ considère un 2^e variable dans l'entrée du modèle avec les précipitations (évapotranspiration, température, humidité ou vitesse du vent). La troisième RNA $III_{P,T,HUM}$ combine la température, l'humidité et les précipitations. Le dernier RNA $V_{P,ETP,T,HUM,VV}$ consiste à collationner les différents paramètres météorologiques avec les précipitations comme variable d'entrée. Les modèles RNA sont conçus pour l'ensemble du bassin avec les mêmes configurations que celles spécifiées ci-dessus. De meilleures simulations de débit ont été fournies par RNA $II_{P,T}$ et RNA $II_{P,VV}$ pour les deux stations de Medjez-Amar II et Bordj-Sabath, respectivement. Cependant, l'application de RNA $V_{P,ETP,T,HUM,VV}$ pour les autres stations et également pour l'ensemble du bassin reflète une stratégie pour la simulation de débit et montre une amélioration de la précision de prédiction par rapport aux autres configurations. Les quatre configurations des modèles neuronaux sont plus performantes que le modèle GR4j pour les six stations d'étude.

Après cela, vérifier l'efficacité de l'intégration de modèles RNA avec les algorithmes métaheuristiques; l'algorithmes génétiques GA, l'optimisation d'essaim de particules PSO, l'algorithmes de luciole FFA et l'optimisation d'essaim de particules améliorée IPSO, également pour la modélisation du débit journalier, où l'entrée des modèles était constituée des précipitations

et du débit antérieurs. Les résultats de l'analyse dans toutes les stations d'étude ont révélé que le modèle RNA-IPSO dépasse RNA-GA, RNA-PSO et RNA-FFA dans l'estimation du débit. Par conséquent, l'algorithme métaheuristique hybride IPSO est la meilleure technique pour améliorer la capacité de RNA dans la modélisation pluie-débit journalier.

Enfin, examiner un apprentissage en profondeur autonome d'un réseau de neurones convolutifs (CNN) et un réseau amélioré utilisant un algorithme compétitif impérialiste (ICA) et une optimisation du loup gris (GWO) pour prédire le débit horaire à plusieurs échelles, allant de 100 km² à plus de 6000 km² dans le bassin d'étude. L'ensemble de données de réanalyse atmosphérique, ERA5 avec une résolution de 31 km généré par le Centre européen de prévisions météorologiques à moyen terme, des indices de variabilité climatique et des observations de débit in situ ont été utilisés dans la modélisation des débits de crues. L'analyse en composante principale a été utilisée pour identifier les variables d'entrée les plus significatives. Les résultats aux six stations d'étude révèlent que les modèles avec des indices climatiques sont plus performants, en particulier pour prédire les débits extrêmes dans les bassins avec des zones de drainage comprises entre 200 km² et 2000 km², que les modèles avec uniquement des données atmosphériques comme entrées. Le modèle CNN-GWO a surpassé CNN-ICA et le modèle autonome pour prédire le débit avec une NSE améliorée jusqu'à 0,99.

Mots clés : bassin de la Seybouse, Pluie-Débit, Débit de crues, modèle conceptuel GR4J, réseaux de neurones artificiels (RNA), algorithmes génétiques (GA), optimisation des essaims de particules (PSO), algorithme de luciole (FFA), optimisation des essaims de particules améliorée (IPSO), réseau de neurones convolutifs (CNN), Algorithme compétitif impérialiste (ICA), Optimisation du loup gris (GWO).

Abstract

Developing trustworthy rainfall-runoff (R-R) models can offer serviceable information for planning and managing water resources. In a context of simplicity, modeling by an Agricultural Engineering (GR) model, which is the GR4j model (Agricultural Engineering model with 4 daily parameters) has the advantage of only requiring series of meteorological data (rainfall, ETP) and hydrometric (flow) in daily time steps. Use of artificial neural network (RNA) in adopting such models and predicting changes in runoff has become popular among many hydrologists from a long time. Integrating modern heuristic optimization approaches with RNA to increase its performance has attracted a lot of attention. On the other side, a deep learning of a convolutional neural network (CNN) has gained remarkable interest by researchers recently, and similar to RNA its integration with heuristic tools improves more its effectiveness.

This research aims firstly to simulate the transformation of rainfall into daily flow in the Seybouse basin located in a semi-arid region in Algeria, using the GR4J conceptual model. The poor results obtained by these models prompted us to change the axis of application to black box models, in particular ANN, at first. Thus, test the feasibility of using RNA with four input configurations to model the daily runoff relationship in the same basin. The 1st RNA I_p only considers precipitation as an input variable. The 2nd RNA $II_{p,ETP}$, RNA $II_{p,T}$, RNA $II_{p,HUM}$, RNA $II_{p,Vv}$ considers a 2nd variable in the model input with precipitation (evapotranspiration, temperature, humidity or wind speed). The third RNA $III_{p,T,HUM}$ combines temperature, humidity and precipitation. The last RNA $V_{p,ET, T,HUM,Vw}$ consists of collating the various meteorological parameters with precipitation as input variable. RNA models are made for the entire basin with the same configurations as specified above. Better flow simulations were provided by RNA $II_{p,T}$ and RNA $II_{p,Vv}$ for the two stations of Medjez-Amar II and Bordj-Sabath, respectively. However, the RNA $V_{p,ET, T,HUM,Vw}$'s application for the other stations and also for the entire basin reflects a strategy for the flow simulation and shows enhancement in the prediction accuracy over the other configurations. The four configurations of the neural models perform better than the GR4j model for the six study stations.

After that, test the efficiency of integrating RNA models with the metaheuristic algorithms; Genetic Algorithms GA, Particle Swarm Optimization PSO, Firefly Algorithm FFA and improved Particle Swarm Optimization IPSO, also for daily runoff modeling, where the model's input was made up of antecedent's rainfall and runoff. The results of the analysis at all study stations revealed that the RNA-IPSO model outperforms RNA-GA, RNA-PSO and RNA-FFA in runoff estimation. Therefore, IPSO hybrid metaheuristic algorithm is the best technique to improve the RNA capability in daily rainfall-runoff modeling.

Finally, examine a standalone deep learning of a convolutional neural network (CNN) and

improved one utilizing an imperialist competitive algorithm (ICA) and a gray wolf optimization (GWO) to predict hourly runoff at multiple scales, ranging from 100 km² to over 6000 km² in the study Basin. The atmospheric reanalysis dataset, ERA5 with a 31 km resolution generated by the European Centre for Medium-Range Weather Forecasts, climate variability indices and in-situ runoff observations were used in the development of the proposed modeling technique. The principal component analysis technique was used to identify the most significant input variables. Results at the six study stations disclose that models with climate indices, perform better especially in predicting extreme runoffs in basins with drainage areas between 200km² and 2000km² than the models with only atmospheric data as inputs. The CNN-GWO model outperformed CNN-ICA and standalone model in predicting runoff with improved NSE up to 0.99.

Keywords: Seybouse basin, Rainfall-Runoff, GR4J conceptual model, Artificial neural networks (RNAs), genetic algorithms (GA), particle swarm optimization (PSO), firefly algorithm (FFA), improved particle swarm optimization (IPSO), Convolutional Neural Network (CNN), Imperialist competitive algorithm (ICA), Gray Wolf Optimization (GWO).

Sommaire

Remerciement.....	I
Dédicaces	II
ملخص.....	III
Résumé.....	V
Abstract.....	VII
Sommaire	IX
Liste des abréviations	XV
Liste des figures	XVII
Liste des tableaux.....	XIX
Introduction Générale	1

CHAPITRE I : Revue Bibliographique.

Introduction	5
Prévision Des Crues à l'aide de la Modélisation Pluie – Débit	5
I.1. La prévision des crues.....	5
I.1.1. Besoins en prévision des crues	6
I.1.2. Les outils de prévision	6
I.2. Modélisation hydrologique.....	7
I.2.1. Qu'est-ce qu'un modèle pluie-débit ?	7
I.2.2. A quoi sert un modèle pluie-débit ?.....	8
I.3. Classification des modèles hydrologiques:.....	9
I.3.1. Selon la nature de la variable.....	10
• Modèle déterministe (variables non aléatoires).....	10
• Modèle stochastique (variables aléatoires).....	10
I.3.2. Selon le traitement de l'espace (Homogénéité du bassin)	11
• Modèle global.....	11
• Modèles semi-distribués et distribués :.....	11
I.3.3. Selon le fondement théorique et approche de développement.....	12
• Modèles boîte noir	12

• Modèles conceptuels ou « à réservoir »	12
• Les Modèles a Base Physique.....	13
I.4. Calibration et validation d'un Modèle	13
I.4.1. Calage des modèles.....	13
I.4.2. Validation des modèles	14
I.4.3. Problèmes et difficultés	15
I.5. Critères de performance du Modèle	15
Conclusion.....	17

CHAPITRE II : Modèle hydrologique conceptuel.

Introduction	18
II.1. Histoire du développement des modèles GR4J.....	18
II.2. Description du modèle pluie-débit journalier GR4J	18
II.2.1. Modèle Conceptuel Global (GR4J)	18
II.2.2. Description mathématique	19
II.2.2.1. Fonction de production	19
II.2.2.2. Fonction de transfert.....	20
II.3-Applications du modèle "GR"	22
Conclusion.....	25

CHAPITRE III : Modèles d'intelligence artificielle.

Introduction	26
III.1. Les réseaux de neurones artificiels (RNA)	26
III.1.1. Histoire du développement des systèmes neuronaux artificiels.....	26
III.1.2. Du neurone biologique au neurone artificiel.....	27
III.1.3. Structure et choix d'un réseau de neurones artificiel	29
III.1.4. Fonction d'activation.....	30
III.1.5. Apprentissage des réseaux de neurones	31
III.1.5.1. Type d'apprentissage.....	33
III.1.5.2. Algorithme d'apprentissage	33
III.1.6. Utilisation des RNA en hydrologie	33
III.1.6.1. Applications dans la modélisation Pluie-Débit.....	34

III.1.6.2. Applications dans la modélisation des débits des cours d'eau	35
III.1.6.3. Application dans la modélisation de la qualité de l'eau.....	35
III.1.6.4. Applications dans les eaux souterraines	36
III.1.6.5. Applications dans l'estimation des précipitations	36
III.2. Algorithmes génétiques (GA).....	37
III.2.1. C'est quoi l'Algorithme Génétique ?	37
III.2.2 Principe.....	37
III.2.3. Rôle des opérateurs génétiques	38
III.2.4. Le modèle hybride RNA-GA.....	39
III.2.5. Application de RNA-GA en hydrologie	39
III.3. Optimisation de l'essaim de particules (PSO).....	41
III.3.1. Intelligence en essaim	41
III.3.2. Le modèle de l'algorithme PSO	41
III.3.3. Paramètres d'algorithme PSO	42
III.3.3.1. Taille de l'essaim.....	42
III.3.3.2. Nombres d'itération	42
III.3.3.3. Composants de vitesse	43
III.3.3.4. Coefficients d'accélération	43
III.3.4. Le modèle hybride RNA-PSO	44
III.3.5. Application de RNA-PSO en hydrologie	45
III.4. Optimisation de l'essaim de particules améliorée (IPSO).....	46
III.4.1. Le modèle de l'algorithme IPSO	46
III.4.2. Le modèle hybride RNA-IPSO.....	47
III.4.3. Application de RNA-IPSO en hydrologie	48
III.5. Algorithme de luciole (FFA).....	48
III.5.1. Comportement de la luciole.....	48
III.5.2. Règles de l'algorithme de luciole	49
III.5.3. Variations d'intensité lumineuse et d'attractivité	50
III.5.4. Le modèle hybride RNA-FFA	51
III.5.5. Application de RNA-FFA en hydrologie	52
III.6. Les réseaux de neurones convolutifs (CNN)	53

III.6.1. Avantages d'employer des CNN	53
III.6.2. Architecture de CNN	53
III.6.3. Application de CNN en hydrologie	55
III.7. Algorithme compétitif impérialiste (ICA)	56
III.7.1. C'est quoi l'Algorithme compétitif impérialiste?	56
III.7.2. Principe de ICA	56
III.7.3. Application de ICA en hydrologie.....	59
III.8. Optimisation du loup gris (GWO)	60
III.8.1. C'est quoi l'Algorithme d'optimisation du loup gris?	60
III.8.2. Principe de GWO	60
III.8.3. Application de GWO en hydrologie.....	62
Conclusion.....	63

CHAPITRE IV : Présentation de la zone d'étude.

Introduction	64
IV.1. Présentation de la zone d'étude.....	64
IV.1.1. Situation géographique.....	64
IV.1.2. Les sous bassins de la Seybouse	65
IV.2. Morphométrie du bassin	66
IV.2.1. Paramètres de forme	67
a. Surface du bassin versant (A).....	67
b. Indice de compacité Gravelius	67
c. Rectangle équivalent.....	67
IV.2.2. Paramètres de relief	68
a. Courbe hypsométrique	68
b. Les indices des pentes.....	69
IV.3. Réseau hydrographique.....	71
IV.4. Profil en long.....	71
IV.5. Climatologie	72
IV.6. L'occupation du sol.....	73
Conclusion.....	74

CHAPITRE V : Traitement des données utilisées.

V.1. Données en usage.....	75
V.1.1. Collecte des données	76
V.1.2. Contrôle des données	77
V.1.3. Caractéristiques des stations	77
V.2. Analyse des écoulements	79
V.2.1. Variation des débits moyens journaliers	80
V.2.2. Variation des débits moyens horaire	82
V.3. Analyse des données	84
V.3.1. Problème de lacunes.....	84
V.3.2. Homogénéisation des données	86
V.4. Choix des variables d'entrée.....	87
Conclusion.....	88

**CHAPITRE VI : Prévion des débits journaliers par le modèle GR4J et les modèles RNA
sous différents paramètres d'entrée météorologiques.**

Introduction	89
VI.1. Mise en œuvre du modèle GR4J.....	90
VI.1.1. Initialisation du système	90
VI.1.2. Application du modèle.....	90
VI.1.3. Acquisition des données pour le modèle GR4J.....	90
VI.1.4. Résultats des modèles GR4J	91
VI.2. Mise en œuvre du modèle RNA.....	94
VI.2.1. Acquisition des données pour le modèle RNA	94
VI.2.2. Sélection des variables d'entrée par l'essai et l'erreur.....	95
VI.2.3. Développement de modèles RNA.....	95
VI.2.4. Résultats des modèles RNA	96
Conclusion.....	107

CHAPITRE VII : Prévion des débits journaliers par les modèles hybrides RNA

Introduction	109
VII.1. Acquisition des données.....	109
VII.2. Sélection des entrées par ACF, PACF et CCF.....	110

VII.3. Développement de modèles hybrides de RNA.....	113
VII.4. Résultats, Analyse et discussion	116
Conclusion.....	123

**CHAPITRE VIII : Prévion des débits de crues horaire par les models CNN et CNN
hybride**

Introduction	123
VIII.1. Acquisition des données.....	123
VIII.2. Sélection des entrées par ACP	126
VIII.3. Développement de modèles CNN et CNN hybrides.....	127
VIII.4. Résultats et discussions	129
Conclusion.....	139
Conclusion générale.....	139
Références bibliographiques	142

Liste des abréviations

ANRH : Agence National des Ressources Hydrauliques

ONM : Office National de la Météorologie

GR4J : Modèle conceptuel Génie rural à 4 paramètres journalier.

GR1A : Génie Rural à 1 paramètre Annuel

GR2M: Génie Rural à 2 paramètres Mensuel

ANN : Artificial neural network

RNA : Réseau de neurones artificiels

GA : Genetic algorithm = Algorithmes génétiques

PSO : Particle swarm optimization = Optimisation des essaims de particules

IPSO : Improved Particle swarm optimization = Optimisation améliorée des essaims de particules

FFA : Firefly algorithm = Algorithme de luciole

DL : Deep learning

CNN : Convolutional neural network = Réseau de neurones convolutifs

ICA : Imperialist competitive algorithm = Algorithme compétitif impérialiste

GWO : Gray wolf optimization = Optimisation du loup gris

ACF : Autocorrelation Function = Fonction d'Autocorrélation

PACF : Partial autocorrelation = Fonction d'Autocorrélation partial

CCF : Cross correlation functions = fonction de corrélation croisée

PCA : Principal Component Analysis

ACP : Analyse en composante principale

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

BP : Back Propagation = Rétro-propagation

BR : Bayesian Regularization = Régularisation bayésienne

LM : Levenberg-Marquardt Algorithm = Algorithme de Levenberg-Marquardt

MAE : Mean Absolute Error = Erreur moyenne absolue

MLP : Multi-Layer Perceptron = Perceptron multicouche

NSE : Nash Sutcliffe criterion = Critère de Nash Sutcliffe

R = Coefficient de corrélation de Pearson

R² = Coefficient de corrélation

RMSE : Root Mean Square Error = Erreur moyenne quadratique

SVM : Support Vector Machine = Machines à vecteurs de support

SVR : Support Vector Regression = Régression à vecteurs de support

WI : Willmott Index = L'indice de Willmott

PSS : Peirce Skill Score = score de compétence de Peirce

EDS : Extreme Dependency Score = score de dépendance extrême

Liste des figures

CHAPITRE I

Figure 1. 1. Schématisation du fonctionnement d'un modèle hydrologique (Mathevet, 2005). .. 8

Figure 1. 2. Relation entre les modèles pluie-débit (Berthier, 2005) 10

CHAPITRE II

Figure 2. 1. Architecture du modèle GR4j (Perrin, 2003) 22

CHAPITRE III

Figure 3. 1. Diagramme schématique d'un neurone biologique 28

Figure 3. 2. Diagramme schématique d'un neurone artificiel simple 28

Figure 3. 3. Réseau à deux couches cachées. 29

Figure 3. 4. Schéma d'un RNA multicouche 30

Figure 3. 5. Erreur moyenne sur la base d'apprentissage en fonction du nombre d'itérations. 32

Figure 3. 6. Diagramme de croisement à un point de croisement aléatoire (emplacement) dans les algorithmes génétiques. 38

Figure 3. 7. Représentation schématique de la mutation sur un seul site en retournant un bit sélectionné au hasard ($1 \rightarrow 0$). 38

Figure 3. 8. Appliquer un filtre ($F \times F$) aux données d'entrée ($N \times N$) afin d'obtenir la valeur de $v_{1,1}$ dans la couche suivante. 54

Figure 3. 9. Procédure de l'algorithme compétitif impérialiste. 59

Figure 3. 10. Mécanisme de l'optimisation du loup gris. 62

CHAPITRE IV

Figure 4. 1. Carte Situation géographique du bassin versant de la Seybouse en Algérie. 65

Figure 4. 2. Courbe hypsométrique (d'après l'ANRH). 68

Figure 4. 3. Carte hydrographique du bassin versant de la Seybouse. 71

Figure 4. 4. Profil en long de l'Oued Seybouse (d'après (Ghachi, 1986)) 72

Figure 4. 5. Carte d'occupation du sol du bassin versant de la Seybouse. 73

CHAPITRE V

Figure 5. 1. Variation journalière de débit des six stations hydrométriques. 82

Figure 5. 2. Variation horaire de débit des six stations hydrométriques. 84

Figure 5. 3. Location des six stations pluviométriques et hydrométriques. 85

CHAPITRE VI

Figure 6. 1. Hydrogrammes issu des simulations réalisées en phase de validation, à l'aide des modèles conceptuels GR4J au six stations d'étude	92
Figure 6. 2. Courbe de convergence des modèles de RNA V, RNA IIP,T et RNA IIP,Vv dans les six stations d'étude.....	1041
Figure 6. 3. Comparaison des débits observés et estimés pour les modèles de RNA V, RNA IIP,T	1043
Figure 6. 4. Nuage de points pour le modèle de RNA V _{P,ETP,T,HUM,Vv} en phase d'apprentissage, de validation et de test.	106
Figure 6. 5. Comparaison des débits observés et estimés pour le modèle de RNA V _{P,ETP,T,HUM,Vv} du bassin de la Seybouse.	106

CHAPITRE VII

Figure 7. 1. Les ACF, PACF de la série chronologique de débit et CCF entre le débit (Q_t) et les précipitations à divers décalages avec la limite de confiance de 95% pour Moulin Rechefort, Medjez-Amar II, Bordj-Sabath, Bouchegouf, Mirebek et Ain Berda.....	113
Figure 7. 2. Organigramme des algorithmes hybrides suggérés (a) RNA-GA, (b) RNA-PSO, (c) RNA-FFA et (d) RNA-IPSO.....	115
Figure 7. 3. Nuages de points des valeurs de débit journalier observées et prévues pendant la phase de test, produits par RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO pour les six stations.	121
Figure 7. 4. Série chronologique des valeurs de débit journalier observées et prévues pendant la phase de test, produite par RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO pour les six stations....	122
Figure 7. 5. Diagrammes de Taylor affichant la comparaison statistique des quatre modèles pendant la période de test dans les six stations d'étude.	123

CHAPITRE VIII

Figure 8. 1. La discrétisation en grille du bassin d'étude et les surfaces drainantes de chaque station hydrométrique.....	125
Figure 8. 2. L'emplacement et l'élévation du bassin de Seybouse.....	125
Figure 8. 3. Organigramme des modèles hybrides a) CNN-GWO et b) CNN-ICA proposés.	129
Figure 8.4. Série chronologiques représentant le débit observé et prévu en m^3/s par CNN-GWO avec et sans CI au sous-bassins de a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rechefort et f) Mirebek dans un ordre croissant de zone de drainage pendant la phase de test.	132
Figure 8. 5. Diagramme de Taylor des modèles CNN, CNN-ICA et CNN-GWO avec et sans CI dans les stations de a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rechefort et f) Mirebek pour la période de test.	133
Figure 8. 6. Graphique radar illustrant les métriques de performance des modèles proposés	

utilisant CI à a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rochefort et f) Mirebek dans l'ordre croissant de la zone de drainage pendant la phase de test.	133
Figure 8. 7. Diagrammes de dispersion du débit horaire observé et prévu par CNN, CNN-ICA et CNN-GWO en utilisant CI à a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II , e) Moulin Rochefort et f) Mirebek pour la période de test.	135
Figure 8. 8. Extreme Dependency Score (EDS) et Perce Skill Score (PSS) pour les débits extrêmes prévus par CNN-GWO avec et sans indices climatiques (CI) en fonction de a) et b) l'aire drainante et c) et d) l'élévation pour la période de validation du modèle.	136

Liste des tableaux

CHAPITRE I

Tableau 1. 1. Exemple de caractéristiques des modèles pluie-débit.....	10
---	----

CHAPITRE III

Tableau 3. 1. Analogie entre le neurone biologique et le neurone formel.....	29
---	----

CHAPITRE IV

Tableau 4. 1. Répartition Altimétrique du bassin.....	688
Tableau 4. 2. Calcul de l'indice de pente de Roche.....	699
Tableau 4. 3. Classification de l'O.R.S.T.O.M.....	70
Tableau 4. 4. Classification des bassins versants selon leur superficie.....	70

CHAPITRE V

Tableau 5. 1. Caractéristiques des débits journalier des stations hydrométriques utilisés dans les modèles GR4J et RNA autonome.	Error! Bookmark not defined.
Tableau 5. 2. Caractéristiques des débits journalier utilisés dans les modèles RNA hybride....	878
Tableau 5. 3. Caractéristiques des données horaire des stations hydrométriques utilisées dans les modèles CNN autonome et hybride.....	79
Tableau 5. 4. Résultat du test d'homogénéité des Station pluviométriques à l'échelle journalier	87
Tableau 5. 5. Résultat du test d'homogénéité des Station hydrométriques à l'échelle journalier	887

CHAPITRE VI

Tableau 6. 1. Période de calage et validation des six stations d'étude	951
Tableau 6. 2. Résultats du calage et de la validation	951
Tableau 6. 3. Subdivision des données pour les stations d'étude.	95
Tableau 6. 4. Indices statistiques du modèle à entrée unique (RNA I_p) appliqués aux six stations hydrométriques réparties dans le bassin de la Seybouse.	97
Tableau 6. 5. Indices statistiques des modèles à deux entrées (RNA $II_{p,ETP}$, RNA $II_{p,T}$, RNA $II_{p,HUM}$, RNA $II_{p,VV}$).	98
Tableau 6. 6. Indices statistiques des modèles à trois entrées (RNA $III_{p,T,HUM}$).....	99
Tableau 6. 7. Indices statistiques du modèle à cinq entrées (RNA $V_{p,ETP,T,HUM,VV}$).	100
Tableau 6. 8. Indices statistiques des modèles appliqués pour l'ensemble du bassin de la Seybouse.	106

CHAPITRE VII

Tableau 7. 1. Classement des données pour les six stations d'étude.....	110
Tableau 7. 2. Valeurs d'autocorrélation, d'autocorrélation partielle et de corrélation croisée des données utilisées.....	112
Tableau 7. 3. Paramètres utilisés pour les quatre algorithmes évolutionnaires	116
Tableau 7. 4. Indicateurs de performance des RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO optimaux au cours des périodes d'apprentissage et de test.....	117

CHAPITRE VIII

Tableau 8. 1. Liste des paramètres utilisés dans l'élaboration des modèles, les observations in-situ, les variables atmosphériques et les indices climatiques.	124
Tableau 8. 2. Le taux de contribution à la variance pour la station Medjez Amar II.	127
Tableau 8. 3. Réglages d'hyperparamètres pour les modèles de CNN proposés.	128
Tableau 8. 4. Indicateurs statistiques des modèles CNN hybrides pendant les périodes d'apprentissage et de validation au niveau des six sous-bassins allant de 102 km ² à Ain Berda à plus de 5950 km ² à Mirebek.....	131

INTRODUCTION GÉNÉRALE

Introduction Générale

Depuis la nuit des temps, l'eau est un facteur prédominant dans le développement socio-économique des êtres humains. Il intervient dans tout le fonctionnement du milieu naturel et représente une ressource vitale principale pour de nombreuses plantes et animaux. En fait, la gestion des ressources en eau est un enjeu politique, économique et social majeur que les gouvernements et les institutions identifient comme une priorité sur l'agenda politique du 21^{ème} siècle. Actuellement, l'enjeu pour l'Algérie, et plus précisément pour le bassin de la Seybouse, est de mieux répondre aux besoins des usagers (approvisionnement en eau domestique, industrie, agriculture) avec des ressources en eau relativement limitées ; en particulier compte tenu de l'utilisation inefficace et inappropriée des ressources en eau disponibles et de la forte augmentation de la demande due à la croissance démographique et au développement industriel et agricole. Par conséquent, les ressources en eau du bassin de la Seybouse sont soumises à de fortes pressions qui menacent gravement leur pérennité. Dans ce contexte, une bonne planification des ressources en eau pourrait être une alternative pour gérer la crise de l'eau et combler le déséquilibre entre l'eau disponible et la demande. Ainsi, l'intérêt demeure élevé en ce qui concerne le développement d'approches de gestion intégrée qui considèrent le bassin versant comme une unité de gestion pertinente.

La modélisation hydrologique du bassin de la Seybouse peut être un outil fondamental pour améliorer sa gestion et permet aux gestionnaires de la ressource en eau d'élaborer une stratégie efficace et rationnelle. De plus, il permet une évaluation des risques hydrologiques liés aux inondations/sécheresses visant à éviter les pertes de biens publics et privés, de vies humaines et de biens corporels, les risques sanitaires et écologiques. Un tel risque est susceptible de se produire en raison de catastrophes. En effet, la prévision du débit s'est récemment avérée être un outil profondément crucial pour l'organisation à long terme des ressources en eau, la prévision des crues extrêmes et des périodes sèches, la production d'énergie hydroélectrique, l'allocation de l'eau pour l'agriculture, la conception d'ouvrages hydrauliques et la régulation optimale des réservoirs. Cependant, le débit présente un degré élevé de non-linéarité, de non-stationnarité et de complexité en raison de sa génération de processus compliquée, ainsi que de l'implication de variabilités naturelles et de facteurs humains. Par conséquent, les hydrologues et les chercheurs ont développé divers modèles pluie-débit afin de capturer et de représenter ce phénomène complexe, où la sélection du modèle doit être faite en fonction de sa capacité et de son niveau de complexité. Ces modèles de prévision pluie-débit sont classés en modèles empiriques/boîte noire et modèles distribués conceptuels ou physiques. Cependant, la prédiction à l'aide de modèles physiques comporte généralement une incertitude inhérente importante causée par une représentation inexacte des processus hydrologiques, des conditions antérieures incomplètes ou incorrectes, des

erreurs dans les variables d'entrée ou une incertitude dans les paramètres du modèle, de plus, ils nécessitaient une grande quantité de données pour simuler le processus hydrologique. En conséquence, cette incertitude dans la prévision du débit a été largement résolue grâce à l'introduction de modèles conceptuels tel que GR4J et les modèles empiriques / basée sur les données tels que les modèles d'intelligence artificielle (AI) et les modèles hybrides.

Description de la problématique de la thèse

La prévision du débit des cours d'eau est difficile en raison de la complexité des systèmes hydrologiques. L'amélioration de la qualité des prévisions de débit des cours d'eau a toujours été une tâche importante pour les chercheurs et les prévisionnistes hydrologiques. Il n'existe pas de méthode unique de prévision des débits qui permette d'obtenir des résultats de prévision optimaux en toutes circonstances. Aucun modèle de prévision n'est suffisamment puissant et général pour surpasser les autres pour tous les types de bassins versants et dans toutes les circonstances, ni même un bassin versant avec différentes phases de comportement. On s'attend à ce que de meilleurs modèles de prévision puissent être développés pour un bassin spécifique en raison de la disponibilité croissante des données, de la puissance de calcul, de la sophistication de la théorie de modélisation et du développement de logiciels. La majorité des études de modélisation pluie-débit des bassins versants algériens ont été élaborées par les modèles conceptuels globaux du Cemagref GR (génie rural). Les premiers utilisateurs ont été [Kabouya et M. Michel \(1990 et 1991\)](#) qui ont appliqué les modèles de pas de temps annuels et mensuels. Ces modèles donnent de bons résultats, mais ils sont incapables de reproduire les pics d'écoulement maximum ([T. Benkaci et N. Dechemi 2004](#)). L'application de modèle d'intelligence artificielle est devenue de plus en plus populaire dans l'hydrologie et la gestion de l'eau en raison de leur capacité et de leur potentiel à fournir une modélisation satisfaisante du mécanisme complexe pluie-débit avec une disponibilité de données limitée. Cette méthode est utile pour les prévisions hydrologiques, en particulier dans les régions éloignées où des données hydrologiques suffisantes ne sont pas disponibles.

Objectif

La présente étude porte sur une série de sujets de recherche liés au développement de modèles conceptuels et modèles d'intelligence artificielle simples et hybrides pour la prévision des débits journaliers et horaires. Les objectifs et les tâches de recherche abordés dans cette étude sont les suivants :

- Analyser les performances de modèle conceptuel GR4J dans la simulation de la transformation de la pluie en débit,
- Examiner l'utilisation des modèles d'intelligence artificielle pour obtenir de meilleures performances de prévision en utilisant différents type de données en entrée.

- Evaluer l'efficacité des réseaux de neurones artificielles sous l'influence de nombreux paramètres d'entrée météorologiques,
- Comparer les modèles de RNA avec le modèle a réservoir GR4J,
- Examiner la performance des modèles de réseau de neurone artificiel RNA, réseau de neurone artificiel hybride et de réseau de neurone convolutif CNN dans le processus de prévision du débit et des débits de crues.
- Améliorer la capacité opérationnelle des modèles RNA en utilisant des algorithmes métaheuristiques tel que l'algorithme génétique GA, l'optimisation d'essaim de particules PSO, l'algorithme de luciole FFA et l'optimisation d'essaim de particules amélioré IPSO.
- Améliorer la capacité opérationnelle des modèles CNN en utilisant un nouvel algorithme métaheuristique basé sur optimisation du loup gris GWO et l'algorithme concurrentiel impérialiste ICA.
- Évaluer l'impact d'utilisation des indices climatiques sur la performance des modèles de l'apprentissage profond CNN autonome et hybride.
- Comprendre l'effet du choix des variables d'entrée sur la qualité de prévision.
- Formuler des recommandations spécifiques pour la prévision des débits et des débits de crues et présenter les modèles les plus fonctionnels pour ces prévisions.

Démarche et organisation de la thèse

Cette thèse est composée de huit chapitres. L'organisation générale de la thèse et l'objet de chaque chapitre peuvent être décrits comme suit : Le premier chapitre consacré à la synthèse bibliographique concernant la prévision des crues, la modélisation pluie-débit et la classification des différents modèles hydrologiques avec leurs critères de performance. Le deuxième chapitre introduit le modèle conceptuel a réservoir GR4J. Le troisième chapitre présente une revue exhaustive sur le réseau de neurones artificiels RNA, les algorithmes métaheuristiques intégrées avec RNA (l'algorithme génétique GA, l'optimisation de l'essaim de particules PSO, l'optimisation de l'essaim de particules amélioré IPSO et l'algorithme de luciole FFA), le réseau de neurones convolutif CNN et les algorithmes métaheuristiques intégrées avec CNN (optimisation du loup gris GWO et l'algorithme concurrentiel impérialiste ICA), ainsi que les travaux de recherche relatifs à ses utilisations dans les problèmes lié à l'hydrologie. Le quatrième chapitre présente les caractéristiques morphologiques et hydrographiques du bassin versant sélectionné, le cinquième chapitre présente l'analyse, le traitement, et les caractéristiques statistiques de l'ensemble des données utilisées dans l'élaboration de ce travail. Le sixième chapitre, présente l'application de GR4J et RNA avec différentes configurations d'entrée pour la prévision des débits journaliers. Le septième chapitre présente la prévision des débits journaliers par les modèles de réseaux de neurones artificiels optimisés par GA, PSO, FFA et IPSO où les variables d'entrée les

plus pertinentes sont sélectionnés en utilisant l'autocorrélation simple et partielle. Le huitième chapitre présente la prévision des débits de crues par les modèles de réseau de neurones convolutif CNN et optimisés par GWO et ICA.

Enfin, une conclusion générale récapitule les principales démarches et l'essentiel des résultats obtenus par cette étude.

CHAPITRE I

REVUE BIBLIOGRAPHIQUE

Introduction

Il est essentiel de résoudre les problèmes liés à la gestion des bassins versants, en particulier la gestion des barrages, afin d'éviter les catastrophes telles que les sécheresses et les inondations. Prévoir les conséquences des inondations nécessite une compréhension approfondie de leurs niveaux d'étiage et des crues. Les crues entraînent des dommages humains et des dégâts matériels importants. Pouvoir prédire avec précision les crues est donc précieux afin d'intervenir en temps utile pour protéger les biens et les personnes. La prévision des phénomènes météorologiques et hydrologiques susceptibles de générer des inondations constitue un élément crucial pour anticiper la crise, s'y préparer et mettre en œuvre au niveau local les mesures individuelles et collectives de mise en sûreté des personnes et des biens. Depuis les années 1960, la prévision des crues (prévision à court terme jusqu'à quelques dizaines d'heures) a fait l'objet de recherches approfondies (voir, par exemple, les revues bibliographiques de (Berthet, 2010; Bois et al., 2005) et a donné lieu à d'innombrables développements opérationnels dans de nombreux pays, en raison des enjeux humains et économiques liés à ces événements. Un des objectifs majeurs de ces travaux a été de mettre au point des chaînes de modélisation hydrométéorologiques suffisamment fiables pour permettre aux prévisionnistes de mieux anticiper les événements de crue. La modélisation hydrologique Pluie - Débit compte parmi les outils incontournables pour prévoir les crues, car elle permet d'atteindre des horizons plus lointains que de nombreuses autres méthodes. Il existe aujourd'hui un grand nombre de modèles mathématiques de simulation de la transformation de la pluie en débit à l'échelle du bassin versant.

Par une synthèse bibliographique, nous allons définir les besoins et les outils de la prévision des crues, puis, mettre en place le contexte de la modélisation pluie-débit qui s'intéresse à des problématiques relatives à la gestion des ressources en eau, à l'aménagement du territoire et aux différents risques hydrologiques (sécheresse, inondation (car cette modélisation constitue une partie importante dans une méthodologie de prévision des crues)).

Prévision Des Crues à l'aide de la Modélisation Pluie – Débit

I.1. La prévision des crues

Qu'est-ce que la « prévision des crues » ?

Il est possible de prévoir un débit (ou une variation de débit), une hauteur (ou une variation de hauteur), un volume (idem), une occurrence de dépassement d'un seuil donné, une vitesse de propagation d'un pic de crue, une date à laquelle une zone donnée va être inondée. . . Mais une crue ? Étymologiquement une « crue » est une montée des eaux. Prévoir, sans référence à une

valeur donnée, une montée des eaux ne doit pas être si difficile, les eaux d'un cours d'eau n'ayant en fait que trois possibilités : monter, baisser, ou rester au même niveau ! Quand le terme « prévision de crue » est utilisé, il implique implicitement l'utilisation d'une variable intermédiaire quantitative à travers laquelle la crue est regardée ; par exemple les variables hydrologiques précédemment citées : débits, hauteurs d'eau, volumes, etc. (Moulin, 2007).

La prévision des crues consiste à estimer en temps réel le niveau futur du débit, le temps d'apparition et la durée d'une crue, en particulier la valeur de la pointe de crue pour un site spécifique, qui résulte des pluies et/ou des fontes de neige. Elle comporte trois aspects : les valeurs prévues, les objectifs de la prévision et les délais de prévision (Jarraud & Bokova, 1990; John C, 1994; WALTER T, 1986).

I.1.1. Besoins en prévision des crues

La prévision des crues est très orientée aujourd'hui vers la prévention des crues catastrophiques et consiste à estimer a priori les valeurs futures des débits en temps réel. Elle constitue un moyen direct pour réduire les dommages humains et matériels causés par les inondations. L'alerte devant une crue imminente permet d'évacuer la population, le cheptel et l'équipement en minimisant les pertes. L'importance de la prévision des crues a été renforcée par les exigences de la gestion des barrages réservoirs. Il existe aussi une prévision hydrologique pour la demande en eau, la navigation, l'agriculture et les étiages. Le conflit entre les différents utilisateurs des ressources en eau est un problème classique. L'efficacité des arbitrages en temps réel entre ces activités est fortement déterminée par la qualité de la prévision. Pour une prévision, qui est émise maintenant, le résultat sera comparé à la réalité quelques heures plus tard, et les professionnels comme les profanes peuvent alors aisément la critiquer. La prévision de crue est donc parfois ressentie comme une activité intellectuelle assez risquée (Klemeš, 1982).

I.1.2. Les outils de prévision

(Moulin, 2007) a cité trois outils hydrologiques de prévision des crues:

- La prévision hydraulique « débit-débit »
- La prévision « pluie-débit »
- La prévision météorologique

Dans cette étude nous allons traiter les modèles hydrologique pluie-débit pour la prévision des débits journalier et débits de crues. Plusieurs recherches ont montrés l'applicabilité de ces dernières à la prévision des crues tel que (Kitanidis & Bras, 1980; O'Connell & Clarke, 1981).

I.2. Modélisation hydrologique

Les outils de modélisation hydrologique sont utilisés dans un large éventail d'applications, par exemple, l'estimation des débits de bassins versants non jaugés, la conception et l'exploitation de structures hydrauliques, l'étude des effets de l'utilisation des terres et du changement climatique et, comme nous l'avons mentionné précédemment, la prévision des crues en temps réel. De nombreuses méthodes ont été développées pour produire des informations hydrologiques non disponibles à partir des données hydrométéorologiques disponibles. La plupart de ces méthodes sont basées sur des modèles hydrologiques. La majorité de ces modèles ont été développés pour simuler des débits résultant de diverses conditions météorologiques, en particulier des précipitations. Certains modèles peuvent par exemple prévoir les débits sur la base de prévisions météorologiques, tandis que d'autres produisent des scénarios hydrologiques correspondant à des scénarios météorologiques sélectionnés ou développés ailleurs (par exemple pour les conditions climatiques présentes ou futures). Les modèles hydrologiques sont nombreux et variés. Ils sont souvent classés selon leurs concepts, la logique et la nature des expressions mathématiques qui définissent les relations quantitatives entre les informations d'entrée du modèle (par exemple, les précipitations) et les informations de sortie du modèle (par exemple, les débits). Les modèles hydrologiques tentent de décrire les relations pluie- débit, et ces relations sont très complexes en raison de la variabilité non linéaire et spatio-temporelle du processus pluviométrique et des caractéristiques du bassin versant.

I.2.1. Qu'est-ce qu'un modèle pluie-débit ?

Le modèle pluie-débit ([figure 1.1](#)) est un modèle mathématique qui intègre les processus hydrologiques à l'échelle du bassin versant pour déterminer la réponse de celui-ci. De nombreuses structures, classifications et définitions des modèles pluie-débit ont été proposées dans la littérature et sont discutées dans les revues bibliographiques de ([Kampf & Burges, 2007](#); [Singh & Woolhiser, 2002](#); [Sivapalan et al., 2003](#)). Un modèle pluie-débit est généralement défini par :

- Variables d'entrée (variables indépendantes) : il s'agit des entrées du modèle, qui sont essentiellement les chroniques de pluie, d'ETP ou de température ;
- Variables de sortie (variables dépendantes) : il s'agit des sorties du modèle, qui sont généralement les débits simulés à l'exutoire du bassin versant, mais qui peuvent parfois être aussi l'ETR, des niveaux piézométriques, ...etc. ;
- Variables d'état : il s'agit des variables internes au système, qui évoluent en fonction du temps et rendent compte de l'état du système à un moment donné. Typiquement, ces

variables sont les niveaux de remplissage des différents réservoirs (neige / production / routage) ;

- Les équations mathématiques : qui relient les variables de sortie aux variables d'entrée et aux variables d'état. Celles-ci permettent de représenter de façon plus ou moins explicite les processus impliqués dans le fonctionnement du bassin versant étudié.
- Les paramètres : qui interviennent dans les équations du modèle, et qui représentent la part non explicitée du fonctionnement du bassin dans ces équations. Ils peuvent avoir une signification physique ou non. Ils servent à adapter les relations régissant le modèle au fonctionnement réellement observé.

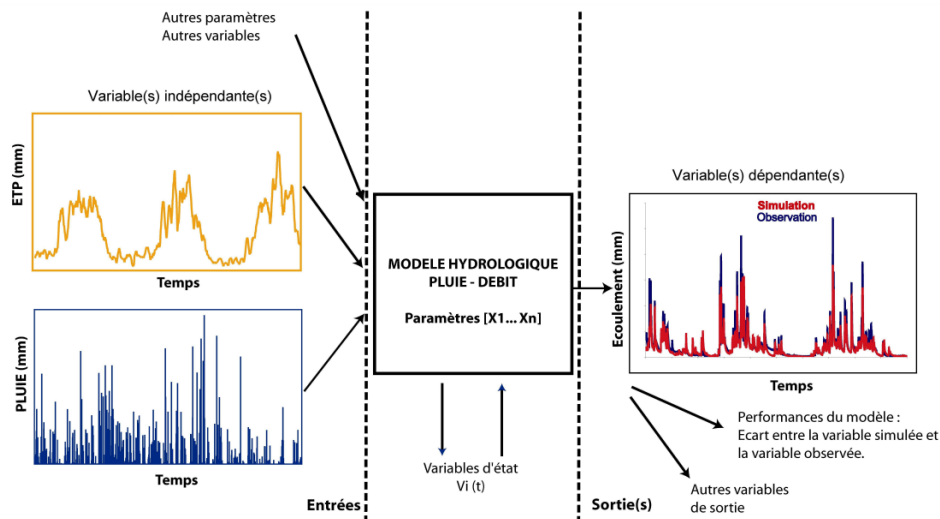


Figure 1. 1. Schématisation du fonctionnement d'un modèle hydrologique (*Mathevet, 2005*).

1.2.2. A quoi sert un modèle pluie-débit ?

Selon l'utilisateur, l'usage de la modélisation a des fonctions variées. Le modèle est destiné à aider à répondre à des questions, il est conçu en fonction de celles-ci, et ne peut être utilisé que dans ce champ particulier, son objectif principal est la réduction de la complexité naturelle. Les modèles pluie-débit servent en premier lieu à représenter dans le temps le cycle de l'eau, et permettent de transposer l'information climatique. Cependant, force en nous est de constater que plusieurs modèles pluie-débit ont été conçus, et la majorité n'ont pas trouvé une application pratique en hydrologie. On peut donc, conclure que la transposition d'un modèle, se mesure par les degrés de robustesse de ses résultats, et de sa représentativité des processus à modéliser.

On peut résumer les fonctions des modèles pluie-débit en :

- Extrapolation des débits

Le calcul d'un débit par le modèle est la tâche la plus courante pour ce dernier, dans ce cas, l'objectif reste la simulation et la génération synthétique des séries hydrométriques. Cette estimation par l'extrapolation de débits peut cependant avoir des objectifs précis tels que :

- Le comblement des lacunes des séries hydrométriques tronquées.
- L'extension des séries courtes, ou des séries de certaines stations hors service (cette simulation quantitative trouve ses intérêts dans le dimensionnement des réseaux d'assainissement et de certains ouvrages hydrauliques).
- L'estimation (directe et/ou indirecte) de certains paramètres hydrologiques et hydrogéologiques.
 - ii. Préviation des débits
 - iii. Gestion des ressources en eau

La gestion des ressources en eau est un problème délicat, du fait de la variabilité de ces ressources et de l'interaction des opérateurs. La modélisation pluie-débit peut intervenir dans cette gestion à trois niveaux :

- D'abord, par l'évaluation des ressources en eau, et de la valorisation de tous les processus participants aux différents écoulements, c'est le cas par exemple de certains bassins non jaugés, dont les méthodes empiriques aboutissent souvent à des résultats aberrants.
- Un modèle peut caractériser l'impact des différents aménagements hydro-agricoles, et de prévoir certains changements des conditions météorologiques, ainsi que de délimiter les zones inondables.
- Un modèle pluie-débit qui représente les différents flux du système dynamique au niveau d'un barrage, pourra être exploité dans la gestion des ressources de ce barrage en fonction de la demande des divers opérateurs intervenant sur le bassin. Il ne s'agit pas d'un système d'aide à la décision, mais plutôt d'un outil destiné à tester différents scénarios de développement.
 - iv. Modèle comme outil de recherche

I.3. Classification des modèles hydrologiques:

Les classifications de modèles que l'on trouve dans la littérature sont nombreuses et peuvent être fonction de plusieurs caractéristiques (Berthier, 2005). Pour ironiser, (Perrin, 2002) disait qu'il y a presque autant de classifications que d'hydrologues. Le tableau suivant propose de classer les différents types de modèles selon leurs caractéristiques (Ambroise, 1998; ANDRÉASSIAN, 2002; CLARKE, 1973; Oudin, 2004; Perrin, 2002).

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

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

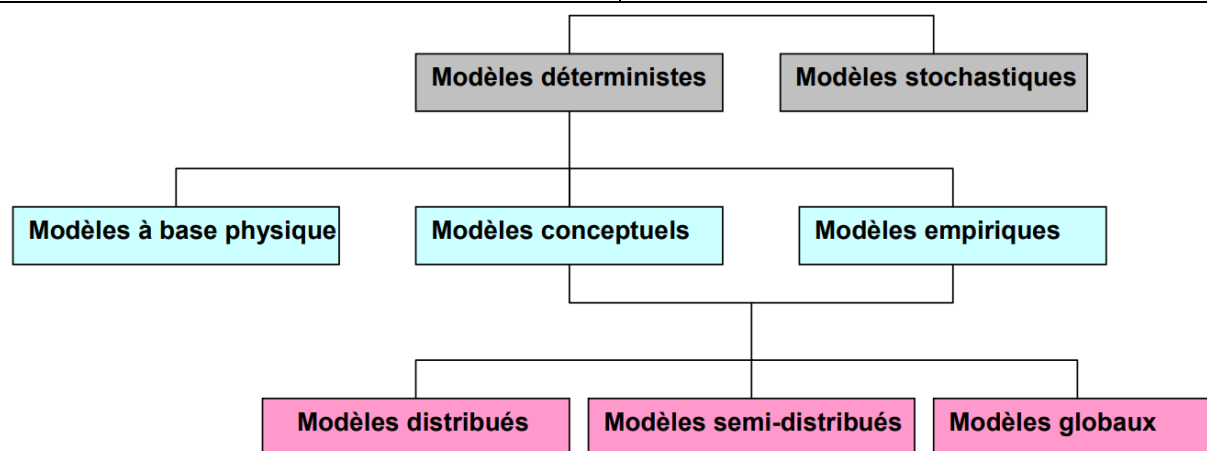


Figure 1. 2. Relation entre les modèles pluie-débit (Berthier, 2005)

I.3.1. Selon la nature de la variable

- Modèle déterministe (variables non aléatoires)

Un modèle est dit déterministe si aucune de ses grandeurs n'est considérée comme aléatoire (HENINE, 2005; 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).

- Modèle stochastique (variables aléatoires)

Au moins une des variables d'entrée (de forçage), des variables d'état ou des paramètres est une variable aléatoire. Par voie de conséquence, la ou les variables de sortie sont des variables aléatoires (Le Clerc, 2004), aux quelles sont associées des fonctions de distribution de probabilités

(Makhlouf, 1994).

I.3.2. Selon le traitement de l'espace (Homogénéité du bassin)

- Modèle global

Comme les modèles du type GR (Edijatno & Michel, 1989), le modèle HEC-1 (Hydrologic Engineering Center, 1998) ou le modèle PDM Probability Distributed Moisture (Moore, 2007) le bassin est considéré comme une seule entité qui réagit dans son ensemble. Les caractéristiques physiques et les grandeurs météorologiques sont considérées comme uniformes à l'échelle du bassin versant assimilé à une unité ponctuelle. Il s'agit de valeurs moyennes applicables à tout le bassin versant. Les processus hydrologiques sont simulés pour l'ensemble du bassin versant. Des recherches menées pour introduire une représentation de la variabilité spatiale des bassins versants dans certains de ces modèles – travaux de (WENDLING, 1992) avec TOPMODEL et de (BOURQUI, 2008) avec GR4H et GR4J – ont montré qu'il n'y avait pas de gain de modélisation suite à la prise en compte de cette variabilité, ces modèles globaux n'apparaissent donc pas pénalisés par l'utilisation d'une pluie moyenne de bassin.

- Modèles semi-distribués et distribués :

Ces modèles tiennent compte de la variabilité spatiale des processus hydrologiques modélisés, les variables d'entrée, les conditions aux limites et les caractéristiques du bassin. Pour les modèles semi-distribués, les quantités mentionnées ci-dessus sont partiellement autorisés à varier dans l'espace en divisant le bassin en petits sous-bassins qui à leur tour sont traités comme une seule unité. On peut aussi choisir de ne spatialiser que les facteurs dont la répartition spatiale est jugée cruciale dans la réponse hydrologique d'un bassin versant. Cela peut concerner à titre d'exemple la précipitation et l'état hydrique initial. Les modèles entièrement distribués en contrepartie, discrétisent l'espace d'étude à des cellules définies par le modélisateur et connue pour être la résolution du modèle. Ces types de modèles effectuent des prévisions distribuées dans l'espace avec des variables d'état moyennées sur le carré de quadrillage, L'approche de distribution donne une meilleure représentation de l'hétérogénéité pouvant exister sur un bassin, cependant, la spatialisation entraîne une complexification des modèles.

Plusieurs études comparatives ont été menées afin de répondre à la question de performance des modèles globaux et distribués, En général, lorsque le problème de modélisation pluie-débit est bien posé, les deux types des modèles simulent le débit à l'exutoire à un degré très proche. Toutefois, une variété d'autres études indique que chaque type de modèle donne des résultats recommandés à son domaine d'utilisation. Les modèles distribués, généralement associés aux modèles à base physique sont plus avantageux dans les études qui concernent 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 raison pour laquelle les modèles de paramètres distribués n'ont pas vu une utilisation répandue est l'indisponibilité des bases de données détaillées. Les améliorations futures dans l'acquisition de données, y compris l'application des systèmes d'information géographique (SIG), vont probablement conduire à une utilisation plus large de modèles de paramètres distribués.

1.3.3. Selon le fondement théorique et approche de développement

Les modèles représentent le comportement d'un bassin versant avec un degré d'abstraction plus ou moins important. On peut les classer en trois groupes principaux : modèles de type « boîte noire » ou empiriques, les modèles « à réservoir », appelés aussi « conceptuels » et les modèles dits « à base physique ».

- Modèles boîte noire

Ce sont des modèles qui visent à établir une relation purement mathématique basée sur les observations de la pluie et du débit d'un bassin versant. Celui-ci est traité comme une « boîte noire » sans faire d'hypothèses sur les processus internes qui contrôlent la transformation des précipitations en ruissellement. Cette catégorie regroupe les modèles régressifs, les méthodes fondées sur les fonctions de transfert comme l'hydrogramme unitaire, les réseaux de neurones, la programmation génétique, la logique floue ...etc. Relativement simple à mettre en œuvre, ce type de modèle peut être utilisé pour la prévision des crues. Cependant, ces modèles ne prévoient que le débit à l'exutoire du bassin versant. Ils nécessitent un grand nombre de données pour leur calage et leurs paramètres sont difficiles à relier aux caractéristiques physiques du bassin. Ils ne permettent donc pas de comprendre le comportement d'un bassin versant en leur offrant un pouvoir explicatif très faible.

- Modèles conceptuels ou « à réservoir »

Les modèles conceptuels ou réservoirs sont basés sur une analogie qui considère le bassin versant comme étant une série de réservoirs interconnectés. Le processus hydrologique est expliqué par des formulations conceptuelles et décrit par des équations paramétrées. Chaque réservoir est caractérisé par plusieurs paramètres qui sont à déterminer par calibrage et validation. Les paramètres du modèle n'ont pas nécessairement un sens physique clair relié aux caractéristiques du bassin versant, cependant, l'idée de faire une analogie entre le processus hydrologique et le comportement des réservoirs offre à ce type de modèle un pouvoir explicatif plus important que celui des boîtes noires. Ce type de modèle souffre d'une subjectivité importante dans la partie d'élaboration, car premièrement, ce sont des modèles établis selon l'expérience propre de

l'hydrologue. Deuxièmement, ils ne s'appliquent pas partout à cause des différences des paramètres hydrologiques d'un bassin versant à un autre et d'un climat à l'autre. Ceci les rend encore très difficiles à appliquer dans les bassins non jaugés même si des tentatives de régionalisation des paramètres des modèles avec les caractéristiques des bassins versants ont été proposées. Malgré les difficultés associées, les modèles conceptuels constituent la grande majorité des modèles utilisés dans des applications pratiques qui visent de reproduire le débit à l'exutoire du bassin versant. Il existe plusieurs modèles de ce type : les modèles GR, les modèles réservoirs (Tank Model), HBV, etc.

- Les Modèles à Base Physique

Tel qu'expliqué par Beven, ces modèles s'appuient sur des lois de physiques validés indépendamment du modèle hydrologique dont les paramètres sont issus du terrain. Ce sont les lois de l'hydrodynamique telles que la conservation de masse, la conservation des quantités de mouvements, la conservation d'énergie, les équations de St. Venant pour les écoulements à surface libre, l'équation de Richards pour l'écoulement non-saturé, PenmanMonteith pour l'évapotranspiration, l'équation de Boussinesq pour l'écoulement souterrain..., etc. Ces modèles nécessitent une discrétisation fine de l'espace permettant donc une représentation détaillée du bassin versant simulant les débits en tout point et tout instant. Ils se basent aussi sur l'utilisation de paramètres reliés directement à des caractéristiques mesurables dans le bassin versant dans l'espoir de l'élimination de l'étape de calibration et donc l'extension de leurs utilisations même dans les bassins versant non-jaugés. Cependant en pratique, ces modèles exigent un nombre très important de données rarement disponibles, et tombent dans le piège de surparamétrisation qui conduit à des calculs importants incompatibles avec la prévision des crues même avec l'avancement technologique actuel des machines de calculs. Pour cette raison, les modèles à base physiques ne sont pas utilisés dans la prévision des crues mais plutôt dans les problèmes de transport solide et la propagation de la pollution. Ils sont aussi très pratiques dans l'étude des impacts environnementaux et l'évaluation de l'impact du réchauffement climatique.

I.4. Calibration et validation d'un Modèle

I.4.1. Calage des modèles

Les modèles hydrologiques contiennent plusieurs paramètres qui ne peuvent pas être mesurés directement. Le processus d'estimation des paramètres est appelé « calibration, calage ou apprentissage du modèle ». Généralement, calibration est effectué en optimisant les paramètres du modèle afin que la sortie du modèle corresponde aussi étroitement que possible aux réponses observées du système hydrologique sur toute période de temps historique.

Le modèle peut être calibré manuellement, automatiquement ou par une combinaison des deux. La calibration manuelle consiste à ajuster manuellement les valeurs des paramètres de manière itérative, ceci demande beaucoup de travail et son succès dépend fortement de l'expérience du modélisateur. Les performances du modèle sont évaluées après chaque ajustement. L'opérateur arrête le calage lorsque la performance atteinte est considérée comme raisonnable. Ce jugement est généralement basé sur la combinaison de critères de performance numériques et graphiques. En raison de la nature chronophage de calibration manuel, de nombreuses recherches ont été menées pour développer des méthodes calibration automatique (p. Ex. (Duan et al., 1992; Madsen, 2000; Solomatine, 1999; Vrugt et al., 2003; Yapo et al., 1996) car elles sont assez facile à mettre en œuvre dans la modélisation hydrologique. Cependant, Les méthodes de calibration automatique sont conçues pour identifier l'ensemble de paramètres qui fournit la valeur optimale d'un critère de performance numérique sélectionné. L'optimisation est réalisée en appliquant des changements itératifs et systématiques aux valeurs des paramètres afin de minimiser les erreurs de simulation pour la fonction objectif correspondante. La calibration automatique nécessite un algorithme d'optimisation mathématique et le code informatique correspondant.

1.4.2. Validation des modèles

La validation du modèle n'équivaut pas à la vérification du modèle. L'objectif de la vérification est de vérifier que le modèle est « réaliste », c'est-à-dire qu'il fournit une représentation la plus proche possible de la réalité. La validation, en revanche, sera considérée comme consistant uniquement à vérifier que le modèle fournit une représentation raisonnable de cette réalité, adaptée à l'objectif visé.

En fait, quelle que soit la capacité du modèle à reproduire la réponse du bassin pour un ensemble donné d'observations, il n'est jamais possible de conclure que le modèle est exact (ou totalement « réaliste »). Par exemple, il est toujours possible que des observations futures soient obtenues pour des événements hydrologiques majeurs qui révéleront un comportement hydrologique qui n'a pas pu être identifié sur la base d'observations passées et ne pourrait donc pas être pris en compte dans le développement du modèle.

Il est donc impossible de vérifier qu'un modèle est pleinement réaliste. Il est cependant possible de conclure que ce n'est pas le cas si une ou plusieurs observations ne peuvent pas être expliquées par le modèle. En revanche, il est en principe possible de valider un modèle, c'est-à-dire de vérifier qu'il est raisonnable pour l'objectif visé. Cependant, aucune méthode universelle n'existe pour une telle validation. Les schémas de validation et les critères utilisés pour évaluer la validité des modèles varient considérablement.

I.4.3. Problèmes et difficultés

Il existe énormément de contraintes qui font face au modélisateur afin qu'il puisse assurer sa tâche de calibration et validation du modèle :

-Il faudrait s'assurer que les mesures de pluie, débit ou évapotranspiration sont de bonne qualité, sinon le comportement du modèle suivra une logique complètement erronée, ce qui conduit à des outputs erronés ou même à des difficultés liées à la calibration.

-Plus, cette période représente une large gamme d'événements différents, plus le modèle sera représentatif du fonctionnement du bassin versant,

-La répartition de l'historique sur les périodes, mise en route, calibration et validation est cruciale, en particulier dans l'insuffisance de la longueur de la série historique,

-Les paramètres calibrés sont dépendants de la période choisie, n'offrant pas un jeu de paramètre unique représentatif des caractéristiques du bassin versant.

-Le choix du type de calage du modèle (manuel ou automatique).

-Le choix adéquat de la fonction objective qui résume l'information de l'erreur entre les simulations et les observations.

I.5. Critères de performance du Modèle

Avant de calibrer un modèle hydrologique, un ou plusieurs critères de performance doivent d'abord être définis. De nombreux critères sont possibles. Ils peuvent également être utilisés dans l'étape d'évaluation du modèle. Les performances du modèle peuvent d'abord être évaluées qualitativement en comparant visuellement les valeurs observées et simulées d'une variable donnée sur un graphique, et peuvent aussi être évaluées quantitativement à l'aide d'un critère de performance numérique donné qui est une fonction mathématique de l'erreur obtenue.

Plusieurs fonctions objectives existent, mais la fonction objectif la plus utilisée en hydrologie est celle du critère de Nash ([NASH & SUTCLIFFE, 1970](#)). D'autres fonctions objectives peuvent être trouvées dans la littérature (par exemple, ([Singh, 1995](#))). Ils reflètent divers objectifs d'optimisation parfois contradictoires. Les objectifs les plus couramment rencontrés visent à obtenir une bonne adéquation entre : 1) les volumes de débit mesurés et simulés sur la période de simulation, 2) les débits observés et simulés dans le temps - que ce soit pour toute la période de simulation ou pour certains événements sélectionnés, 3) les crues caractéristiques (p. ex., débits de pointe, temps de montée, volumes de crue) et 4) caractéristiques de faible débit (p. ex. facteurs de décroissance,

réserve disponible).

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{cal,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})^2} \quad (1.1)$$

Cette fonction compare la simulation du modèle sur n pas de temps à la moyenne des observations prise comme modèle de référence. Plus le NSE est proche de 1, plus la simulation est proche de l'observation. Si le $NSE > 0$, alors le modèle est meilleur que la moyenne des débits, et Si le $NSE < 0$, alors le modèle ne fait pas mieux que la moyenne des débits.

Le NSE est strictement équivalent au critère des moindres carrés (il suppose donc les mêmes conditions concernant la structure statistique des erreurs), Son grand avantage est qu'il est normalisé. Il peut donc être utilisé pour comparer les performances d'un modèle dans différents contextes de simulation et pour différents bassins versants. L'inconvénient de ce critère est que les valeurs élevées sont fortement pondérées. Pour augmenter le poids des valeurs faibles, la même formulation est parfois utilisée sur le logarithme ou la racine carrée de la variable. De telles formulations doivent être préférées en particulier lorsqu'elles se concentrent sur les faibles débits.

Les fonctions d'erreur quadratique

On peut évaluer l'erreur quadratique moyenne, Root Mean Square Error (RMSE) et l'erreur absolue moyenne (MAE) pour décrire aussi la dispersion entre les variables simulées et observées.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{cal,i} - Q_{obs,i})^2} \quad (1.2)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_{cal,i} - Q_{obs,i}| \quad (1.3)$$

Plus le RMSE et MAE sont faible, plus la dispersion est faible et plus la variable simulée par le modèle est proche de celle observée.

On peut aussi calculer un coefficient de corrélation pour évaluer la corrélation entre les variables observée et simulée. Ce coefficient de corrélation R^2 est défini comme étant le carré du coefficient de corrélation de Pearson (R):

$$R^2 = \frac{\sum_{i=1}^n [(Q_{obs,i} - \bar{Q}_{obs})(Q_{cal,i} - \bar{Q}_{cal})]^2}{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})^2 \sum_{i=1}^n (Q_{cal,i} - \bar{Q}_{cal})^2} \quad (1.4)$$

L'indice de Willmott ($0 < WI \leq 1$) est défini par :

$$WI = 1 - \left[\frac{\sum_{i=1}^n (Q_{cal,i} - Q_{obs,i})^2}{\sum_{i=1}^n (|Q_{cal,i} - \bar{Q}_{obs}| + |Q_{obs,i} - \bar{Q}_{obs}|)^2} \right] \quad (1.5)$$

Pour toutes les expressions mathématiques mentionnées ci-dessus, $Q_{cal,i}$ et $Q_{obs,i}$ sont

respectivement les débits simulés et observés au pas de temps i , $\overline{Q_{obs,i}}$ est la moyenne des débits observés, $\overline{Q_{cal,i}}$ est la moyenne des débits simulés et n le nombre de pas de temps considérés.

Pour évaluer les capacités du modèle à prévoir les événements extrêmes, le score de compétence de Peirce (PSS) ‘Peirce Skill Score’ et le score de dépendance extrême (EDS) ‘Extreme Dependency Score’ sont définis par :

$$PSS = \frac{a}{a+c} - \frac{b}{b+d} \quad (-1 < PSS \leq 1) \quad (1.6)$$

$$EDS = \frac{2 \ln\left(\frac{a+c}{n}\right)}{\ln\left(\frac{a}{n}\right)} - 1 \quad (-1 < EDS \leq 1) \quad (1.7)$$

où a représente le nombre d'occasions où l'événement extrême a été prédit et observé, b représente le nombre de fois où l'événement a été prédit mais non observé (fausses alarmes), c représente le nombre de fois où l'événement a été observé mais non prédit (manque), et d représente le nombre de fois où l'événement n'a été ni prédit ni observé (rejets corrects), avec $n = a + b + c + d$ désignant le nombre total de cas.

Conclusion

Nous avons présenté dans ce premier chapitre le contexte général dans lequel s’inscrivent nos recherches. La modélisation hydrologique pluie-débit est considérée comme un des outils essentiels de la prévision des débits de crues, car elle compte parmi les moyens les mieux adaptés pour décrire de façon assez sommaire une réalité complexe d’un bassin versant. Transcriptions mathématiques de la transformation (pluie en débit), les modèles qui ont été développés depuis une quarantaine d’années sont très variés, faisant appel à différentes perceptions du monde réel et répondant à différents objectifs. Notre analyse nous a conduit à identifier différentes catégories de modèles, dont la multitude est le reflet des difficultés que rencontre la modélisation dans la représentation du comportement du bassin versant, ces modèles pluie-débit ont pour but de prédire les débits de repense d’un bassin aux événements pluvieux à partir d’une série d’observations pluies-débits.

Dans cette étude, on cherchera à analyser les performances, robustesses et fiabilités en extrapolation les modèles à boîte noire (modèles basés sur l’intelligence artificielle), afin de modéliser les débits de crues pour un bassin semi-aride, Seybouse.

CHAPITRE II

MODÈLE HYDROLOGIQUE CONCEPTUEL

Introduction

La modélisation pluie-débit est la première étape de la gestion des ressources en eau. C'est le seul moyen de simuler le comportement hydrologique du bassin pour une bonne évaluation de la potentialité de celui-ci en termes de production d'eau. Comme mentionnée au chapitre précédent, de nombreuses approches sont actuellement utilisées. Dans les modèles physiquement distribués, des relations déterministes issues des lois de conservation de la physique (conservation de la masse, conservation de la quantité de mouvement) sont résolues pour décrire les processus hydrologiques générant l'écoulement et leur interaction. Un modèle numérique d'élévation (Digital Elevation Model 'DEM') qui doit être le plus complet possible est associé. La complexité des équations à résoudre et l'énorme quantité de données requises, l'incertitude de ces données rendent ces modèles d'une utilité limitée. Les modèles conceptuels pluie-débit sont souvent préférés par les hydrologues. Ces modèles sont basés sur des équations reliant de manière réaliste les différents termes du cycle hydrologique. Ils sont plus simples que les modèles déterministes et plus flexibles, les modèles conceptuels sont généralement globaux. Selon la manière dont les termes du cycle hydrologique sont pris en compte, le modèle conceptuel peut être qualifié d'empirique ou non. Parmi ces modèles globaux est le modèle du Génie Rural à 4 paramètres Journalier (GR4J) que nous allons présenter dans ce chapitre son description mathématique notamment ses fonction et ses différents applications.

II.1. Histoire du développement des modèles GR4J

Le développement du modèle GR4J a été initié au Cemagref (France) au début des années 1980, pour objectif de mettre au point un modèle de simulation pluie-débit robuste et fiable en vue d'utilisations pour des applications de gestion de la ressource en eau et d'ingénierie (dimensionnement d'ouvrage, prévision des crues et des étiages, gestion de réservoirs, détection d'impact...). Ce modèle a connu plusieurs versions, proposées successivement par [Edijatno \(1989\)](#); [Edijatno \(1991\)](#), [Nascimento \(1995\)](#), [Edjijatno et al, \(1999\)](#), [Perrin \(2000\)](#), et qui ont permis d'améliorer progressivement les performances du modèle. La version utilisée dans ce travail a été mise au point par Perrin en 2002 et améliorée par [Perrin et al. en 2003](#).

II.2. Description du modèle pluie-débit journalier GR4J

II.2.1. Modèle Conceptuel Global (GR4J)

Le modèle GR4J (modèle du Génie Rural à 4 paramètres Journalier) est un modèle pluie-débit global à quatre paramètres. Le modèle utilise en entrée la hauteur de pluie moyenne sur le bassin versant P (mm) et l'évapotranspiration potentielle E (mm).

Bien que GR4J soit un modèle empirique, sa structure l'apparente à des modèles conceptuels à réservoirs, avec une procédure de suivi de l'état d'humidité du bassin qui permet de tenir compte des conditions antérieures et d'en assurer un fonctionnement en continu. Sa structure associe un réservoir de production et un réservoir de routage, des hydrogrammes unitaires ainsi qu'une fonction d'ouverture sur l'extérieur non atmosphérique permettant de simuler le gros du comportement hydrologique du bassin.

Le modèle GR4J a certaines fonctions communes avec le modèle mensuel GR2M (par exemple la fonction de production liée au réservoir sol). Son module de routage est cependant plus sophistiqué qu'au pas de temps mensuel (Perrin et al., 2007).

II.2.2. Description mathématique

La modélisation pluie-débit par le modèle conceptuel (à réservoir), le GR4j, est réalisée par deux processus différents, à savoir la fonction de production (fortement non-linéaire), qui sépare la pluie en une partie infiltrée et une partie ruisselée et la fonction de transfert (qu'on considère linéaire) qui achemine la pluie ruisselée à l'exutoire du bassin versant.

Le modèle comporte deux réservoirs (figure 2.1) et nécessite quatre paramètres à caler:

- X1 : capacité maximale du réservoir de production,
- X2: paramètres d'échanges souterrains,
- X3 : capacité à un jour du réservoir de routage,
- X4 : temps de base de l'hydrogramme unitaire.

II.2.2.1. Fonction de production

Les deux variables d'entrée sont la pluie, et l'évapotranspiration potentielle. La fonction de production se divise en deux phases :

a) La phase d'interception : dans cette partie, on calcule la pluie nette (Pn) et l'évapotranspiration nette (En), suivant deux cas :

$$\text{Si } P \geq E \text{ alors } P_n = P - E \text{ et } E_n = 0 \quad (2.1)$$

$$\text{Si } P < E \text{ alors } P_n = 0 \text{ et } E_n = E - P$$

b) La phase de production (Réservoir sol) : ce réservoir est limité par une capacité maximale X1, qui est le premier paramètre du modèle à caler. Le réservoir sol, sert à conditionner l'humidité du bassin.

Si la pluie nette (Pn) est nulle, l'évapotranspiration fait diminuer le niveau du réservoir sous l'effet d'évapotranspiration réelle (Es). Si la pluie nette est supérieure à zéro, le niveau du réservoir

augmente, et cette quantité de pluie (P_s) est stockée dans ce réservoir.

P_s et E_s sont données par :

$$P_s = \frac{x_1 \left(1 - \left(\frac{S}{x_1}\right)^2\right) \tanh\left(\frac{P_n}{x_1}\right)}{\left(1 + \frac{S}{x_1}\right) \tanh\left(\frac{P_n}{x_1}\right)} \quad \text{si } P_n > 0 \quad (2.2)$$

$$E_s = \frac{s \left(2 - \left(\frac{S}{x_1}\right)^2\right) \tanh\left(\frac{E_n}{x_1}\right)}{1 + \left(1 - \frac{S}{x_1}\right) \tanh\left(\frac{E_n}{x_1}\right)} \quad \text{si } E_n > 0 \quad (2.3)$$

A la sortie du réservoir sol, les percolations (per) contribuent à l'écoulement :

$$Per = S \left[1 - \left(1 + \left(\frac{S}{2.25 \cdot x_1}\right)^4\right)^{\frac{-1}{4}} \right] \quad (2.4)$$

II.2.2.2. Fonction de transfert

a) Hydrogrammes unitaires

L'hydrogramme unitaire s'intercale sur la pluie nette, déterminée par le réservoir sol et le réservoir eau gravitaire, il permet d'étaler cette même pluie nette afin de reproduire correctement les montées de crue. La valeur de Pr est divisée en deux composantes d'écoulement ; 90 % étant routés par un hydrogramme unitaire HU1 et un réservoir de routage et 10 % par un unique hydrogramme unitaire symétrique HU2.

HU1 et HU2 dépendent du même paramètre X_4 et du temps de base de HU1 exprimé en jours. Les ordonnées des hydrogrammes sont calculées à partir des courbes en S notées respectivement SH1 et SH2. SH1 et SH2 sont définies en fonction du temps par [Edijatno \(1991\)](#), [Makhlouf \(1994\)](#) et [PERRIN \(2000\)](#).

$$\left\{ \begin{array}{ll} \text{Pour } t \leq 0 & SH1(t) = 0 \\ \text{Pour } 0 < t < X_4 & SH1(t) = \left(\frac{t}{X_4}\right)^{5/2} \\ \text{Pour } t \geq X_4 & SH1(t) = 1 \end{array} \right\} \quad (2.5)$$

$$\left\{ \begin{array}{ll} \text{Pour } t \leq 0 & SH2(t) = 0 \\ \text{Pour } 0 < t \leq X & SH2(t) = \frac{1}{2} \left(\frac{t}{X_4}\right)^{5/2} \\ \text{Pour } X_4 < t < 2 \cdot X_4 & SH2(t) = 1 - \frac{1}{2} \left(2 - \frac{t}{X_4}\right)^{5/2} \\ \text{Pour } t \geq 2 \cdot X_4 & SH2(t) = 1 \end{array} \right\} \quad (2.6)$$

Les ordonnées de HU1 et HU2 sont alors calculées par :

$$\begin{aligned} UH1(j) &= SH1(j) - SH1(j-1) \\ UH2(j) &= SH2(j) - SH2(j-1) \end{aligned} \quad (2.7)$$

A chaque pas de temps i , les sorties Q_9 et Q_1 des deux hydrogrammes correspondent à la convolution des pluies antérieures par la clé de répartition donnée par l'hydrogramme discrétisé et sont calculées par :

$$\begin{aligned} Q_9(i) &= 0.9 \sum_{k=1}^i UH1(k) \cdot Pr(i-k+1) \\ Q_1(i) &= 0.1 \sum_{k=1}^m UH2(k) \cdot Pr(i-k+1) \end{aligned} \quad (2.8)$$

b) Fonction d'échange

Un terme F permet de tenir compte des infiltrations profondes ou des échanges d'eau souterrains. Il dépend d'un paramètre X_2 (négatif ou positif).

Un échange souterrain en eau dans la version de [Perrin et al. \(2003\)](#) est calculé par :

$$F = X_2 = \left(\frac{R}{X_3}\right)^{7/2} \quad (2.9)$$

Où R est le niveau dans le réservoir, X_3 est la capacité à un jour du réservoir et X_2 est le coefficient d'échange en eau qui peut être positif dans le cas d'apports, négatif dans le cas de pertes vers des nappes profondes ou nul. En effet, l'interprétation physique de cette fonction d'échange n'est pas directe.

c) Réservoir de routage

Après avoir été retardé par l'hydrogramme unitaire, la principale composante d'écoulement transite par un réservoir de routage non linéaire qui se vidange suivant une loi :

$$Qr(t) = K[R(t)]^5 \quad (2.10)$$

Où K est une constante et R le niveau dans le réservoir de routage. Le niveau du réservoir de routage est donc mis à jour d'après :

$$\frac{1}{R_{k+1}^4} = \frac{1}{R_k^4} + \frac{1}{X_3^4} \quad (2.11)$$

Où X_3 est la capacité maximale du réservoir de routage. On a posé :

$$\frac{1}{X_3^4} = 4 \cdot K \cdot \Delta t \quad (2.12)$$

avec $\Delta t = 1$ jour, pas de temps de fonctionnement. Le débit du réservoir est alors :

$$Qr = R_{k-1} - R_k \quad (2.13)$$

d) Ecoulement total

La sortie Q_1 de l'hydrogramme HU2 est soumise aux mêmes échanges pour donner la composante d'écoulement Q_d :

$$Q_d = \max(0 ; Q_1 + F)$$

Le débit total Q est alors donné par :

$$Q = Q_r + Q_d \tag{2.14}$$

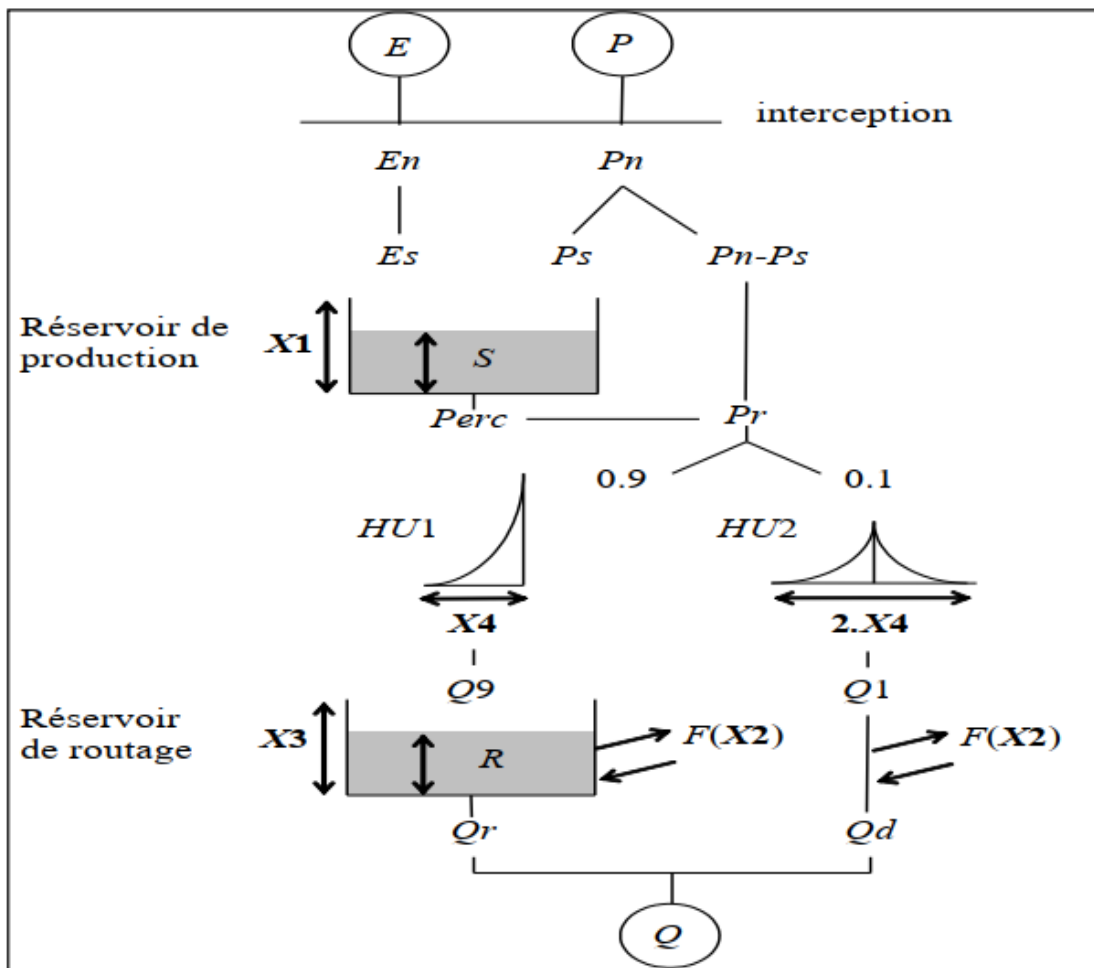


Figure 2. 3. Architecture du modèle GR4j (Perrin, 2003)

II.3-Applications du modèle "GR"

Ce modèle a été efficacement utilisé dans la modélisation hydrologique et a démontré une grande puissance de calcul dans divers recherches, tout en étant un outil fiable pour modéliser plusieurs systèmes non linéaires tels que la relation pluie-débit.

[Ague. \(2014\)](#) a comparé un modèle conceptuel GR4J et un modèle semi-distribué GéoSFM sur le bassin versant de l'Ouémé à Savè au Bénin. Son étude s'est appuyée sur trois types de données : météorologiques (pluie, évapotranspiration potentielle), hydrométriques (débit) et planimétriques (carte). Ses résultats montrent que le modèle GR4J surclasse le modèle GéoSFM, où les coefficients de corrélation entre les débits observés et simulés donnés par le modèle GR4J sont supérieures à 50% de ceux fournis par le modèle GéoSFM.

[Boulfekhar et al. \(2016\)](#) a essayé deux approches assez différentes pour la modélisation pluie-débit dans le bassin versant de l'Oued Rhumel-Smendou aux pas de temps annuel et mensuel: une empirique de type boîte noire sous la forme $lames\ d'eau\ écoulées = f(pluie)$ où f est déterminée par une régression effectuée sur les chroniques pluies-débits. L'autre conceptuelle globale représentée par le modèle du Génie Rural (GR) élaboré par le Cemagref. Les résultats obtenus par la simulation de la transformation de la pluie en débit par l'utilisation des modèles du Génie Rural GR1A et GR2M sont plus satisfaisants que la modélisation par approche corrélatrice.

[Benzineb. \(2017\)](#) a comparés trois modèles de réseaux de neurones $Neur_1$, $Neur_2$, et $Neur_3$ (modèle à boîte noire) avec un autre type de modèle le GR4j (modèle conceptuel à réservoirs) pour modéliser la relation pluie-débit en milieu semi-aride algérien (cas du bassin d'oued Ouahrane) au pas de temps journalier sur des courtes durées. Elle a trouvé que les réseaux de neurones ($Neur_1$) avec une seule entrée (pluie) sont moins performants que le modèle GR4j. En revanche, l'ajout de l'évapotranspiration (ETP) comme variable explicative à l'entrée des modèles neuronaux développés ($Neur_2$) a fortement amélioré leurs performances. En effet, le modèle neuronal ($Neur_2$) est plus performant que le modèle GR4j tant en calage qu'en validation. L'introduction d'une troisième entrée (humidité du sol simulé par le modèle GR4j) paraît nécessaire pour améliorer les performances du réseau de neurone. Le modèle neuronal ($Neur_3$) à trois entrées (pluie, ETP et humidité du sol) a donné des résultats meilleurs que ceux obtenus par les autres modèles.

[Amireche. \(2018\)](#) a modélisé la relation pluie-débit sur quatre bassins versants algériens au pas de temps mensuel et journalier avec trois modèles différents : Les modèles GR (Génie Rural), les modèles « boîte noire » : Systèmes Neuro-Flous et le Tank Model couplé au Filtre de Kalman Standard et Étendu. Ses résultats obtenus montrent une supériorité remarquable du Tank Model couplé au Filtre de Kalman Étendu sur le reste des modèles et son adaptation aux conditions climatiques semi-arides très courantes en Algérie.

[Noumon et al. \(2020\)](#) a utilisé la version [Perrin et al., \(2003\)](#) du modèle Génie Rural à 4 Paramètres Journaliers (GR4J) pour simuler les débits d'étiage du fleuve Mono à l'exutoire d'Athiémé en prévision de l'utilisation durable des ressources en eau à des fins agricoles, où il a exploité les données hydro-climatiques journalières (Pluie, Evapotranspiration, Débits), sur la

période de 1970 à 2019. Ses résultats montrent que les valeurs du critère de Nash-Sutcliffe avant la construction du barrage en 1988, sont de l'ordre de 70% (sous-estimation) en calage et validation et les valeurs de KGE (Gupta et al., 2009) de 0,8317 et 0,8421 (proches de 1). Ces valeurs traduisent une bonne performance et robustesse du modèle GR4J sur le bassin du Mono. Mais ces valeurs sont très dégradées sur la période après barrage du fait du régime hydrologique modifié par les lâchers d'eau lors du turbinage, contrariées par le caractère lacunaire des observations sur cette période.

En générale, les domaines d'applications des modèles "GR" se résument en:

- la reconstitution ou l'extension de séries de débit : après calage, le modèle est appliqué en simulation sur une période sur laquelle on dispose de données pluviométriques observées ;
- la prédétermination : les séries de débit observé étant souvent courte, il peut être intéressant de les étendre à l'aide d'un modèle pluie-débit. On peut pour cela soit utiliser des séries de pluie observée si elles sont suffisamment longues, soit utiliser un générateur stochastique de pluie qui permettra d'obtenir des séries probables de pluie sur le bassin (un tel générateur demandant un calage préalable sur des séries de pluie observée) ;
- la prévision à court terme (quelques heures à quelques jours): elle est particulièrement utile pour les événements de crues. Le modèle doit alors intégrer une procédure d'assimilation des débits observés, ce qui permet d'améliorer de façon substantielle les prévisions;
- la prévision à moyen ou long terme (de quelques semaines à quelques mois): elle est intéressante pour les problématiques d'étiage et de gestion de la ressource. Dans ce cas, se pose le problème de l'incertitude sur les pluies futures. Pour en tenir compte, on doit adopter un cadre de prévision probabiliste en utilisant de nombreux scénarios de pluie future à partir de l'instant de prévision, scénarios issus soit de prévisions d'ensemble de modèle météorologiques, soit d'archives météorologiques si elles existent, soit d'un générateur stochastique de pluie;
- la détection de tendance dans le comportement hydrologique du bassin versant : l'utilisation d'un modèle hydrologique permet d'identifier dans la variabilité des séries de débit ce qui vient de la variabilité naturelle des conditions climatiques de ce qui vient de changements de caractéristiques du bassin versant;
- la gestion ou le dimensionnement d'ouvrages : grâce au modèle, on peut dans une étude de dimensionnement simuler en continu des apports au réservoir et ainsi optimiser son dimensionnement pour des objectifs particuliers (soutien d'étiage, écrêtement de crue, etc.) en tenant compte ainsi de la variabilité naturelle de ces apports. En conditions opérationnelles, la prévision des apports peut permettre de mieux gérer l'ouvrage.

Conclusion

Le GR4J est un modèle global conceptuel pluie-débit appliqué avec seulement quatre paramètres, à un pas de temps journalier et utilisant peu de variables. Le modèle GR4J permet d'obtenir la simulation des débits journaliers dans un bassin hydrologique, de réaliser la prévision des crues et des étiages, de reproduire le fonctionnement du bassin et d'obtenir l'interpolation et l'extrapolation des conditions climatiques du bassin.

Les modèles du Génie Rural du fait de leur construction simplifiée, ne peuvent être que parcimonieux (peu de paramètres à caler). Cette simplicité, si elle n'est pas un objectif en soi, s'est imposée au cours de leur développement parce que de nombreuses hypothèses de fonctionnement, empruntées à l'arsenal des modèles conceptuels, étaient rejetées par des données observées lorsque de nombreux bassins étaient pris en compte et que le test en calage-contrôle était appliqué avec rigueur. C'est ainsi par exemple que les sous modèles classiques d'infiltration n'ont pu être retenus dans les architectures finales. Notons également que les fonctions d'échanges vers l'extérieur non atmosphérique du bassin, absentes de la grande majorité des modèles conceptuels, sont apparues comme indispensables à tous les pas de temps.

CHAPITRE III

MODÈLE D'INTELLIGENCE ARTIFICIELLE

Introduction

Les modèles de l'intelligence artificielle ont montré une grande capacité de modélisation et de prévision des séries chronologiques non linéaires et non stationnaires par rapport à d'autres techniques, en raison de leurs propriétés de modélisation non linéaires et flexibles. Les réseaux de neurones artificiels (RNA) et les réseaux de neurones convolutifs (CNN) sont les modèles les plus connus dans le domaine de l'intelligence artificielle qui fournit une précision raisonnable pour les problèmes hydrologiques, et un outil plus efficace pour les applications d'ingénierie. Pour cette raison, des techniques de modélisation basées sur des réseaux de neurones artificiels (RNA) et des réseaux de neurones convolutifs (CNN) ont été utilisées dans cette étude pour développer des modèles de prévision de débit à l'échelle journalière et horaire. Ces modèles de l'intelligence artificielle ont été optimisée avec des algorithmes métaheuristiques (l'algorithme génétique (GA), l'optimisation de l'essaim de particules (PSO), l'optimisation de l'essaim de particules amélioré (IPSO), l'algorithme de luciole (FFA), l'optimisation du loup gris (GWO) et l'algorithme compétitif impérialiste (ICA)) et comparés les uns aux autres sur six stations hydrométriques basant sur les critères de performance que ceux utilisés pour les modèles autonomes.

III.1. Les réseaux de neurones artificiels (RNA)

III.1.1. Histoire du développement des systèmes neuronaux artificiels

Le développement des systèmes neuronaux artificiels a une histoire intéressante. Puisqu'il n'est pas possible de couvrir cette histoire en profondeur dans un court paragraphe, seules les réalisations majeures sont mentionnées. L'année 1943 est souvent considérée comme l'année initiale du développement des systèmes neuronaux artificiels. En 1943, McCulloch et Pitts ont décrit les premiers éléments formels pour effectuer des opérations logiques, et ainsi il pourrait fonctionner comme un élément de calcul arithmétique-logique. Cependant, la mise en œuvre de son modèle électronique compact n'était pas technologiquement réalisable à l'ère des tubes à vide encombrants. Cependant, le modèle neuronal de McCulloch et Pitts a jeté les bases d'un développement futur. En 1949, Donald Hebb a proposé pour la première fois un schéma d'apprentissage pour mettre à jour les connexions des neurones, appelé règle d'apprentissage Hebbian. Il a déclaré que les informations peuvent être stockées dans des connexions et a postulé la technique d'apprentissage qui a eu un impact profond sur les développements futurs dans ce domaine. Dans les années 1950, les premiers neuro-ordinateurs ont été construits et testés par Minsky en 1954. Ils ont adapté les connexions automatiquement. Au cours de cette étape, Frank Rosenblatt a inventé l'élément de type neurone appelé perceptron en 1958. C'était une machine entraînable capable d'apprendre à classer certains modèles en modifiant les connexions aux éléments de seuil. L'idée a attiré

l'imagination des ingénieurs et des scientifiques et a jeté les bases des algorithmes d'apprentissage automatique de base qui sont encore utilisés aujourd'hui. Au début des années 1960, un dispositif appelé ADALINE (pour ADaptive LINear combiner) a été introduit, et une nouvelle règle d'apprentissage puissante appelée règle d'apprentissage Widrow-Hoff a été développée par Bernard Widrow et Marician Hoff en 1962 (Zurada, 1992). La règle a minimisé l'erreur quadratique additionnée pendant l'entraînement impliquant la classification de modèle. Malgré le succès et l'enthousiasme du début et du milieu des années 1960, les théorèmes d'apprentissage automatique de l'époque étaient trop hebdomadaires pour prendre en charge des problèmes de calcul plus complexes. Bien que les goulots d'étranglement aient été exactement identifiés dans le travail de Nilsson et que les architectures de réseau neuronal appelées réseaux en couches étaient également connues, il n'existait à l'époque aucun schéma d'apprentissage efficace qui contournerait les formidables obstacles. La recherche sur les réseaux neuronaux est entrée dans la phase de stagnation. Une autre raison qui a contribué à ce ralentissement de la recherche à cette époque était les ressources de calcul relativement modestes disponibles à ce moment-là. Le dernier épisode de cette époque a été la publication d'un livre de Marvin Minsky et Seymour Papert en 1969 qui a donné plus de doute quant au potentiel des réseaux d'apprentissage en couches. Les limitations déclarées des réseaux de classe perceptron ont été rendues publiques; cependant, le défi n'a été résolu qu'au milieu des années 80 (Zurada, 1992). Au cours de la période de 1982 à 1986, plusieurs publications fondamentales ont été publiées qui ont considérablement accru le potentiel des réseaux de neurones. L'ère de la renaissance a commencé avec John Hopfield en 1986, introduisant une architecture de réseau neuronal récurrent pour les mémoires associatives. Son article a formulé les propriétés de calcul d'un réseau d'unités entièrement connecté. Une autre revitalisation du domaine est venue de la publication en 1986 de deux volumes sur le traitement distribué parallèle, édités par James McClelland et David Rumelhart en 1986. Les nouvelles règles d'apprentissage et d'autres concepts introduits dans ce travail ont supprimé l'un des obstacles les plus essentiels à la formation des réseaux qui a fondé les efforts traditionnels du milieu des années 60 (Zurada, 1992). Ainsi de suite, jusqu'à ce que les réseaux neuronaux se développent remarquablement et soient utilisés dans divers domaines, dont celui de l'hydrologie. De nos jours, l'utilisation des réseaux neuronaux en hydrologie continue de croître. Les applications sont nombreuses et variées (voir sections suivantes).

III.1.2. Du neurone biologique au neurone artificiel

Les réseaux de neurones artificiels sont des outils puissants qui peuvent apprendre à résoudre des problèmes d'une manière similaire au cerveau humain. Un neurone artificiel est un modèle informatique inspiré des neurones naturels. Les neurones naturels reçoivent des signaux via des synapses situées sur les dendrites ou la membrane du neurone. Lorsque les signaux reçus sont

suffisamment forts (dépassent un certain seuil), le neurone est activé et émet un signal à travers l'axone. Ce signal pourrait être envoyé à une autre synapse et activer d'autres neurones. La complexité des vrais neurones est très abstraite lors de la modélisation avec des neurones artificiels. Celles-ci consistent essentiellement en des entrées (comme les synapses), qui sont multipliées par des poids (force des signaux respectifs), puis calculées par une fonction mathématique qui détermine l'activation du neurone. Une autre fonction (qui peut être l'identité) calcule la sortie du neurone artificiel (parfois en fonction d'un certain seuil). Les RNA combinent des neurones artificiels pour traiter les informations. Le neurone biologique schématisé et le neurone artificiel sont représentés sur les figures 3.1 et 3.2. La figure 3.2 montre la structure de RNA simple. C'est une combinaison de plusieurs neurones uniques.




Figure 3. 1. Diagramme schématisé d'un neurone biologique

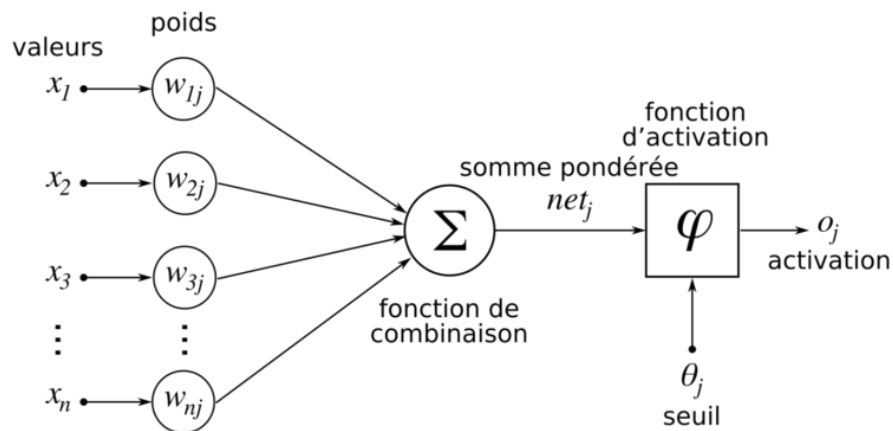


Figure 3. 2. Diagramme schématisé d'un neurone artificiel simple

Où $x_1, x_2, x_3 \dots x_n$ sont les entrées, $w_{1j}, w_{2j}, w_{3j} \dots w_{nj}$ sont les poids, φ est la fonction d'activation. Mathématiquement, tel qu'illustré par la figure 3.2, chaque neurone reçoit des entrées sous forme vectorielle puis il calcule une somme pondérée de ses entrées pour que le résultat passe ensuite par la fonction d'activation afin de créer une sortie.

Tableau 3. 1. Analogie entre le neurone biologique et le neurone formel

Neurone artificiel	Neurone biologique
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrite
Fonction d'activation	Soma

III.1.3. Structure et choix d'un réseau de neurones artificiel

Plusieurs types de réseaux de neurones existent comme le réseau de neurones à fonction de régression générale (GRNN), réseau de neurones à fonction de base radial (RBFN) et le perceptron multicouche (MLP). Mais, le perceptron multicouche avec une ou plusieurs couches cachées entre la couche d'entrée et la sortie est utilisé dans cette étude. Les structures des RNA sont décrites dans un certain nombre de manuels et d'articles classiques, par ex. (ASCE, 2000; Bishop, 1995; Schalkoff, 1997). Un RNA est composé d'une série d'éléments de traitement de l'information appelés nœuds ou neurones. Les informations sont transmises entre les nœuds via des connexions. Des poids sont ensuite associés à chaque connexion, ce qui représente l'ampleur ou la force de cette connexion. À l'intérieur du nœud se trouve une fonction de transformation non linéaire, appelée fonction d'activation, qui est appliquée aux signaux d'entrée entrant dans le nœud pour produire un signal de sortie. Les nœuds ou neurones sont ensuite disposés en une série de couches: une couche d'entrée; une ou plusieurs couches cachées; et une couche de sortie (Figure 3.3). Une matrice de poids W, un vecteur de biais b et une fonction d'activation ou de transfert f sont associés à chaque couche cachée (Schalkoff, 1997).

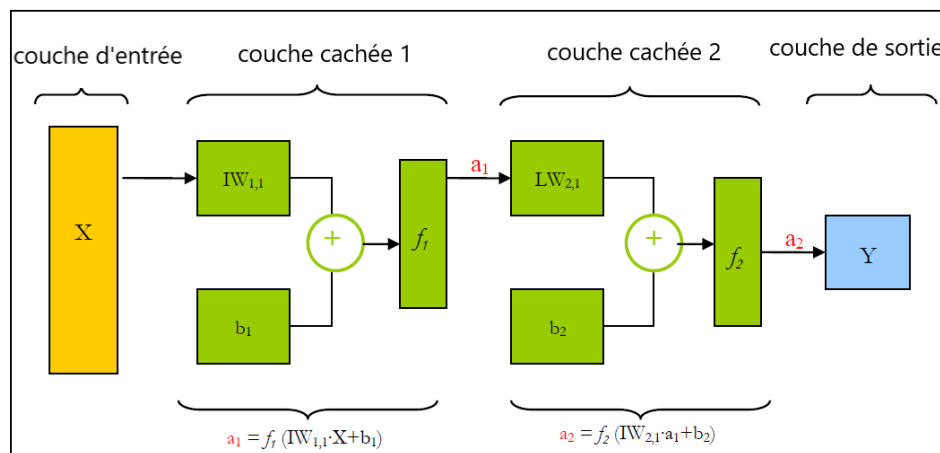


Figure 3. 3. Réseau à deux couches cachées.

La couche d'entrée est l'endroit où les informations externes sont reçues et fournies au réseau tandis

que la couche de sortie produit les prévisions. Chaque nœud est connecté à tous les autres nœuds de la couche précédente et suivante. La représentation des nœuds dans chaque couche et les interconnexions sont plus clairement illustrées dans la [figure 3.4](#). Ceci est un exemple de réseau à feedforward, c'est-à-dire que les informations circulent dans une direction forward à travers le réseau et il n'y a pas d'effets de rétroaction (feedback).

La sortie de chaque nœud est obtenue en calculant la valeur de la fonction d'activation par rapport au produit du vecteur d'entrée et du vecteur poids, moins la valeur du biais associé à ce nœud. Il est possible d'exprimer le traitement forward à travers le réseau sous la forme d'une seule équation. Un réseau avec une couche cachée et k sorties aurait la forme fonctionnelle suivante:

$$f_k(x, y) = w_{k0} + \sum_{j=1}^q w_{kj} g(w_{j0} + \sum_{i=1}^p w_{ji} x_i) \quad (3.1)$$

Où p est le nombre d'entrées, q est le nombre de nœuds dans la couche cachée, g est la fonction d'activation des nœuds de la couche cachée et x et w sont les poids. Les indices i et j correspondent respectivement au nœud de sortie et aux nœuds de couche masqués. Cependant, les RNA sont rarement exprimés de cette manière car l'équation n'est pas interprétable.




Figure 3. 4. Schéma d'un RNA multicouche

III.1.4. Fonction d'activation

La fonction d'activation (ou fonction de transfert) sert à convertir le résultat de la somme pondérée des entrées d'un neurone en une valeur de sortie, cette conversion s'effectue par un calcul de l'état du neurone en introduisant une non-linéarité dans le fonctionnement du neurone (Cybenkot, 1989). Le biais b joue un rôle de seuil, quand le résultat de la somme pondérée dépasse ce seuil, l'argument de la fonction de transfert devient positif ou nul; dans le cas contraire, il est considéré négatif. Finalement si le résultat de la somme pondérée est:

1. En dessous du seuil, le neurone est considéré comme non-actif
2. Aux alentours du seuil, le neurone est considéré en phase de transition.
3. Au-dessus du seuil, le neurone est considéré comme actif.

Il y a plusieurs types de fonctions de transfert qui peuvent être utilisées dans les RNA, les fonctions d'activation souvent utilisées sont représentées ci-dessous:

i. **La fonction non linéaire sigmoïde**

La fonction sigmoïde est définie par : $f(x) = \frac{1}{1+e^{-x}}$ (3.2)

ii. **La fonction à seuil**

On peut citer comme exemple la fonction Heaviside et la fonction Signe qui sont définies respectivement comme suit :

Fonction Heaviside : $h(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases}$ (3.3)

Fonction Signe : $sgn(x) = \begin{cases} +1 & \text{si } x \geq 0 \\ -1 & \text{sinon} \end{cases}$ (3.4)

iii. **La fonction linéaire à seuil**

On peut la définir comme suit : $F(x) = \begin{cases} x & \text{si } x \in [u, v] \\ v & \text{si } x \geq v \\ u & \text{si } x \leq u \end{cases}$ (3.5)

III.1.5. Apprentissage des réseaux de neurones

Le point crucial du développement d'un réseau de neurones est son apprentissage. Il s'agit d'une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information (Grossberg, 1982; Hebb, 1949; Rumelhart et al., 1986). Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt. Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience. Les poids sont initialisés avec des valeurs aléatoires. Puis des exemples expérimentaux représentatifs du fonctionnement du procédé dans un domaine donné, sont présentés au réseau de neurones. Ces exemples sont constitués de couples expérimentaux de vecteurs d'entrée et de sortie. Une méthode d'optimisation modifie les poids au fur et à mesure des itérations pendant lesquelles on présente la totalité des exemples, afin de minimiser l'écart entre les sorties calculées et les sorties expérimentales. Afin d'éviter les problèmes de

surapprentissage, la base d'exemples est divisée en deux parties : la base d'apprentissage et la base de test. L'optimisation des poids se fait sur la base d'apprentissage, mais les poids retenus sont ceux pour lesquels l'erreur obtenue sur la base de test est la plus faible. En effet, si les poids sont optimisés sur tous les exemples de l'apprentissage, on obtient une précision très satisfaisante sur ces exemples mais on risque de ne pas pouvoir généraliser le modèle à des données nouvelles. A partir d'un certain nombre d'itérations, le réseau ne cherche plus l'allure générale de la relation entre les entrées et les sorties du système, mais s'approche trop près des points et « apprend » le bruit (Pollard et al., 1992).

Sur la [figure 3.5](#) ci-dessous, on peut observer qu'au début de l'apprentissage, pour les premières itérations, l'erreur sur la base d'apprentissage est grande et peut légèrement augmenter étant donné que les poids initiaux sont choisis aléatoirement. Ensuite, cette erreur diminue avec le nombre d'itérations. L'erreur sur la base de test diminue puis augmente à partir d'un certain nombre d'itérations. Les poids retenus sont ceux qui minimisent l'erreur sur la base de test.




Figure 3. 5. Erreur moyenne sur la base d'apprentissage en fonction du nombre d'itérations.

Surapprentissage

Il arrive qu'à faire apprendre un réseau de neurones toujours sur le même échantillon, celui-ci devient inapte à reconnaître autre chose que les éléments présents dans l'échantillon. Le réseau ne cherche plus l'allure générale de la relation entre les entrées et les sorties du système, mais cherche à reproduire les allures de l'échantillon. On parle alors de surapprentissage : le réseau est devenu trop spécialisé et ne généralise plus correctement. Ce phénomène apparaît aussi lorsqu'on utilise trop d'unités cachées (de connexions), la phase d'apprentissage devient alors trop longue (trop de paramètres réglables dans le système) et les performances du réseau en généralisation deviennent médiocres.

III.1.5.1. Type d'apprentissage

Il existe de nombreux types de règles d'apprentissage qui peuvent être regroupées en trois catégories (Hassoun, 1995) : les règles d'apprentissage supervisé, non supervisé, et renforcé. Mais l'objectif fondamental de l'apprentissage reste le même : soit la classification, l'approximation de fonction ou encore la prévision (Weiss & Kulikowski, 1991). La prévision des séries temporelles est classiquement réalisée par l'apprentissage supervisé mais nous verrons dans la suite que l'utilisation de l'apprentissage non supervisé est aussi possible. Dans l'apprentissage non supervisé, l'algorithme va lui-même, sans information supplémentaire, catégoriser les variables d'entrées. Ce type d'apprentissage permet l'élaboration d'une représentation interne de l'espace des données d'entrée en identifiant une structure statistique sous-jacente des variables sous une forme plus ou moins simple. De façon générale, l'apprentissage artificiel supervisé consiste à créer un modèle de prédiction (classification ou prévision) à partir d'une base d'apprentissage comprenant les exemples d'entrée ainsi que les sorties désirées associées. Les paramètres du modèle vont ainsi s'adapter en comparant à chaque fois les sorties obtenues et les sorties désirées, d'où l'appellation supervisé. Une fois le modèle obtenu par une base d'apprentissage, l'utilisation d'une base de test, comprenant des nouveaux exemples non utilisés pendant l'apprentissage, permet de mesurer les performances de la méthode. Dans cette thèse, on s'intéressera uniquement à savoir la prévision des séries temporelles. On utilisant deux types de méthodes : les réseaux de neurones artificiels (RNA) et les réseaux de neurones convolutifs (CNN).

III.1.5.2. Algorithme d'apprentissage

L'algorithme d'apprentissage est la méthode mathématique qui va modifier les poids de connexions afin de converger vers une solution qui permettra au réseau d'accomplir la tâche désirée. L'apprentissage est une méthode d'identification paramétrique qui permet d'optimiser les valeurs des poids du réseau. Plusieurs algorithmes itératifs peuvent être mis en œuvre, parmi les algorithmes d'apprentissage supervisé les plus couramment utilisés sont :

- Algorithme de rétropropagation (BP)
- Algorithme de Levenberg-Marquardt (LM)
- Algorithme de régularisation bayésienne (BR)

III.1.6. Utilisation des RNA en hydrologie

L'utilisation des réseaux de neurones artificiels dans le domaine d'hydrologie devient de plus en plus importante. Cette technique a été appliquée dans la modélisation hydrologique avec succès et a montré, un pouvoir de calcul important dans plusieurs travaux et, qu'elle est une outile robuste pour modéliser de nombreux processus non linéaires tels que Pluie-Débit, le débit des cours d'eau,

la gestion des eaux souterraines, la simulation de la qualité de l'eau et les précipitations. Dans cette section, on présente une brève recherche bibliographique sur l'application des RNA dans quelques disciplines hydrologiques.

III.1.6.1. Applications dans la modélisation Pluie-Débit

La détermination de la relation entre la pluie et le débit pour un bassin versant est l'un des problèmes les plus importants auxquels sont confrontés les hydrologues et les ingénieurs. Des informations sur la pluie et le débit sont nécessaires à des fins de conception et de gestion hydrologiques. Cette relation est connue pour être hautement non linéaire et complexe. Outre la pluie, le débit dépend de nombreux facteurs tels que l'humidité initiale du sol, l'utilisation des terres, la géomorphologie des bassins versants, l'évaporation, l'infiltration, la distribution, la durée des précipitations, etc. Bien que de nombreux bassins versants aient été mesurés pour fournir des enregistrements continus du débit des cours d'eau, les ingénieurs sont souvent confrontés à des situations où peu ou pas d'informations sont disponibles. Dans de tels cas, les modèles de simulation sont souvent utilisés pour générer des flux synthétiques. Un certain nombre de chercheurs ont étudié le potentiel des réseaux neuronaux dans la modélisation du débit des bassins versants en fonction des entrées de pluie.

Dans une étude préliminaire, (Albert H et al., 1993) ont conçu un RNA en utilisant les hyétographes des précipitations observées comme entrées et les hydrogrammes enregistrés par l'U.S. Geological Survey (USGS) à Bellvue, Washington, comme sorties, pour prédire le débit. (Hjelmfelt & Wang, 1993a, 1993c, 1993b) ont développé un réseau neuronal basé sur la théorie de l'hydrogramme unitaire dans le bassin versant du ruisseau Goodwater (12,2 km²) dans le centre du Missouri. Il a été démontré que le réseau résultant reproduit mieux l'hydrogramme unitaire que celui obtenu grâce à la représentation standard de la fonction gamma. (Smith & Eli, 1995) ont appliqué un modèle de réseau neuronal à rétropropagation pour prédire le débit de pointe et le temps nécessaire pour atteindre un pic sur un bassin hydrographique hypothétique. Sur le bassin de la rivière aux Feuilles, (Pan et al., 2008) ont utilisé un RNA anticipé à trois couches et un RNA récurrent pour la modélisation quotidienne de pluie-débit. (Dawson & Wilby, 1998) ont utilisé un réseau de rétropropagation à trois couches pour déterminer le ruissellement sur les bassins versants des rivières Amber et Mole. (Tokar & Johnson, 1999) ont rapporté que les modèles de RNA offraient une précision élevée d'apprentissage et de test plus que les modèles de régression et conceptuels simples. Leur objectif était de prévoir le débit quotidien de la rivière Little Patuxent, dans le Maryland, les précipitations quotidiennes, la température et l'équivalent de la fonte des neiges servant d'intrants. (Rajurkar et al., 2002a) a appliqué les réseaux de neurones artificiels pour modéliser les débits quotidiens lors des crues de mousson pour un bassin versant de grande taille

de la rivière Narmada dans le Madhya Pradesh (Inde). (Srinivasulu & Jain, 2006a) a comparé diverses méthodes d'apprentissage disponibles pour la formation de réseaux de neurones artificiels (RNA) de type perceptron multicouche (MLP) pour modéliser le processus pluie-débit. En revanche, (Randrianarivony et al., 2010a) ont conclu que les RNA représentent des outils très utiles pour les modèles pluie-débit pour combler les lacunes en termes de données d'enquête. (Rezaeianzadeh et al., 2013a) a évalué un modèle hydrologique conceptuel et les réseaux de neurones artificiels pour la prévision des débits quotidiens à la sortie du bassin versant de Khosrow Shirin en Iran. (Benzineb & Remaoun, 2016) a fait la modélisation pluie-débit quotidienne par les réseaux neuronaux en zone semi-aride dans le bassin d'Oued Ouahrane. (Vilanova et al., 2019) a fait une évaluation des combinaisons de paramètres d'entrée / sortie de réseaux de neurones artificiels pour mieux simuler le débit quotidien dans des bassins versants de la forêt tropicale atlantique brésilienne. (Sharma et al., 2020) a réalisé une modélisation du processus pluie-débit à l'aide d'un réseau neuronal artificiel en mettant l'accent sur la sensibilité des paramètres, dans trois bassins, deux des États-Unis et un de l'Australie.

III.1.6.2. Applications dans la modélisation des débits des cours d'eau

Les débits des cours d'eau sont souvent traités comme des estimations du débit du bassin versant et pourraient être considérés comme faisant partie de la section précédente. L'accent est mis ici sur les articles qui ont traité directement de l'écoulement fluvial lui-même, généralement sans inclure les précipitations comme intrant. Dans certaines études, la prédiction du débit fluviale était un objectif intermédiaire. Dans l'une des applications antérieures impliquant les débits fluviaux, Kang et al (1993) ont utilisé des RNA et des modèles de moyenne mobile autorégressifs pour prédire les débits fluviaux quotidiens et horaires dans le bassin de la rivière Pyung Chang en Corée. Cette étude préliminaire a conclu que les RNA sont des outils utiles pour prévoir les débits fluviaux. Dans des études plus détaillées dans le même sens, on a celle de (Birikundavyi et al., 2002; Karunanithi et al., 1994; Kişi, 2009; Leea & Kanga, 2016; Muttiah, et al., 1997; Oluwatobi et al., 2018; Vidyarthi et al., 2020a).

III.1.6.3. Application dans la modélisation de la qualité de l'eau

Ces dernières années, les RNA ont trouvé un certain nombre d'applications dans le domaine de la modélisation de la qualité de l'eau. La qualité de l'eau est influencée par de nombreux facteurs tels que le débit, la charge de contaminants, le moyen de transport, les niveaux d'eau, les conditions initiales et d'autres paramètres spécifiques au site. L'estimation de ces variables est souvent un problème complexe et non linéaire, ce qui le rend approprié pour une application de RNA. (Maier & Dandy, 1996) ont illustré l'utilité des RNA pour estimer la salinité au Murray Bridge sur la rivière Murray en Australie-Méridionale.

(Starrett et al., 1998) ont utilisé un RNA pour prédire le lessivage des pesticides dans le sol recouvert de gazon. Après une procédure de sélection approfondie, les variables choisies comme intrants de RNA étaient la solubilité des pesticides, le taux d'application des pesticides, le temps écoulé depuis l'application des pesticides et le type de pratique d'irrigation mis en œuvre. Et d'autres études comme cel de : (Chen et al., 2020; Cordoba et al., 2014; Diamantopoulou et al., 2005; Gupta et al., 2019; Palani et al., 2008).

III.1.6.4. Applications dans les eaux souterraines

Il est difficile de séparer l'eau souterraine et la qualité de l'eau en différentes sections. De nombreux articles ont abordé ces deux sujets dans une certaine mesure (Rogers et al., 1995; Rogers & Dowla, 1994a). (C.-C. Yang et al., 1997) ont utilisé un RNA pour prédire l'élévation de la nappe phréatique dans les terres agricoles drainées sous la surface. Les précipitations quotidiennes, l'évapotranspiration potentielle et les emplacements précédents de la nappe phréatique ont été sélectionnés comme intrants pour le RNA. La sortie était l'emplacement actuel de la nappe phréatique. Ils ont constaté qu'un RNA anticipée à trois couches pouvait prédire les élévations de la nappe phréatique de manière satisfaisante après l'entraînement en utilisant les valeurs observées. Et des nombreux autres études tel que : (Benzer & Benzer, 2018; Chitsazan et al., 2013; Djurovic et al., 2015; Jr et al., 2003; Khudair et al., 2018; Kılıçaslan et al., 2014; Maskey et al., 2000; Mohanty et al., 2009; Nourani et al., 2008; Roshni, 2020; Xiaomin & Songhao, 2002).

III.1.6.5. Applications dans l'estimation des précipitations

Les précipitations sont le moteur de la plupart des processus hydrologiques. Il est difficile à prévoir car il présente une grande variabilité spatiale et temporelle. (French et al., 1992) ont utilisé un RNA anticipé à trois couches avec rétro-propagation pour prévoir les champs d'intensité des précipitations à un délai d'une heure avec le champ actuel comme entrée. (Tohma & Igata, 1994) ont utilisé un RNA à trois couches pour estimer les champs de pluie sur la base d'images de nuages visibles et infrarouges à distance dans la région côtière du sud-ouest de Hokkaido et dans une zone de fortes précipitations de Hokkaido, au Japon. (Kuligowski & Barros, 1998) présentent une approche de RNA pour la prévision des précipitations à court terme. Et plusieurs autres études tel que : (Ammar et al., 2018; Fallah Ghalhary et al., 2009; Kalteh, 2017; Lee et al., 2018; Paraskevas et al., 2014; Salimi et al., 2019; Somvanshi et al., 2006; Stefano & Isabella, 2000; Terzi & Çevik, 2012).

III.2. Algorithmes génétiques (GA)

III.2.1. C'est quoi l'Algorithme Génétique ?

Les GA sont parmi les algorithmes évolutifs les plus populaires en termes de diversité de leurs applications. Une grande majorité des problèmes d'optimisation bien connus ont été essayés par des GA. Les GA présentent de nombreux avantages par rapport aux algorithmes d'optimisation traditionnels. Deux des plus notables sont la capacité de traiter des problèmes complexes et le parallélisme. Les GA peuvent traiter différents types d'optimisation, que la fonction objectif (fitness) soit stationnaire ou non stationnaire (change avec le temps), linéaire ou non linéaire, continue ou discontinue, ou avec un bruit aléatoire. Parce que plusieurs descendants dans une population agissent comme des agents indépendants, la population (ou n'importe quel sous-groupe) peut explorer l'espace de recherche dans de nombreuses directions simultanément. Cette fonctionnalité est idéale pour paralléliser les algorithmes pour la mise en œuvre. Différents paramètres et même différents groupes de chaînes codées peuvent être manipulés en même temps. Cependant, les algorithmes génétiques présentent également certains inconvénients. La formulation d'une fonction de fitness, l'utilisation de la taille de la population, le choix de paramètres importants tels que le taux de mutation et de croisement, et les critères de sélection de la nouvelle population doivent être effectués avec soin. Tout choix inapproprié rendra l'algorithme difficile à converger ou produira simplement des résultats dénués de sens. Malgré ces inconvénients, les algorithmes génétiques restent l'un des algorithmes d'optimisation les plus largement utilisés dans l'optimisation non linéaire moderne.

III.2.2 Principe

L'essence de GA implique l'encodage d'une fonction d'optimisation sous forme de tableaux de bits ou de chaînes de caractères pour représenter les chromosomes, les opérations de manipulation de chaînes par des opérateurs génétiques, et la sélection en fonction de leur fitness, dans le but de trouver un bien (voire optimal) solution au problème concerné. Cela se fait souvent par la procédure suivante: (1) codage des objectifs ou des fonctions de coût; (2) définir une fonction de fitness ou un critère de sélection; (3) créer une population d'individus; (4) effectuer le cycle d'évolution ou les itérations en évaluant la fitness de tous les individus de la population, créer une nouvelle population en effectuant des croisements et des mutations, une reproduction proportionnée à la fitness, etc., et en remplaçant l'ancienne population et en répétant à nouveau en utilisant la nouvelle population; (5) décoder les résultats pour obtenir la solution au problème.

Le codage de la fonction objectif est généralement sous la forme de tableaux binaires ou de tableaux à valeurs réelles. Pour plus de simplicité, nous utilisons des chaînes binaires pour

l'encodage et le décodage. Les opérateurs génétiques comprennent le croisement, la mutation et la sélection dans la population. Le croisement de deux chaînes parentes est l'opérateur principal avec une probabilité p_c plus élevée et est effectué en échangeant un segment d'un chromosome avec le segment correspondant sur un autre chromosome à une position aléatoire (Figure 3.6). Le croisement réalisé de cette manière est un croisement à un seul point. Le croisement peut également se produire sur plusieurs sites, qui intervertissent essentiellement les segments multiples avec ceux de leur chromosome correspondant. Le croisement en plusieurs points est utilisé plus souvent dans les GA pour augmenter l'efficacité évolutive des algorithmes.

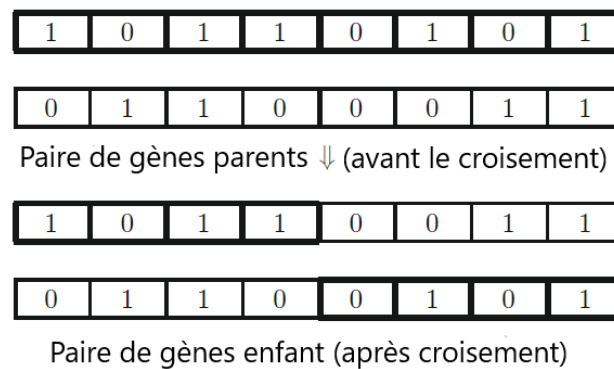


Figure 3. 6. Diagramme de croisement à un point de croisement aléatoire (emplacement) dans les algorithmes génétiques.

L'opération de mutation est réalisée en faisant basculer les bits sélectionnés au hasard (voir la figure 3.7), et la probabilité de mutation p_m est généralement faible. En outre, la mutation peut également se produire sur plusieurs sites simultanément, ce qui peut être des avantages dans la pratique et les mises en œuvre.




Figure 3. 7. Représentation schématique de la mutation sur un seul site en retournant un bit sélectionné au hasard ($1 \rightarrow 0$).

III.2.3. Rôle des opérateurs génétiques

Comme présenté précédemment, les algorithmes génétiques ont trois principaux opérateurs génétiques : le croisement, la mutation et la sélection. Leurs rôles peuvent être très différents.

- Crossover : Échange de parties de la solution avec une autre dans les chromosomes ou les représentations de solution. Le rôle principal est de fournir le mélange des solutions et la convergence dans un sous-espace.
- Mutation : Le changement de parties d'une solution au hasard, ce qui augmente la diversité de la population et fournit un mécanisme pour échapper à un optimum local.
- Sélection du plus apte ou élitisme : L'utilisation de solutions hautement aptes à être transmises aux générations suivantes, qui est souvent réalisée sous la forme d'une certaine forme de sélection des meilleures solutions.

III.2.4. Le modèle hybride RNA-GA

Malgré tous les avantages des réseaux de neurones, ils souffrent de certains problèmes tels qu'une convergence lente et être coincés dans un minimum local. Pour surmonter ces problèmes, les chercheurs ont récemment suggéré une méthode hybride pour augmenter les performances des RNA et atteindre le minimum global. Dans cette méthode, compte tenu d'une fonction de fitness appropriée, des paramètres importants de RNA (le nombre optimal de couches cachées et les poids initiaux) seront déterminés et modifiés. Le principal objectif de l'utilisation du modèle hybride RNA-GA est d'ajuster un ensemble de poids et de biais pour minimiser la fonction objective. Cette méthode a été utilisée et développée avec succès pour résoudre de nombreux problèmes d'ingénierie (Mohamad, 2016; Momeni, 2014; Saemi et al., 2007). Le schéma d'optimisation de ce modèle est résumé comme suit:

Étape 1: Le modèle combiné RNA-GA génère une population initiale. Les étapes suivantes sont répétées jusqu'à ce que le critère de fin soit satisfait. Étape 2: Chaque chromosome est évalué dans la population. Il serait attribué une valeur de fitness pour chaque chromosome par le modèle RNA bien formé. Étape 3: Une population pour la prochaine génération est créée par les opérations génétiques (croisement et mutation). Ces opérations sont appliquées aux chromosomes dans une génération formelle avec les probabilités basées sur leur fitness. Étape 4: Une nouvelle génération est générée. Cet algorithme est répété pour reproduire la prochaine génération. Enfin, la population passera à la condition correspondant à la valeur la plus faible de la coercivité.

III.2.5. Application de RNA-GA en hydrologie

Parce que les RNA et les GA sont des méthodes populaires qui ont été utilisées par divers chercheurs pour optimiser les problèmes non linéaires, la conjonction entre ces deux techniques est devenue une méthode puissante de modélisation et d'optimisation des processus complexes (Ahmad et al., 2004; Istadi & Amin, 2007; Nandi et al., 2004).

RNA-GA a été développée pour améliorer la vitesse de convergence vers des valeurs optimales de poids et de biais dans le processus de modélisation des pluie-débit (Parasuraman & Elshorbagy, 2007). (Jain & Srinivasulu, 2004) ont appliqué GA couplée pour entraîner le RNA, et ont indiqué que le RNA-GA couplée prédisait le débit quotidien plus précisément que la back-propagation BP-RNA conventionnelle. (Behzad et al., 2009) a montré l'application de machines à vecteurs de support (SVM) par rapport aux modèles RNA et RNA-GA pour la prévision du débit quotidien, en particulier les décharges de grande valeur du bassin versant de la rivière Bakhtiyari, sur la base des précipitations des jours précédents et d'autres informations climatiques disponibles. (Dhamge et al., 2012) a utilisé un modèle de RNA basé sur un algorithme génétique pour l'estimation de débit dans les bassins versants indiens. (Bozorg-Haddad et al., 2016) a proposé un RNA-GA couplée dans laquelle RNA sert à la simulation et GA à l'optimisation de la simulation et de la prévision des débits mensuels, ses objectifs sont de former et d'évaluer (tester) les performances de RNA dans la simulation et la prévision des pluie-débit, d'évaluer les facteurs hydrologiques et météorologiques effectifs (température, évapotranspiration, précipitations et afflux) dans la simulation et les prévisions des modèles pluie-débit, et l'amélioration de l'estimation des paramètres de RNA. (Jahandideh-Tehrani et al., 2020) a développé et évalué des modèles pluie-débit ; RNA-PSO et RNA-GA pour prévoir le débit du cours d'eau en temps réel dans le bassin de la rivière Nerang, dans le sud-est du Queensland, en Australie. Dans une autre étude de (Kasiviswanathan et al., 2013), GA a été utilisé pour entraîner le RNA conventionnel à des fins de prévision du débit de cours d'eau en utilisant des données hydrologiques enregistrées sur 12 ans. Sur la base des résultats obtenus et de la comparaison entre le RNA-GA et RNA conventionnel, il a été signalé que le RNA-GA avait une capacité d'entraînement plus rapide ainsi que des résultats de modélisation plus précis. Plus récemment, une application de RNA-GA à la prévision du débit du cours d'eau a été étudiée par (Moeeni et al., 2017). Ils ont appliqué GA comme outil d'optimisation pour identifier le nombre optimal de couches cachées dans le RNA. Ils ont également comparé les performances de RNA-GA avec le modèle SARIMA (Seasonal Autoregressive Integrated Moving Average). Ils ont conclu que le RNA-GA est plus efficace pendant les années pluvieuses et la prévision des crues. (Burchard-Levine et al., 2014) a utilisé un modèle combiné RNA-GA, trois variables de qualité de l'eau, NH₃-N, COD_{mn} et le carbone organique total (COT), dans un fleuve de Chine ont été modélisées. Les variables d'entrée dans leur modèle proposé étaient COT, COD_{mn}, TP, NH₃-N et turbidité. La performance du modèle RNA-GA proposé a démontré sa capacité à prévoir la qualité de l'eau. Également GA a été utilisé efficacement pour résoudre divers modèles de gestion des eaux souterraines (Aly & Peralta, 1999; Bhattacharjya & Datta, 2009, 2009; Cieniawski et al., 1995; McKinney & Lin, 1994; Morshed & Kaluarachchi, 2000; Rao et al., 2006; Ritzel et al., 1994; Rogers & Dowla, 1994b).

III.3. Optimisation de l'essaim de particules (PSO)

L'optimisation des essaims de particules (PSO) a été développée par Kennedy et Eberhart en 1995 sur la base du comportement des essaims dans la nature, comme le banc de poissons et d'oiseaux. Depuis lors, PSO a généré des intérêts beaucoup plus larges et forme un sujet de recherche passionnant et en constante expansion, appelé l'intelligence en essaim. PSO a été appliqué à presque tous les domaines de l'optimisation, de l'intelligence informatique et des applications de conception.

III.3.1. Intelligence en essaim

De nombreux algorithmes tels que les algorithmes de colonie de fourmis et l'algorithme de luciole utilisent le comportement de ce que l'on appelle l'intelligence en essaim (Kennedy et al., 2001; X.-S. Yang & Karamanoglu, 2013). PSO, est devenue l'un des algorithmes basés sur l'intelligence en essaim les plus largement utilisés en raison de sa simplicité et de sa flexibilité. Plutôt que d'utiliser la mutation / croisement, il utilise le hasard en nombre réel et la communication globale entre les particules de l'essaim. Par conséquent, il est également plus facile à mettre en œuvre car il n'y a pas de codage ou de décodage des paramètres en chaînes binaires comme avec ceux des algorithmes génétiques où des chaînes de nombres réels peuvent également être utilisées. De nombreux nouveaux algorithmes basés sur l'intelligence des essaims ont pu s'inspirer de différentes sources, mais ils présentent une certaine similitude avec certains des composants utilisés dans PSO. En ce sens, PSO a été le pionnier des idées de base du calcul basé sur l'intelligence en essaim.

III.3.2. Le modèle de l'algorithme PSO

L'algorithme (PSO) est une technique de recherche parallèle multi-agents qui maintient un essaim de particules et chaque particule représente une solution potentielle dans l'essaim. Toutes les particules volent à travers un espace de recherche multidimensionnel où chaque particule ajuste sa position en fonction de sa propre expérience et de celle des voisins.

Initialement, les populations (particules) sont initialisées par des valeurs de position générées aléatoirement. La meilleure position et emplacement de chaque particule (pbest) continuellement stocké localement avec les informations de la meilleure particule globale (gbest). Toutes les populations sont mises à jour leur vitesse et leur position en utilisant Eq. 3.6 et Eq. 3.7 respectivement (Andries P, 2007).

$$v_{ij}^{t+1} = \omega v_{ij}^t + c_1 r_{1j}^t [P_{best,i}^t - x_{ij}^t] + c_2 r_{2j}^t [G_{best,i}^t - x_{ij}^t] \quad (3.6)$$

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1} \quad (3.7)$$

Où : ω est le poids d'inertie de la particule actuelle utilisée pour modifier la prochaine génération de particules, v_{ij}^t et x_{ij}^t est le vecteur vitesse et vecteur de position de la particule i en dimension j au temps t ; respectivement.

$p_{best,i}^t$ et G_{best} est la meilleure position et la meilleure position globale de la particule i en dimension j trouvée depuis l'initialisation au temps t ;

c_1 et c_2 sont des constantes d'accélération positives qui sont utilisées pour niveler respectivement la contribution des composantes cognitive et sociale;

r_{1j}^t et r_{2j}^t sont des nombres aléatoires de distribution uniforme $U(0,1)$ au temps t .

v_{ij}^{t+1} est la vitesse nouvellement générée qui formera la nouvelle position x_{ij}^{t+1} en étant additionnée à l'ancienne position x_{ij}^t .

III.3.3. Paramètres d'algorithme PSO

Certains paramètres de l'algorithme PSO peuvent affecter ses performances. Pour tout problème d'optimisation donné, certaines des valeurs et des choix de ces paramètres ont un impact important sur l'efficacité de PSO, et d'autres paramètres ont peu ou pas d'effet (Carlisle, 2001). Les paramètres PSO de base sont la taille de l'essaim, le nombre d'itérations, les composantes de vitesse et les coefficients d'accélération. En outre, la PSO est également influencée par le poids d'inertie et d'autres paramètres.

III.3.3.1. Taille de l'essaim

La taille de l'essaim ou la taille de la population est le nombre de particules n dans l'essaim. Un gros essaim génère de plus grandes parties de l'espace de recherche à couvrir par itération. Un grand nombre de particules peut réduire le nombre d'itérations nécessaires pour obtenir un bon résultat d'optimisation. En revanche, d'énormes quantités de particules augmentent la complexité de calcul par itération et prennent plus de temps. À partir d'un certain nombre d'études empiriques, il a été montré que la plupart des implémentations PSO utilisent un intervalle de $n \in [20,60]$ pour la taille de l'essaim.

III.3.3.2. Nombres d'itération

Le nombre d'itérations pour obtenir un bon résultat dépend également du problème. Un nombre trop faible d'itérations peut arrêter le processus de recherche prématurément, tandis que des itérations trop grandes ont pour conséquence une complexité de calcul supplémentaire inutile et plus de temps (Andries P, 2007).

III.3.3.3. Composants de vitesse

Les composantes de vitesse sont très importantes pour mettre à jour la vitesse des particules. Il existe trois termes de la vitesse de la particule dans les équations (3.6) et (3.7) :

1. Le terme v_{ij}^t est appelé composante d'inertie qui fournit une mémoire de la direction de vol précédente qui signifie mouvement dans le passé immédiat. Ce composant se présente comme un élan qui empêche de changer radicalement la direction des particules et de biaiser vers la direction du courant.
2. Le terme $c_1 r_{1j}^t [P_{best,i}^t - x_{ij}^t]$ est appelé composant cognitif qui mesure la performance des particules i par rapport aux performances passées. Ce composant ressemble à une mémoire individuelle de la position qui était la meilleure pour la particule. L'effet de la composante cognitive représente la tendance des individus à retourner aux positions qui les satisfaisaient le plus dans le passé. La composante cognitive appelée la nostalgie de la particule.
3. Le terme $c_2 r_{2j}^t [G_{best} - x_{ij}^t]$ est appelé composante sociale qui mesure la performance des particules par rapport à un groupe de particules ou voisines. L'effet de la composante sociale est que chaque particule vole vers la meilleure position trouvée par le voisinage de la particule.

III.3.3.4. Coefficients d'accélération

Les coefficients d'accélération c_1 et c_2 , avec les valeurs aléatoires r_1 et r_2 , maintiennent respectivement l'influence stochastique des composantes cognitives et sociales de la vitesse de la particule. La constante c_1 exprime la confiance qu'une particule a en elle-même, tandis que c_2 exprime la confiance qu'une particule a en ses voisins (Andries P, 2007). Il existe certaines propriétés de c_1 et c_2 :

- Quand $c_1=c_2=0$, alors toutes les particules continuent de voler à leur vitesse actuelle jusqu'à ce qu'elles atteignent la limite de l'espace de recherche. Par conséquent, à partir des équations (2.6) et (2.7), l'équation de mise à jour de la vitesse est calculée comme suit:

$$v_{ij}^{t+1} = v_{ij}^t \quad (3.8)$$
- Quand $c_1>0$ et $c_2=0$, toutes les particules sont indépendantes. L'équation de mise à jour de la vitesse sera

$$v_{ij}^{t+1} = v_{ij}^t + c_1 r_{1j}^t [P_{best,i}^t - x_{ij}^t] \quad (3.9)$$
 Au contraire, quand $c_2>0$ et $c_1=0$, toutes les particules sont attirées en un seul point (i.e. G_{best}) dans tout l'essaim et la vitesse de mise à jour deviendra :

$$v_{ij}^{t+1} = v_{ij}^t + c_2 r_{2j}^t [G_{best} - x_{ij}^t] \text{ pour Gbest PSO} \quad (3.10)$$

$$\text{ou, } v_{ij}^{t+1} = v_{ij}^t + c_2 r_{2j}^t [L_{best,i} - x_{ij}^t] \text{ pour lbest PSO} \quad (3.11)$$

- Quand $c_1=c_2$, toutes les particules sont attirées vers la moyenne de $P_{best,i}^t$ et G_{best} .
- Quand $c_1 \gg c_2$, chaque particule est plus fortement influencée par sa meilleure position personnelle, ce qui entraîne une errance excessive. En revanche, lorsque $c_2 \gg c_1$ toutes les particules sont alors beaucoup plus influencées par la meilleure position globale, ce qui fait que toutes les particules se dirigent prématurément vers l'optimum (Andries P, 2007; van den Bergh & Engelbrecht, 2002).

Normalement, c_1 et c_2 sont statiques, leurs valeurs optimisées étant trouvées empiriquement. Une mauvaise initialisation de c_1 et c_2 peut entraîner un comportement divergent ou cyclique (Andries P, 2007). A partir des différentes recherches empiriques, il a été proposé que les deux constantes d'accélération soient $c_1 = c_2 = 2$.

III.3.4. Le modèle hybride RNA-PSO

Plusieurs chercheurs ont tenté d'améliorer les performances des RNA dans les applications d'ingénierie et de science grâce à l'utilisation d'algorithmes PSO (Bashir & El-Hawary, 2009; Gordan et al., 2016). Puisque BP est un algorithme d'apprentissage de la recherche locale, le processus de recherche optimal de RNA peut échouer et renvoyer une solution non satisfaite. En revanche, PSO est connu comme une méthode de recherche globale robuste et, en tant que tel, peut être utilisé pour ajuster le poids et le biais des RNA et ainsi améliorer la capacité de performance de ces derniers. Au minimum local, l'utilisation des RNA augmente la probabilité de convergence, alors que PSO est capable de trouver un minimum global. Par conséquent, un modèle hybride RNA-PSO bénéficie des propriétés de recherche à la fois de RNA et de PSO.

La procédure d'apprentissage impliquée dans les modèles hybrides RNA-PSO commence par l'initialisation d'un groupe de particules aléatoires, au cours de laquelle les positions de ces particules représentatives des poids et biais de RNA sont attribuées de manière aléatoire. À la suite de cette étape, en utilisant les poids et biais initiaux (les positions initiales des particules), le RNA-PSO est formé et l'erreur entre les valeurs réelles et prévues est calculée. A chaque itération, l'erreur calculée est diminuée en changeant les positions des particules. Pour mettre à jour l'équation de vitesse, les valeurs de $\overrightarrow{p_{best}}$ (l'erreur la plus faible obtenue par chaque particule jusqu'à ce moment) et $\overrightarrow{g_{best}}$ (l'erreur la plus faible obtenue par toutes les particules jusqu'à ce moment) sont utilisées. En conséquence, une valeur est produite avec laquelle ajuster les positions des particules aux meilleures solutions. Ensuite, en utilisant les positions mises à jour, une nouvelle erreur est obtenue. Cette procédure se poursuit jusqu'à ce que les critères de terminaison soient satisfaits, avec la sortie d'optimisation obtenue par rapport à la valeur de $\overrightarrow{G_{best}}$.

III.3.5. Application de RNA-PSO en hydrologie

Le PSO a été appliqué avec succès à de nombreux problèmes d'optimisation de la vie réelle en ingénierie. Ces dernières années, l'optimisation PSO améliore considérablement l'estimation des paramètres des modèles hydrologiques (Gaur et al., 2011; Gill et al., 2006). Pour la modélisation pluie-débit, il a été récemment constaté que l'application de l'algorithme PSO au lieu de LM pour la formation de RNA, peut améliorer considérablement l'efficacité des modèles (Cheng et al., 2015; Kuok et al., 2009). (K. Chau, 2004) a appliqué PSO pour prévoir le débit dans la rivière Siu Lek Yuen, Hong Kong, pour des délais de 1 et 2 jours. (K. W. Chau, 2006) ont également suggéré une approche du perceptron basée sur PSO pour prédire le stade de l'eau dans la rivière Shing Mun, à Hong Kong. (Kuok et al., 2009) ont appliqué l'optimisation des essaims de particules réseau de neurones feed-forward pour la modélisation horaire de pluie-débit dans Bedup bassin en Malaisie ; ils ont montré que le modèle proposé peut fournir une prévision précise du débit jusqu'à 12 heures à l'avance. (Asadnia et al., 2014) ont appliqué une optimisation améliorée de l'essaim de particules (PSO) pour entraîner le RNA pour la prédiction des niveaux d'eau dans le bassin hydrographique de Heshui, en Chine. (Cheng et al., 2015) ont mené une étude de recherche consistant en la prévision quotidienne du débit des réservoirs; dans la procédure de modélisation, ils acquièrent un réseau de neurones en utilisant l'optimisation de l'essaim de particules pour le processus d'entraînement. Les résultats ont révélé que le modèle RNA basé sur PSO surpasse le modèle RNA de base. De plus, ils ont conclu que le modèle proposé pouvait être appliqué efficacement pour la modélisation du débit quotidien. (Motahari & Mazandaranizadeh, 2017) a appliqué un modèle RNA-PSO pour simuler le processus pluie-débit dans la rivière Karaj pendant un et deux jours à l'avance. (Mohd Romlay et al., 2019) a proposé un modèle pluie-débit basé sur le RNA avec Levenberg Marquardt (LM), la régularisation bayésienne (BR) et l'optimisation des essaims de particules (PSO) comme algorithmes d'apprentissage. (Vidyarathi et al., 2020a) a appliqué PSO pour la formation du modèle RNA pluie-débit dans le bassin du Jardin, etc. (Sedki & Ouazar, 2010), a proposé un RNA basé sur un algorithme hybride combinant (PSO) et (BP) pour prévoir les débits des cours d'eau quotidiens dans un bassin situé dans une région semi-aride du Maroc. (Taormina & Chau, 2015), a proposé une approche multi-objectifs MO pour la formation à l'optimisation croisée des essaims de RNA utilisée pour la prédiction des futurs débits des cours d'eau dans le bassin versant de la rivière Shenandoah, en Virginie (USA). (Hayder et al., 2020), a fait une modélisation du débit de la rivière basée sur des données météorologiques dans la région de Sungai Kelantan à l'aide d'un réseau neuronal en cascade entraîné avec l'algorithme d'optimisation des essaims de particules (CFNNPSO). (Chi Zhou et al., 2006), a employé PSO pour former le RNA, puis l'a appliqué à la classification des modèles et à la prédiction de la qualité de l'eau. (Changjun Zhu et al., 2009), a adopté un RNA basé sur le PSO pour le modèle d'évaluation

de la qualité des eaux de surface dans la rivière Suzhou. (Mohammadi & Shahraki, 2017), a simulé les paramètres de qualité des eaux souterraines de la plaine de Ramhormoz, y compris le taux d'adsorption du sodium (SAR), la conductivité électrique (CE) et les solides dissous totaux (TDS), via les modèles RNA et RNA- PSO et à la fin a comparé leurs résultats avec les données mesurées. (Alizamir & Sobhanardakani, 2018), a prédit la contamination par les métaux lourds (As, Pb, Cu et Zn) dans les ressources en eaux souterraines de la plaine de Toyserkan en tant que zone agricole importante dans la province de Hamedan, à l'ouest de l'Iran, en utilisant une approche d'optimisation des réseaux de neurones artificiels et de l'essaim de particules (RNA-PSO). (Gaur et al., 2013), a développé et couplé des modèles de RNA et de PSO pour la gestion des eaux souterraines du bassin de la rivière Dore en France. (O. Kisi et al., 2017), a modélisé les fluctuations des eaux souterraines par trois techniques de réseau neuronal évolutif différentes (RNA-GA, RNA -PSO et RNA -ICA) en utilisant des données hydro-climatiques. (Balavalikar et al., 2018), a développé un modèle hybride de prévision du niveau des eaux souterraines basé sur RNA-PSO pour prévoir le niveau des eaux souterraines des trois puits d'étude situés dans le district d'Udupi.

III.4. Optimisation de l'essaim de particules améliorée (IPSO)

III.4.1. Le modèle de l'algorithme IPSO

Dans le PSO amélioré, les particules sont ajustées de manière aléatoire à l'aide d'un nombre généré par la distribution standard normale (Normand) comme suit :

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1}(I) \quad (3.12)$$

$$v_{ij}^{t+1}(I) = r_3 [G_{best} - x_{ij}^t] + Normand(0,1) \times \gamma_k \quad (3.13)$$

Où, $v_{ij}^{t+1}(I)$ est la vitesse améliorée qui est ajustée pour les nouvelles positions. $v_{ij}^{t+1}(I)$ est déterminé en fonction de la meilleure position de la particule (G_{best}) et d'un nombre aléatoire généré par une distribution normale avec une moyenne de 1 et une STD de 0 ($Normand(0,1)$). La partie aléatoire normale est mise à l'échelle à l'aide d'un facteur γ_k déterminé par la relation suivante (Keshtegar, Hao, et al., 2017; Keshtegar, Ozbakkaloglu, et al., 2017) :

$$\gamma_k = \sqrt{1 - \frac{k}{NI}} \quad (3.14)$$

Le facteur γ_k tend à 1 aux premières itérations et à 0 aux itérations de remplissage $\gamma_k \in [0,1]$. Comme le montre l'amélioration de la vitesse, les nouvelles positions des particules sont ajustées à l'aide d'un processus normal aléatoire. Ainsi, les nouvelles et les meilleures particules n'ont pas

les mêmes positions. Par conséquent, la chance d'atteindre l'optimum local est réduite par rapport à la PSO d'origine par cette approche d'optimisation présentée. La formulation de l'IPSO est présentée dans l'Eq. (3.15) en utilisant deux procédures d'ajustement aléatoires données par une vitesse améliorée présentée dans l'Eq. (3.13).

$$x_{ij}^{t+1}(I) = \begin{cases} x_{ij}^t + v_{ij}^{t+1}(I) & r \leq P_k \\ x_{ij}^t + v_{ij}^{t+1} & r > P_k \end{cases} \quad (3.15)$$

Où, $r \in [0,1]$ est un nombre aléatoire sexué par une distribution uniforme entre 0 et 1. Dans IPSO, la vitesse initiale et ses paramètres sont déterminés aléatoirement ainsi que PSO.

P_k est nommé comme ajustement du taux de particules, qui est calculé comme suit :

$$P_k = 0.2 + 0.8 \sqrt{\frac{k}{NI}} \quad (3.16)$$

P_k est fourni au hasard un modèle pour ajuster la nouvelle particule en utilisant deux formulations de PSO et IPSO. En augmentant P_k , la chance d'appliquer une vitesse améliorée pour déterminer les nouvelles positions des particules est augmentée. Nous avons couramment utilisé cette formule présentée dans l'équation. (3.12 et 3.13) aux itérations finales. Ainsi, il s'agit d'une recherche locale sur la meilleure position pour calculer les résultats optimaux globaux aux itérations finales. Comme on le voit dans l'Eq. (3.15), il est appliqué deux termes de vitesse pour ajuster les positions des nouvelles particules tandis que dans le PSO, nous appliquons la vitesse des particules en utilisant l'équation. (3.6) qui est déterminé en utilisant Pbest et Gbest ; et ce sont les principales différences entre PSO et IPSO.

III.4.2. Le modèle hybride RNA-IPSO

L'algorithme PSO amélioré est convaincu d'avoir la capacité de rechercher des optima globaux avec une convergence rapide. Afin de combiner les avantages de deux méthodes RNA et IPSO, un modèle hybride RNA-IPSO est proposé pour la prédiction de la relation pluie-débit. Dans ce modèle hybride, le réseau feed-forward avec un algorithme d'entraînement à rétropropagation est construit pour l'initialisation du modèle. Ensuite, toutes les valeurs de poids et de seuil du réseau sont considérées comme la position des particules, et l'algorithme IPSO est appliqué pour optimiser les paramètres du réseau. La procédure de la méthode hybride RNA-IPSO peut être menée comme suit :

Étape 1 : chargez l'ensemble de données d'entrée et sélectionnez les échantillons d'apprentissage et de test ;

Étape 2 : initialiser les paramètres de RNA incluant les valeurs de poids et de seuil correspondant à la particule initialisée d'IPSO ;

Étape 3 : calculez la fonction de fitness et trouvez la solution optimale ;

Étape 4 : exécuter l'opération de croisement et de mutation, mettre à jour Pbest et Gbest d'IPSO;

Étape 5 : attribuer les valeurs de poids et de seuil de RNA avec Pbest et Gbest d'IPSO, si l'itération maximale d'IPSO est atteinte, passer à l'étape 6, sinon générer de nouvelles particules et revenir à l'étape 3 ;

Étape 6 : testez le modèle de prédiction RNA optimisé jusqu'à ce que les critères d'arrêt soient satisfaits.

III.4.3. Application de RNA-IPSO en hydrologie

Le PSO amélioré (IPSO) pourrait résoudre des problèmes d'optimisation de combinaisons multi-objectifs dans de nombreuses recherches. En fait, il y a très peu d'études qui ont appliqué RNA-IPSO en hydrologie telle que l'étude de (Asadnia et al., 2014) où il a appliqué un PSO amélioré pour former un réseau de neurones artificiels (RNA) pour la prédiction du niveau d'eau dans le bassin hydrographique de Heshui en Chine. (ZHANG et al., 2011) a proposé l'algorithme (IPSO) pour l'optimisation de la planification de l'énergie hydroélectrique dans les systèmes multi-réservoirs. Ensuite, un modèle d'exploitation à long terme d'un système multi-réservoir basé sur IPSO a été conçu et une étude de cas a été réalisée dans le bassin de Minjiang en Chine, où se trouve un système électrique composé de 26 centrales hydroélectriques.

III.5. Algorithme de luciole (FFA)

L'algorithme de luciole (FFA) a été développé pour la première fois par Xin-She Yang fin 2007 et publié en 2008 (X.-S. Yang, 2010a, 2010c). FFA était basé sur les schémas de clignotement et le comportement des lucioles. Par conséquent, commençons par une description du comportement de clignotement des lucioles tropicales.

III.5.1. Comportement de la luciole

La lumière clignotante des lucioles est une vue incroyable dans le ciel d'été dans les régions tropicales et tempérées. Il existe environ 2000 espèces de lucioles et la plupart des lucioles produisent des éclairs courts et rythmés. Le motif des éclairs est souvent unique pour une espèce particulière. La lumière clignotante est produite par un processus de bioluminescence; les véritables fonctions de ces systèmes de signalisation sont encore débattues. Cependant, deux fonctions fondamentales de ces flashes sont d'attirer les partenaires d'accouplement

(communication) et d'attirer des proies potentielles (Lewis & Cratsley, 2008). De plus, le clignotement peut également servir de mécanisme d'avertissement protecteur pour rappeler aux prédateurs potentiels le goût amer des lucioles. Le flash rythmique, le taux de clignotement et la durée entre les flashes font partie du système de signalisation qui réunit les deux sexes (Lewis & Cratsley, 2008). Les femelles réagissent au modèle unique de clignotement d'un mâle chez la même espèce, tandis que chez certaines espèces comme *Photuris*, les lucioles femelles peuvent écouter les signaux de parade bioluminescents et même imiter le modèle de clignotement d'accouplement d'autres espèces afin d'attirer et de manger les lucioles mâles, qui peut prendre les flashes comme un compagnon approprié potentiel. Certaines lucioles tropicales peuvent même synchroniser leurs éclairs, formant ainsi un comportement biologique autoorganisé émergent.

On sait que l'intensité lumineuse à une distance r particulière de la source lumineuse obéit à la loi des carrés inverses. C'est-à-dire que l'intensité lumineuse I diminue à mesure que la distance r augmente en termes de $I \propto 1 / r^2$. De plus, l'air absorbe la lumière, qui devient de plus en plus faible à mesure que la distance augmente. Ces deux facteurs combinés rendent la plupart des lucioles visibles à une distance limite, généralement plusieurs centaines de mètres la nuit, ce qui est suffisant pour que les lucioles puissent communiquer. La lumière clignotante peut être formulée de manière à être associée à la fonction objective à optimiser, ce qui permet de formuler de nouveaux algorithmes d'optimisation.

III.5.2. Règles de l'algorithme de luciole

Maintenant, nous pouvons idéaliser certaines des caractéristiques clignotantes des lucioles afin de développer des algorithmes inspirés des lucioles. Pour simplifier la description de FFA standard, nous utilisons maintenant les trois règles idéalisées suivantes:

- Toutes les lucioles sont unisexes, donc une luciole sera attirée par d'autres lucioles quel que soit leur sexe.
- L'attractivité est proportionnelle à la luminosité d'une luciole. Ainsi, pour deux lucioles clignotantes, la moins brillante se déplacera vers la plus lumineuse. L'attractivité est proportionnelle à la luminosité, toutes deux diminuant à mesure que leur distance augmente. S'il n'y en a pas de plus brillant qu'une luciole en particulier, elle se déplacera au hasard.
- La luminosité d'une luciole est affectée ou déterminée par le paysage de la fonction objectif.

Pour un problème de maximisation, la luminosité peut simplement être proportionnelle à la valeur de la fonction objectif. D'autres formes de luminosité peuvent être définies de manière similaire à la fonction de fitness dans les algorithmes génétiques.

III.5.3. Variations d'intensité lumineuse et d'attractivité

Dans l'algorithme de luciole, il y a deux problèmes importants: la variation de l'intensité lumineuse et la formulation de l'attractivité. Pour simplifier, nous pouvons toujours supposer que l'attractivité d'une luciole est déterminée par sa luminosité, qui à son tour est associée à la fonction objective codée. Dans le cas le plus simple pour des problèmes d'optimisation maximale, la luminosité I d'une luciole à un emplacement particulier x peut être choisie comme $I(x) \propto f(x)$. Cependant, l'attractivité β est relative; il doit être vu dans les yeux du spectateur ou jugé par les autres lucioles. Ainsi, il variera avec la distance r_{ij} entre la luciole i et la luciole j . De plus, l'intensité lumineuse diminue avec la distance de sa source, et la lumière est également absorbée dans le média, nous devons donc permettre à l'attractivité de varier avec le degré d'absorption.

Dans la forme la plus simple, l'intensité lumineuse $I(r)$ varie selon la loi de l'inverse carré,

$$I(r) = \frac{I_s}{r^2} \quad (3.17)$$

où I_s est l'intensité à la source. Pour un milieu donné avec un coefficient d'absorption lumineuse fixe γ , l'intensité lumineuse I varie avec la distance r . C'est,

$$I = I_0 e^{-\gamma r} \quad (3.18)$$

où I_0 est l'intensité lumineuse d'origine à une distance nulle $r = 0$. Pour éviter la singularité à $r = 0$ dans l'expression I_s/r^2 , l'effet combiné de la loi du carré inverse et de l'absorption peut être approximé comme la forme gaussienne suivante:

$$I(r) = I_0 e^{-\gamma r^2} \quad (3.19)$$

Parce que l'attractivité d'une luciole est proportionnelle à l'intensité lumineuse vue par les lucioles adjacentes, nous pouvons maintenant définir l'attractivité β d'une luciole par:

$$\beta = \beta_0 e^{-\gamma r^2} \quad (3.20)$$

où β_0 est l'attractivité à $r = 0$. Comme il est souvent plus rapide de calculer $1 / (1 + r^2)$ qu'une fonction exponentielle, cette fonction, si nécessaire, peut être commodément approximée comme

$$\beta = \frac{\beta_0}{1 + \gamma r^2} \quad (3.21)$$

Il peut être avantageux d'utiliser cette approximation dans certaines applications. (3.20) et (3.21) définissent une distance caractéristique $\Gamma = 1/\sqrt{\gamma}$ sur laquelle l'attractivité change significativement de β_0 à $\beta_0 e^{-1}$ pour l'équation (3.20) ou $\beta_0/2$ pour l'équation (3.21).

Dans la mise en œuvre réelle, la fonction d'attractivité $\beta(r)$ peut être n'importe quelle fonction décroissante de manière monotone telle que la forme généralisée suivante:

$$\beta(r) = \beta_0 e^{-\gamma r^m}, \quad (m \geq 1) \quad (3.22)$$

Pour un γ fixe, la longueur caractéristique devient

$$\Gamma = \gamma^{-1/m} \rightarrow 1, \quad m \rightarrow \infty \quad (3.23)$$

Inversement, pour une échelle de longueur Γ donnée dans un problème d'optimisation, le paramètre γ peut être utilisé comme valeur initiale typique. C'est,

$$\gamma = \frac{1}{\Gamma^m} \quad (3.24)$$

La distance entre deux lucioles i et j à x_i et x_j , respectivement, est la distance cartésienne

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (3.25)$$

où $x_{i,k}$ est la k ème composante de la coordonnée spatiale x_i de la i ème luciole. Dans un cas 2D, nous avons

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.26)$$

Le mouvement d'une luciole i attirée par une autre luciole plus attrayante (plus brillante) j est déterminé par

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha \epsilon_i^t \quad (3.27)$$

où le deuxième terme est dû à l'attraction. Le troisième terme est la randomisation, α étant le paramètre de randomisation, et ϵ_i est un vecteur de nombres aléatoires tirés d'une distribution gaussienne ou d'une distribution uniforme. Par exemple, la forme la plus simple est ϵ_i peut être remplacée par $\text{rand} - 1/2$, où rand est un générateur de nombres aléatoires uniformément distribué dans $[0,1]$. Pour la plupart de notre implémentation, nous pouvons prendre $\beta_0 = 1$ et $\alpha \in [0, 1]$.

III.5.4. Le modèle hybride RNA-FFA

L'algorithme de lucioles peuvent facilement être appliqué à la formation de RNA, tout comme PSO. Elle est utilisée pour optimiser les poids de RNA, pour obtenir les réglages de paramètres optimaux pour son apprentissage et pour réduire le taux d'erreur. Au début, n vecteur comprenant les paramètres entraînaibles (poids et biais (w) de RNA) sont initialisés, et le coefficient γ est également défini. Les fonctions objectives qui sont les fonctions d'erreur dans ce cas sont ensuite

calculées pour chaque population de luciole (w_i). FFA est motivé par l'idée qu'une luciole est plus attractive si elle est plus brillante. $I_i = f(w_i)$ est la luminosité de la luciole i à un emplacement w_i , alors cette attractivité est évaluée par d'autres lucioles. On voit que la luminosité varie alors en fonction de la distance entre deux lucioles aléatoires i et j . En d'autres termes, le jugement dépend également de cette distance.

Dans les deux processus d'apprentissage inspirés par la nature (PSO et FFA), l'erreur de l'ensemble de validation est surveillée, et si le critère de convergence est satisfait, les poids et les biais de RNA sont sélectionnés et enregistrés. Enfin, les performances sont testées par le sous-ensemble de test.

III.5.5. Application de RNA-FFA en hydrologie

L'algorithme de luciole (FFA) basé sur des essaims, suscite une attention considérable dans la recherche, un certain nombre d'études rapportant une amélioration favorable de leur précision de modélisation (Ebtehaj et al., 2016; Ebtehaj & Bonakdari, 2016). Le FFA s'avère plus robuste que les autres méthodes d'optimisation car les optima globaux et locaux des données de prédicteur peuvent être résolus simultanément et efficacement (Kavousi-Fard et al., 2014; Łukasik & Žak, 2009; Xiong, 2014; X.-S. Yang, 2010b). Cette technique a été utilisée dans plusieurs recherches liées à l'hydrologie où a été couplé avec différents machine learning. Comme il y a peu d'études en hydrologie qui ont utilisé RNA-FFA, nous donnons dans ce paragraphe quelques littératures d'utilisation de FFA avec SVM et ANFIS en modélisation hydrologique. Pour la prévision mensuelle du débit de la rivière Pahang en Malaisie, (Yaseen et al., 2017) a proposé une nouvelle combinaison du modèle ANFIS avec FFA comme outil d'optimisation pour construire un modèle hybride ANFIS-FFA. (Khatibi et al., 2017) a étudié la prévision des débits des cours d'eau à Bear River, aux États-Unis ; en intégrant MLP avec FFA et les résultats ont été comparés à un modèle plus traditionnel d'utilisation des RNA en intégrant un modèle MLP feed-forward avec un Levenberg–Marquardt algorithme d'apprentissage de rétropropagation. (Darbandi & Pourhosseini, 2018a), a adopté une nouvelle approche de simulation appelée MLP-FFA pour les prévisions mensuelles de débit cours d'eau au bassin versant d'Ajichay, dans l'est de l'Azerbaïdjan. (Danandeh Mehr et al., 2019), a adopté une approche basée sur l'intégration de la régression vectorielle de support (SVR) et de FFA pour la prévision des précipitations à un mois à l'avance dans deux stations de pluie situées dans une zone semi-aride, en Iran. (Samantaray & Ghose, 2020a), a proposé une intégration de SVR avec l'algorithme FFA et la reconstruction de l'espace de phase (PSR) pour estimer le débit pour cinq bassins versants de Balangir, Odisha, Inde, puis il a comparé les résultats de ces modèles SVM-FFA, PSR-SVM-FFA avec SVM et modèles empiriques pour ajuster l'ampleur du ruissellement pour contrôler les inondations dans la région.

III.6. Les réseaux de neurones convolutifs (CNN)

Les CNN ont été largement appliqués dans une gamme de domaines différents, y compris la vision par ordinateur, le traitement de la parole, la reconnaissance faciale, etc. La structure des CNN a été inspirée par les neurones du cerveau humain et animal, semblable à un réseau de neurones conventionnel. Plus précisément, dans le cerveau d'un chat, une séquence complexe de cellules forme le cortex visuel ; cette séquence est simulée par le CNN (Alzubaidi et al., 2021). LeCun et ses collègues ont introduit les réseaux de neurones convolutifs en 1995 (LeCun & Bengio, 1995), un type de feed-forward (RNA) qui effectue des connexions locales entre les couches.

III.6.1. Avantages d'employer des CNN

Les avantages de l'utilisation des CNN par rapport à d'autres réseaux de neurones traditionnels dans l'environnement de vision par ordinateur sont répertoriés comme suit :

1. La principale raison d'envisager CNN est la fonction de partage de poids, qui réduit le nombre de paramètres de réseau pouvant être entraînés et aide à son tour le réseau à améliorer la généralisation et à éviter le surapprentissage.
2. L'apprentissage simultané des couches d'extraction de caractéristiques et de la couche de classification fait que la sortie du modèle est à la fois hautement organisée et fortement dépendante des caractéristiques extraites.
3. La mise en œuvre d'un réseau à grande échelle est beaucoup plus facile avec CNN qu'avec d'autres réseaux de neurones.

III.6.2. Architecture de CNN

L'architecture de CNN se compose d'un certain nombre de couches (ou blocs de construction multiples).

Couche convolutive (**Convolutional layer**)

La couche convolutive est censée effectuer l'opération de convolution sur les données. En fait, l'entrée pourrait être considérée comme une fonction, le filtre appliqué à celle-ci est une autre fonction et l'opération de convolution est un algorithme utilisé pour mesurer les changements causés par l'application d'un filtre sur l'entrée. La taille d'un filtre indique la couverture de ce filtre. Chaque filtre utilise un ensemble partagé de poids pour effectuer l'opération de convolution. Les poids sont mis à jour pendant le processus d'entraînement.

Supposons que l'entrée de couche $l - 1$ soit une matrice $N \times N$ et que des filtres convolutifs $F \times F$

soient utilisés. Ensuite, en utilisant l'équation (3.28), l'entrée de la couche 1, est calculée. Dans la couche suivante, la valeur de $v_{1,1}$ est obtenue en introduisant un filtre à l'entrée de données Fig. 3.8 Avant d'atteindre la couche suivante, chaque sortie de filtre est routée via une fonction d'activation, la plus utilisée est 'ReLU' Eq 3.29.

$$v_{i,j}^l = \delta(\sum_{k=0}^{F-1} \sum_{m=0}^{F-1} w_{k,m} V_{i+k,j+m}^{l-1}) \tag{3.28}$$

$v_{i,j}^l$ = la valeur de la couche l à la ligne i et à la colonne j, $w_{k,m}$ = le poids du filtre à la ligne k et à la colonne m et δ = fonction d'activation.

$$f(x) = \max(0, x) \tag{3.29}$$

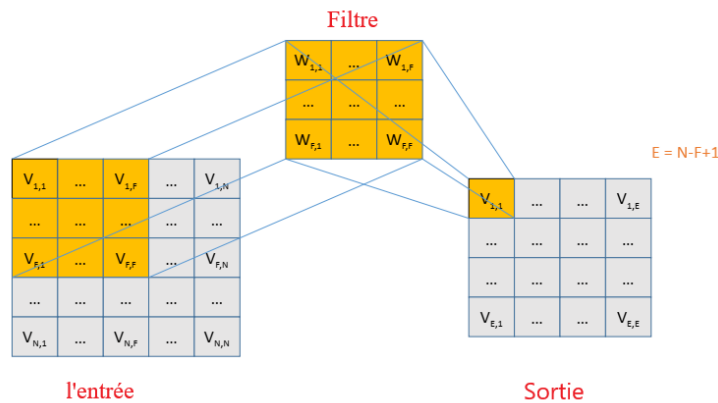


Figure 3. 8. Appliquer un filtre ($F \times F$) aux données d'entrée ($N \times N$) afin d'obtenir la valeur de $v_{1,1}$ dans la couche suivante.

Couche de mise en commun (**pooling layer**)

La couche de pooling est responsable du sous-échantillonnage des données. Cette opération, non seulement réduit le coût de calcul du processus d'apprentissage, mais est également un moyen de gérer le problème de surapprentissage dans CNN. Le surapprentissage est une situation qui survient lorsqu'un modèle entraîné s'adapte trop aux données d'entraînement, de sorte qu'il ne peut pas se généraliser aux futures données invisibles. Il a un lien avec le nombre de paramètres appris et la quantité de données à partir de laquelle le modèle de prédiction est appris. Les modèles profonds, y compris les CNN, ont généralement de nombreux paramètres. Ainsi, ils sont enclins à surajuster plus que les modèles peu profonds. Certaines méthodes ont été suggérées pour éviter le surapprentissage. L'utilisation de couches de pooling dans les CNN peut aider à réduire le risque de surapprentissage. Toutes les valeurs à l'intérieur d'une fenêtre de pooling sont converties en une seule valeur. Cette transformation réduit la taille de l'entrée des couches suivantes et, par conséquent, réduit le nombre de paramètres qui doivent être appris par le modèle, ce qui à son tour

réduit le risque de surapprentissage.

Couche entièrement connectée (**fully connected layer**)

La couche entièrement connectée est un réseau multicouche perceptron MLP qui se trouve dans les couches finales de CNN. Il est chargé de transformer les caractéristiques récupérées des couches précédentes dans la sortie finale. L'équation 3.30 définit la relation entre deux couches consécutives :

$$v_i^j = \delta(\sum_k v_k^{j-1} w_{k,i}^{j-1}) \quad (3.30)$$

v_i^j = la valeur du neurone i à la couche j , $w_{k,i}^{j-1}$ = poids de connexion entre le neurone k de la couche $j - 1$ et le neurone i de la couche j , δ = fonction d'activation (Hoseinzade & Haratizadeh, 2019).

III.6.3. Application de CNN en hydrologie

Les algorithmes d'apprentissage en profondeur [i. e., réseaux de neurones convolutifs (CNN)] qui bénéficient de diverses couches cachées, ont été développés pour résoudre des processus plus complexes avec un degré de précision plus élevé. Ce type d'algorithme a été appliqué avec succès pour la cartographie de la susceptibilité aux aléas naturels, y compris les crues éclair, la qualité de l'eau, les ressources en eau et les eaux souterraines, alors qu'ils ont été très rarement utilisés pour des problèmes de modélisation pluie-débit.

(Khosravi et al., 2020) a utilisé l'approche de réseau de neurones convolutifs CNN pour la prédiction spatiale des risques d'inondation à l'échelle nationale de l'Iran. (Barzegar et al., 2020) a développés deux modèles autonomes d'apprentissage profond, le modèle de mémoire à long court terme (LSTM) et le réseau de neurones convolutifs (CNN), ainsi que leur modèle hybride (LSTM-CNN) pour prédire deux variables de la qualité de l'eau, à savoir l'oxygène dissous et la chlorophylle-a dans le petit lac de Prespa en Grèce. (Haidar & Verma, 2018) a proposés le réseau de neurones convolutifs profonde (CNN) pour prédire les précipitations mensuelles pour un emplacement sélectionné dans l'est de l'Australie. (Van et al., 2020) a étudié l'application des modèles CNN et LSTM pour la prédiction quotidienne de processus pluie-débit sur la rivière Bassac dans le delta du Mékong vietnamien (VMD).

Similaires à RNA, les algorithmes CNN ont de nombreux paramètres dans leurs structures qui doivent être optimisés à l'aide d'approches d'optimisation telles que : l'optimisation du loup gris et l'algorithme compétitif impérialiste.

III.7. Algorithme compétitif impérialiste (ICA)

III.7.1. C'est quoi l'Algorithme compétitif impérialiste?

ICA a été présenté pour la première fois par (Atashpaz-Gargari & Lucas, 2007), c'est l'un des algorithmes évolutionnaires robustes inspirés des sociétés humaines qui peuvent être utilisés pour résoudre de nombreux problèmes d'optimisation (Barkhoda & Sheikhi, 2020). Semblable aux autres algorithmes évolutionnaires, l'ICA commence avec une population primitive appelée "pays", à partir de laquelle certains des meilleurs pays sont sélectionnés pour être impérialistes, et les autres deviennent des colonies, qui forment ensemble des empires. Parmi les impérialistes mentionnés, toutes les colonies de population initiale sont divisées en fonction de leur pouvoir. Ensuite, ils commencent à se diriger vers leur pays impérialiste concerné. Après cela, la compétition impérialiste commence entre tout l'empire. Tout empire qui ne gagnera pas dans la compétition et ne pourra pas augmenter sa puissance sera éliminé. La concurrence impérialiste augmentera progressivement le pouvoir des empires puissants tout en diminuant le pouvoir des plus faibles, ces derniers perdront leur pouvoir et finiront par s'effondrer. Le mouvement des colonies vers leurs impérialistes concernés, ainsi que la concurrence entre les empires et le mécanisme d'effondrement, mèneront, espérons-le, à une situation dans laquelle il n'y a qu'un seul empire mondial et tous les autres pays sont des colonies de cet empire.

III.7.2. Principe de ICA

Les procédures de l'ICA (Figure. 3.9) sont décrites comme suit.

1. Générer des empires initiaux

L'objectif de l'optimisation est d'identifier la meilleure solution en fonction des variables du problème. Nous créons un tableau de valeurs de variables à optimiser, le terme pays est utilisé pour ce tableau. Dans un problème d'optimisation dimensionnelle N_{Var} , un pays est un tableau $1 \times N_{Var}$. Ce tableau est défini par :

$$country = [P_1, P_2, P_3, \dots, P_{N_{Var}}] \quad (3.31)$$

La fonction de coût de n'importe quel pays a été évaluée par l'équation suivante :

$$Cost = f(country) = f(P_1, P_2, P_3, \dots, P_{N_{Var}}) \quad (3.32)$$

Pour démarrer l'algorithme compétitif impérialiste, différents paramètres tels que le nombre de pays initiaux ($N_{country}$), le nombre d'impérialistes (N_{imp}) et le nombre de pays restants sont des colonies appartenant chacune à un empire (N_{col}) ont été générés. Pour diviser proportionnellement

les colonies entre les impérialistes, le coût normalisé d'un impérialiste est représenté comme suit :

$$C_n = c_n - \max_i \{C_i\} \quad (3.33)$$

Où : c_n est le coût du nième impérialiste et C_n est son coût normalisé. En ayant le coût normalisé de tout impérialiste, le pouvoir de chaque impérialiste s'exprime comme suit :

$$P_n = \left| \frac{C_n}{\sum_{i=1}^{N_{imp}} C_i} \right| \quad (3.34)$$

De l'autre côté, le pouvoir normalisé d'un impérialiste est déterminé en fonction de ses colonies. Alors, le nombre initial d'un impérialiste sera :

$$N.C_n = \text{round}\{P_n \cdot N_{col}\} \quad (3.35)$$

Où $N.C_n$ représente le nombre initial de colonies du n-ième empire et N_{col} est le nombre de toutes les colonies. Afin de diviser les colonies entre les impérialistes, $N.C_n$ des colonies est sélectionné au hasard et attribué à chaque impérialiste. Les colonies avec l'impérialiste forment le n-ième empire.

2. Déplacer les colonies d'un empire vers l'impérialiste

Les pays impérialistes essaient d'améliorer leurs colonies et d'en faire une partie de leurs impérialistes. Mouvement de toutes les colonies vers leur propre impérialiste mis en œuvre pour représenter ce fait. Ce comportement de mouvement est montré sur la [figure 3.9](#), où la colonie se déplace vers l'impérialiste de x (est une variable aléatoire avec une distribution uniforme) unités.

$$x \sim U(0, \beta \times d) \quad (3.36)$$

Où : d est la distance entre un impérialiste et une colonie et β est un nombre supérieur à 1. Lorsqu'une colonie atteint une position à moindre coût que celle de son impérialiste, l'impérialiste et la colonie changent de position.

3. La puissance totale d'un empire

Le pouvoir de l'impérialiste et de ses colonies à le plus d'impact sur le pouvoir total d'un empire. De ce fait, le coût total d'un empire est obtenu par l'expression suivante :

$$T.C_n = \text{cost}(\text{imperialist}_n) + \xi \text{mean}\{\text{cost}(\text{colonies of } \text{impire}_n)\} \quad (3.37)$$

Où $T.C_n$ est le coût total du nième empire, et ξ est un nombre positif qui est considéré comme inférieur à 1. Une petite valeur pour ξ implique que la puissance totale d'un empire à obtenir uniquement par l'impérialiste et l'augmenter accentuera l'importance des colonies dans la

détermination de la puissance totale d'un empire. La valeur de 0,1 pour ξ est une valeur appropriée dans la plupart des implémentations.

4. Concurrence impérialiste

Tous les empires font des efforts pour gagner des colonies des autres empires et les gérer. Le défi impérialiste entraîne progressivement une diminution de la puissance des empires les plus faibles et une augmentation de la puissance des plus vigoureux. Ce défi est relevé en sélectionnant simplement certaines (généralement une) des colonies les plus faibles des empires les plus faibles et en faisant une compétition entre tous les empires pour posséder ces colonies. La probabilité de possession de chaque empire est calculée en fonction de sa puissance totale au début du processus de compétition. Le coût total normalisé est déterminé par l'expression suivante :

$$N.T.C_n = T.C_n - \max_i\{T.C_i\} \tag{3.38}$$

Où $T.C_n$ et $N.T.C_n$ sont respectivement le coût total et le coût total normalisé du n-ième empire. En ayant le coût total normalisé, la probabilité de possession de chaque empire est obtenue par l'équation suivante :

$$P_{P_n} = \left| \frac{N.T.C_n}{\sum_{i=1}^{N_{imp}} N.T.C_i} \right| \tag{3.39}$$

Pour répartir les colonies introduites entre les empires, le vecteur P est formé comme :

$$P = [P_{P_1}, P_{P_2}, P_{P_3}, \dots, P_{P_{N_{imp}}}] \tag{3.40}$$

Ensuite, un vecteur dont les nombres sont créés aléatoirement et uniformément distribués avec un vecteur de même taille que P nommé vecteur R comme suit :

$$R = [r_1, r_2, r_3, \dots, r_{N_{imp}}] \tag{3.41}$$

Après cela, en soustrayant R de P, le vecteur D est créé :

$$D = P - R[D_1, D_2, D_3, \dots, D_{N_{imp}}] \tag{3.42}$$

En référence au vecteur D, la colonie mentionnée (les colonies) est contrôlée par un empire dont l'indice correspondant dans D est maximisé.

Des empires impuissants se rencontreront dans le processus de compétition impérialiste et leurs colonies seront divisées entre d'autres empires. A la fin de l'algorithme compétitif impérialiste, tous les empires, sauf le plus puissant, engloberont, et toutes les colonies seront gérées par cet empire unique. Il convient de noter qu'ici, impérialistes et colonies ont la même position et le

même pouvoir à ce stade.

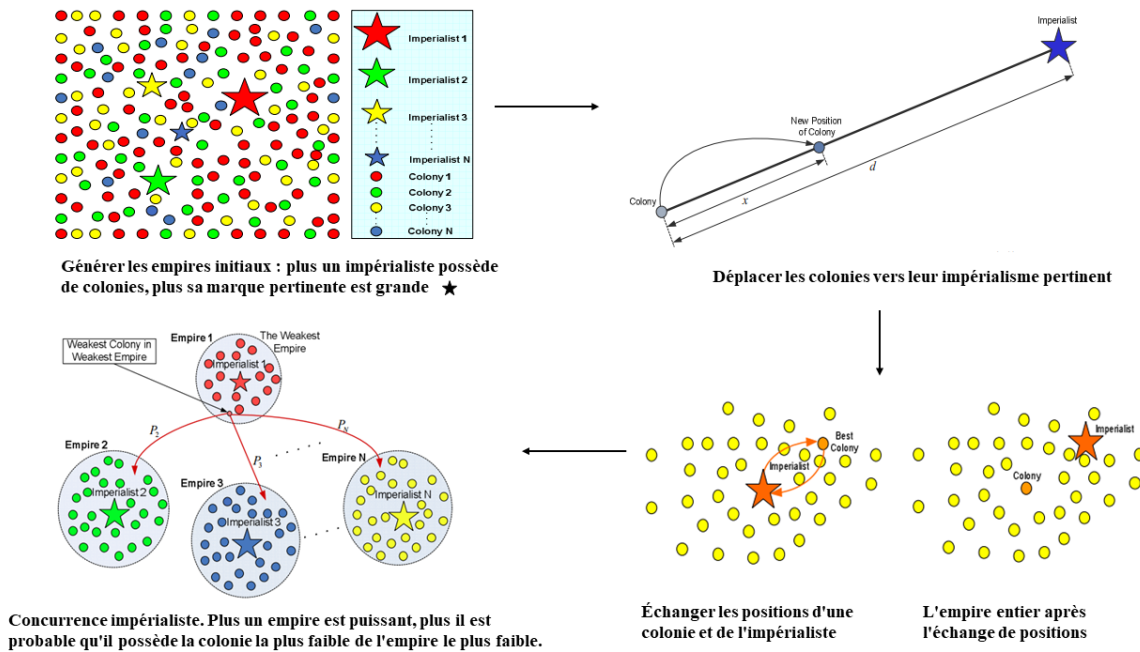


Figure 3. 9. Procédure de l'algorithme compétitif impérialiste.

III.7.3. Application de ICA en hydrologie

ICA intégré à l'apprentissage automatique comme beaucoup d'autres algorithmes métaheuristiques a été utilisé dans le domaine de l'hydrologie dans différentes applications, par exemple (Emami & Parsa, 2020) a introduit l'algorithme compétitif impérialiste pour prédire la capacité de stockage du réservoir du barrage de Shaharchay situé dans le bassin du lac Urmia au nord-ouest de l'Iran. (Ashraf Vaghefi et al., 2012) a appliqué le réseau de neurone artificiel formés par l'algorithme compétitif impérialiste (ICA) à la prévision des flux dans le bassin versant de Karkheh au sud-ouest de l'Iran. (Bui et al., 2018) a appliqué le système d'inférence neuro-floue adaptative (ANFIS) basées sur l'algorithme compétitif impérialiste (ANFIS-ICA) et algorithme luciole (ANFIS-FA) pour la modélisation spatiale des inondations et à sa cartographie dans le bassin versant de Haraz dans la province septentrionale de Mazandaran, en Iran. (Tashekaboud & Tashekaboud, 2018) a utilisé (ICA) pour prédire la charge sédimentaire en suspension quotidienne de la rivière Zarinehrood.

De ce qui précède, il n'y a pas d'étude qui utilise CNN intégré avec ICA pour la modélisation de la relation pluie-débit ce qui montre la nouveauté de cette recherche.

III.8. Optimisation du loup gris (GWO)

III.8.1. C'est quoi l'Algorithme d'optimisation du loup gris?

GWO a été proposé récemment par (Mirjalili et al., 2014), c'est une technique d'optimisation qui imite le comportement social des loups gris à la recherche de l'emplacement de proie approprié. Pendant la chasse, la proie est recherchée par les loups en adoptant un mécanisme hiérarchique à quatre niveaux comprenant des loups *alpha*, *bêta*, *delta* et *oméga* dans un ordre séquentiel (Figure.3.10.a, Figure.3.10.b) (Shukla et al., 2020). Le nombre total de loups représente l'ensemble de la population de solutions d'optimisation réalisables. La pertinence de la solution est déterminée par la proximité des loups avec la proie. Au cours du processus de recherche, les loups situés le plus près de la proie sont appelés loups *alpha*, ce qui correspond à la meilleure solution pour l'itération donnée. Selon la hiérarchie, les deuxièmes et troisièmes meilleures solutions sont respectivement appelées loups *bêta* et *delta*, tandis que les autres loups constituant le dernier niveau de la hiérarchie sont appelés loups *oméga*. Pour une population de N solutions, N - 3 solutions constituent les loups *oméga*. À partir de la randomisation initiale, la position/les solutions des loups sont mises à jour de manière itérative, pour les guider vers la proie, c'est-à-dire la solution optimale. La procédure itérative adoptée par l'optimisation du loup gris vise à converger vers la solution optimale globale.

III.8.2. Principe de GWO

La procédure adoptée par les loups pour la chasse aux proies comprend quatre étapes principales comme suit :

1. *Encerclement de proies* Pour une itération k donnée, une proie située en $\vec{X}_p(k)$ est encerclée par les loups gris, qui mettent à jour leur position individuelle $X(k)$ comme :

$$\vec{X}(k+1) = \vec{X}_p(k) - \vec{A} \cdot \vec{D} \quad (3.43)$$

Le sens de déplacement \vec{D} est défini comme :

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(k) - \vec{X}(k)| \quad (3.44)$$

Où \vec{A} et \vec{C} représentent les vecteurs de coefficients calculés comme :

$$\vec{A} = 2 \cdot \vec{a} \cdot r_1 - \vec{a} \quad (3.45)$$

$$\vec{C} = 2 \cdot r_2 \quad (3.46)$$

Le paramètre \vec{a} est un vecteur qui maintient un compromis entre l'exploration et l'exploitation en

diminuant linéairement avec l'itération, et r_1 et r_2 indiquent des vecteurs aléatoires compris entre 0 et 1 (Figure.3.10.c).

2. Chasse (Figure.3.10.d) En utilisant les informations reçues des loups *alpha*, *bêta* et *delta*, la chasse est effectuée dans laquelle tous les loups sont invités à mettre à jour leurs emplacements selon l'emplacement des meilleurs agents de recherche comme :

$$\vec{X}(k+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (3.47)$$

Où \vec{X}_1 , \vec{X}_2 et \vec{X}_3 sont calculés comme :

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \quad (3.48)$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \quad (3.49)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (3.50)$$

Où \vec{X}_α , \vec{X}_β , et \vec{X}_δ sont les positions des loups *alpha*, *bêta* et *delta* à l'itération k. Les variables \vec{A}_1 , \vec{A}_2 et \vec{A}_3 sont obtenues à l'aide de l'Eq. (3.45), tandis que \vec{D}_α , \vec{D}_β , and \vec{D}_δ sont définis comme :

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (3.51)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (3.52)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (3.53)$$

Où \vec{C}_1 , \vec{C}_2 , et \vec{C}_3 sont évalués à l'aide de l'équation (3.46).

3. Attaquer (Figure.3.10.e(a)) Le mécanisme de chasse des loups gris est terminé, lorsque l'emplacement de la proie n'est plus mis à jour. La stratégie d'attaque des loups gris offre une meilleure capacité d'exploitation aux agents de recherche. La stratégie d'attaque des agents de recherche est modélisée en attribuant une valeur décrémentant de \vec{a} au cours du processus itératif comme :

$$\vec{a} = 2 - k \frac{2}{Max_{iter}} \quad (3.54)$$

Où k est l'itération courante et Max_{iter} indique le nombre maximum d'itérations. Avec une valeur décroissante de \vec{a} , les itérations ultérieures sont principalement consacrées à l'exploitation de la meilleure des meilleures solutions.

4. Recherche de proies (Figure.3.10. e (b)) Les vecteurs de coefficients \vec{A} et \vec{C} dans (3.45) et (3.46), respectivement, sont principalement responsables du maintien de la forte capacité d'exploration tout au long du processus de recherche itératif, réduisant ainsi la probabilité de se faire piéger dans les optima locaux. La nature adaptative de \vec{A} maintient un compromis entre l'exploration et l'exploitation. Lors de la phase initiale du processus de recherche, la valeur plus élevée de \vec{A} ($A > 1$) préconise l'exploration, tandis que la deuxième phase du processus de recherche avec $A < 1$ est consacrée à l'exploitation. Le caractère aléatoire du vecteur de coefficient \vec{C} maintient la capacité d'exploration tout au long du processus de recherche, augmentant ainsi la probabilité de convergence globale (Shukla et al., 2020).

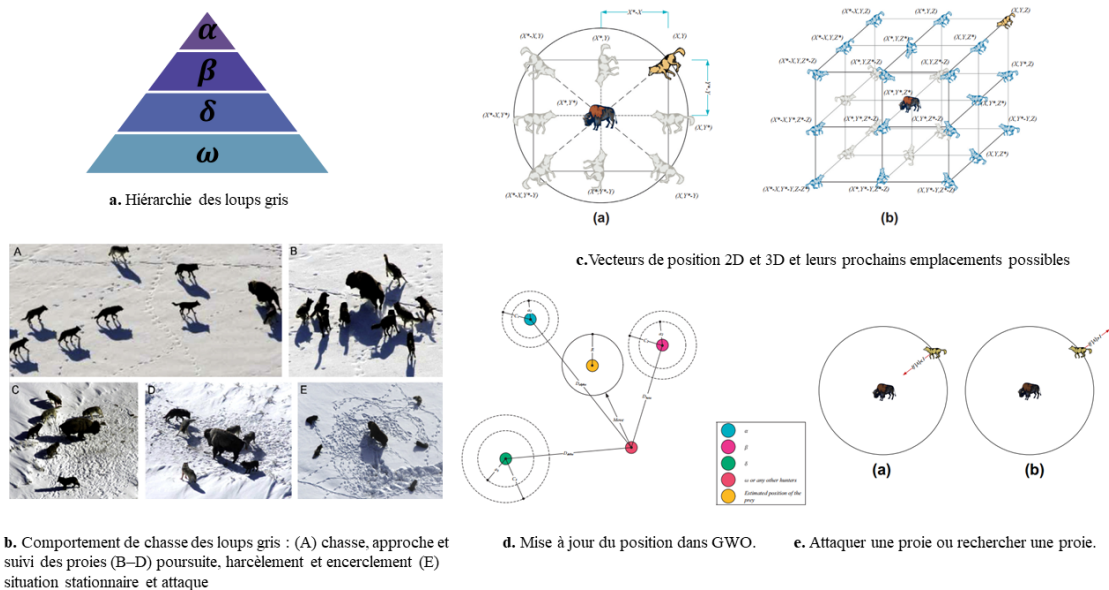


Figure 3. 10. Mécanisme de l'optimisation du loup gris.

III.8.3. Application de GWO en hydrologie

L'utilisation de l'optimisation du loup gris dans le domaine d'hydrologie devient de plus en plus importante. Plusieurs études ont utilisé GWO combinées avec l'intelligence artificielle pour modéliser des phénomènes naturels complexes.

(Malik et al., 2021) a intégré la régression vectorielle de support (SVR) avec l'optimisation du loup gris (GWO), pour la prédiction de la sécheresse météorologique (MD) en utilisant l'EDI (indice de sécheresse efficace) dans les régions de Kumaon et Garhwal de l'État d'Uttarakhand (Inde). (Tikhamarine et al., 2020a) a proposé un système hybride efficace en intégrant l'algorithme d'optimisation du loup gris (GWO) avec la régression vectorielle de support (SVR) pour prédire le

débit mensuel du haut barrage d'Assouan. (Panahi et al., 2021) a proposé un algorithme d'apprentissage en profondeur autonome et optimisé d'un réseau de neurones convolutifs (CNN) utilisant l'optimisation du loup gris (GWO), un algorithme génétique (GA) et une impérialiste compétitive algorithme (ICA) pour la prédiction de l'infiltration cumulative et du taux d'infiltration. De même, jusqu'à présente il n'y a aucune étude qui couvre l'utilisation du loup gris avec CNN pour la prévision du ruissellement ou la modélisation du processus pluie-débit.

Conclusion

Ce chapitre a été consacré à la présentation des différentes modèles d'intelligence artificielle qui sont appliquées dans cette recherche pour la modélisation des débits journalier et horaire (chapitre V). Plusieurs études ont conclu que les modèles de RNA et les RNA combinées avec les algorithmes métaheuristique agissent comme un outil de prévision impeccable, en particulier pour la prévision pluie-débit, la prévision de l'écoulement des cours d'eau, l'hydrologie des eaux souterraines, etc. par rapport à d'autres modèles. Les RNA autonome et RNA optimisées gagnent en popularité, comme en témoigne le nombre croissant d'articles sur ce sujet parus dans des revues d'hydrologie, en particulier au cours de la dernière décennie. D'un autre côté, Le CNN (algorithme d'apprentissage en profondeur) a apparue récemment, et diverses études ont montré sa supériorité par rapport aux modèles d'apprentissage automatique traditionnels en raison de leur plus grande flexibilité et de leur précision prédictive.

En termes d'applications hydrologiques, ces outils de modélisation en sont encore à leurs balbutiements. La communauté hydrologique praticienne commence tout juste à prendre conscience du potentiel des RNA et CNN en tant qu'outils de modélisation alternatif.

CHAPITRE IV

PRÉSENTATION DE LA ZONE D'ÉTUDE

Introduction

Le bassin-versant de la Seybouse, d'une superficie de 6471 km², présente, à l'instar des bassins à écoulement exoréique de l'Algérie orientale (Kébir-Rhumel, Soummam, etc...), une extension latitudinale importante. Les limites méridionales du bassin sont à 120 km à vol d'oiseau de la mer Méditerranée. Ce bassin se révèle, un objet d'étude approprié pour l'analyse de la variabilité hydro-climatique et de ses effets sur les ressources en eau. Ainsi, les éléments du milieu physique du bassin versant de la Seybouse, à savoir sa situation géographique, ses caractéristiques morphométriques (paramètres de forme et paramètres de relief) son réseau hydrographique, son climatologie et son occupation des sols seront présentés. Cette description sera achevée par une vue d'ensemble sur les potentialités du bassin en matière de ressources en eau.

IV.1. Présentation de la zone d'étude

IV.1.1. Situation géographique

Le bassin de la Seybouse d'une superficie de 6471 km², est l'un des constituants du grand bassin hydrographique nommé CONSTANTINOIS-SEYBOUSE MELLEGUE (ABH, 1996). Il est situé au cœur de la Numidie au Nord-est de l'Algérie, entre 06°47'02" et 07°58'47" de longitude Est et entre 35°47'49" et 36°55'43" de latitude Nord (figure 4.1). Il s'étend vers le sud sur une distance de 160 Km, jusqu'aux confins de l'atlas saharien, il atteint une largeur maximale de 120 Km au niveau de djebel Ouahch (Source de l'Oued Semendou à l'Ouest jusqu'à Oued El Kebir à l'Est). Le bassin versant de la Seybouse englobe sept wilayas de l'Est algérien : Guelma, Annaba, Souk Ahras, El Tarf, Oum El Bouaghi, Constantine et Skikda, et 68 communes dont 30 sont entièrement incluses dans le bassin et 38 partiellement principales villes : ANNABA, GUELMA et SEDRATA.

Ses limites naturelles sont :

- Au Nord : la mer Méditerranée,
- Au Sud : les monts de Mahouna, Ain larbi et Sedrata,
- A l'Ouest : le massif de l'Edough, les monts de Houara et Débagh,
- A l'Est : le prolongement oriental du système aquifère Annaba-Bouteldja et les monts de Nador N'bail.

La population est estimée à plus d'un million trois cent mille (1.300.000) habitants répartis dans les 68 communes et les sept wilayas. La seule agglomération de Annaba représente dix-huit pour cent (18%) de la population totale du bassin.

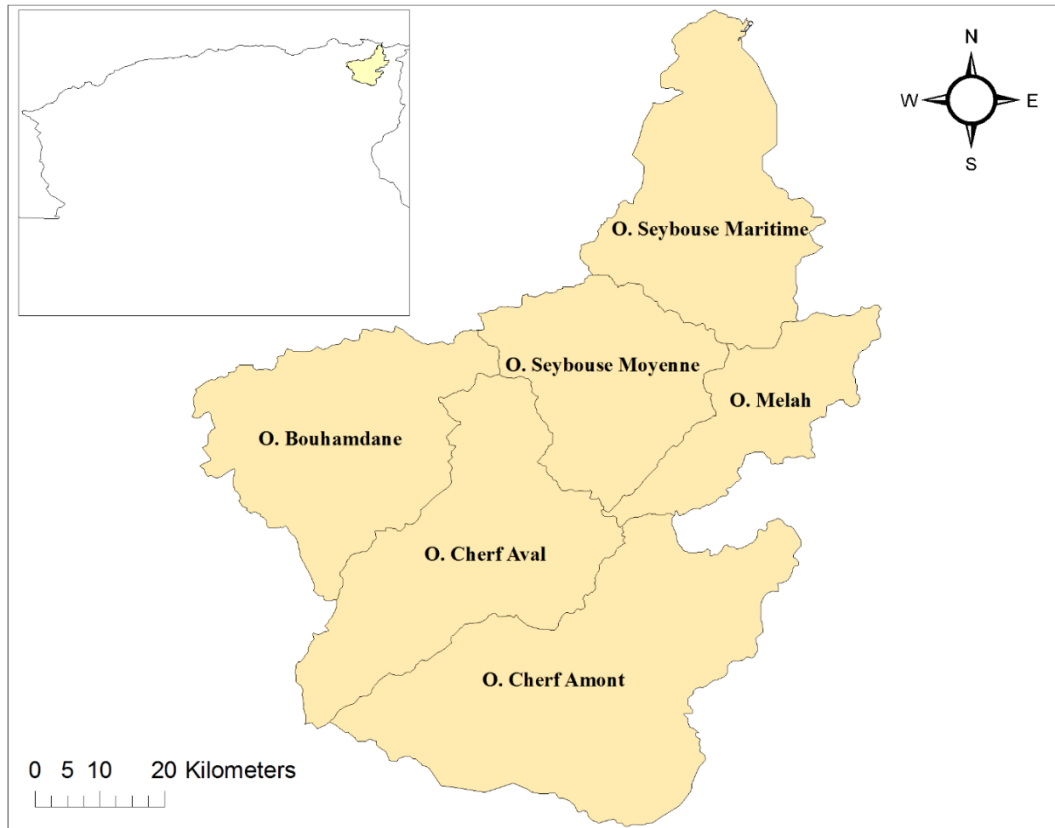


Figure 4. 1. Carte Situation géographique du bassin versant de la Seybouse en Algérie (ABH, 1996).

IV.1.2. Les sous bassins de la Seybouse

D'après le cahier de l'Agence du Bassin Hydrographique (ABH), le bassin versant de la Seybouse se compose de six sous bassins principaux (Figure 4.1) :

- Cheref amont (14-01) qui représente la haute Seybouse,
- Cheref aval (14-02),
- O. Bouhamdane (14-03),
- La moyenne Seybouse dit aussi Guelma (14-04),
- Mellah (14-05),
- Maritime (14-06) appelé aussi la basse Seybouse.

Dans la zone haute Seybouse, le relief est assez simple dans son ensemble. Les oueds et leurs affluents convergent tous vers Moulin Rochefort.

Le sous bassin de Cheref amont se compose essentiellement de la plaine de Sedrata et de la plaine de Tamlouka, ce dernier est drainé par l'Oued Melah qui prend ses sources dans le Djebel Amar. La plaine de Sedrata représente la plus grande partie de ce sous bassin.

La zone moyenne Seybouse, est une vaste partie centrale de la Seybouse, se caractérise par une hétérogénéité du relief et son cloisonnement (montagnes, vallées, plaines, collines, versants...) qui introduisent des variations marquées du point de vue climat, ce dernier se caractérise par des étages bioclimatiques qui se succèdent rapidement de l'humide au semi-aride.

Le sous bassin de Charef aval de type "gouttière" ou de nombreux petits Oueds orientés Est – Ouest, dans son ensemble est orienté à l'Oued de Charef, une série d'Oueds dans les deux rives droite et gauche, sur la rive droite, ce sont l'Oued Nil, l'Oued Sept, l'Oued Chenior, sur la rive gauche, ce sont l'Oued Medjez Bgar, l'Oued Anouna, l'Oued Mgaisba.

Le sous bassin Oued Bouhamdane : l'Oued Zenati et l'Oued Sabath forment par leur jonction l'Oued Bouhamdane, qui se jette dans la Seybouse à Medjez Amar, il est l'affluent le plus important après le Charef, entre Medjez Amar et Bordj Sabath la chaîne numidique a obligé le Bouhamdane à prendre la même direction.

Le sous bassin de Guelma : à Medjez Amar, la Seybouse considérablement accrue par l'union du Bouhamdane et du Charef, débouche dans le vaste bassin de Guelma ; l'Oued suit l'axe de ce dernier orienté Ouest –Est et le traverse dans toute sa longueur sur environ 25 Km, durant ce parcours la Seybouse a tracé de nombreux méandres.

Le sous bassin Mellah : d'orientation Sud-ouest/Nord-Est et en forme de couloir, le sous bassin du Mellah un relief très hétérogène, composé par des forêts de liège et de zen. Il est drainé par plusieurs oueds tels que, les oueds de RBIBA, SEKAKA, EL HAMAM, ZOUARA, SFA, CHEHAM, et GHANEM, la réunion des trois derniers oueds forme le cours d'eau principal.

La zone basse Seybouse est une région à vocation agricole avec de grands périmètres d'irrigation moderne (par aspersion). Il comporte une vingtaine d'unités industrielles dont cinq unités d'une grande importance. Il présente des ensembles naturels très hétérogènes, ce qui engendre des modes d'alimentation et de ruissellement différents.

Le sous bassin Maritime ou basse Seybouse : Le cours d'eau de la Seybouse prend sa voie entre Bouchegouf et Dréan dans une direction Sud-Nord, où il reçoit Oued Ressoul, qui est un affluent très dynamique, qui draine la région humide d'Ain Berda, Après la Seybouse continue sa route vers la mer, en formant de méandres et des bras morts, qui redevient fonctionnel lors des grandes crues.

IV.2. Morphométrie du bassin

Les caractéristiques morphologiques d'un bassin versant, unité fondamentale dans une étude hydrologique, jouent un rôle primordial dans la détermination des différents comportements du

régime hydrologique.

IV.2.1. Paramètres de forme

a. Surface du bassin versant (A)

Le bassin versant étant l'aire de réception des précipitations, il est donc tout à fait logique que ce paramètre soit le premier à rechercher. Cette surface peut être déterminée par planimétrie sur des cartes d'échelle convenable ou en utilisant les techniques de digitalisation actuelles.

La superficie $A = 6570 \text{ Km}^2$

Le périmètre $P = 996 \text{ Km}$

b. Indice de compacité Gravelius

L'indice admis par les hydrologues pour caractériser la forme d'un bassin versant est l'indice de compacité de GRAVELIUS.

Si A est la surface du bassin en Km^2 et P son périmètre en km, le coefficient K_c est égal à : $0.28 \frac{P}{\sqrt{A}}$

En fonction de la valeur de ce paramètre, on dira que le bassin est ramassé ou allongé. Ce paramètre caractérise le temps de réaction du bassin, il détermine l'allure de l'hydrogramme de crue.

Pour notre bassin d'étude, $K_c=3.44 > 1.12$; alors notre Bassin versant est de forme rectangulaire (Allongé).

c. Rectangle équivalent

Un autre paramètre permet de comparer les bassins versant entre eux, c'est le rectangle équivalent. C'est une transformation purement géométrique où la forme du bassin est rendue comme étant celle d'un rectangle ayant même périmètre et même superficie que le bassin versant.

La longueur du rectangle équivalent $L : L = \frac{K_c \sqrt{A}}{1.128} \left[1 + \sqrt{1 - \left(\frac{1.128}{K_c} \right)^2} \right] = 480.72 \text{ Km}$

La largeur du rectangle équivalent $l : l = \frac{K_c \sqrt{A}}{1.128} \left[1 - \sqrt{1 - \left(\frac{1.128}{K_c} \right)^2} \right] = 13.67 \text{ Km}$


IV.2.2. Paramètres de relief

a. Courbe hypsométrique

Comme la plupart des phénomènes hydrologiques et climatologiques sont directement liés à l'altitude, il est donc important de connaître la répartition des altitudes dans le bassin. On utilise pour cela la représentation de la courbe hypsométrique. Elle peut aussi être donnée sous forme d'histogramme, c'est la courbe des fréquences altimétriques. La forme de cette courbe donne implicitement une certaine idée sur les pentes du bassin et leurs répartitions en altitude et permet d'apprécier le potentiel érosif du bassin versant. La courbe hypsométrique est déterminée par planimétrie des surfaces entre les courbes de niveau.

Tableau 4. 1. Répartition Altimétrique du bassin

Altitude (m)	S. partielle Si (km ²)	S cumulée (km ²)	Si (%)	Si cumulée (%)	Altitude moy hi (Km)
1600	5.86	0		0	1.5
1400	17.28	5.86	0.09	0.09	1.3
1200	159.41	23.14	0.26	0.35	1.1
1000	2867.85	182.55	2.43	2.78	0.9
800	1693.42	3050.4	43.65	46.43	0.7
600	844.92	4743.82	25.77	72.2	0.5
400	478.78	5588.74	12.86	85.06	0.3
200	402.48	6067.52	7.29	92.35	0.1
0		6470	7.65	100	

**Figure 4. 2.** Courbe hypsométrique (d'après l'ANRH).

b. Les indices des pentes

Le relief d'un bassin est caractérisé par des indices qui ont été définis pour rendre compte de l'influence de la pente sur le régime hydrologique, pour comparer des bassins entre eux, etc.

L'indice de pente de Roche introduit en (1963) : C'est un indice qui rend bien compte de l'influence du facteur pente sur le régime hydrologique du bassin.

$$I_p = \frac{1}{\sqrt{L}} \sum \sqrt{S_i(h_i - h_{i-1})} \quad (4.1)$$

Dans cette formule, L, S_i, h_i et h_{i-1} représentent respectivement la longueur du rectangle équivalent en (m), La Surface de la bande i limitée par les deux courbes de niveau h_i et h_{i-1} et les limites B.V, les côtes les courbes de niveau i et i-1.

Donc $I_p=14.90\%$

Tableau 4. 2. Calcul de l'indice de pente de Roche

Altitude(m)	Surface S _i (%)	h _i -h _{i-1}	S _i (h _i -h _{i-1})	$\sqrt{S_i(h_i - h_{i-1})}$
1600-1400	0.09	200	18	4.24
1400-1200	0.26	200	52	7.21
1200-1000	2.43	200	486	22.05
1000-800	43.65	200	8730	93.43
800-600	25.77	200	5154	71.79
600-400	12.86	200	2572	50.71
400-200	7.29	200	1458	38.18
200-0	7.65	200	1530	39.12
	100			326.73

L'indice de pente global I_g sert à caractériser la pente d'un bassin et de permettre des comparaisons et des classifications. Il est déterminé à partir de la connaissance de la répartition hypsométrique du bassin. Il est donné par la formule :

$$I_g = \frac{H_{95\%} - H_{5\%}}{L} \quad (4.2)$$

Dans cette formule, H_{95%} et H_{5%} représentent les altitudes qui correspondent respectivement à 95% et à 5% de la surface totale du bassin. Elles sont toutes les deux tirées de la courbe hypsométrique. L, qui est la longueur du rectangle équivalent, est exprimé en kilomètre.

$D = H_{5\%} - H_{95\%} = 850\text{m}$ ou, $H_{5\%}$ et $H_{95\%}$ sont déduite de la courbe hypsométrique et ont pour valeur : $H_{5\%} = 983,33 \text{ m}$ et $H_{95\%} = 133,33 \text{ m}$. et $L=480.72 \text{ Km}$

$$I_g = 1.768 \text{ m/Km}$$

Dénivelée spécifique

Le dénivelé spécifique sert à classer les bassins en fonction de leurs reliefs. Cette dénivelée est donnée par :

$$D_s = I_g \sqrt{A} \tag{4.3}$$

Avec : **Ds** : Dénivelée spécifique (m), **A** : Superficie du bassin versant (km^2) et **Ig** : Indice de pente globale (m/km^2).

$$D_s = 143.30 \text{ m}$$

On se réfère généralement à la classification dressée par l'Office de la recherche scientifique et technique outre-mer l'O.R.S.T.O.M pour classer les bassins en fonction de leurs reliefs. Cette classification est donnée par le tableau 4.2.

Tableau 4. 3. Classification de l'O.R.S.T.O.M

Relief			Valeur de Ds
1	Relief très faible	$I_g < 0.002$	$D_s < 10$
2	Relief faible	$0.002 < I_g < 0.005$	$10 < D_s < 25$
3	Relief assez faible	$0.005 < I_g < 0.01$	$25 < D_s < 50$
4	Relief modère	$0.01 < I_g < 0.02$	$50 < D_s < 100$
5	Relief assez fort	$0.02 < I_g < 0.05$	$100 < D_s < 250$
6	Relief fort	$0.05 < I_g < 0.5$	$250 < D_s < 500$
7	Relief très fort	$0.5 < I_g$	$500 < D_s$

Selon la classification de l'O.R.S.T.O.M (illustrée sur le tableau 4.3), le relief de notre bassin versant est assez fort.

Tableau 4. 4. Classification des bassins versants selon leur superficie (LADJAL, 2012)

Très petit bassin versant	Petit bassin versant	Grand bassin versant	Très grand bassin versant
$0 \leq A \leq 10 \text{ Km}^2$	$10 \leq A \leq 200 \text{ Km}^2$	$200 \leq A \leq 2000 \text{ Km}^2$	$A > 2000 \text{ Km}^2$

D'après cette classification, notre bassin de surface 6570 Km^2 est de type très grand.

IV.3. Réseau hydrographique

Le réseau hydrographique est l'ensemble des cours d'eau, affluents et sous affluents permanents ou temporaires, par lesquels s'écoulent toutes les eaux de ruissellement et convergent vers un seul point de vidange du bassin versant (exutoire). Le réseau hydrographique du bassin de la Seybouse possède un régime hydrologique de type pluvial, fortement dominé par les précipitations sur l'ensemble de l'année avec un chevelu hydrologique de plus de (3.000Km). Quarante-deux oueds ont une longueur supérieure à 10Km, dont deux : le Cherf (88.61Km), et le Bouhamdane (37.49Km), se réunissent à Medjez Amar pour donner naissance à l'oued Seybouse (134.74Km), qui serpente vers le Nord en parcourant la basse plaine de Annaba, souvent inondée au moment des crues, avant de se jeter dans la baie d'Annaba par l'estuaire de Sidi Salem.




Figure 4. 3. Carte hydrographique du bassin versant de la Seybouse (ABH, 1996).

IV.4. Profil en long

Le profil en long d'un cours d'eau permet d'estimer sa pente moyenne nécessaire dans l'estimation

du temps de concentration des eaux dans le bassin. Le bassin de Seybouse s'étend sur 160 km, suivant une disposition sensiblement Sud-Ouest–Nord-Est, des confins des Garaet El Tarf et Guelif au Sud, jusqu'à la mer au Nord. L'oued Cherf prend naissance dans les Hautes Plaines (Berriche et Ain Babouche) et rencontre à l'Ouest de Guelma, l'oued Bouhamdane qui coule Sud-Ouest - Nord-Est, le long du versant Sud-tellien. Ces deux cours d'eau donnent lieu à l'oued Seybouse qui s'écoule d'Ouest en Est jusqu'à sa confluence avec l'oued Mellah, affluent issu du versant septentrional bien arrosé des Monts de Medjerda (cf. profil en long, [figure 4.4](#)). Depuis, la Seybouse change de direction pour rejoindre, plus au Nord, la mer Méditerranée, après avoir traversé la plaine côtière, comprise entre Dréan et Annaba.




Figure 4. 4. Profil en long de l'Oued Seybouse (d'après ([Ghachi, 1986](#)))

IV.5. Climatologie

La Seybouse, Oued méditerranéen, naît dans les hautes plaines semi-arides, sur le revers méridional de l'atlas Tellien ([ANRH, 2003](#)). Le bassin de la Seybouse se trouve dans la zone subtropicale et soumis aux influences des climats sahariens, méditerranéens et aux descentes polaires.

- Sahariens : car elles se manifestent par les hautes pressions tropicales (Anticyclone saharien), par le Sirocco (Chehili) qui souffle en été, c'est un vent chaud et sec qui est redouté par les agriculteurs il est synonyme de sécheresse.
- Méditerranéens : pour le régime des pluies en hiver et la sécheresse estivale.

- Polaires : des masses d'air froides en provenance de Sibérie ou du pôle viennent lécher la partie Nord du Maghreb en hiver.

En revanche, le climat est de type tempéré et ensoleillé. Les hivers sont froids avec des épisodes neigeux parfois importants sur les régions Sud. Les étés sont très chauds et secs, quelques nuages orageux rompent la monotonie du temps, accompagnés d'averses de grêle et de fortes précipitations brèves et locales, alterne souvent avec des chaleurs brûlantes qui peuvent se manifester de manière violente même en Juillet et début Août.

IV.6. L'occupation du sol

La répartition spatiale de l'occupation des sols au niveau du bassin versant de la Seybouse indique plusieurs domaines : les terres agricoles (cultures, cultures associées aux parcours et oléiculture) dominent sur ce bassin ; céréales et cultures maraîchères sont les principales spéculations des périmètres irrigués (irrigation traditionnelle ou gravitaire dans le bassin du haut Charef, et irrigation moderne ou par aspersion dans la basse Seybouse). Les formations forestières qui sont protecteurs contre l'érosion hydrique occupent un espace très important du bassin versant. Le reste de la superficie du bassin est occupé par des terres improductives (terrains rocheux, terrains nus, plan d'eau et terres urbanisées), ces domaines se trouvent un peu partout dans le bassin versant.

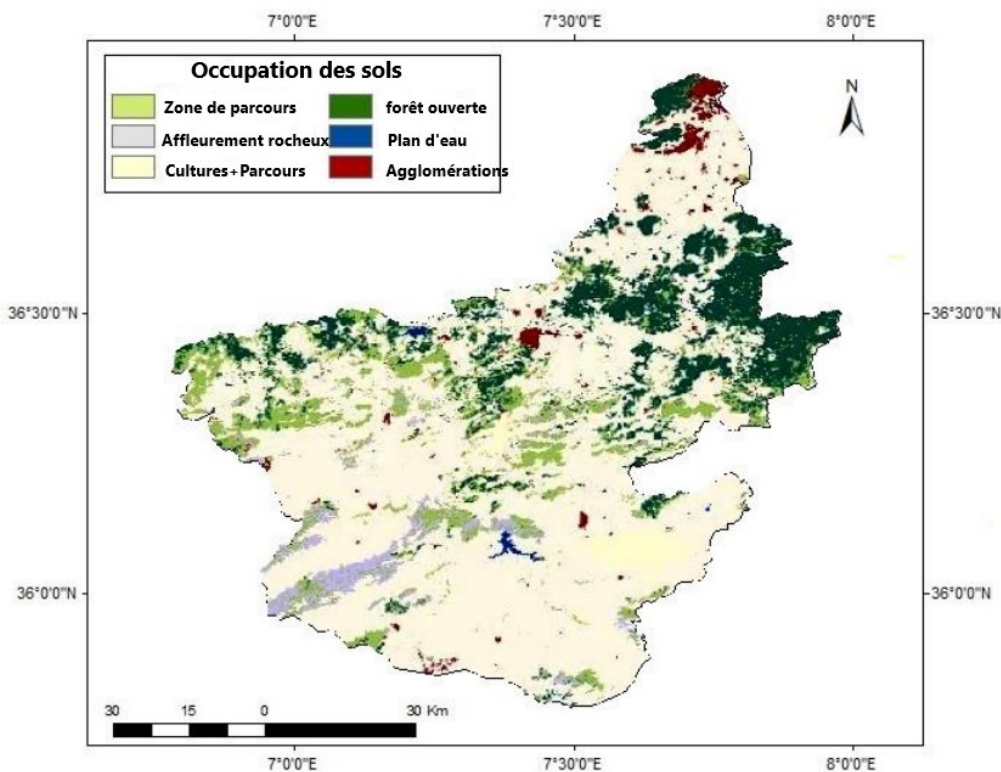


Figure 4. 5. Carte d'occupation du sol du bassin versant de la Seybouse (ABH, 1996).

Conclusion

Avant tout projet, l'étude du site est nécessaire pour connaître la caractéristique physique du lieu et les facteurs influençables sur le problématique étudié. Dans ce chapitre nous avons présenté les caractéristiques morphologiques et géologiques du bassin versant de Seybouse, sujets de notre application. Cette région est caractérisée par un climat semi-aride et par l'hétérogénéité des grandes unités naturelles et une diversité de la géologique.

Une superficie étendue du bassin de l'ordre de 6471 Km² s'étend au Nord-est de l'Algérie à une forme allongée et un relief assez fort.

Des caractères morphométriques déterminant des différences sensibles dans l'aptitude des terrains au ruissellement, un climat semi-aride à forte variabilité spatiale et surtout temporelle, un couvert végétal très discontinu, essentiellement dans l'espace et secondairement dans le temps. Telles sont les principales conditions physico-géographiques caractérisant le bassin de Seybouse et dont la combinaison est déterminante dans le comportement hydrologique des diverses unités du bassin.

CHAPITRE V

TRAITEMENT DES DONNEES UTILISEES

Introduction

Les conditions climatiques jouent un rôle dans l'influence du débit d'un cours d'eau ; néanmoins, les précipitations, en particulier liquides, qui constituent l'élément le plus essentiel intervenant par, leur hauteur totale annuelle qui détermine l'abondance pluviale, leur répartition mensuelle et saisonnière qui distingue les régimes hydrologiques, ainsi que leur hauteur journalière maximale et surtout les averses génératrices des crues. Des caractéristiques physiques (altitude...), facteurs climatiques (l'évapotranspiration, la température, l'humidité et la vitesse du vent) et atmosphériques influent sur l'écoulement et le régime hydrologique du bassin, et se conjuguent pour modifier à des degrés divers ces différents aspects des précipitations.

Toute étude de modélisation hydrologique est basée sur la collecte des données. La quantité et la qualité de ces dernières conditionnent les résultats obtenus. Dans cette partie nous allons définir, analyser et traiter l'ensemble des données et paramètres hydro-climatiques collectées de différentes sources et utilisées dans le développement des modèles proposés.

V.1. Données en usage

Pour un bassin versant donné, les stations fournissent des mesures ponctuelles. Elles sont installées dans des conditions propres et forment le réseau d'observation. Les données des stations sont d'une grande importance pour les statistiques climatiques, la planification, la gestion des ressources et les projets de construction. La représentativité des précipitations par les mesures est une fonction du réseau d'observation. Plus elles sont denses, meilleure est l'information et plus l'ensemble des mesures est représentatif de la lame d'eau tombée sur une surface particulière.

Sur notre site d'étude, les stations sélectionnées sont présentées dans le tableau ci-dessous. Bien évidemment, garantir la fiabilité de ces informations est une étape préalable à la réalisation de toute étude temporelle ou spatiale. Il n'y a pas de processus générateurs d'informations en dehors des processus de mesure. Cet adage vieux comme le monde s'applique à toute approche scientifique et à la climatologie en particulier. De ce fait, l'étude du climat et le suivi de son évolution nécessitent donc de longues et nombreuses séries d'observations. Malheureusement, nous n'avons jamais de séries de données parfaitement continues. La constitution d'échantillons, au sens statistique du terme est donc un processus long parsemé d'embûches et au cours duquel de nombreuses erreurs de nature fort différente sont susceptibles d'être commises.

Ce travail est constitué de trois chapitres d'application des modèles (modèle conceptuel GR4J, modèles RNA autonome, modèles RNA hybrides, et modèles CNN autonome et hybrides) pour modéliser les débits à deux échelles; horaires et journaliers.

V.1.1. Collecte des données

A l'échelle journalier, la base de données utilisées dans l'application des modèles est constituée des données de précipitations (P), et de débits (Q) collectées auprès de l'agence nationale des ressources hydriques ANRH d'Alger, des données de température de l'Office National de Météorologie – ONM d'Alger, des données d'humidité et vitesse du vent obtenues à partir du site POWER Data Access Viewer v2.0.0 (site : <https://power.larc.nasa.gov/data-access-viewer/>) et d'évapotranspiration potentielle calculée en utilisant le modèle de (Oudin et al., 2005) (Eq. 5.2). Le modèle utilise comme seule donnée d'entrée la température et il utilise également le calcul de la radiation extraterrestre détaillée par (Morton, 1983).

$$ETP = \frac{R_e T_a + K_2}{\lambda \rho K_1} \text{ Si } T_a + K_2 > 0 \quad (5.1)$$

ETP = 0 sinon

Avec : ETP : Evapotranspiration potentielle (mm/jour) ; Re : Radiation extra-terrestre (MJ m⁻²/jour) calculée en fonction de la latitude et du jour ; T_a : Température journalière en °C ; λ : Flux de chaleur latente (2.48 MJ/Kg) ; ρ : Densité de l'eau (Kg/m³). K₁ (°C) est un facteur d'échelle permettant d'ajuster le volume total d'ETP dans l'année et K₂ (°C) permet d'imposer un seuil sur les températures, afin que les ETP ne soient pas systématiquement nuls lorsque la température de l'air est négative. Dans les formules de Jensen-Haise et de McGuinness-Bordne, (K₁, K₂) vaut respectivement (40, 0) et (68, 5). L'ajustement de ces deux constantes a permis d'obtenir la formulation suivante pour l'ETP en mm j⁻¹ :

$$ETP = \frac{R_e T_a + 5}{\lambda \rho 100} \text{ Si } T_a + 5 > 0 \quad (5.2)$$

ETP = 0 sinon

A l'échelle horaire, les données de débits (Q) ont été recueillies auprès de l'agence nationale des ressources hydriques ANRH d'Alger, les données de précipitations totales, température de l'air à 2 m, pression de surface, 10 m u-composant du vent, 10 m v-composante du vent, température du sol niveau 1 et couche d'eau du sol volumétrique 1, sont obtenus à partir des données horaires de réanalyse ERA5 à des niveaux uniques de 1979 à 2021 dans le magasin de données climatiques du service Copernicus sur le changement climatique (C3S). Pour les indices climatiques : Oscillation antarctique (AAO), oscillation arctique (AO), oscillation de l'Atlantique Nord (NAO) et configuration nord-américaine du Pacifique (PNA) sont obtenus du Centre de prévision climatique (Climate Prediction Center (CPC)), et les données de l'indice de température de surface de la mer dans la région Nino3.4 de l'océan Pacifique équatorial oriental (SST_Nino34) sont obtenus du site : https://www.cpc.ncep.noaa.gov/data/indices/sstoi_indices.

V.1.2. Contrôle des données

Avant de pouvoir exploiter l'ensemble des données hydro-climatiques et bien qu'elles soient dans un format adéquat, il importe de contrôler leur fiabilité et leur précision. Le contrôle de la validité des données d'observation est un travail préalable indispensable à toute analyse correcte malgré les nombreux contrôles manuels intervenant dans la chaîne de traitement des données climatologiques.

Le contrôle manuel se fait à plusieurs niveaux, d'abord au niveau de la station, puis au niveau du service central où souvent encore des erreurs de nature fort différente sont susceptibles d'être relevées. Elles peuvent être dues au capteur mal entretenu ou à des erreurs de transcription des données du carnet d'observation sur les CRQ (compte rendu quotidien) et des CRQ sur les TCM (tableaux climatologiques mensuels) ou sur support informatique. Le contrôle manuel est basé sur l'expérience du correcteur cependant le contrôle automatique a pour but de trier les données considérées comme correctes et les données considérées comme douteuses.

Il est évident que la base des études climatologiques ou hydrologiques nécessite des séries de données régulières continues et de longue durée; l'application des méthodes statistiques sur ces séries impose un certain nombre de conditions entre autres, la continuité des observations dans le temps et la pérennité des méthodes d'observations.

V.1.3. Caractéristiques des stations

Pour un bon traitement des données recueillies, et comme mentionnée précédemment, il est nécessaire et indispensable que la période de collecte soit suffisamment longue, autrement dit l'échantillon doit être suffisamment grand (El Ouissi A. 2004). Cependant, la réalité est différente à cause des lacunes que nous trouvons souvent dans les séries d'observations. (Azzaz H. 2001). Pour être utilisables, les observations doivent être aussi exactes que possible et comparables les unes aux autres, donc synchrones et faites dans les mêmes conditions.

Pour le choix de la période d'étude, nous avons choisi de débiter notre période d'étude à partir des dates où le réseau de stations commence à avoir une certaine stabilité. Le tableau 5.1 présente l'ensemble des caractéristiques statistiques des périodes de données journalier de débits utilisées dans les modèles GR4J et RNA pour les six stations d'étude.

Tableau 5.1. Caractéristiques des débits journalier des stations hydrométriques utilisés dans les modèles GR4J et RNA autonome.

Code	Nom	Rivière	Superficie (km ²)	Période	Totale de données	Max m ³ /s	Min m ³ /s	Moy m ³ /s
14-02-02	Moulin Rochefort	Cherf	1710	1981-1994	4824	60.61	0	0.51
14-03-01	Medjez-Amar II	Moyenne Seybouse	1105	1981-2002	7704	649.10	0	2.46
14-03-02	Bordj-Sabath	Bouhamdane	304	1981-2015	12398	274.66	0	0.62
14-05-01	Bouchegouf	Melah	550	1981-1995	5275	192.39	0	1.44
14-06-01	Mirebek	Seybouse	5950	1981-1995	5111	1006.85	0	7.39
14-06-02	Ain Berda	Ressoul	102	1981-1997	6040	50.76	0	0.43

Les caractéristiques des données journalière de débits utilisées dans le développement des modèles RNA hybrides sont présentées dans le tableau 5.2.

Tableau 5.2. Caractéristiques des débits journalier utilisés dans les modèles RNA hybride.

Nom	Période	Base de données	Totale de données	Max m ³ /s	Min m ³ /s	Moy m ³ /s
Moulin Rochefort	1974-1994	Apprentissage (80%)	5210	60.60	0	0.47
		Test (20%)	1303	21.83	0	0.39
		Totale (100%)	6513	60.60	0	0.45
Medjez-Amar II	1981-2002	Apprentissage (80%)	5601	649.10	0	2.32
		Test (20%)	1401	9.19	0.076	3.84
		Totale (100%)	7002	649.10	0	2.63
Bordj-Sabath	1980-2015	Apprentissage (80%)	9512	351.95	0	0.59
		Test (20%)	2379	192.07	0	0.52
		Totale (100%)	11891	351.95	0	0.58
Bouchegouf	1980-1995	Apprentissage (80%)	3784	192.39	0	1.43
		Test (20%)	947	65.35	0.012	1.17
		Totale (100%)	4731	192.39	0	1.43
Mirebek	1981-1995	Apprentissage (80%)	3703	1006.85	0	7.29
		Test (20%)	926	286.20	0	8.47
		Totale (100%)	4629	1006.85	0	7.57
Ain Berda	1977-1997	Apprentissage (80%)	5328	50.76	0	0.35
		Test (20%)	1333	43.96	0	0.30
		Totale (100%)	6661	50.76	0	0.34

A l'échelle horaire, le tableau 5.3 récapitule les caractéristiques statistiques des données horaire de débits utilisées dans les modèles CNN autonome et hybride pour les six stations d'étude.

Tableau 5.3. Caractéristiques des données horaire des stations hydrométriques utilisées dans les modèles CNN autonome et hybride.

Nom	Période	Base de données	Totale de données	Max m ³ /s	Min m ³ /s	Moy m ³ /s
Moulin Rochefort	Nov-83-Fev-94	Apprentissage (80%)	2640	65.4	0	6.21
		Test (20%)	660	63.4	0	6.69
		Totale (100%)	3300	65.4	0	6.38
Medjez-Amar II	Sep-86-Avr-03	Apprentissage (80%)	5892	475	0	15.05
		Test (20%)	1474	455	0	14.56
		Totale (100%)	7366	475	0	14.72
Bordj-Sabath	Sep-86-Avr-05	Apprentissage (80%)	10280	302	0	7.98
		Test (20%)	2570	174	0	6.68
		Totale (100%)	12850	302	0	7.21
Bouchegouf	Oct-90-May-03	Apprentissage (80%)	10339	204	0.02	7.17
		Test (20%)	2584	784	0.03	15.10
		Totale (100%)	12923	784	0.02	11.10
Mirebek	Oct-86 to Jun-91	Apprentissage (80%)	6260	679.5	0	34.89
		Test (20%)	1565	681.36	0.14	59.80
		Totale (100%)	7825	681.36	0	46.78
Ain Berda	Sep-90-May-03	Apprentissage (80%)	7089	170	0	2.95
		Test (20%)	1773	145	0	5.99
		Totale (100%)	8862	170	0	4.37

V.2. Analyse des écoulements

Les enregistrements des débits des rivières sur une série d'années montrent des variations systématiques des principaux facteurs physiques et géographiques influençant le débit. Le régime hydrologique d'une rivière résume l'ensemble de ses caractéristiques hydrologiques et leur mode de variation. Il est donc nécessaire de comprendre l'évolution des données hydrométriques collectées dans une station hydrométrique, car elles seront utilisées d'une part pour l'évaluation des apports liquides à différentes échelles de temps, et d'autre part l'analyse de la variabilité événementielle du débit.

Les variations des débits à différents échelles, les bilans hydrologiques, les régimes fluviaux, les


intensités des crues extrêmes et des étiages ainsi que leur fréquence sont autant de paramètres pris en compte pour illustrer l'intérêt de l'hydrologie dans les principales problématiques liées à la gestion de l'eau telles que le contrôle des régimes hydrologiques.

V.2.1. Variation des débits moyens journaliers


La génération des débits au niveau d'un bassin, résulte d'un grand nombre de processus superficiels et souterrains qui interagissent d'une façon plus générale dans le cycle de l'eau à des échelles spatio-temporelles différentes.

Vu l'importance des variations des régimes fluviaux pendant des durées très courtes de 24 heures au niveau de bassin, et leurs affluences sur les transports solides, une étude des débits à l'échelle journalière est obligatoire. Le ruissellement se développe surtout quand l'intensité de la pluie dépasse la capacité d'infiltration du sol d'où l'engorgement rapide par l'eau et l'apparition des premières montées des pics (Bouzeria., 2018). Les variations journalières de débits des six stations d'étude sont présentées dans la (figure 5.1). Pour la station Moulin Rochefort, le débit maximal est atteint 60.6 m³/s, 649.1 m³/s à Medjez-Amar II, 274.6 m³/s à Bordj-Sabath, 192.3 m³/s à Bouchegouf, 1006.8 m³/s à Mirebek et 50.7 m³/s à Ain Berda.


Moulin Rochefort



Medjez-Amar II



Bordj-Sabath



Boucheouf





Figure 5.1. Variation journalière de débit des six stations hydrométriques.

Mirebek



Ain Berda





Figure 5.1. Continue.


V.2.2. Variation des débits moyens horaire

L'application horaire des modèles hydrologiques suscite un intérêt croissant, car la prévision horaire des crues devient importante en raison de la prévalence d'événements hydrologiques extrêmes provoqués par des précipitations intenses. De plus, les pics de crue peuvent ne pas être simulés de manière fiable sur la base d'une résolution temporelle grossière (par exemple, pas de temps journalier) (Hailegeorgis & Alfredsen, 2015). Par conséquent, des prévisions horaires basées sur des paramètres calibrés à l'aide d'observations horaires sont nécessaires à des fins de gestion de l'eau. L'évolution horaire de débit est visualisée dans la figure 5.2 Pour la station Moulin Rochefort, un pic a été enregistré avec $65.4 \text{ m}^3/\text{s}$, à Medjez-Amar II $475 \text{ m}^3/\text{s}$, à Bordj-Sabath $302 \text{ m}^3/\text{s}$, à Bouchegouf $784 \text{ m}^3/\text{s}$, à Mirebek $681.36 \text{ m}^3/\text{s}$ et à Ain Berda $170 \text{ m}^3/\text{s}$.


Moulin Rochefort



Medjez-Amar II



Bordj-Sabath



Boucheouf





Figure 5. 2. Variation horaire de débit des six stations hydrométriques.

Mirebek



Ain Berda




Figure 5. 2. Continue.

V.3. Analyse des données

L'étude de variables hydrométéorologiques repose sur l'homogénéité des séries mesurées. Une série chronologique hydrométéorologique homogène est définie comme celle où les variations sont causées uniquement par des variations dans le temps et le climat. Toutefois, ces séries sont souvent touchées par des inhomogénéités. En effet, les conditions de mesures dans lesquelles les données hydrométéorologiques sont collectées peuvent changer au cours du temps. Parfois, les causes sont les déplacements des stations, l'utilisation de nouveaux instruments de mesures, le changement de l'opérateur ou l'effet de l'urbanisation autour d'une station de mesure. Par ailleurs, il est fréquent que les chroniques présentent des périodes de données manquantes (panne d'un appareil de mesures, absence de l'observateur non signalée). Dans ce cas, si les trous dans les séries de données sont trop importants et n'apparaissent pas de manière aléatoire dans l'échantillon, l'analyse statistique n'est pas applicable (BELARBI, 2017).

V.3.1. Problème de lacunes

Le traitement des données avec observations manquantes est un problème concret et toujours embarrassant, et si cela n'a pas de conséquences pratiques lorsqu'on dispose de données très

nombreuses, cela peut supprimer tout intérêt à l'étude si le nombre de données restantes est trop faible. Dans notre étude, Seize stations pluviométriques sont mises à notre disposition, cependant, la plupart d'entre eux présentent des lacunes qui correspondent à des années et des mois d'observations incomplètes, dont il est difficile de combler. Néanmoins, par manque de données, on peut utiliser une seule station dans le cas des bassins de petite taille, on considère donc l'étude spécifique au sous bassin versant.

Par conséquent, six stations pluviométriques parmi seize moins lacunaires ont été sélectionnées (une par chaque sous bassin) : Ain Makhlof, Medjez-Amar II, Bordj-Sabath, Oued Cheham, Boukhamouza et Ain Berda (voir [figure. 5.3](#)). Seulement trois stations révèlent des lacunes ponctuelles au pas du temps journalier. Parce que la taille des échantillons pour ces stations est si grande (la station Bordj Sabath $N > 34$ ans, Oued cheham $N > 14$ ans et Ain Berda $N > 16$ ans), nous n'avons pris que les jours où les données étaient disponibles. Tandis que les données restantes au pas du temps journalier et horaire (mentionnées dans la section V.1.1), sont des séries successives complètes et ne contiennent pas des lacunes.

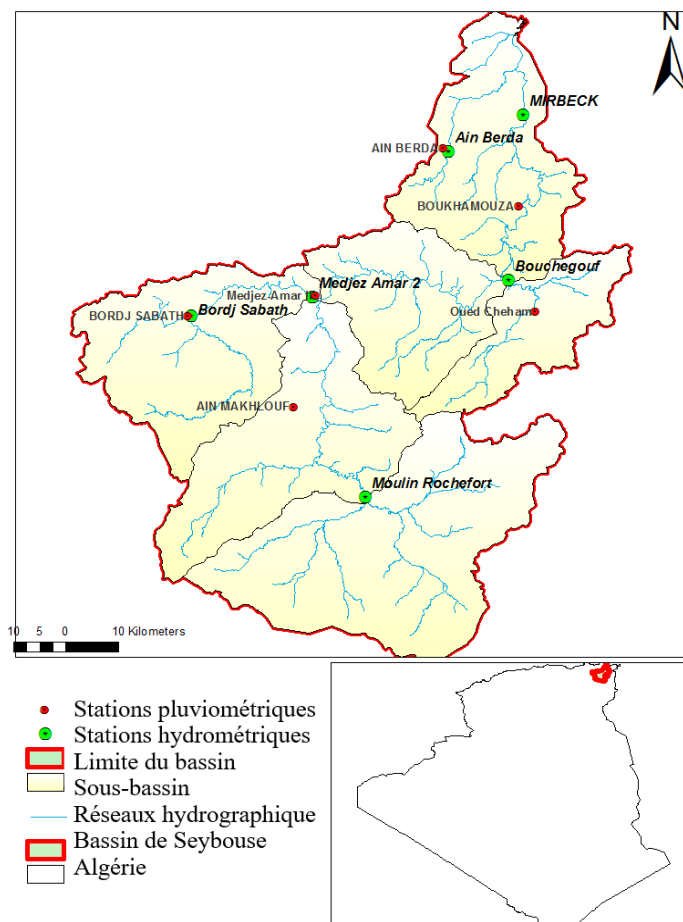


Figure 5.3. Location des six stations pluviométriques et hydrométriques.

V.3.2. Homogénéisation des données

Toute étude hydrologique est basée sur l'exploitation de séries de données recueillies pendant des périodes plus ou moins longues, continues ou discontinues. Les méthodes statistiques d'analyse de ces séries, exigent une homogénéité de leurs composantes, il est donc nécessaire, avant toute utilisation des variables pluviométriques ou hydrométriques, de contrôler leur qualité par l'emploi d'outils statistiques et graphiques, afin de réduire les erreurs systématiques qui pourraient les affecter. L'hypothèse d'homogénéité exprime que les échantillons extraits de la même population sont identiques et par conséquent ont les mêmes fonctions de répartition. Une série de données est dite homogène, si les propriétés statistiques de l'erreur de mesure affectant les données sont restées invariables au cours de la période d'observation.

Dans ce travail nous avons utilisé une méthode numérique à savoir - Test de Wilcoxon pour s'assurer de l'homogénéité de nos série pluviométrique et hydrométriques. Le test de Wilcoxon est le plus puissant des tests non paramétriques qui utilise la série des rangs des observations, au lieu de la série de leurs valeurs. Le procédé du test est :

Soit une série de précipitations ou de débits de longueur N dont on veut vérifier l'homogénéité, le test suit les étapes suivantes :

- ✚ On divise la série en deux sous série X, Y de tailles respectivement N_1, N_2 , avec $N_1 < N_2$
- ✚ On classe la série (X+Y) par ordre croissant et on détermine l'origine de chaque valeur.
- ✚ On calcule W_x où $W_x = \sum rangs(X)$
- ✚ On calcule W_{min}, W_{max}

$$W_{min} = \frac{(N_1 + N_2 + 1)N_1 - 1}{2} - \mu_{1-\frac{\alpha}{2}} \sqrt{\frac{N_1 N_2 (N_1 + N_2 + 1)}{12}} \quad (5.3)$$

Avec $\mu_{1-\frac{\alpha}{2}}$: valeur de la variable réduite de Gauss correspondant à une probabilité de $1 - \frac{\alpha}{2}$

$$W_{max} = (N_1 + N_2 + 1)N_1 - W_{min} \quad (5.4)$$

Si $W_{min} < W_x < W_{max}$ l'homogénéité de la série est vérifiée.

D'après les tests d'homogénéité mentionnés dans le tableau ci-dessous, on peut conclure que nos séries pluviométriques et hydrométriques de données des stations aux deux échelles journalier et horaire étudiées sont homogènes.

Tableau 5. 4. Résultat du test d'homogénéité des Station pluviométriques à l'échelle journalier

Paramètres	Station pluviométriques					
	Ain Makhlouf	Medjez-Amar II	Bordj-Sabath	Oued Cheham	Boukhamouza	Ain Berda
W_{min}	78.57	84.775	210.7	38.56	56.67	100.46
W_x	94	103	238	59	78.75	140
W_{max}	131.43	145.225	329.3	73.44	94.76	179.54
Résultat	homogène	homogène	homogène	homogène	homogène	homogène

Tableau 5. 5. Résultat du test d'homogénéité des Station hydrométriques à l'échelle journalier

Paramètres	Station hydrométriques					
	Moulin Rochefort	Medjez-Amar II	Bordj-Sabath	Boucheougouf	Mirebek	Ain Berda
W_{min}	78.57	84.775	210.7	38.56	38.56	100.46
W_x	115	109	296	67	67	124
W_{max}	131.43	145.225	329.3	73.44	73.44	179.54
Résultat	homogène	homogène	homogène	homogène	homogène	homogène

V.4. Choix des variables d'entrée

Après avoir collecter, analyser et traiter l'ensemble des données qui seront utilisées dans les models proposées, un problème important de la plupart des méthodes basées sur les données, y compris les RNA et les CNN, est la sélection appropriée des variables d'entrée, ainsi que d'autres aspects tels que la structure des modèles. Il est maintenant bien connu que la sélection appropriée des variables d'entrée a un impact fondamental sur la performance des modèles basés sur les données. Une revue de la littérature dans le domaine de la prévision des débits révèle que les chercheurs, à travers leurs expériences, ont généralement sélectionné les variables d'entrée de manière successive ou, dans la plupart des cas, par une méthode limitée d'essais et d'erreurs. Aucune de ces méthodes n'est fiable et cohérente lorsqu'il s'agit de grands problèmes multivariables. La sélection du sous-ensemble optimal dans les ensembles de données disponibles peut conduire à une meilleure description de la sortie du modèle. Différentes méthodes de sélection des entrées ont été étudiés, notamment l'analyse en composantes principales, le test Gamma, les méthodes de sélection directe, matrice de corrélation...etc., et chacune a démontré dans un domaine de recherche précis son application réussite sur les résultats. Par conséquent, le processus

de sélection des entrées est une étape très importante pour une prédiction robuste dans ces circonstances. Dans cette recherche, différentes méthodes de sélection des entrées ont été appliquées à savoir procédure d'essai et d'erreur, matrice de corrélation, fonction d'autocorrélation (ACF), fonction d'autocorrélation partiels (PACF) et l'analyse en composantes principales (ACP) (voir chapitres suivants).

Conclusion

Dans ce chapitre nous avons pu recueillir des données journalière et horaire de 6 stations pluviométriques, 6 stations hydrométriques, des données atmosphériques et des indices climatiques sur des périodes longues réparties sur l'ensemble du bassin hydrographique « Seybouse ». Le traitement des données, a permis de surpasser le problème des lacunes et d'homogénéiser les données étudiées. Le régime hydrométrique du bassin d'étude est caractérisé par une variabilité importante des écoulements journalière et horaire et cela sur le plan temporel et spatial.

La sélection appropriées des entrées a une grande importance sur la modélisation ou la prévision hydrologique afin d'obtenir des performances robustes. La base de données sera mise en application dans les chapitres suivants, afin de développer les différents modèles proposés.

CHAPITRE VI

**PRÉVISION DES DÉBITS JOURNALIERS PAR LE
MODÈLE GR4J ET LES MODÈLES RNA SOUS
DIFFÉRENTS PARAMÈTRES D'ENTRÉE
MÉTÉOROLOGIQUES.**

Introduction

La modélisation pluie-débit a suscité un intérêt croissant depuis quatre décennies dans la communauté des hydrologues. Parmi les très nombreux modèles proposés, des dizaines font partie de la classe des modèles conceptuels à réservoirs, qui nous intéressent particulièrement ici. Les modèles conceptuels, transforment la pluie en écoulement à l'exutoire d'un bassin par une modélisation mathématique, et des expressions comportant généralement un nombre assez élevé de paramètres qu'il faudra optimiser pour obtenir la réponse de ce bassin. Cependant cette optimisation est généralement influencée par le risque d'être bloqué par un optimum secondaire, c'est-à-dire un jeu de paramètres moins performant que le jeu idéal (Edijatno, 1991), d'où la nécessité d'établir un modèle avec un nombre de paramètres réduit. C'est dans ce contexte de simplicité que nous avons choisi dans un premier temps, d'aborder notre modélisation par un modèle Génie Rural (GR), qui est le modèle GR4j (modèle du Génie Rural à 4 paramètres Journalier) qui est l'avantage de n'exiger que des séries de données météorologiques (pluie, ETP) et hydrométrique (débit) au pas de temps journalier.

De l'autre côté, au cours des deux dernières décennies, Le réseau de neurones artificiels (RNA) s'est avéré être un modèle très nouveau et utile appliqué à la résolution de problèmes et à l'apprentissage automatique. Ainsi qu'il a montré des progrès significatifs dans la prédiction et la modélisation des applications hydrologiques non linéaires, telles que le processus pluie-débit, qui peuvent apporter une contribution utile à la planification et à la gestion des ressources en eau. Plusieurs recherches ont conclu que les RNA représentent des outils très utiles pour les modèles de prévision hydrologiques afin de combler les lacunes dans les données d'enquête. Cependant, plus nous disposons de données, plus nous pouvons réaliser des prévisions réalistes. De plus, certains articles ont montré la possibilité d'utiliser d'autres variables d'entrée que les précipitations afin d'augmenter les performances de RNA développées pour prédire le ruissellement. Ce chapitre prétend qu'un simple ajustement aux données d'entrée de RNA peut être effectué pour améliorer leurs performances dans la simulation de débit. Par exemple, le débit ne dépend pas seulement des précipitations totales, mais aussi d'autres paramètres météorologiques. Par conséquent, nous pensons que l'utilisation de l'évapotranspiration, de l'humidité, de la température et de la vitesse du vent comme paramètres d'entrée pour les RNA peut avoir un impact positif sur leurs performances.

L'objectif principal de ce chapitre dans un premier temps, est de simuler la transformation de la pluie en débit dans la zone semi-aride bassin de la Seybouse en utilisant le modèle conceptuel GR4J, ensuite, les modèles RNA avec différentes configurations d'entrée. Les données journalières moyennes de précipitation, de température, d'évapotranspiration potentielle, d'humidité, de vitesse

du vent et de débit, dérivées du bassin ont été utilisées pour développer tous les modèles proposés. Une variété de mesures d'évaluation de performance statistique et d'indicateurs de performance graphiques ont été utilisés pour valider tous les modèles étudiés.

VI.1. Mise en œuvre du modèle GR4J

VI.1.1. Initialisation du système

Les modèles conceptuels, notamment le GR4j permettent de simuler le comportement du bassin versant à travers des réservoirs censés reproduire le cycle hydrologique. Si la simulation par le modèle débute par une période très humide, il est indispensable d'initialiser les états initiaux de ces réservoirs, par des valeurs relativement élevées pour mieux rapprocher la valeur du débit calculé avec celle du premier débit observé (Benkaci, 2006). Une autre technique consiste à définir une période de mise en route du modèle, généralement une période n'excédant pas une année, et de tester le modèle après cette durée d'adaptation du modèle. Dans notre cas, on utilise la 2ème technique avec une période de mise en route d'une année entière.

VI.1.2. Application du modèle

Le calage du modèle concerne les paramètres X1, X2, X3, X4, il est réalisé à l'aide de la méthode d'optimisation Shuffled Complex Evolution "SCE-UA" en utilisant comme fonction objective le critère de Nash Sutcliffe (1970), cette opération est faite automatiquement par le logiciel EXCEL, en utilisant la fonction "solveur".

La méthode SCE-UA (Duan et al, 1992) est une méthode probabiliste multi-départ, basé sur le même principe des algorithmes génétiques. C'est derniers permettent de retenir d'une itération à la suivante des individus qui n'améliorent pas la qualité de la population totale, ce qui limite la convergence sur des optima locaux.

VI.1.3. Acquisition des données pour le modèle GR4J

La base de données utilisée dans la modèle GR4J, représente des ensembles journaliers de valeurs pluie-débit et d'évapotranspiration potentielle calculé par la formule d'Oudin (chapitre V).

Le tableau 6.1 présente la division des données en deux périodes pour effectuer l'opération de calage et validation du modèle.

CHAPITRE VI Pr vision des d bits journaliers par le mod le GR4J et les mod les RNA sous diff rents param tres d'entr e m t orologiques

Tableau 6.1. P riode de calage et validation des six stations d' tude.

	Moulin Rochefort	Medjez- Amar II	Bordj Sabath	Boucheouf	Mirebek	Ain Berda
Calage	1981–1985 1990–1994	1981–1988 1995–2002	1981–1992 2003–2015	1981–1985 1990–1995	1981–1985 1990–1995	1981–1986 1992–1997
Validation	1985–1990	1988–1995	1992–2003	1985–1990	1985–1990	1986–1992


VI.1.4. R sultats des mod les GR4J

Les r sultats du calage et de la validation des six stations d' tude sont pr sent s dans le tableau 6.2 et illustr s sur les figures 6.1.


Tableau 6.2. R sultats du calage et de la validation

		Moulin Rochefort	Medjez- Amar II	Bordj- Sabath	Boucheouf	Mirebek	Ain Berda
Calage	NSE (%)	39.3	13.6	15.9	59.4	36.2	61.1
	Bilan (%)	50.1	104.7	109	81.8	77.6	110.7
Validation	NSE (%)	22	3.8	3.3	56.9	64.8	73.5
	Bilan (%)	66.5	139.6	79.2	138.3	83.2	110.4

Moulin Rochefort



Medjez-Amar II



Bordj-Sabath






Figure 6. 4. Hydrogrammes issu des simulations réalisées en phase de validation, à l’aide des modèles conceptuels GR4J au six stations d’étude.

Bouchegouf



Mirebek



Ain Berda




Figure 6. 5. Continue.

CHAPITRE VI Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques

D'après le tableau 6.2 et la figures 6.1, il apparaît nettement que le modèle GR4j a donné des mauvais résultats pour les six stations en phase de calage et validation. En effet, en phase de calage, les critères de Nash sont relativement inférieur à 60% pour toutes les stations, sauf Ain Berda (61%) et les bilans varient entre 50 et 110. En phase de validation, le NSE sont aussi inférieur à 60% pour toutes les stations, sauf Mirebek et Ain Berda (64.8% et 73.5, respectivement) et les bilans varient entre 66% et 139%.

Les très mauvais résultats obtenues par les modèles conceptuels à réservoirs GR4J ainsi que leurs faible pouvoir prédictive, nous oriente a pensée a d'autre méthodes de modélisation afin d'améliorer les performance des résultats. L'application des méthodes d'intelligence Artificiel apparait comme un outil très nouveau et utile à la résolution de problèmes non linéaire en hydrologie. C'est dans ce contexte, que nous allons développer d'autre modèles basées sur les données, notamment les réseaux de neurones artificiels (RNA) autonome et hybride et les réseaux de neurones convolutifs (CNN) (voir chapitre suivants).

VI.2. Mise en œuvre du modèle RNA

Les résultats précédents ont montré la nécessité d'améliorer les performances de modélisation. Pour cela, nous avons dans cette partie d'appliquer les RNA avec différents configurations d'entrée.

VI.2.1. Acquisition des données pour le modèle RNA

La base de données utilisée ici pour le développement des modèles RNA, est constituée des valeurs journaliers de pluie-débit et de variables météorologiques (évapotranspiration, humidité, température et vitesse du vent). Les séries chronologiques ont été collectées à partir de la base de données disponible à l'ANRH, l'ONM en Algérie, et à partir du site de POWER Data Access Viewer v2.0.0.

Pour appliquer la modélisation sur une série temporelle, la série de données doit être divisée en trois parties ; 70 % pour l'apprentissage, 15 % pour la validation et 15 % pour le test. Après plusieurs séries d'apprentissage de RNA pour trouver le réseau qui correspond à la plus petite erreur et aux plus grandes valeurs de performance, un test final est établi pour confirmer la sélection du réseau. Il s'agit d'utiliser une autre base de données de la même station (qui n'est pas utilisée ni dans l'apprentissage, la validation, ou le test du réseau) et de calculer l'erreur absolue moyenne MAE en appliquant le réseau choisi (plus de détails dans la partie résultats et discussion). Le tableau 6.3 présente les ensembles de données des différentes stations d'étude utilisées pour l'apprentissage, la validation et le test de RNA, ainsi que les données utilisées pour le test MAE.

CHAPITRE VI **Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques**

Tableau 6. 3. Subdivision des données pour les stations d'étude.

Station	Période d'observation des données utilisées pour l'apprentissage, la validation et le test de RNA	Période d'observation des données utilisées pour le test MAE
Moulin Rochefort	(1981–1985) et (1990–1994)	1985–1990
Medjez-Amar II	(1981–1988 et (1995–2002)	1988–1995
Bordj-Sabath	(1981–1992) et (2003–2015)	1992–2003
Bouchegouf	(1981–1985) et (1990–1995)	1985–1990
Mirebek	(1981–1985) et (1990–1995)	1985–1990
Ain Berda	(1981–1986) et (1992–1997)	1986–1992

VI.2.2. Sélection des variables d'entrée par l'essai et l'erreur

Le choix des variables d'entrée constitue une phase importante qui conditionne la performance des résultats de la modélisation par les méthodes de l'intelligence artificielle. Nous nous sommes proposés dans ce chapitre de procéder à un choix préalable des variables d'entrée en appliquant plusieurs configurations d'entrées pour les modèles de RNA en utilisant la procédure d'essai et d'erreur permettant une sélection optimale des entrées.

La méthode d'essais et d'erreur est une méthode de résolution de problèmes dans laquelle plusieurs tentatives sont faites pour parvenir à une solution. L'essai et l'erreur se caractérise par des tentatives répétées et variées qui se poursuivent jusqu'au succès ou jusqu'à ce que le pratiquant cesse d'essayer.

VI.2.3. Développement de modèles RNA

Toutes les procédures d'apprentissage et de test des RNA ont été menées à l'aide du logiciel 'MATLAB R2018b' qui est acheté avec sa plateforme complète et ses licences. Les RNA ont été développés premièrement pour chaque sous-bassin, où les stations de jaugeage mentionnées précédemment sont réparties régulièrement dans la région d'étude, ensuite, pour l'ensemble du bassin.

Quatre configurations différentes ont été considérées. Le premier consistait en un développement classique (modèle à entrée unique), qui est un RNA estimant le débit quotidien à partir d'une seule variable d'entrée pertinente exclusivement liée aux totaux précipités (RNA I_p). Le deuxième type était toujours un RNA estimant le débit journalier, mais ses variables d'entrée comprenaient les précipitations et l'une des variables météorologiques (modèle à deux entrées), par conséquent quatre sous-modèles à deux entrées ont été développés (RNA $II_{p,ETP}$, RNA $II_{p,T}$, RNA $II_{p,HUM}$,

RNA $II_{P,V}$). Le troisième type était un RNA qui utilise trois variables d'entrée liées aux précipitations, à la température et à l'humidité pour estimer le débit journalier (RNA $III_{P,T,HUM}$). Enfin, la quatrième et la dernière configuration consiste à développer un RNA avec cinq variables d'entrée (précipitations, évapotranspiration, température, humidité et vitesse du vent) pour estimer plus précisément le débit journalier (RNA $V_{P,ETP,T,HUM,V}$). Le but derrière l'application de ces différentes configurations, est de trouver la meilleure combinaison d'entrée pour les modèles développées afin de trouver des résultats fiables. La modélisation des différentes configurations est activée, une fois les données saisies et le réseau créé avec son architecture complète (type, structure, fonction, couches, neurones). La structure du RNA développée dans cette recherche était Perceptron multi couches (PMC) 'Multi layer Perceptron MLP' avec un algorithme de rétro-propagation, tandis que le nombre de neurones dans la couche intermédiaire était de 30. La fonction d'activation utilisée dans ce type de réseau pour générer la sortie (Q) du nœud, est le sigmoïde tangent (Eq. 6.1) dont les performances sont meilleures que le sigmoïde logistique selon les résultats de (Rezaeianzadeh et al., 2013b). L'apprentissage de RNA utilise l'algorithme de Levenberg-Marquardt,

$$f(Sj) = \frac{2}{(1+e^{-2Sj})} - 1 \quad (6.1)$$

VI.2.4. Résultats des modèles RNA

Afin de mieux apprécier les performances et la robustesse des modèles développés, et donc leur pouvoir prédictif, nous présentons ci-dessous les résultats en termes de statistiques de performances de tous les modèles de RNA appliqués aux six stations étudiées. Le premier modèle, qui consiste en un développement classique pour estimer le débit journalier, utilise une seule entrée (base de données des précipitations en entrée). Différents scénarios de RNA ont été formés en faisant varier les nœuds de la couche intermédiaire. Pour chaque scénario de RNA, le réseau a été formé. La session d'entraînement a été interrompue après chaque itération pour vérifier l'erreur de performance (MSE) déterminée pour les phases d'entraînement et de test. L'apprentissage a été finalisée dans l'itération qui faisait référence à l'erreur de réseau la plus faible calculée à l'aide de l'échantillon de validation. Le modèle de RNA final a été sélectionné sur la base des critères de performances maximales possibles trouvés pour un nombre de nœuds de la couche intermédiaire égal à 30. Une fois le réseau est sélectionné, une dernière vérification confirme les performances du modèle choisi. Elle consiste à appliquer le Réseau trouvé, à un autre échantillon de précipitation P enregistré de la même station pour définir une nouvelle variable y où $y = \text{réseau (P')}$, puis à calculer l'erreur absolue moyenne (MAE) entre cette variable et l'échantillon de débit Q : $MAE = \text{mean2}(\text{abs}(y - Q))$. Cette erreur doit être minimale pour confirmer notre sélection et avoir un bon réseau. Les valeurs des indicateurs de performance de RNA I_p les plus efficaces pour chacune des

six stations étudiées, sont présentées dans le tableau 6.4. D'après le tableau, on constate que les résultats obtenus pour la station Medjez-Amar II sont très satisfaisants ; un critère NSE est supérieur à 88 % et un très fort coefficient de corrélation de Pearson varie de 0,91 à 0,96 dans les phases d'apprentissage, de validation et de test de RNA I_P. Même le MAE calculé entre les deux échantillons restants de (P et Q) confirme l'efficacité de ce modèle avec une valeur minimale de 0,74. Cependant, les résultats de ce modèle (entrée unique) pour la station d'Ain Berda sont très mauvais par rapport aux autres stations NSE < 60 % et R = 0,77. Les résultats des autres stations sont satisfaisants (un bon NSE varie entre 66 et 83 et un très fort R entre 0,81 à 0,91).

Tableau 6. 4. Indices statistiques du modèle à entrée unique (RNA I_P) appliqués aux six stations hydrométriques réparties dans le bassin de la Seybouse.

Critères de performance			Station de jaugeage					
			Moulin Rochefort	Medjez-Amar II	Bordj-Sabath	Bouchegouf	Mirebek	Ain Berda
RNA I _P	<i>R</i> <i>Pearson</i>	Apprentissage	0.80	0.94	0.90	0.80	0.87	0.73
		validation	0.85	0.96	0.94	0.95	0.85	0.87
		test	0.78	0.91	0.93	0.93	0.71	0.86
		all	0.81	0.93	0.91	0.87	0.86	0.77
	<i>NSE</i>		66.1	88.2	83.2	77.1	74.7	59.9
	<i>RMSE</i>		0.05	0.40	0.52	0.51	0.16	1.04
	<i>MAE</i>		0.04	0.74	0.59	0.3	0.14	0.61

La combinaison d'un autre paramètre d'entrée et des précipitations améliore les performances des modèles de RNA précédents, quel que soit le paramètre d'entrée utilisé (évapotranspiration ETP, température T, humidité HUM ou vitesse du vent V_v). Pour la station du Moulin Rochefort, l'utilisation de l'humidité comme 2e variable d'entrée a donné de bons résultats (NSE = 68,5 % et R = 0,82) par rapport aux modèles utilisant l'évapotranspiration (ETP), la température (T) ou la vitesse du vent (V_v), tandis que pour la station de Bordj-Sabath, l'utilisation de la vitesse du vent a donné de meilleurs résultats (NSE = 88 % et R = 0,93). L'influence de la température était la plus dominante dans les autres stations. Par conséquent, l'utilisation de ce paramètre météorologique à ces stations a montré plus d'influence sur les oscillations quotidiennes du débit. La station d'Ain Berda, qui donnait des résultats peu satisfaisants dans le modèle précédent, a été améliorée avec le modèle RNA I_{P,T} avec un bon NSE (74 %) et un très fort coefficient de Pearson (0,86). L'amélioration dans les stations restantes était encore meilleure. Les résultats sont inclus dans le tableau 6.5.

CHAPITRE VI *Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques*

Tableau 6. 5. Indices statistiques des modèles à deux entrées (RNA II_{P,ETP}, RNA II_{P,T}, RNA II_{P,HUM}, RNA II_{P,Vv}).

Critères de performance			Station de jaugeage					
			Moulin Rochefort	Medjez- Amar II	Bordj- Sabath	Bouchegouf	Mirebek	Ain Berda
RNA II _{P,ETP}	<i>R</i> <i>Pearson</i>	Apprentissage	0.81	0.93	0.91	0.87	0.91	0.81
		Validation	0.91	0.97	0.93	0.95	0.80	0.81
		Test	0.77	0.96	0.96	0.90	0.72	0.90
		All	0.82	0.95	0.93	0.89	0.88	0.83
	NSE		67.4	90.7	86.5	80.5	78.9	69.2
	<i>RMSE</i>		0.04	0.35	0.46	0.47	0.15	0.91
	<i>MAE</i>		0.03	0.67	0.40	0.31	0.13	0.94
RNA II _{P,T}	<i>R</i> <i>Pearson</i>	Apprentissage	0.83	0.95	0.92	0.86	0.91	0.84
		Validation	0.83	0.92	0.94	0.95	0.87	0.88
		Test	0.72	0.97	0.93	0.90	0.81	0.90
		All	0.82	0.95	0.93	0.89	0.90	0.86
	NSE		67.9	91.5	86.6	80.7	81.5	74.1
	<i>RMSE</i>		0.04	0.34	0.46	0.47	0.14	0.84
	<i>MAE</i>		0.03	0.76	0.18	0.22	0.12	0.53
RNA II _{P,HUM}	<i>R</i> <i>Pearson</i>	Apprentissage	0.83	0.92	0.93	0.88	0.91	0.84
		Validation	0.85	0.96	0.92	0.80	0.81	0.90
		Test	0.71	0.98	0.90	0.92	0.74	0.90
		All	0.82	0.95	0.92	0.88	0.89	0.85
	NSE		68.5	91	86	77.6	80.6	73.6
	<i>RMSE</i>		0.04	0.35	0.47	0.51	0.14	0.85
	<i>MAE</i>		0.03	0.69	0.56	0.29	0.15	0.56
RNA II _{P,Vv}	<i>R</i> <i>Pearson</i>	Apprentissage	0.82	0.93	0.93	0.83	0.89	0.80
		Validation	0.77	0.90	0.96	0.95	0.72	0.87
		Test	0.84	0.98	0.90	0.92	0.76	0.84
		All	0.81	0.95	0.93	0.88	0.87	0.83
	NSE		67	90.6	88	78.7	76.7	69.8
	<i>RMSE</i>		0.04	0.35	0.43	0.5	0.15	0.91
	<i>MAE</i>		0.04	0.85	0.68	0.33	0.14	0.87

CHAPITRE VI Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques

Étant donné que les modèles à deux entrées de RNA II_{P,T} et RNA II_{P,HUM} ont fourni de meilleurs résultats par rapport aux autres modèles, la combinaison de la température et de l'humidité avec les précipitations a été utilisée pour former un réseau à trois entrées (RNA III_{P,T,HUM}). Les résultats ont montré des améliorations des critères de performance pour les stations de Moulin Rochefort (NSE = 70 % et R = 0,83) et de Bouchegouf (NSE = 84 % et R = 0,91), tandis que les stations restantes ont montré une détérioration de leur performance par rapport aux modèles à deux entrées. Les résultats sont présentés dans le tableau 6.6.

Tableau 6. 6. Indices statistiques des modèles à trois entrées (RNA III_{P,T,HUM}).

Critères de performance			Station de jaugeage					
			Moulin Rochefort	Medjez-Amar II	Bordj-Sabath	Bouchegouf	Mirebek	Ain Berda
RNA III _{P,T,Hu}	R <i>Pearson</i>	Training	0.83	0.95	0.91	0.92	0.91	0.82
		Validation	0.79	0.80	0.92	0.82	0.72	0.91
		Test	0.86	0.83	0.89	0.94	0.80	0.91
		all	0.83	0.93	0.90	0.91	0.89	0.85
	NSE		70	88.2	81.4	84	80.5	72
	RMSE		0.04	0.40	0.54	0.43	0.14	0.87
	MAE		0.04	0.75	0.51	0.29	0.12	0.55

Pour optimiser les modèles neuronaux pour les différentes stations, nous avons décidé de combiner avec les précipitations les quatre paramètres météorologiques (ETP, T, HUM et Vv) utilisés séparément dans les modèles précédents. Ainsi, un réseau de cinq variables d'entrée a été créé. Le modèle RNA V_{P,ETP,T,HUM,Vv} développé pour chaque station a été optimisé et comparé aux autres modèles (modèle à une entrée RNA I_p, modèle à deux entrées RNA II et modèle à trois entrées RNA III_{P,T,HUM}). Les résultats présentés dans le tableau 4.5 indiquent une amélioration notable des performances du réseau neuronal. En effet, dans la plupart des stations étudiées, nous avons obtenu une augmentation considérable des critères de performance par rapport aux modèles discutés ci-dessus (par exemple pour la station d'Ain Berda, le critère NSE a augmenté à 82 % et le coefficient de Pearson à 0,9). Les résultats obtenus par ce modèle sont très satisfaisants ce qui prouve son bon fonctionnement. (Randrianarivony et al., 2010b) ont montré que plus les données d'entrée du réseau neuronal sont disponibles, les prédictions sont plus proches des valeurs réelles et les modèles sont plus efficaces.

CHAPITRE VI Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques

Tableau 6. 7. Indices statistiques du modèle à cinq entrées (RNA $V_{P,ETP,T,HUM,Vv}$).


Critère de performance			Station de jaugeage					
			Moulin Rochefort	Medjez- Amar II	Bordj- Sabath	Bouchegouf	Mirebek	Ain Berda
RNA $V_{P,ETP,T,HUM,Vv}$	<i>R</i> <i>Pearson</i>	Apprentissage	0.84	0.93	0.92	0.93	0.93	0.90
		validation	0.83	0.97	0.81	0.88	0.88	0.88
		test	0.89	0.97	0.95	0.93	0.87	0.88
		all	0.85	0.95	0.92	0.93	0.92	0.90
	NSE		72.9	90.8	85	86.6	85.1	82
	<i>RMSE</i>		0.04	0.35	0.49	0.39	0.12	0.70
	<i>MAE</i>		0.04	1.08	0.46	0.25	0.13	0.88

Le modèle à cinq entrées n'est pas nécessaire pour les stations Medjez-Amar II et Bordj-Sabath (voir résultats des tableaux 6.5 et 6.7). Par conséquent, le développement de deux modèles à deux entrées (RNA $II_{P,T}$ et RNA $II_{P,Vv}$) pour ces stations, respectivement, est très suffisant pour obtenir de très bons résultats. Tandis que le modèle RNA $V_{P,ETP,T,HUM,Vv}$ a montré de très bons résultats dans les autres stations. La [figure 6.3](#) (A_I, B_I, C_I, D_I, E_I, F_I) montre un alignement de nuage de points approchant la ligne $y = x$ à 45° pour toutes les stations de jaugeage. On constate un très bon chevauchement entre les valeurs de débits estimés et observés dans les phases d'apprentissage, de validation et de test pour toutes les stations de bassin ([figure 6.3](#) A_{II}, B_{II}, C_{II}, D_{II}, E_{II}, F_{II}).

Ces indicateurs de performance graphiques confirment l'efficacité des modèles RNA $II_{P,T}$ et RNA $II_{P,Vv}$ pour Medjez-Amar II et Bordj-Sabath respectivement, et RNA $V_{P,ETP,T,HUM,V}$ pour le reste de stations.


Moulin Rochefort

RNA V



Medjez-Amar II

RNA II_{P,T}



Bordj-Sabath

RNA II_{P,VV}






Figure 6. 6. Courbe de convergence des modèles de RNA V, RNA II_{P,T} et RNA II_{P,VV} dans les six stations d'étude.

Bouhegouf



Mirebek



Ain Berda




Figure 6. 7. Continue.

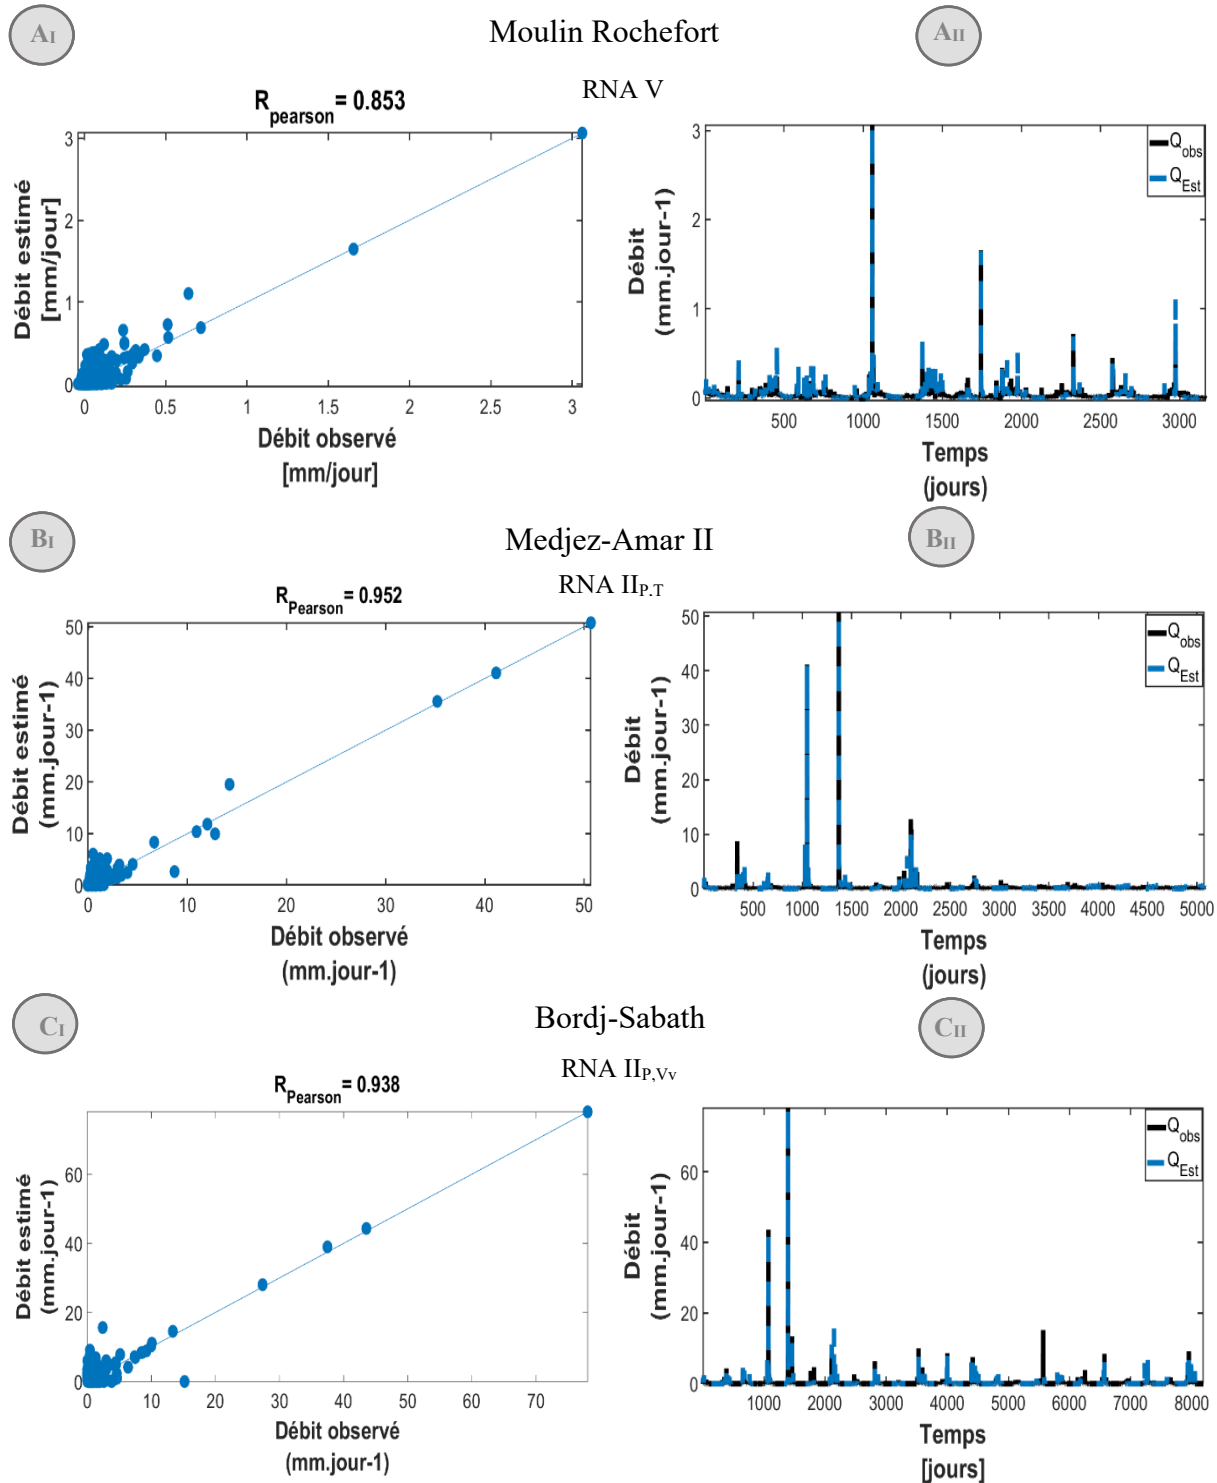


Figure 6.3. Comparaison des débits observés et estimés pour les modèles de RNA V, RNA II_{p,T} RNA II_{p,Vv} dans les six stations d'étude; Q_{obs} = débit observé, Q_{Est} = débit estimé.

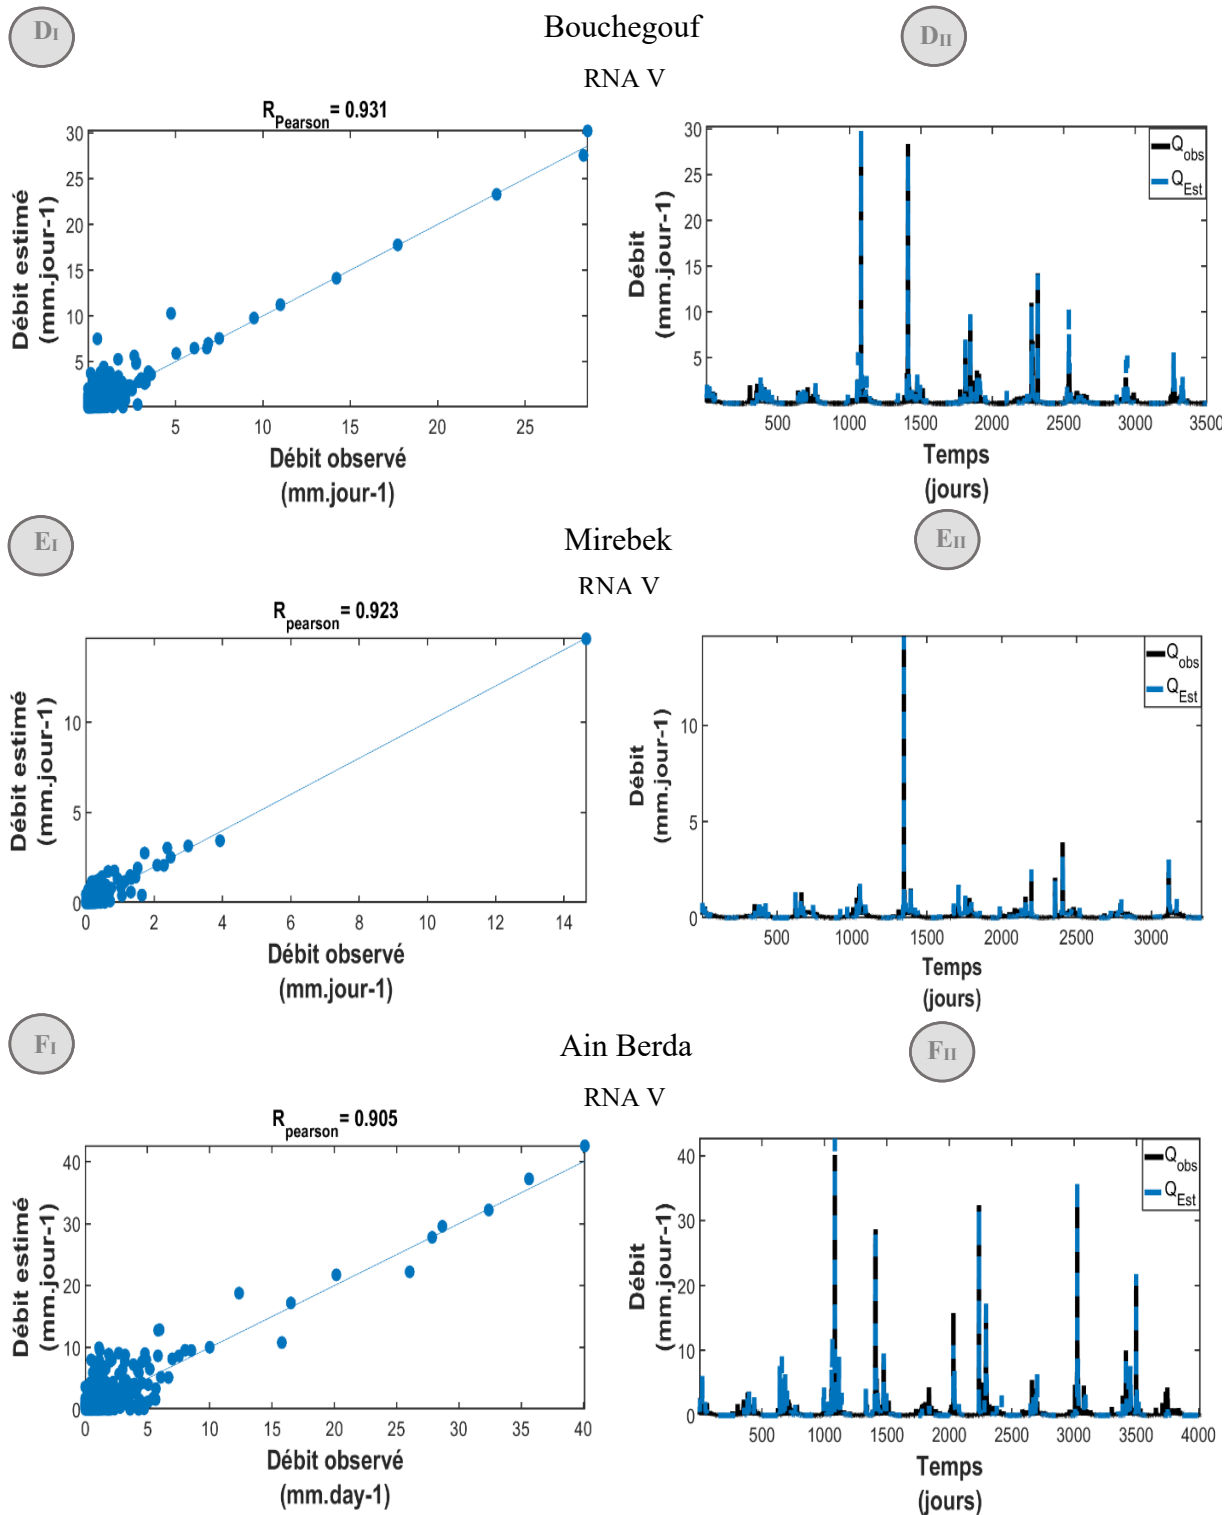


Figure 6.3. Continue.

MODÈLES de RNA POUR L'ENSEMBLE DU BASSIN

La modélisation des débits dans six stations réparties dans tout le bassin, ainsi que les bons résultats produits par la plupart des modèles, nous ont incités à proposer une modélisation pour l'ensemble du bassin. Pour cela, nous avons rassemblé des bases de données pour toutes les stations afin d'établir les différents modèles décrits ci-dessus (modèle à entrée unique, à deux entrées, à trois entrées et à cinq entrées). Pour le premier modèle (entrée unique), la variable d'entrée était un regroupement des données de précipitations des six stations utilisées pour estimer le débit quotidien pour l'ensemble du bassin. Comme expliqué ci-dessus, avant de commencer l'apprentissage de RNA, l'ensemble des données recueillies (P et Q des différentes stations) pour former l'ensemble de l'échantillon a été divisé en trois parties comme suit : 70 % pour l'apprentissage, 15 % pour la validation croisée, et 15 % pour le test. Les autres modèles à entrées multiples ont été développés de la même manière, c'est-à-dire que la base de données météorologiques a été utilisée comme variables d'entrée combinées aux précipitations, après avoir collecté toutes les données des stations. Les critères de performance des différents modèles appliqués dans le bassin sont présentés dans le tableau 2.8. Le modèle avec une seule entrée a donné de bons résultats (NSE = 77% et R = 0,88).

Le deuxième paramètre d'entrée a amélioré les résultats obtenus (quelle que soit la variable météorologique utilisée, y compris ETP, T, HUM et Vv. Tous ont fourni des résultats presque très proches, avec NSE de 77 à 79% et R de 0,88 à 0,89. Le modèle à trois entrées (combinaison de la température et de l'humidité avec les précipitations) a également amélioré les résultats par rapport au modèle à entrée unique. Cependant, ses résultats étaient très proches de ceux du modèle à deux entrées. Nous avons décidé d'améliorer l'efficacité des modèles de réseaux de neurones et avons utilisé le modèle à cinq entrées. Le modèle a généré des résultats très satisfaisants (NSE = 83% et coefficient de corrélation de Pearson 0,9) pour les indicateurs de performance graphiques [figure 6.4 et 6.5](#), les valeurs de débit estimées et observées se chevauchant presque, et l'alignement du nuage de points approchait de la ligne $y = x$ à 45°.

Tableau 6.8. Indices statistiques des modèles appliqués pour l'ensemble du bassin de la Seybouse.

Critères de performance		Valeurs pour le modèle RNA						
		RNA I _P	RNA II _{P,ETP}	RNA II _{P,T}	RNA II _{P,HUM}	RNA II _{P,Vv}	RNA III _{P,T,HUM}	RNA V _{P,ETP,T,HUM,Vv}
<i>R</i> <i>Pearson</i>	Apprentissage	0.86	0.87	0.87	0.90	0.88	0.88	0.91
	Validation	0.92	0.90	0.90	0.86	0.89	0.91	0.87
	test	0.90	0.89	0.90	0.84	0.88	0.85	0.90
	all	0.88	0.88	0.88	0.89	0.88	0.88	0.91
NSE		77.9	77.7	78.4	79.4	78.2	79	83
RMSE		0.69	0.69	0.68	0.66	0.68	0.67	0.60
MAE		0.49	0.47	0.46	0.47	0.46	0.46	0.49




Figure 6. 4. Nuage de points pour le modèle de RNA V_{P,ETP,T,HUM,Vv} en phase d'apprentissage, de validation et de test.

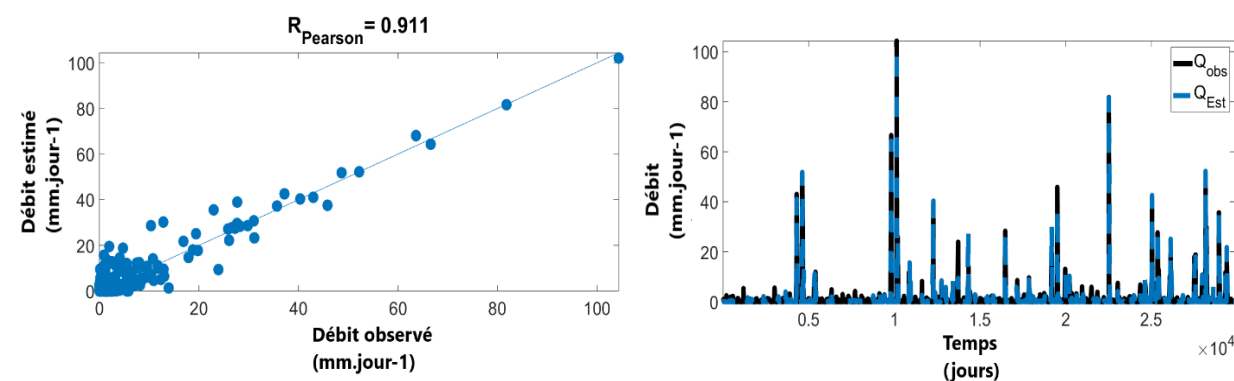


Figure 6. 5. Comparaison des débits observés et estimés pour le modèle de RNA V_{P,ETP,T,HUM,Vv} du bassin de la Seybouse.

CHAPITRE VI Prévision des débits journaliers par le modèle GR4J et les modèles RNA sous différents paramètres d'entrée météorologiques

Les résultats trouvés dans cette partie montrent le dépassement d'efficacité des modèles RNA pour les quatre configurations sur les modèles GR4J. Les comparaisons des réseaux de neurones avec d'autres modèles, conceptuels ou physiques, apportent la preuve que les RNA peuvent fournir des prévisions aussi meilleures que les approches plus "classiques", (Hsu et al, 1995).

Conclusion

Dans l'optique de mieux apprécier la performance et la robustesse des modèles conceptuels GR4j ainsi que leur pouvoir prédictif, son application pour la modélisation des débits sur six stations réparties dans le bassin de Seybouse a été établie. Cependant les résultats obtenus par ces modèles sont décourageants, ce qui nous incite à changer l'axe d'application vers les modèles boîte noire notamment les RNA dans un premier temps.

L'objectif d'application des modèles boîte noire était la recherche des meilleurs modèles de RNA pour la prévision des débits journaliers. Initialement, les modèles de RNA ont été développés pour six sous-bassins, puis pour l'ensemble du bassin versant, en considérant quatre configurations d'entrée différentes. Le 1^{er} (RNA I_p) considère uniquement les précipitations comme variable d'entrée pour la simulation du débit journalier. La 2^e (RNA II) considère le 2^e variable dans l'entrée du modèle avec les précipitations ; c'est un des paramètres météorologiques (évapotranspiration, température, humidité ou vitesse du vent). La troisième (RNA III_{p,T,HUM}) considère une combinaison de température, d'humidité et de précipitations. La dernière (RNA V_{p,ETP,T,HUM,vv}) consiste à collationner différents paramètres météorologiques avec les précipitations comme variable d'entrée. Les modèles RNA sont développés pour l'ensemble du bassin avec les mêmes configurations que celles précisées ci-dessus. De meilleures simulations d'écoulement ont été fournies par (RNA II_{p,T}) et (RNA II_{p,vv}) pour les deux stations de Medjez-Amar II et Bordj-Sabath, respectivement. Cependant, l'application de (RNA V_{p,ETP,T,HUM,vv}) pour les autres stations et également pour l'ensemble du bassin reflète une stratégie de simulation d'écoulement et montre une amélioration de la précision de la prédiction par rapport aux autres modèles étudiés.

Une comparaison faite entre les performances des modèles neuronaux et le modèle GR4j montre que les quatre configurations du modèle neuronal sont plus performantes que le modèle GR4j pour les six stations. L'application des modèles RNA sous différents paramètres d'entrée météorologiques dans la modélisation des débits journaliers et les très bons résultats obtenus, nous motivent de penser d'ajouter des algorithmes d'optimisation au modèle RNA et modéliser les débits sans utiliser les paramètres météorologiques. Ensuite, élargir encore le cercle de recherche vers d'autres types de modèles d'apprentissage profond qui sont les réseaux de neurones convolutifs (CNN). Que nous allons les traiter dans les chapitres qui suivent.

CHAPITRE VII

**PRÉVISION DES DÉBITS JOURNALIERS PAR LES
MODÈLES HYBRIDES RNA.**

Introduction

Le réseau de neurones artificiels s'avère efficace parmi d'autres techniques d'apprentissage automatique. Récemment, plusieurs outils heuristiques conventionnels ont été créés pour faciliter la résolution de problèmes d'optimisation difficiles et obtenir les paramètres de RNA optimaux en entraînement ; afin d'augmenter son efficacité. Parmi ces outils : l'algorithme génétique (GA), l'optimisation d'essaim de particules (PSO) et l'algorithme de luciole (FFA) etc. Conjointement avec les techniques d'intelligence, GA est devenue une méthode puissante de modélisation et d'optimisation de processus complexes, elle est utilisée comme amplificateur de paramètres de RNA pour améliorer l'efficacité du modèle. PSO, est plus facile à mettre en œuvre que GA. Il pourrait également être utilisé pour optimiser des systèmes irréguliers et non linéaires et résoudre des problèmes complexes avec une grande vitesse de convergence vers la solution idéale. De plus, PSO pourrait être impliqué en tant qu'algorithme d'entraînement pour le modèle RNA. FFA une approche d'optimisation relativement récente, simple avec un fort potentiel pour converger plus rapidement vers des solutions optimales que d'autres techniques intelligentes. Enfin, la nouvelle version de l'algorithme PSO qui est le PSO amélioré (IPSO) pourrait résoudre des problèmes d'optimisation de combinaisons multi-objectifs dans de nombreuses recherches.

L'objectif principal de ce chapitre est d'étudier la capacité de RNA-IPSO à modéliser la relation pluie-débit dans la Seybouse afin de fournir une méthode efficace pour résoudre un problème hydrologique aussi complexe. Afin d'évaluer la fiabilité de l'IPSO dans l'amélioration de l'efficacité de RNA, cette méthode a été comparée aux trois autres optimiseurs métaheuristiques évolutifs mentionnées ci-dessus, GA, PSO et FFA en s'intégrant dans le RNA en tant qu'algorithme d'entraînement. Dans le but d'identifier l'algorithme d'entraînement de RNA le plus puissant, la précision des modèles hybrides a été évaluée et comparée à l'aide de mesures de performance et analyse graphique.

VII.1. Acquisition des données

La base de données compilée de deux paramètres les plus mesurés du cycle hydrologique, précipitations (P) et débit fluvial (Q) dans les six stations réparties sur le bassin d'étude a été appliquée pour simuler la relation pluie-débit. L'ensemble de ces données ont été acquises auprès de l'ANRH d'Alger.

Comme mentionné au chapitre précédent, dans le but de faire évoluer le modèle, la première étape consiste à diviser les données en différentes catégories pour l'apprentissage et les tests d'efficacité du modèle. L'objectif principal d'une telle étape est de s'assurer que le modèle fonctionne avec un degré constant de précision ; au cas où il connaîtrait des données invisibles au lieu de s'entraîner.

Selon (Gholamy et al., 2018), les meilleurs résultats sont obtenus si nous attribuons 20 à 30 % des points de données d'origine pour les tests et utilisons les 80 à 70 % restants pour l'entraînement. Pour cette division, nous obtenons des estimations de précision qui sont : valide - dans le sens où ils ne surestiment pas l'exactitude (c'est-à-dire qu'ils ne sous-estiment pas l'erreur d'approximation), et sont les plus précises parmi les estimations valides - c'est-à-dire que leur surestimation de l'erreur d'approximation est le plus petit possible. Dans ce contexte, les données utilisées dans cette section pour les six stations d'étude ont été classées en deux parties principales (tableau 7.1) ; la première pour entraîner les modèles avec 80% des données collectées et la seconde pour tester les modèles calibrés avec 20% des données et examiner leurs performances.

Tableau 7. 1. Classement des données pour les six stations d'étude.

Station	Location		80% Apprentissage	20% test
	X	Y		
Moulin Rochefort	7,224093	36,374004	1974-1990	1990-1994
Medjez-AmarII	7,310283	36,444445	1981-1998	1998-2002
Bordj-Sabath	7,037219	36,418058	1980-2008	2008-2015
Bouhegouf	7,709725	36,45944	1980-1992	1992-1995
Mirebek	7,750935	36,583701	1981-1992	1992-1995
Ain Berda	7,596389	36,691941	1977-1993	1993-1997

L'ensemble de données d'entrée x^* a été normalisé dans l'intervalle [0.1, 0.9], Eq. (7.1):

$$0.1 + \frac{0.8(x-x_{min})}{(x_{max}-x_{min})} \quad (7.1)$$

où : x est les données historiques, x_{min} et x_{max} sont respectivement les valeurs minimale et maximale.

VII.2. Sélection des entrées par ACF, PACF et CCF

Le développement d'un modèle de prévision des débits des cours d'eau est d'une importance capitale pour différents domaines de l'ingénierie des ressources en eau. L'un des principaux facteurs contribuant à la fiabilité de la modélisation et la performance des résultats y afférant, est l'optimisation des variables d'entrée. Cette étape est considérée comme un défi pour les modélisateurs. Il est donc crucial de développer une méthode capable de déterminer les combinaisons d'entrée optimales. Cette étude présente l'utilisation des fonctions d'autocorrélation, d'autocorrélation partielle et de corrélation croisée (ACF, PACF et CCF), afin de trouver une meilleure sélection des combinaisons des variables d'entrée.

L'ACF est une méthode classique de sélection des caractéristiques statistiques dans l'analyse des séries temporelles, qui peut être une technique puissante pour la prévision, car l'ACF peut détecter la corrélation linéaire d'une série chronologique entre le temps t et $t - k$ (Koprinska et al., 2015). L'ACF mesure le degré de corrélation linéaire entre les observations d'une série temporelle qui sont séparées par un décalage k . Le PACF aide à déterminer le nombre de termes autorégressifs nécessaires pour révéler la saisonnalité de la série ou pour révéler la tendance au niveau de la moyenne ou de la variance de la série. Le graphique de la fonction d'autocorrélation (ACF) est appelé corrélogramme. L'idée principale de l'ACF est de calculer le coefficient de corrélation entre la série et la série elle-même avec un décalage de retard k . Une corrélation élevée est sélectionnée comme variable d'entrée, ce qui signifie que les variables qui n'ont pas un coefficient de corrélation significatif sont éliminées du vecteur d'entrée. L'identification peut être faite en traçant le diagramme de la fonction d'autocorrélation. La fonction de corrélation croisée peut être utile pour mieux comprendre la relation entre deux séries chronologiques (Ex, les précipitations et le débit des cours d'eau) ainsi que pour tester l'ensemble de données. L'approche consiste à calculer l'autocorrélation des précipitations et la corrélation croisée de débit avec les précipitations. La [figure 7.1](#) présentent les tracés ACF et PACF des séries de débit journalier des six stations d'étude et CCF entre le débit et les précipitations à divers décalages avec la limite de confiance de 95%.

Pour cette section, un scénario d'entrée a été appliqué aux quatre modèles hybrides de RNA, basés sur ces fonctions qui ont été utilisés pour identifier le nombre des décalages effectifs des précipitations et des débits. Ces méthodes ont été proposées par plusieurs recherches (Yaseen et al., 2019, Adnan et al., 2020; Hadi et al., 2019; Ö. Kisi, 2008; Sudheer et al., 2002) pour déterminer les entrées optimales pour les modèles basées sur les données. Le tableau 7.2 liste les valeurs de ACF, PACF et CCF des six stations étudiées. Le CCF indique que les précipitations au temps t et un décalage sont considérablement efficaces sur le débit par rapport aux précipitations pour deux et trois décalages, tandis que les autres décalages sont tombés dans la limite de confiance. Par conséquent, P_{t-1} a été considéré comme l'un des paramètres inclus dans le scénario d'entrée utilisé dans les modèles développés. De plus, le PACF dans toutes les stations indique que le premier décalage de débit a un effet considérable, et que les deuxième et troisièmes décalages sont très proches de la limite de confiance (mais pour la station « Bordj-Sabath », les décalages Q_{t-2} , Q_{t-3} sont dans la limite de confiance *). Par conséquent, ces deux entrées ont été ignorées. Comme les précipitations au-delà du 2e décalage n'affectent pas vraiment le débit à l'instant t , de même que le débit n'est pas efficace au-delà du même décalage. Par conséquent, la combinaison d'entrées considérée pour le scénario utilisé dans cette recherche pour modéliser le processus pluie-débit est composée de P_t , P_{t-1} et Q_{t-1} pour simuler la sortie Q_t .

Tableau 7. 2. Valeurs d'autocorrélation, d'autocorrélation partielle et de corrélation croisée des données utilisées.

Ensemble de variables	Séries chronologiques	Ensemble de données complètes pour les différentes stations hydrométrique					
		Moulin Rechfort	Medjez-Amar II	Bordj-Sabath	Bouchegouf	Mirebek	Ain Berda
Autocorrélation	$Q_t_Q_{t-1}$	0.38	0.58	0.46	0.57	0.52	0.50
	$Q_t_Q_{t-2}$	0.22	0.29	0.21	0.26	0.42	0.34
	$Q_t_Q_{t-3}$	0.18	0.10	0.08	0.22	0.38	0.26
Autocorrélation partielle	$Q_t_Q_{t-1}$	0.38	0.58	0.46	0.57	0.52	0.48
	$Q_t_Q_{t-2}$	0.09	-0.07	*	-0.10	0.20	0.12
	$Q_t_Q_{t-3}$	0.08	-0.05	*	0.17	0.14	0.07
Corrélation croisée	$Q_t_P_{t-1}$	0.22	0.42	0.28	0.36	0.25	0.30
	$Q_t_P_{t-2}$	0.10	0.21	0.13	0.19	0.14	0.17
	$Q_t_P_{t-3}$	0.08	0.07	0.05	0.17	0.13	0.12

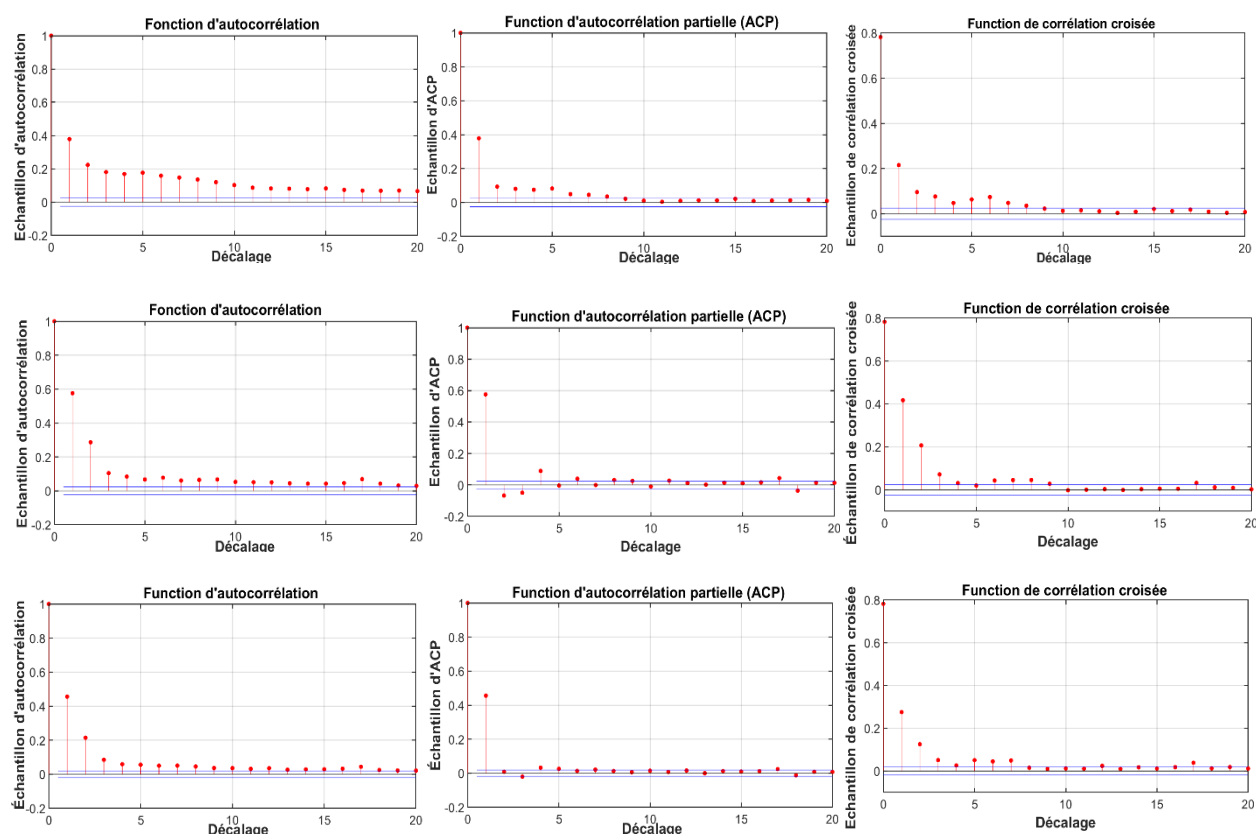


Figure 7. 1. Les ACF, PACF de la série chronologique de débit et CCF entre le débit (Q_t) et les précipitations à divers décalages avec la limite de confiance de 95% pour Moulin Rechfort, Medjez-Amar II, Bordj-Sabath, Bouchegouf, Mirebek et Ain Berda.

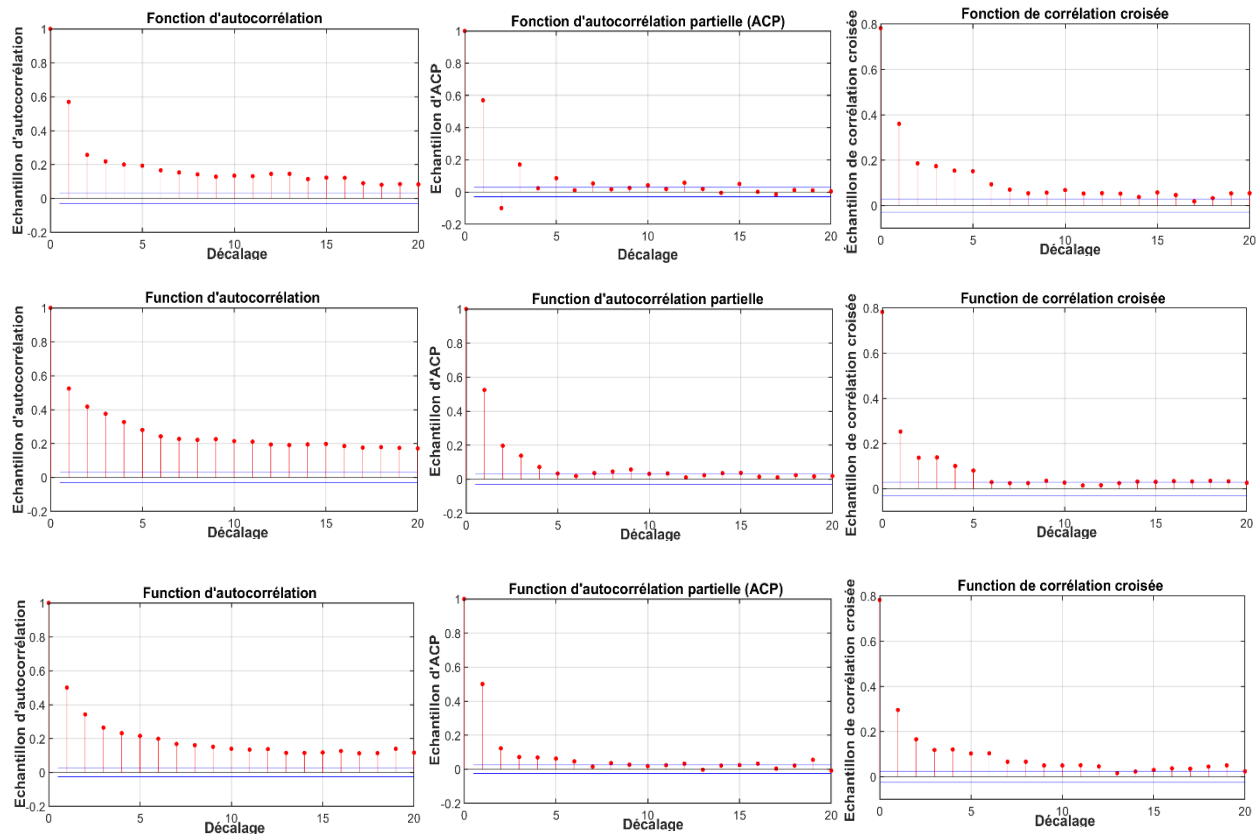


Figure 7. 1. Continue.

VII.3. Développement de modèles hybrides de RNA

Dans ce chapitre, quatre modèles de RNA ont été créés et comparés les uns aux autres pour modéliser la relation pluie-débit. Le premier modèle utilisant GA pour sa formation a été appelé RNA-GA, le second utilisant l'algorithme PSO s'appelait RNA-PSO, le troisième utilisant le (FFA), s'appelait RNA-FFA et le dernier utilisant (IPSO) s'appelait RNA-IPSO.

En fait, puisque l'efficacité de chaque modèle dépend généralement de la détermination de la variable appropriée, ces quatre techniques d'optimisation ont été combinées avec le modèle de RNA pour améliorer le calibrage de ses variables (optimiser ses poids et biais). Le choix des nombres des couches cachées ainsi que le nombre de neurones ont été décidé après avoir effectué différentes combinaisons. En effet, nous avons pu observer, à travers plusieurs tests, que l'augmentation du nombre de couches intermédiaires ou celle de neurones n'entraînait pas d'amélioration des résultats, au contraire elle rendait le réseau plus difficile à caler et son temps d'entraînement plus long. De plus, une probabilité plus élevée de convergence vers un minimum local peut être introduite, il n'y a donc aucune justification notionnelle pour l'utilisation de plus de deux couches intermédiaires (BENZINEB et al., 2018), (Foram S & Mahesh, 2014). D'un autre

côté, l'utilisation de trop peu de nœuds dans les couches intermédiaires par rapport à la complexité des données du problème entraînera un sous-apprentissage et l'utilisation d'un trop grand nombre de neurones pourrait entraîner un surapprentissage qui se produit lorsqu'inutilement plus de neurones sont présentés dans le réseau (Lo et al., 2015; Panchal et al., 2011). Dans ce travail, l'utilisation d'une seule couche cachée s'est avérée suffisante pour obtenir des résultats de simulation du modèle avec une bonne convergence et de bonnes performances (Lallahem & Mania, 2003; Riad et al., 2004). Le nombre idéal de nœuds dans la couche intermédiaire a été défini suivant une méthode d'essais et d'erreurs (approche directe) en changeant le nombre de neurones de la couche intermédiaire (Aqil et al., 2007; Darbandi & Pourhosseini, 2018b; Jahandideh-Tehrani et al., 2021; Lohani et al., 2011; Vidyarthi et al., 2020b), dans ce cas, nous partons d'une architecture avec 2 nœuds dans la couche intermédiaire, après cela, entraînez et testez le RNA, puis augmentez constamment le nombre de neurones cachés. Nous avons répété la procédure ci-dessus jusqu'à amélioration de l'apprentissage et des tests, puis nous retenons l'architecture qui donne le minimum d'erreur sur la base de test (Foram S & Mahesh, 2014). En conséquence, les meilleures architectures de RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO obtenues étaient avec une couche cachée et 10 neurones. Les quatre programmes informatiques qui montrent le processus de développement des modèles hybrides ont été développés dans MATLAB. La [figure 7.2](#) décrit la procédure d'optimisation des paramètres de RNA par les algorithmes GA, PSO, FFA et IPSO.

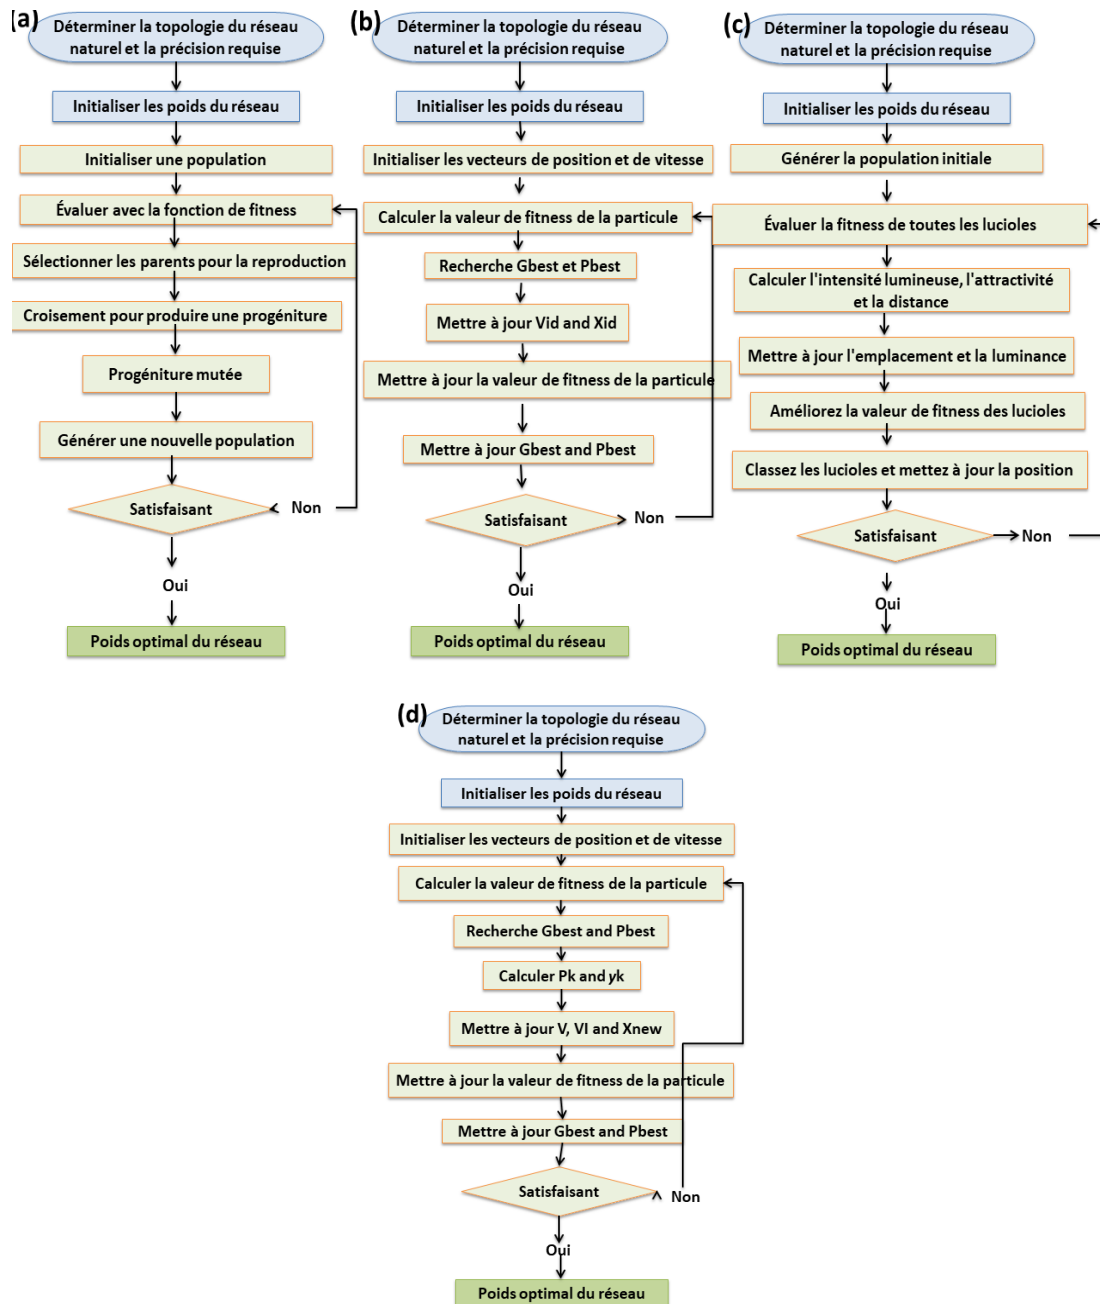


Figure 7. 2. Organigramme des algorithmes hybrides suggérés (a) RNA-GA, (b) RNA-PSO, (c) RNA-FFA et (d) RNA-IPSO.

Lors de l'application de GA, PSO, FFA et IPSO, plusieurs paramètres doivent être spécifiés. Une sélection appropriée de paramètres influence le taux de convergence de l'algorithme. Le tableau 7.3 affiche les valeurs des paramètres utilisées pour les quatre algorithmes d'optimisation.

Tableau 7.3. Paramètres utilisés pour les quatre algorithmes évolutionnaires

Paramètres de GA	Paramètres de PSO et IPSO	Paramètres de FFA
Taille de la population: 160	Taille de l'essaim: 200	Taille de l'essaim: 150
Itération maximale: 50	Itération maximale: 35	Itération maximale =50
Type de croisement: arithmétique (50%)	C1, C2 = 2	$\gamma=1$
Mutation: 35%	$w_{\max}=0.9$	$\beta_0=2$
Recombinaison: 15%	$w_{\min}=0.6$	$\alpha=0.2$

VII.4. Résultats, Analyse et discussion

Dans cette partie, une évaluation approfondie des modèles hybrides RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO dans la simulation de la sortie Q_t en utilisant un scénario défini (P_t , P_{t-1} et Q_{t-1}) est présentée, et leur efficacité en termes de nombreux indicateurs statistiques lors de l'apprentissage et de test pour les différentes stations d'étude est démontré dans le tableau 7.4. Au stade de l'apprentissage (tableau 7.4), on peut observer que pour toutes les stations hydrométriques qui sont réparties dans le bassin d'étude, le modèle RNA-IPSO offre des valeurs de débit simulées plus approximatives des débits réels que les modèles RNA-GA, RNA-PSO et RNA-FFA ; à titre d'illustration, pour la station 'Medjez-Amar II' dans le sous-bassin B3, le modèle de RNA entraîné par l'algorithme génétique (GA) a donné un fort coefficient de corrélation R (0,823), un bon coefficient d'efficacité NSE (0,666) et une faible erreur quadratique moyenne $RMSE$ (0,744). Alors que le RNA qui a utilisé l'optimisation de l'essaim de particules comme algorithme d'entraînement (PSO) a encore amélioré ces statistiques de performance, où R est devenu très fort (0,941), NSE très bon (0,868) et $RMSE$ faible (0,466). Et pour le modèle hybride RNA-FFA, les indicateurs de performance sont devenus plus importants ($R=0,961$, $NSE=0,916$ et $RMSE=0,425$). Cependant, le RNA formé par PSO amélioré (IPSO) a été le meilleur modèle pour la modélisation pluie-débit, où $R=0,993$, $NSE=0,985$ et $RMSE=0,177$. De plus, l'application du modèle RNA-GA dans la 2e station 'Bordj-Sabath' a fourni des valeurs de R (0,798), NSE (0,622) et $RMSE$ (0,948) qui sont très mauvais que celles fournies par RNA-PSO où R , NSE et $RMSE$ sont respectivement de 0,918, 0,818 et 0,554. Le modèle de RNA entraîné par l'algorithme Firefly (FFA) a également donné de bons résultats par rapport aux modèles précédents ($R=0,927$, $NSE=0,85$ et $RMSE=0,64$). Alors que le RNA-IPSO offrait de meilleures valeurs de performance ($R=0,961$, $NSE=0,923$ et $RMSE=0,459$).

Tableau 7. 4. Indicateurs de performance des RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO optimaux au cours des périodes d'apprentissage et de test.

Station	Modèle	Apprentissage (80%)			Test (20%)		
		R	NSE	RMSE	R	NSE	RMSE
Moulin Rochefort	RNA-GA	0.782	0.590	0.046	0.805	0.643	0.047
	RNA-PSO	0.850	0.715	0.039	0.878	0.764	0.039
	RNA-FFA	0.869	0.743	0.039	0.908	0.765	0.028
	RNA-IPSO	0.904	0.813	0.034	0.919	0.839	0.023
Medjez-Amar II	RNA-GA	0.823	0.666	0.744	0.916	0.814	0.621
	RNA-PSO	0.941	0.868	0.466	0.975	0.926	0.394
	RNA-FFA	0.961	0.916	0.425	0.986	0.942	0.341
	RNA-IPSO	0.993	0.985	0.177	0.987	0.943	0.052
Bordj-Sabath	RNA-GA	0.798	0.622	0.948	0.831	0.675	0.971
	RNA-PSO	0.918	0.818	0.554	0.971	0.842	0.947
	RNA-FFA	0.927	0.850	0.640	0.978	0.896	0.395
	RNA-IPSO	0.961	0.923	0.459	0.980	0.960	0.245
Bouchegouf	RNA-GA	0.808	0.627	0.615	0.837	0.697	0.389
	RNA-PSO	0.875	0.743	0.513	0.926	0.857	0.253
	RNA-FFA	0.920	0.842	0.405	0.962	0.847	0.249
	RNA-IPSO	0.970	0.939	0.252	0.965	0.929	0.170
Mirebeck	RNA-GA	0.810	0.656	0.207	0.821	0.65	0.176
	RNA-PSO	0.821	0.670	0.156	0.965	0.859	0.203
	RNA-FFA	0.863	0.720	0.183	0.972	0.895	0.108
	RNA-IPSO	0.940	0.882	0.119	0.975	0.950	0.075
Ain Berda	RNA-GA	0.807	0.638	0.862	0.831	0.666	0.905
	RNA-PSO	0.843	0.707	0.811	0.902	0.806	0.572
	RNA-FFA	0.870	0.745	0.743	0.912	0.812	0.614
	RNA-IPSO	0.957	0.915	0.428	0.944	0.891	0.467

Les mêmes remarques sur le dépassement d'excellence du modèle de RNA qui utilise IPSO comme algorithme d'entraînement sur le modèle de RNA qui emploie GA, PSO et FFA durant l'apprentissage, sont valables pour les stations restantes (sous-bassin B2 Station de 'Moulin Rochefort', sous-bassin B5 station de 'Bouchegouf', sous-bassin B6 stations du 'Mirebek et Ain Berda'). D'une part, la disproportion des performances entre les deux modèles de réseaux de neurones entraînés par GA et PSO séparément peut être due à plusieurs raisons : La mise en œuvre

de GA est généralement un processus complexe qui implique des opérations évolutives telles que la sélection, le croisement et la mutation. De plus, la vitesse de convergence pourrait être considérablement diminuée si la taille de l'échantillon est grande. Cependant, l'algorithme PSO est plus facile à mettre en œuvre et, contrairement à GA, il atteint ses valeurs de variables finales dans des générations inférieures (voir le tableau 7.4), il converge plus rapidement, il a moins de paramètres et il n'a pas d'opérateurs évolutionnaires complexes comme le croisement et mutation. Un autre point important a été noté lors de la simulation, à savoir que le temps de calcul pour GA est relativement faible contrairement à l'outil d'amélioration PSO, même s'il augmente proportionnellement au nombre de générations de PSO et GA. Par conséquent, le plus grand temps de calcul de PSO résulte de l'interaction entre les particules. D'un autre côté, le FFA a montré une capacité plus intéressante que PSO et GA à modéliser ce phénomène complexe, il s'est donc avéré être un algorithme d'optimisation encourageant ; en raison de l'influence de la fonction d'attractivité spécifique au comportement de la luciole. Cependant, le PSO est préférable au firefly en ce qui concerne le temps nécessaire pour que la valeur optimale soit produite. Mêmes résultats obtenus par (X.-S. Yang, 2010c), où il a constaté que l'essaim de particules dépasse fréquemment les algorithmes conventionnels comme les algorithmes génétiques, alors qu'en termes d'efficacité et de taux de réussite, l'algorithme moderne Firefly est supérieur à la fois au PSO et au GA. Alors que l'IPSO a potentiellement démontré qu'il s'agit d'un outil d'optimisation plus puissant que FFA pour résoudre des problèmes d'optimisation complexes et non linéaires.

Une tendance identique est également constatée pour la phase de test, où le RNA-IPSO a beaucoup mieux fonctionné que les modèles RNA-GA, RNA-PSO et RNA-FFA en termes de tous les indicateurs d'efficacité. En gardant le même exemple des stations qu'au stade d'apprentissage, l'application du modèle de RNA-GA dans la station 'Medjez-Amar II' du sous-bassin B3 a donné un très fort coefficient de corrélation R (0,916), un NSE (0,814) et un RMSE de 0,621, alors que l'utilisation du modèle RNA-PSO améliorerait mieux ces indices où la valeur de R augmentait encore à 0,975, NSE à 0,926 et RMSE diminuait (0,394). Aussi, le RNA-FFA a amélioré encore les indices de performances à (R=0,986, NSE=0,942 et RMSE=0,341). Cependant, le RNA-IPSO a fourni les valeurs de performance les plus élevées (R=0,987, NSE=0,943 et RMSE=0,052) ; ces valeurs confirment l'excellence de ce modèle. Pour la Station 'Bordj-Sabath' du même sous-bassin B3, le RNA-IPSO a fourni un coefficient de corrélation de 0,98 et un NSE de 0,96 et un RMSE de 0,245 qui sont bien meilleurs que le R (0,978), NSE (0,896) et RMSE (0,395) obtenus par le RNA-FFA et largement supérieurs à ceux fournis par le RNA-PSO (R=0,971, NSE=0,842 et RMSE=0,947) et RNA-GA (R=0,831, NSE=0,675 et RMSE=0,971). Toutes les observations discutées ci-dessus sur l'efficacité du modèle de RNA-IPSO par rapport à RNA-GA, RNA-PSO et RNA-FFA en période de test pour le sous-bassin B3, restent vertueuses pour les stations de sous-

bassin restantes. Par rapport au RNA-GA, le RNA-IPSO a amélioré la précision de la modélisation pluie-débit de 51 %, 92 %, 75 %, 56 %, 57 % et 48 % par rapport au RMSE pour les stations de Moulin Rochefort, Medjez-Amar II, Bordj-Sabath, Bouchegouf, Mirebek et Ain Berda, respectivement. Les pourcentages correspondants par rapport au RNA-FFA sont respectivement de 18 %, 85 %, 38 %, 32 % et 24 % pour les stations de Moulin Rochefort, Medjez-Amar II, Bordj-Sabath, Bouchegouf et Mirebek, respectivement. Tout cela prouve clairement la supériorité de RNA-IPSO sur les autres alternatives dans la modélisation pluie-débit.

Après avoir analysé et discuté les résultats obtenus à partir des deux phases des modèles appliqués, une remarque importante peut être déduite est que, les fiabilités des modèles dans la phase d'apprentissage sont nettement inférieures à celles de la phase de test (valeurs de R et NSE tableau 7.4). Peut-être que la cause principale est la structure de données d'apprentissage qui est plus compliquée ; et qui a une courbe de distribution comprend des pics de débit et de précipitations beaucoup plus élevés que l'ensemble de données de test.

Les nuages de points pour les valeurs de débit journalier prévues et observées pour les six stations d'étude au cours de la période de test fournies par les quatre modèles hybrides sont indiqués à la [figure 7.3](#). Comme clairement observé, la tendance linéaire de RNA-IPSO est la plus proche de la ligne $y=x$ par rapport à celles de RNA-GA, RNA-PSO et RNA-FFA. De même, les séries chronologiques du débit prévu par RNA-IPSO sont comparées à celles observées durant la période de test ([figure 7.4](#)). Un bon ajustement et un accord décent sont remarqués entre le débit observé et prédit par le modèle RNA-IPSO.

Le diagramme de Taylor

Le diagramme de Taylor ([Karl E., 2001](#)) a été utilisé pour fournir une compréhension visuelle des mesures d'efficacité qui trace pour les résultats de la modélisation un ensemble de points sur un tracé polaire, le diagramme a été utilisé pour démontrer la variation spatiale du débit attendu par le RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO sur la valeur observée pendant la période de test pour les six stations d'étude. L'écart type (SD) entre les valeurs attendues et observées est défini par le diagramme de Taylor le long des intervalles radiaux avec des racines, et les valeurs R sont définies comme angles de direction. L'hypothèse est que sur le diagramme de Taylor, les valeurs observées ont un affichage indépendant et plus les indicateurs de performance des prédictions sont proches des valeurs observées, plus la performance du modèle est forte. Comme illustré à la [figure 7.5](#), les résultats trouvés par RNA-IPSO sont plus proches de ceux observés par rapport au RNA-GA, RNA-PSO et RNA-FFA, ce qui indique une plus grande précision de ce modèle comme mentionné précédemment au [tableau 7.4](#), et [figures 7.3, 7.4](#).

Le RNA standard est utilisé avec succès dans les problèmes de gestion des ressources en eau. Par

exemple, l'estimation et/ou prédiction du débit et fournir des données pour les systèmes d'alerte précoce contre les inondations possibles. En réalité, le RNA présente cependant certains inconvénients tels que la décélération de la méthode d'entraînement, le stockage dans les minima locaux et le surapprentissage. Ainsi, de nouveaux algorithmes métaheuristiques sont nécessaires pour résoudre ce problème et améliorer son efficacité. Cela a été confirmé par les résultats trouvés ici après avoir appliqué les modèles hybrides de RNA formés par GA, PSO, FFA et IPSO, où ils ont révélé la supériorité de RNA-IPSO sur RNA-FFA, RNA-PSO et RNA-GA en phase d'apprentissage et de test pour les six stations réparties dans le bassin d'étude. En conséquence, l'algorithme IPSO a pu améliorer les capacités de résolution de ce problème complexe avec une vitesse de convergence élevée par rapport à FFA, PSO et GA. En outre, il pourrait être utilisé pour améliorer d'autres problèmes anormaux qui changent avec le temps. De tels modèles peuvent être utilisés comme module dans les modèles généraux d'analyse hydrologique (Danandeh Mehr et al., 2019; Jahandideh-Tehrani et al., 2021; Vidyarthi & Chourasiya, 2020). (Darbandi & Pourhosseini, 2018b) ont utilisé MLP-RNA et MLP-FFA pour prévoir le débit fluvial mensuel pour un ensemble d'intervalles de temps à l'aide de données observées. Leurs résultats montrent que le modèle MLP-FFA est satisfaisant pour la simulation mensuelle du débit fluvial dans le bassin versant d'Ajichay dans la province de l'Azerbaïdjan oriental. (Jahandideh-Tehrani et al., 2020) ont comparé PSO et GA pour la modélisation journalière de pluie-débit dans le sud-est du Queensland, en Australie. Les résultats ont indiqué que le modèle RNA-PSO surpassait considérablement le modèle RNA-GA en termes de vitesse de convergence, de précision et d'évaluation de la fonction de fitness.

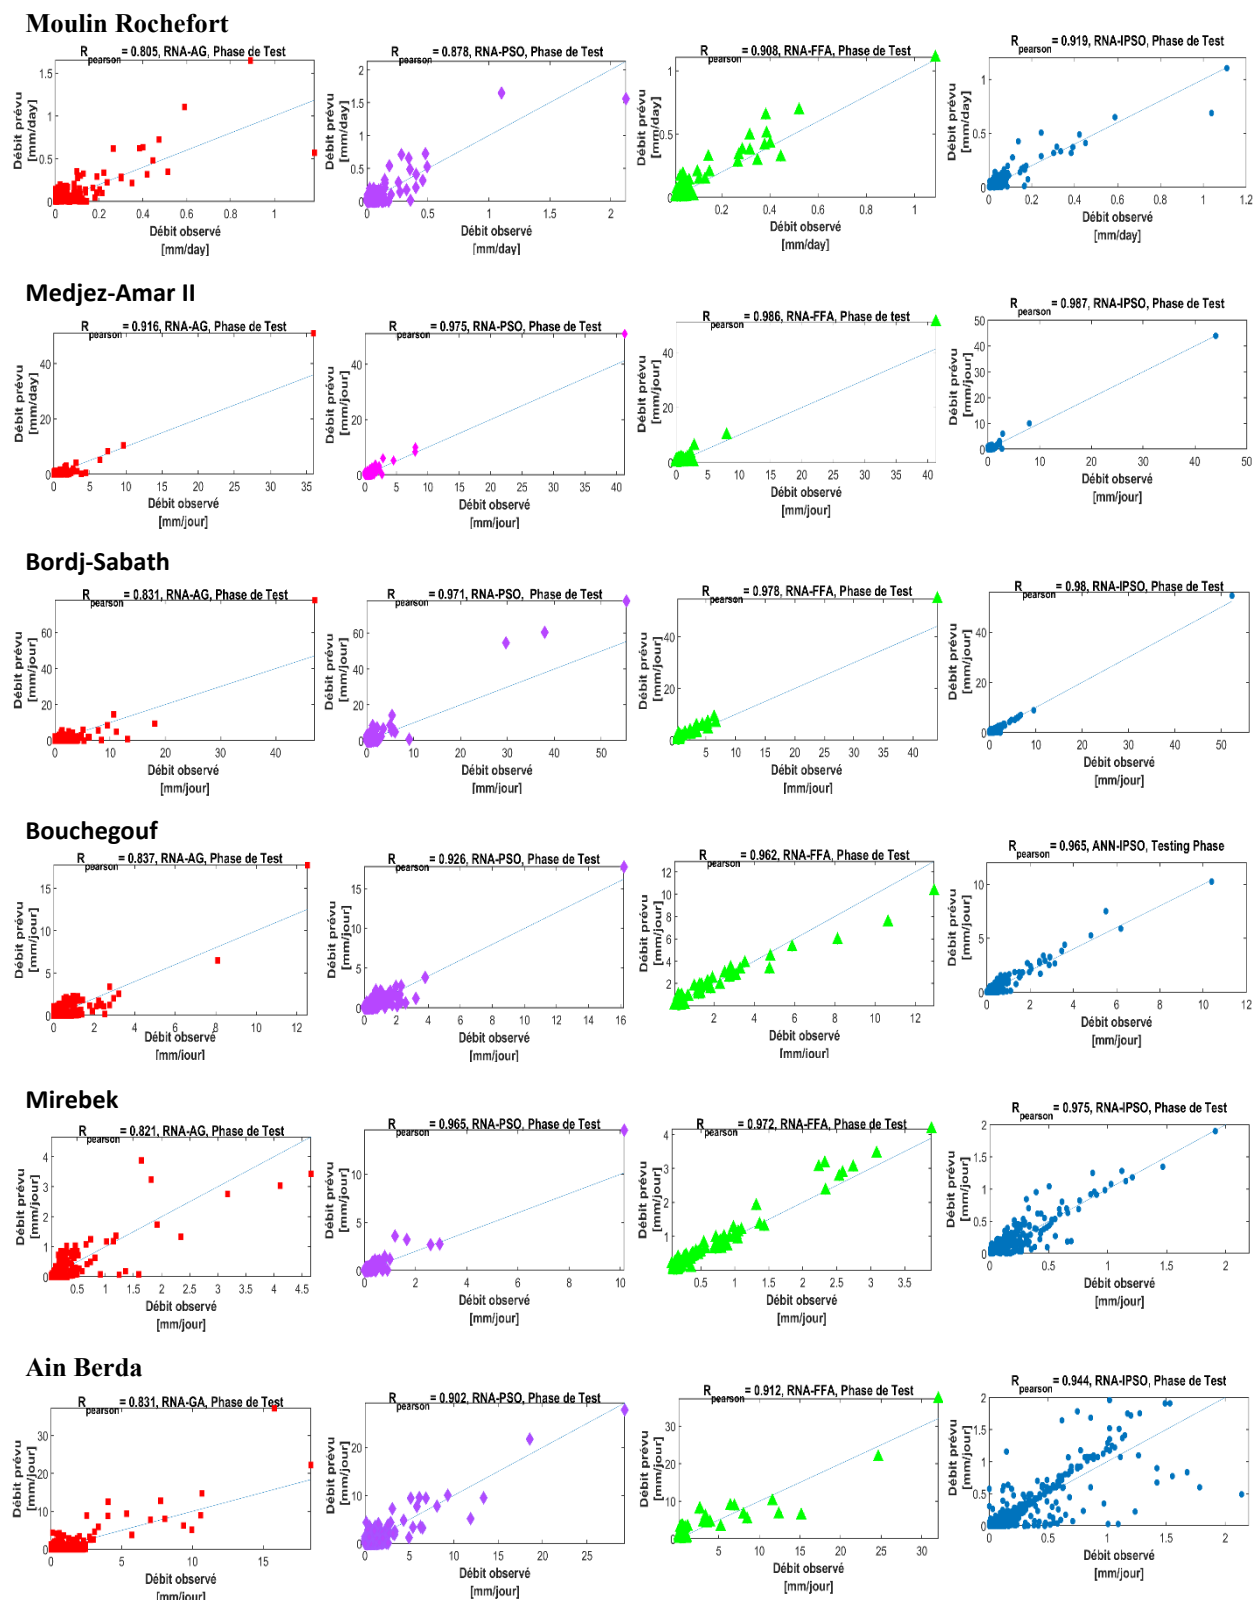


Figure 7. 3. Nuages de points des valeurs de débit journalier observées et prévues pendant la phase de test, produits par RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO pour les six stations.

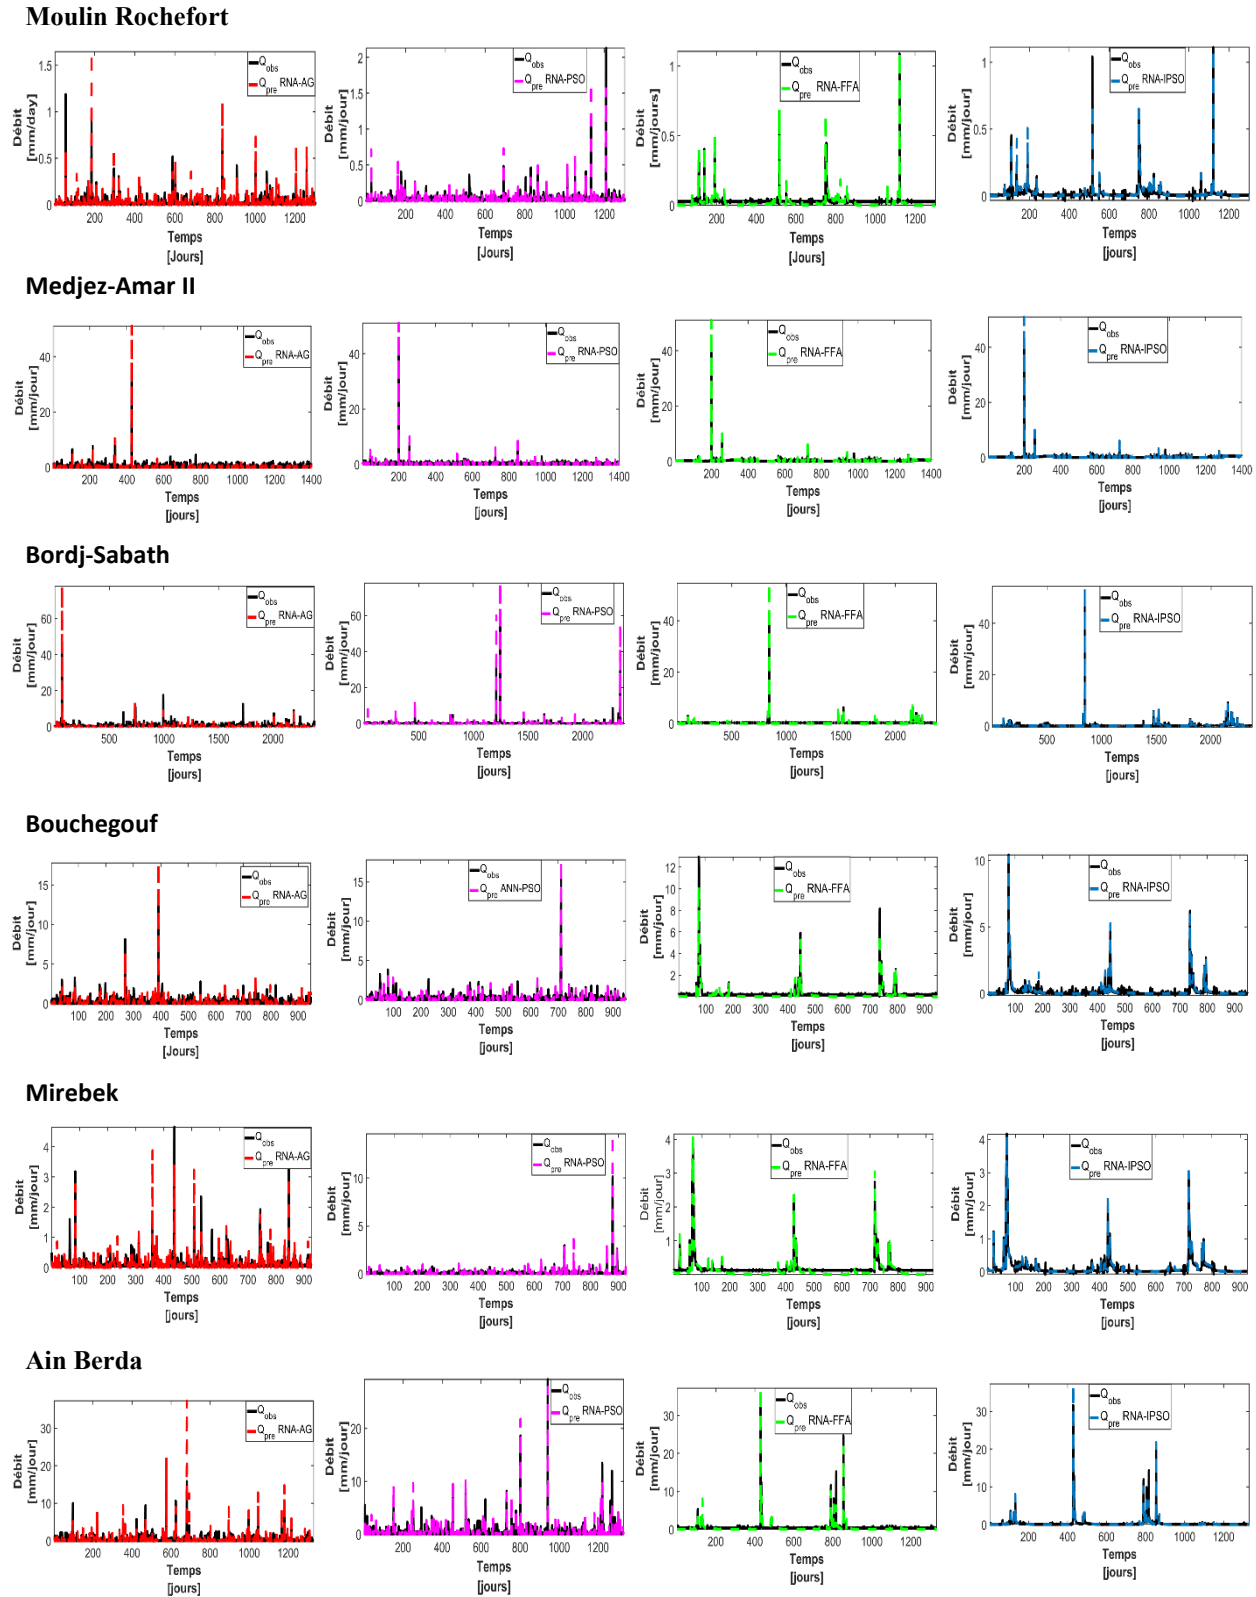


Figure 7. 4. Série chronologique des valeurs de débit journalier observées et prévues pendant la phase de test, produite par RNA-GA, RNA-PSO, RNA-FFA et RNA-IPSO pour les six stations.

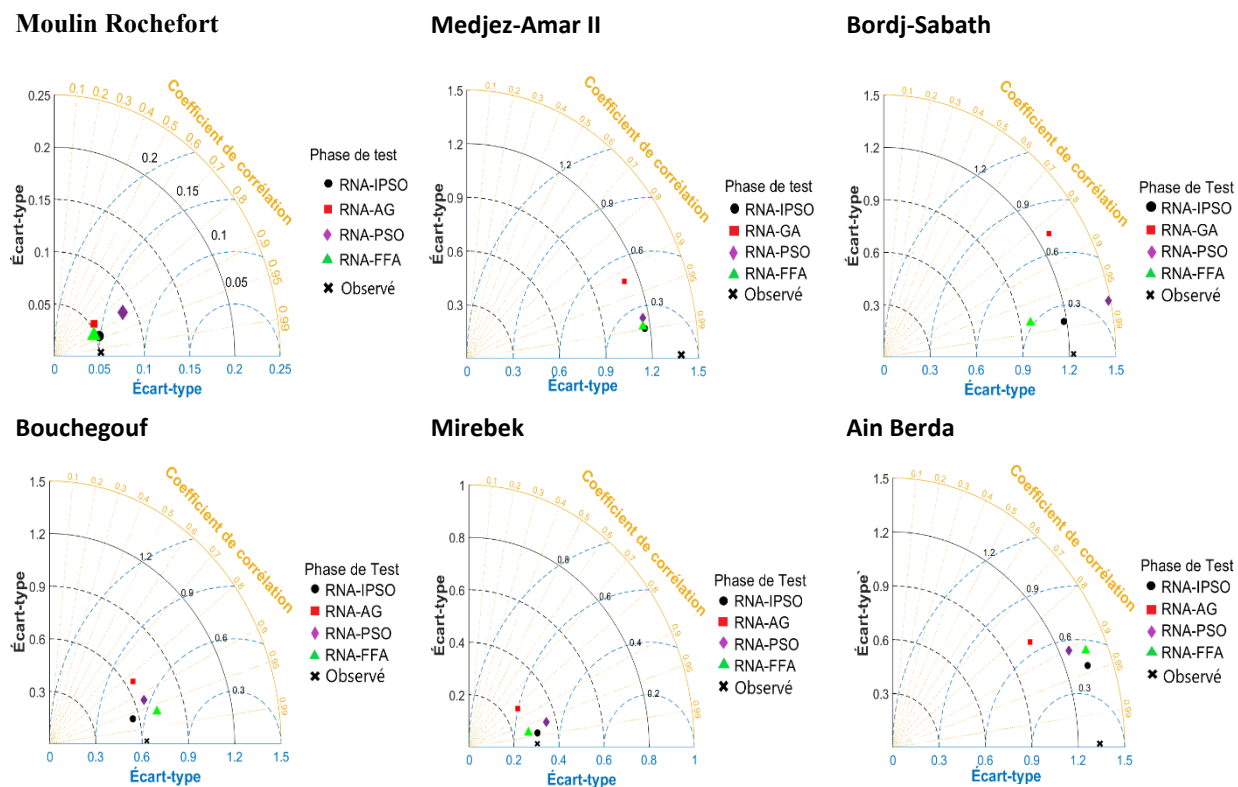


Figure 7. 5. Diagrammes de Taylor affichant la comparaison statistique des quatre modèles pendant la période de test dans les six stations d'étude.

Conclusion

Ce chapitre consiste à développer un modèle de prédiction précis basé sur une approche combinée de réseau de neurones artificiels-algorithme d'optimisation d'essaim de particules amélioré (RNA-IPSO) pour simuler le débit journalier. Dans l'ensemble, l'étude a indiqué que GA, PSO, FFA et IPSO peuvent être utilisés dans la modélisation du processus pluie-débit. Cependant, les résultats optimaux d'un point de vue évolutif ont prouvé de manière significative la supériorité et la capacité de RNA-IPSO sur RNA-GA, RNA-PSO et RNA-FFA en termes de tous les critères statistiques et d'interprétation graphique, où les prédicteurs d'entrée sont P_t, P_{t-1} et Q_{t-1} .

Ces résultats confirment incontestablement l'efficacité de IPSO dans l'amélioration des paramètres du modèle RNA et renforcent sensiblement ses performances de prédiction. Ce modèle hybride basé sur IPSO peut ainsi être utilisé dans différentes fonctionnalités et, plus particulièrement en hydrologie et ses disciplines connexes. En conséquence, cette étude indique que le modèle RNA optimisé par IPSO est plus puissant pour la modélisation pluie-débit et une meilleure alternative aux autres modèles basés sur des métaheuristiques appliqués ici.

CHAPITRE VIII

**PRÉVISION DES DÉBITS DE CRUES HORAIRE PAR
LES MODÈLES CNN ET CNN HYBRIDES.**

Introduction

Dans le domaine d'apprentissage automatique (Machine Learning), l'apprentissage en profondeur (Deep Learning), en raison de son succès considérable, est actuellement l'une des tendances de recherche les plus importantes, dont le réseau de neurones convolutifs (CNN) est l'algorithme le plus connu et le plus couramment utilisé. Le principal avantage de CNN par rapport à ses prédécesseurs est qu'il identifie automatiquement les fonctionnalités pertinentes sans aucune supervision humaine. Cependant, CNN, similaire au RNA, système d'inférence neuro-floue adaptatif (ANFIS) et à d'autres réseaux de neurones, a une structure complexe avec de nombreux paramètres qui doivent être optimisés.

Les études existantes n'ont pas comparé les performances de prédiction d'un modèle CNN autonome avec celles de CNN amélioré par l'optimisation concurrentielle impérialiste (CNN-ICA) et du loup gris (CNN-GWO) en utilisant des ensembles de données combinés dans l'estimation du débit. L'objectif de ce chapitre, est d'évaluer la puissance du modèle autonome CNN et de deux nouveaux modèles hybrides CNN-ICA et CNN-GWO dans la prévision du débit dans le même bassin d'étude, en examinant deux scénarios : un en intégrant les données horaires de la réanalyse atmosphérique globale ERA5 (précipitations totales, température de l'air à 2 m, pression de surface, 10 m u-composante du vent, 10 m v-composante du vent, température du sol niveau 1 et couche d'eau volumétrique du sol 1), les indices de variabilité climatique (oscillation antarctique (AAO), température de surface de la mer dans la région Nino3.4 de l'océan Pacifique équatorial oriental (SST_Nino34), oscillation arctique (AO), oscillation nord-atlantique (NAO) et configuration nord-américaine du Pacifique (PNA)) et enfin les observations de débit in-situ, et deux sans utiliser les indices climatiques, afin de simuler précisément le débit horaire.

VIII.1. Acquisition des données

Les modèles de CNN, CNN-ICA et CNN-GWO proposés, sont entraînés et testés à l'aide d'ensembles de données combinés : observations horaires in situ du débit aux six stations d'étude collectées toujours auprès de l'ANRH, indices climatiques (AAO, AO, NAO et PNA) obtenus du Climate Prediction Center (CPC) et les données de l'indice SST_Nino3.4 du site <https://www.cpc.ncep.noaa.gov/data/indices/sstoi.indices> . Et enfin, les estimations horaires des variables climatiques atmosphériques (précipitations totales, température de l'air à 2 m, pression de surface, 10 m u-composant du vent, 10 m v-composante du vent, température du sol niveau 1 et couche d'eau volumétrique du sol 1) téléchargé au magasin de données climatiques du service Copernicus sur le changement climatique (C3S). Le pool de paramètres utilisés dans les modèles est répertorié dans le tableau 8.1.

Tableau 8. 1. Liste des paramètres utilisés dans l'élaboration des modèles, les observations in-situ, les variables atmosphériques et les indices climatiques.

Variable	Indice	Unité	Type
Débits	Q	m ³ /s	Obs
Précipitations totales	T _p	M	Atm
Température de l'air à 2m	T _{2m}	K	Atm
pression de surface	Sp	Pa	Atm
10m u-composant du vent	u10	m/s	Atm
10m v- composant du vent	v10	m/s	Atm
Température du sol niveau 1	Stl1	K	Atm
Couche d'eau volumétrique du sol 1	Swvl1	m ³ /m ³	Atm
Oscillation Antarctique	AAO	/	Clim
Oscillation arctique	AO	/	Clim
Oscillation nord-atlantique	NAO	/	Clim
configuration nord-américaine du Pacifique	PNA	/	Clim
Température de surface de la mer au Nino3.4	SST Nino 3.4	/	Clim

Pour l'apprentissage du modèle, 80 % des données sont utilisées, tandis que pour tester leur étalonnage et examiner leurs performances, les 20 % restants sont utilisés. Les valeurs de l'indice climatique pour l'oscillation antarctique (AAO), l'oscillation arctique (AO), l'oscillation nord-atlantique (NAO) et le modèle nord-américain du Pacifique (PNA) sont caractérisées par la première composante principale des anomalies de hauteur de 700 mb vers le pôle de 20 S. (SST Niño 3.4) est utilisé pour représenter l'activité El Niño-oscillation australe (ENSO) car il mesure les anomalies de température de surface de la mer (SST) du Pacifique équatorial central (Rasouli et al., 2012). La zone d'étude dans cette partie, a été discrétisée a plus de 50 cellules de 10 × 10 km (pour un total de 6471 km²) et les données horaires ERA5 atmosphériques ont été téléchargées pour chaque cellule appartenant à la zone de drainage de chaque station hydrométrique (Figure 8.1).

La carte qui représente l'élévation du bassin d'étude est montrée dans la figure 8.2, tandis que les élévations des stations d'étude sont :

Ain Berda : 63m, Bordj-Sabath: 526m, Bouchegouf : 137m, Medjez-Amar II : 301m, Moulin Rochefort : 736m, Mirebek: 15m.

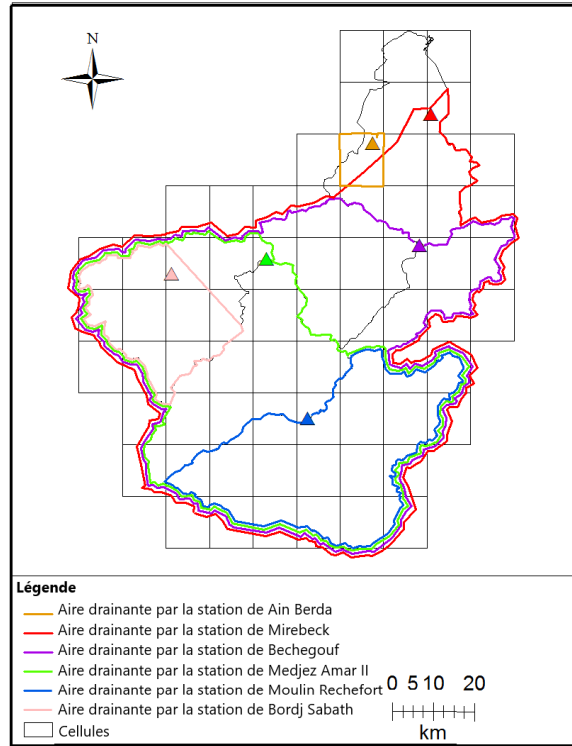


Figure 8. 1. La discrétisation en grille du bassin d'étude et les surfaces drainantes de chaque station hydrométrique.

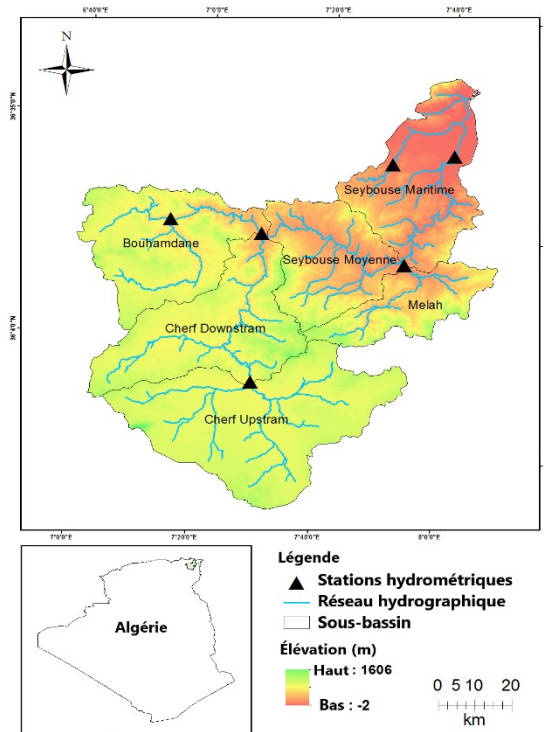


Figure 8. 2. L'emplacement et l'élévation du bassin de Seybouse.

VIII.2. Sélection des entrées par ACP

Comme mentionnée précédemment (chapitre VII), dans l'approche du réseau de neurones, le criblage des variables possibles pour l'entrée du modèle est une étape critique dans la sélection de la meilleure architecture du modèle ; car la sélection des entrées est l'un des éléments les plus importants affectant l'efficacité du modèle. Les précipitations, la température et l'humidité peuvent tous être des facteurs causatifs dans le processus pluie-débit. Le nombre de variables différentes dépend de la disponibilité des données et des objectifs de l'étude. Dans certaines études comme celle du chapitre VII, les précipitations et le débit antérieur avec diverses combinaisons temporelles sont utilisés comme intrants, tandis que dans d'autres, certaines variables météorologiques sont utilisées. Dans la présente partie, sept variables atmosphériques différentes sont utilisées pour les modèles proposés (précipitations totales, température de l'air à 2 m, pression de surface, 10 m u-composant du vent, 10 m v composante du vent, température du sol niveau 1 et couche d'eau du sol volumétrique 1). Afin d'identifier les composants les plus importants qui affectent le débit pour chaque station d'étude, la zone d'étude a été divisée en 100 cellules, et ces données atmosphériques ont été collectées pour chaque cellule de la région de drainage par chaque station hydrométrique (Figure 8.1). Par conséquent, une grande quantité de données a été obtenue, donc, leur compression est requise. L'Analyse en Composante Principale (ACP) est l'une des techniques puissantes utilisées pour diminuer le nombre de dimensions en compressant les données et en trouvant leurs caractéristiques générales multidimensionnelles, elle a été appliquée ici pour réduire la redondance et la dimensionnalité au sein des données d'entrée pour les six stations d'étude. De nombreuses études dans le domaine de l'hydrologie ont utilisé cette technique pour identifier les meilleures variables d'entrée (par exemple, (Kumar et al., 2019; Liu et al., 2021; Remesan et al., 2018; Wang et al., 2020; Zhang et al., 2021)). Un exemple de représentation des résultats de l'ACP trouvés pour la station Medjez Amar II est présenté dans le tableau 8.2, où il représente les 7 facteurs les plus significatifs obtenus sur 217 vecteurs, qui représentaient environ 98% de la variance totale dans l'ensemble de données. Pour la station Bordj Sabath : 6 facteurs significatifs ont été obtenus sur 49, pour Moulin Rechefort : 7 sur 98, Bouchegouf : 8 sur 294, Mirebek : 8 sur 329, et pour Ain Berda : 2 sur 7. Ainsi, la combinaison d'entrées considérée pour le premier scénario utilisé dans le développement du modèle est constituée des variables les plus significatives obtenues par L'ACP appliquées aux données atmosphériques. Alors que pour le deuxième scénario, cinq autres indices climatiques sont ajoutés (AAO, AO, NAO, PNA et SST dans la région Niño 3.4).

Tableau 8. 2. Le taux de contribution à la variance pour la station Medjez Amar II.

	ACP1	ACP2	ACP3	ACP4	ACP5	ACP6	ACP7
Eigenvalue	91.5	41.3	31.5	22.033	14.4	8.8	2.8
Variance (%)	42.2	19.0	14.5	10.1	6.6	4.1	1.2
Cumulative variance (%)	42.2	61.2	75.7	85.9	92.5	96.6	97.9

VIII.3. Développement de modèles CNN et CNN hybrides

Dans cette étude, un algorithme d'apprentissage en profondeur est motivé par nos techniques hybrides proposées appelées CNN-ICA et CNN-GWO pour modéliser le processus pluie-débit, puis les deux modèles hybrides proposés ont été comparés au modèle de référence CNN. L'ensemble de ces modèles sont développés dans Matlab R2018b

Comment choisir l'architecture de modèle appropriée à partir d'une variable d'entrée donnée et spécifier le nombre de nœuds cachés est un défi crucial dans l'application de CNN, mais il n'y a pas de règle universelle pour traiter ce problème. En conséquence, la méthode d'essais et d'erreurs est une approche unique en son genre pour surmonter cet obstacle (Van et al., 2020). Lorsque le niveau d'erreurs acceptable est atteint ou que le nombre d'itérations dépasse une certaine valeur, l'apprentissage des modèles de réseaux de neurones est arrêté. La meilleure configuration de modèle RN qui minimise les erreurs et optimise R est choisie, et l'ensemble de l'analyse est répété plusieurs fois.

L'optimisation des paramètres du modèle est l'une des étapes les plus essentielles du processus de modélisation. Dans cette recherche, les paramètres optimaux, en particulier les poids dans la fonction d'appartenance de l'approche de CNN, ont été découverts à l'aide de deux algorithmes métaheuristiques. ICA et GWO peuvent être utilisés pour former le CNN, dans le but d'atteindre la précision exacte nécessaire tout en diminuant les indicateurs de complexité du réseau et la précision des erreurs d'approximation (Panahi et al., 2021), les processus de construction pour CNN-ICA et CNN-GWO sont concis sur la figure 8.3. Pour atteindre cet objectif, il est nécessaire de pouvoir calculer l'erreur sur l'ensemble d'entraînement ainsi que la fonction de fitness de la solution vectorielle. Ici, la fonction de fitness (f) est calculée comme suit :

$$f = 0.5 \left(\sqrt{\frac{\sum_{i=1}^n (o-y)^2}{R}} \right) \quad (\text{Panahi et al., 2021}) \quad (8.1)$$

La sortie souhaitée est représentée par o , la sortie réelle est représentée par y et le nombre de données d'entraînement est représenté par R . Lorsque l'itération prédéterminée est terminée et que la fonction de fitness calculée est inférieure à une constante donnée, la procédure peut être

terminée. La précision de l'erreur d'approximation est à son point le plus bas, tandis que les indicateurs de complexité du réseau sont à leur point le plus élevé. Les paramètres de CNN, CNN-ICA et CNN-GWO sont présentés dans le tableau 8.3.

Tableau 8.3. Réglages d'hyperparamètres pour les modèles de CNN proposés.

Modèle		CNN	CNN-ICA	CNN-GWO
Couche convolutive	Active	Oui	Oui	Oui
	Nombre de filtres	8	16	32
	Taille du filtre	3×3	3×3	3×3
	Normalisation par lots	Oui	Oui	Oui
	Fonction d'activation	Sigmoïde	Relu	Relu
	Taux d'abandon	10%	10%	10%
	Active Pooling	Oui	Oui	Oui
	Type de Pooling	Pooling max	Pooling moyen	Pooling moyen
Couche entièrement connectée	Active	Oui	Oui	Oui
	Nombre de nœuds	3	6	9
	Normalisation par lots	Oui	Oui	Oui
	Fonction d'activation	Sigmoïde	Relu	Relu
	Taux d'abandon	10%	10%	10%
	Active	Oui	Oui	Oui

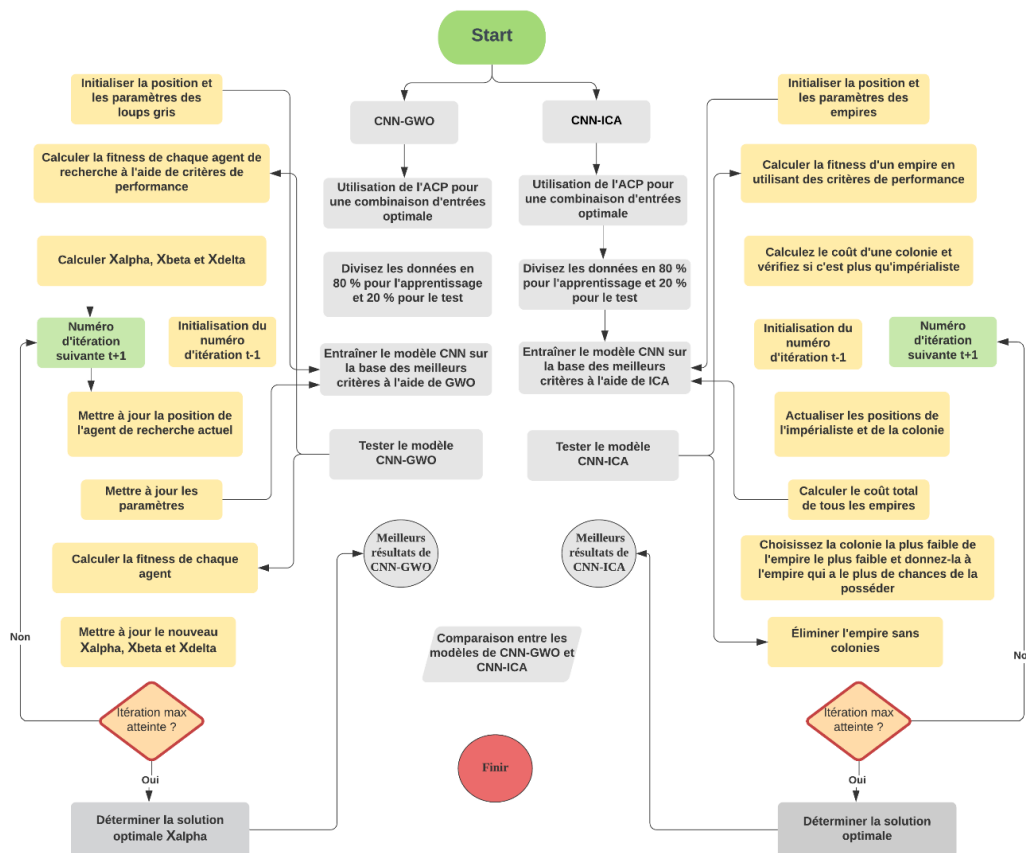


Figure 8. 3. Organigramme des modèles hybrides a) CNN-GWO et b) CNN-ICA proposés.

VIII.4. Résultats et discussions

L'utilité des modèles CNN hybrides anticipés a été évaluée en comparant les valeurs de débit prévues et observées à chaque station. L'efficacité des modèles pour prédire le débit horaire a été examinée à l'aide d'une variété de mesures statistiques (MAE, RMSE, R, NSE et WI) et d'une évaluation graphique des données via des nuages de points, des séries chronologiques, des graphiques radar et des diagrammes de Taylor.

La faisabilité des modèles CNN, CNN-ICA et CNN-GWO lors de l'apprentissage et de tests en termes de métriques de performance utilisant et non des indices climatiques avec des données atmosphériques est illustrée dans le Tableau 8.4. L'utilisation d'indices climatiques avec des données atmosphériques comme entrées pour les trois modèles développés, a montré une augmentation notable de R, NSE et WI ainsi qu'une diminution des erreurs au cours des deux phases pour les six stations d'étude par rapport aux modèles sans l'utilisation d'indices climatiques (voir Tableau 8.4). À titre d'exemple, les valeurs NSE et WI à la station Medjez-Amar II pendant la période de test ont été trouvées respectivement égale à 0,907 et 0,972 pour CNN sans utiliser

les indices climatiques, cependant, 0,944 et 0,986 pour CNN avec l'utilisation d'indices climatiques, ainsi que 0,941 et 0,984, respectivement pour CNN-ICA sans l'utilisation d'indices climatiques(CI) et 0,970 et 0,992, respectivement avec l'utilisation de CI. Enfin, le CNN-GWO a été obtenu pour être plus efficace avec ou sans l'utilisation d'indices climatiques par rapport à CNN et CNN-ICA, où les valeurs NSE et WI ont été trouvées respectivement égale à 0,946 et 0,984 sans l'utilisation de CI et à 0,985 et 0,996, respectivement en utilisant CI. L'utilisation d'indices climatiques a montré une amélioration significative des résultats en termes de toutes les mesures de performance. Où, les valeurs de R, NSE et WI pour les modèles proposés ont été obtenues respectivement à plus de 0,81, 0,75 et 0,81 à la période d'apprentissage et respectivement à 0,91, 0,82 et 0,95 à la période de test dans toutes les stations d'étude, ce qui implique une efficacité satisfaisante des modèles de prévision du débit dans la région d'étude. La plus faible précision des modèles lors de la phase d'apprentissage par rapport à la phase de validation (voir les valeurs de R, NSE et WI) peut être attribuée à la structure plus compliquée des ensembles de données d'apprentissage, qui ont une distribution plus asymétrique, y compris des pics de précipitations et débits considérablement plus élevés que les données de validation. La [figure 8.4](#) illustre les séries chronologiques des valeurs observées par rapport aux valeurs prédites de $Q(t)$ horaire en utilisant le modèle optimal CNN-GWO avec et sans indices climatiques pendant la phase de validation, il est évident que les séries chronologiques prédites par le modèle CNN-GWO avec CI étaient obtenu extrêmement proche de celui observé.

Tableau 8. 4. Indicateurs statistiques des modèles CNN hybrides pendant les périodes d'apprentissage et de validation au niveau des six sous-bassins allant de 102 km² à Ain Berda à plus de 5950 km² à Mirebek.

Station	Indicateurs climatiques CI	Modèles	Période d'apprentissage (80%)					Période de validation (20%)				
			MAE	RMSE	R	NSE	WI	MAE	RMSE	R	NSE	WI
Ain Berda	Sans CI	CNN	0.033	0.092	0.804	0.740	0.780	0.053	0.076	0.942	0.858	0.960
		CNN-ICA	0.030	0.057	0.900	0.788	0.940	0.045	0.072	0.951	0.871	0.965
		CNN-GWO	0.029	0.053	0.916	0.819	0.950	0.042	0.066	0.960	0.892	0.972
	Avec CI	CNN	0.086	0.112	0.810	0.750	0.809	0.022	0.057	0.962	0.921	0.978
		CNN-ICA	0.028	0.052	0.918	0.827	0.952	0.017	0.038	0.989	0.965	0.992
		CNN-GWO	0.027	0.050	0.925	0.837	0.956	0.014	0.030	0.989	0.978	0.994
Bordj-Sabath	Sans CI	CNN	0.077	0.143	0.884	0.777	0.935	0.061	0.114	0.907	0.802	0.949
		CNN-ICA	0.063	0.126	0.913	0.826	0.950	0.045	0.095	0.932	0.862	0.959
		CNN-GWO	0.061	0.127	0.911	0.823	0.948	0.042	0.082	0.952	0.897	0.970
	Avec CI	CNN	0.053	0.108	0.934	0.872	0.965	0.052	0.089	0.939	0.879	0.967
		CNN-ICA	0.049	0.099	0.945	0.892	0.970	0.041	0.077	0.955	0.911	0.976
		CNN-GWO	0.049	0.092	0.954	0.908	0.975	0.036	0.062	0.971	0.942	0.985
Bouche gouf	Sans CI	CNN	0.068	0.113	0.894	0.793	0.936	0.143	0.340	0.930	0.829	0.945
		CNN-ICA	0.067	0.109	0.901	0.809	0.944	0.136	0.303	0.939	0.864	0.961
		CNN-GWO	0.054	0.097	0.922	0.847	0.956	0.112	0.270	0.951	0.892	0.969
	Avec CI	CNN	0.049	0.095	0.928	0.856	0.958	0.113	0.292	0.946	0.874	0.961
		CNN-ICA	0.048	0.087	0.938	0.878	0.966	0.104	0.239	0.959	0.915	0.977
		CNN-GWO	0.047	0.079	0.949	0.899	0.972	0.092	0.216	0.967	0.931	0.982
Medjez-Amar II	Sans CI	CNN	0.128	0.209	0.932	0.868	0.963	0.119	0.267	0.961	0.907	0.972
		CNN-ICA	0.107	0.202	0.941	0.877	0.966	0.105	0.212	0.975	0.941	0.984
		CNN-GWO	0.108	0.185	0.950	0.897	0.972	0.093	0.203	0.984	0.946	0.984
	Avec CI	CNN	0.094	0.145	0.970	0.937	0.983	0.104	0.208	0.973	0.944	0.986
		CNN-ICA	0.084	0.142	0.970	0.939	0.984	0.072	0.151	0.986	0.970	0.992
		CNN-GWO	0.082	0.125	0.976	0.953	0.988	0.067	0.106	0.993	0.985	0.996
Moulin Rochefort	Sans CI	CNN	0.061	0.098	0.845	0.709	0.900	0.060	0.082	0.876	0.764	0.933
		CNN-ICA	0.054	0.089	0.894	0.761	0.918	0.055	0.074	0.908	0.806	0.937
		CNN-GWO	0.051	0.086	0.917	0.773	0.919	0.047	0.064	0.933	0.854	0.955
	Avec CI	CNN	0.044	0.076	0.909	0.826	0.949	0.054	0.070	0.915	0.829	0.956
		CNN-ICA	0.039	0.075	0.917	0.829	0.948	0.049	0.066	0.923	0.847	0.959
		CNN-GWO	0.040	0.059	0.949	0.895	0.970	0.039	0.051	0.954	0.910	0.977
Mirebe	Sans CI	CNN	0.224	0.369	0.933	0.862	0.965	0.408	0.587	0.943	0.884	0.968

k		CNN-ICA	0.230	0.334	0.942	0.887	0.969	0.383	0.497	0.960	0.917	0.977
		CNN-GWO	0.202	0.312	0.950	0.902	0.974	0.339	0.449	0.967	0.932	0.982
	Avec CI	CNN	0.155	0.266	0.975	0.929	0.984	0.236	0.381	0.976	0.951	0.988
		CNN-ICA	0.142	0.235	0.972	0.944	0.986	0.244	0.358	0.980	0.957	0.989
		CNN-GWO	0.151	0.231	0.973	0.946	0.986	0.220	0.311	0.985	0.968	0.992

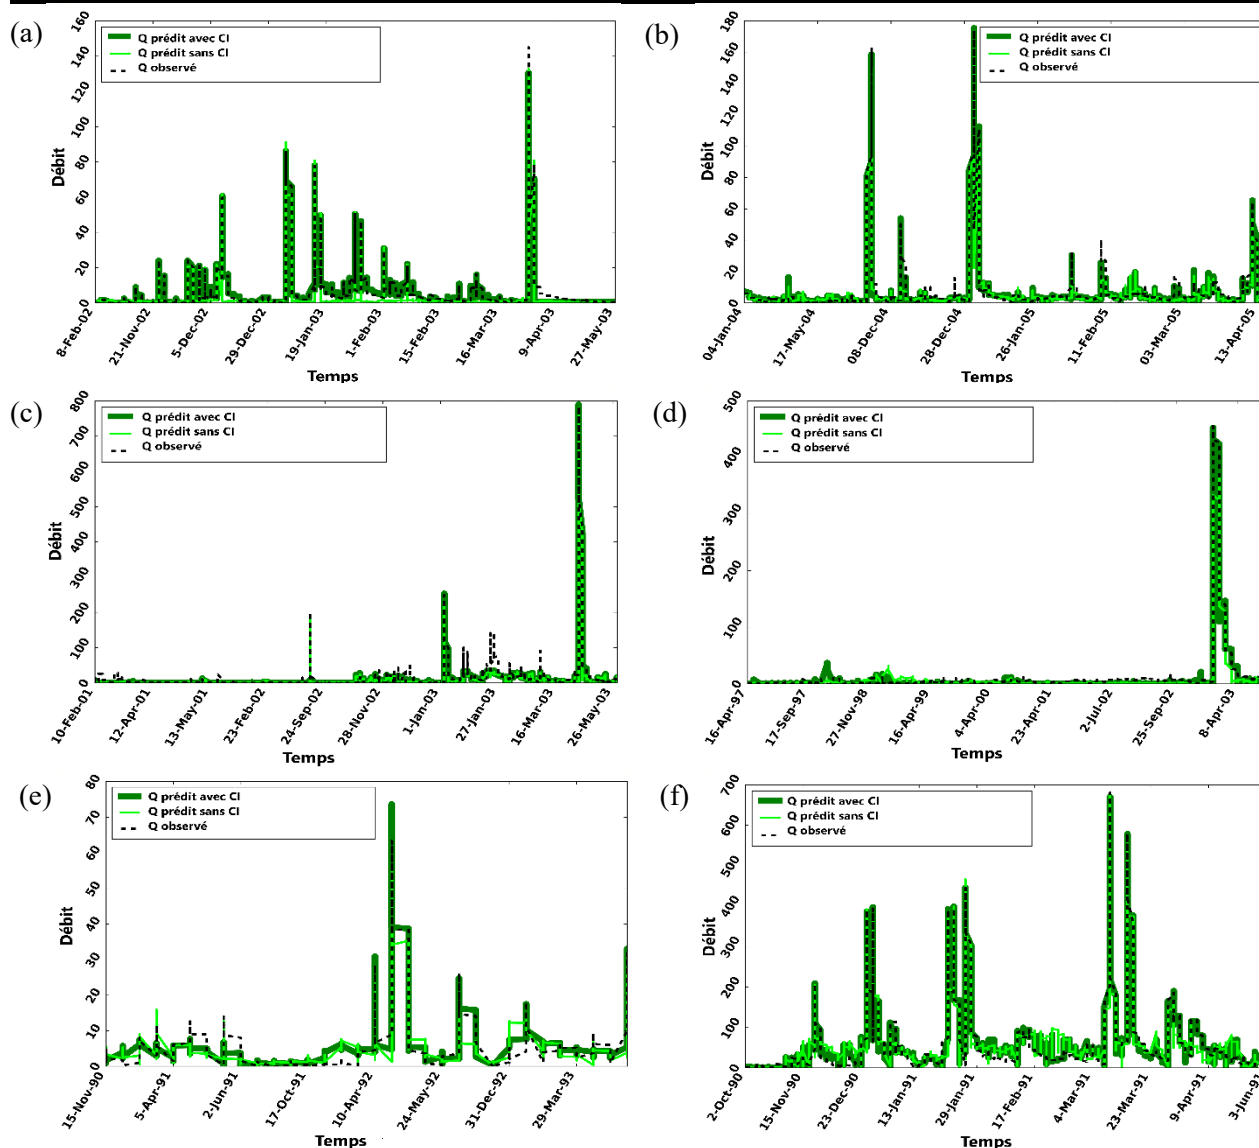


Figure 8. 4. Série chronologiques représentant le débit observé et prévu en m^3/s par CNN-GWO avec et sans CI au sous-bassins de a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rochefort et f) Mirebek dans un ordre croissant de zone de drainage pendant la phase de test.

Afin d'évaluer davantage le potentiel prédictif des modèles utilisant des indices climatiques par rapport à ceux qui n'en utilisent pas, des diagrammes de Taylor ont été créés (Figure 8.5). Il a révélé que le modèle CNN-GWO qui utilisait les CI présentait la meilleure efficacité par rapport à

CNN-GWO sans CI ainsi qu'à d'autres modèles, car les coefficients de corrélation pour les six stations d'étude étaient assez élevés.

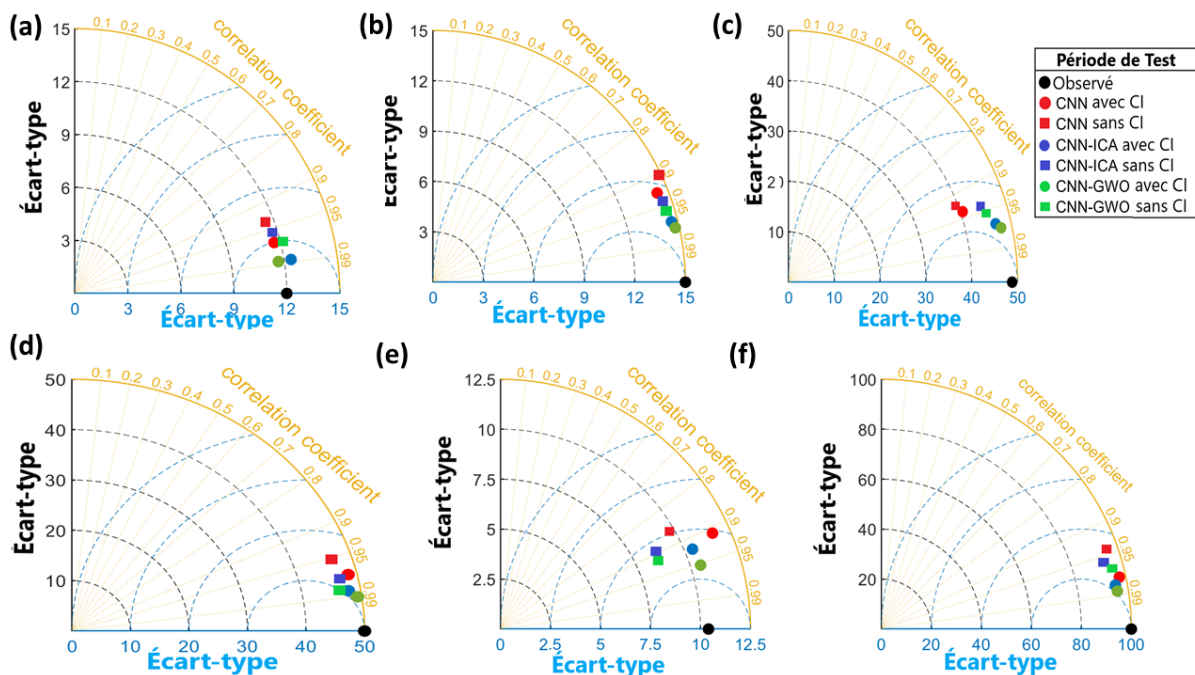


Figure 8. 5. Diagramme de Taylor des modèles CNN, CNN-ICA et CNN-GWO avec et sans CI dans les stations de a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rochefort et f) Mirebek pour la période de test.

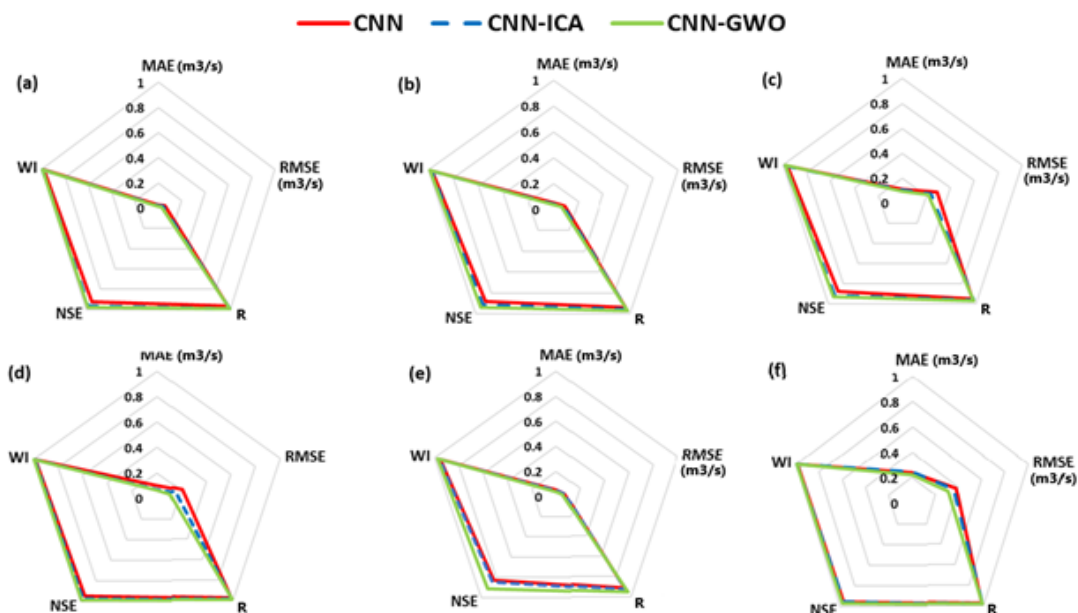


Figure 8. 6. Graphique radar illustrant les métriques de performance des modèles proposés utilisant CI à a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II, e) Moulin Rochefort et f) Mirebek dans l'ordre croissant de la zone de drainage pendant la phase de test.

Les métriques de performance dérivées pour les trois modèles développés à l'aide d'indices climatiques pendant la phase de test sont également affichées à l'aide de cartes radar (Figure 8.6). L'ensemble des métriques de performance a montré que le CNN-GWO surclassait les deux autres modèles, notamment à la station Moulin Rochefort (Fig. 8.6 e). La figure 8.7 fournit des diagrammes de dispersion des valeurs observées par rapport aux valeurs prévues de $Q(t)$ horaire à l'aide de CNN, CNN-ICA et CNN-GWO avec des indices climatiques pendant la phase de test ; il est évident que les valeurs prédites des modèles ont été obtenues pour être presque alignées sur la ligne diagonale à toutes les stations.

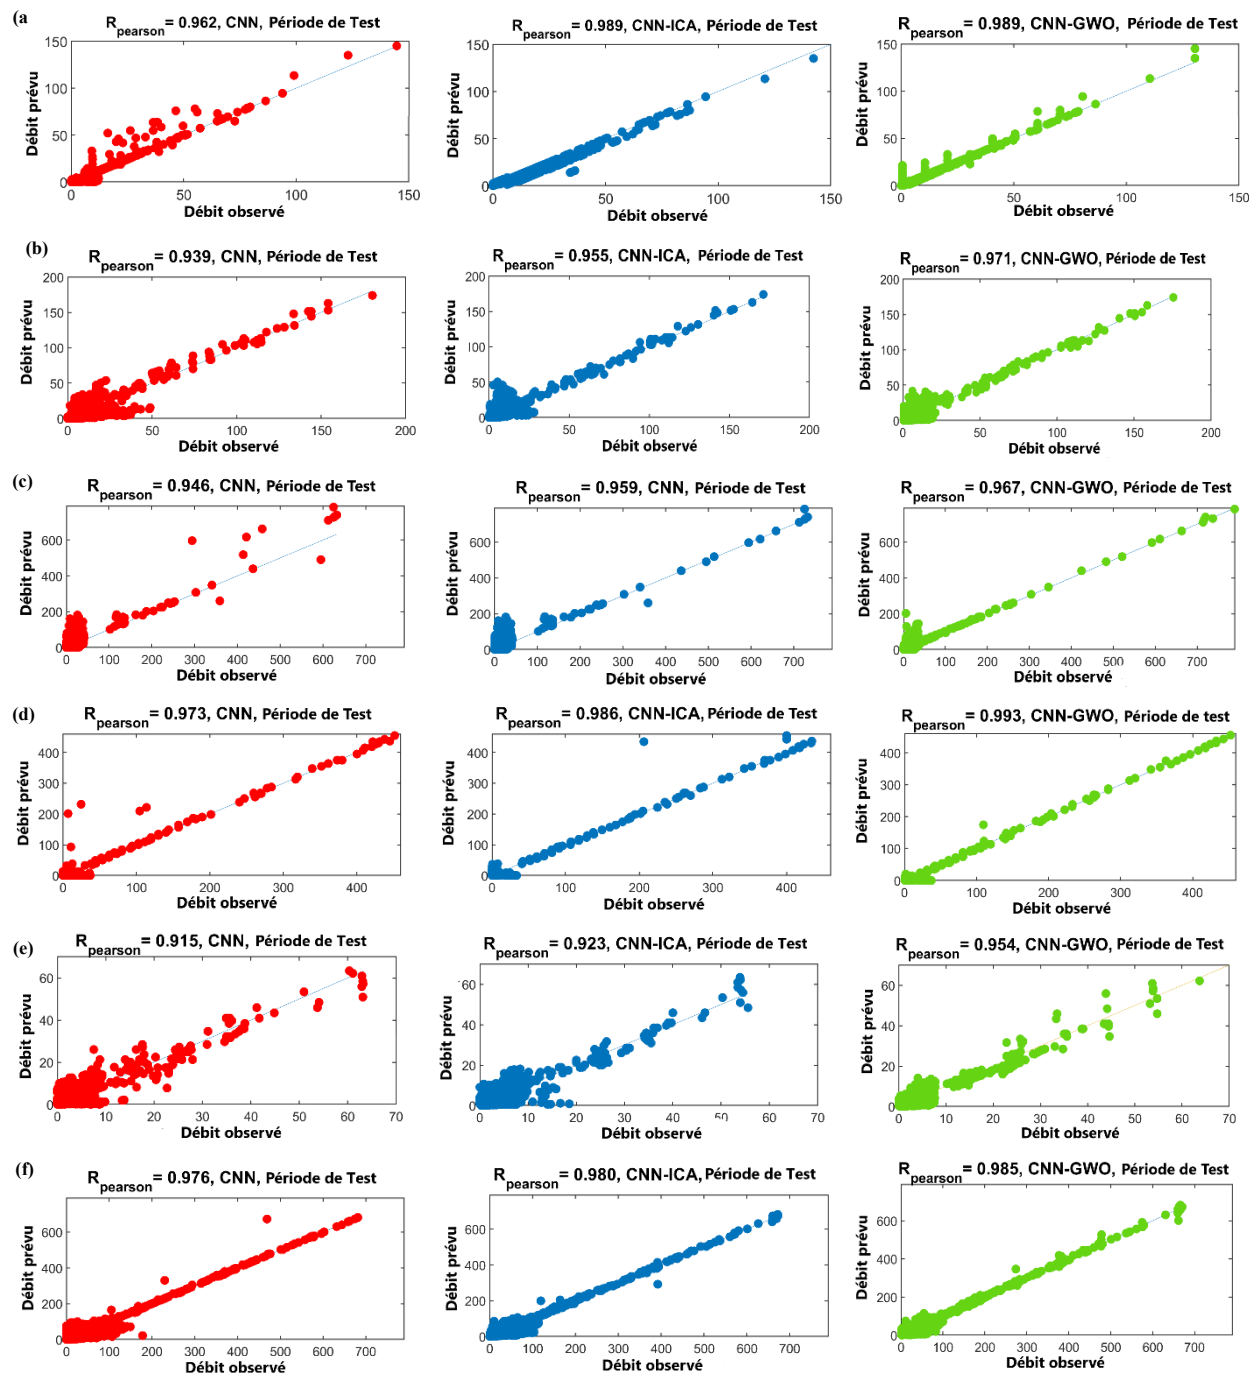


Figure 8. 7. Diagrammes de dispersion du débit horaire observé et prévu par CNN, CNN-ICA et CNN-GWO en utilisant CI à a) Ain Berda, b) Bordj-Sabath, c) Bouchegouf, d) Medjez-Amar II , e) Moulin Rochefort et f) Mirebek pour la période de test.

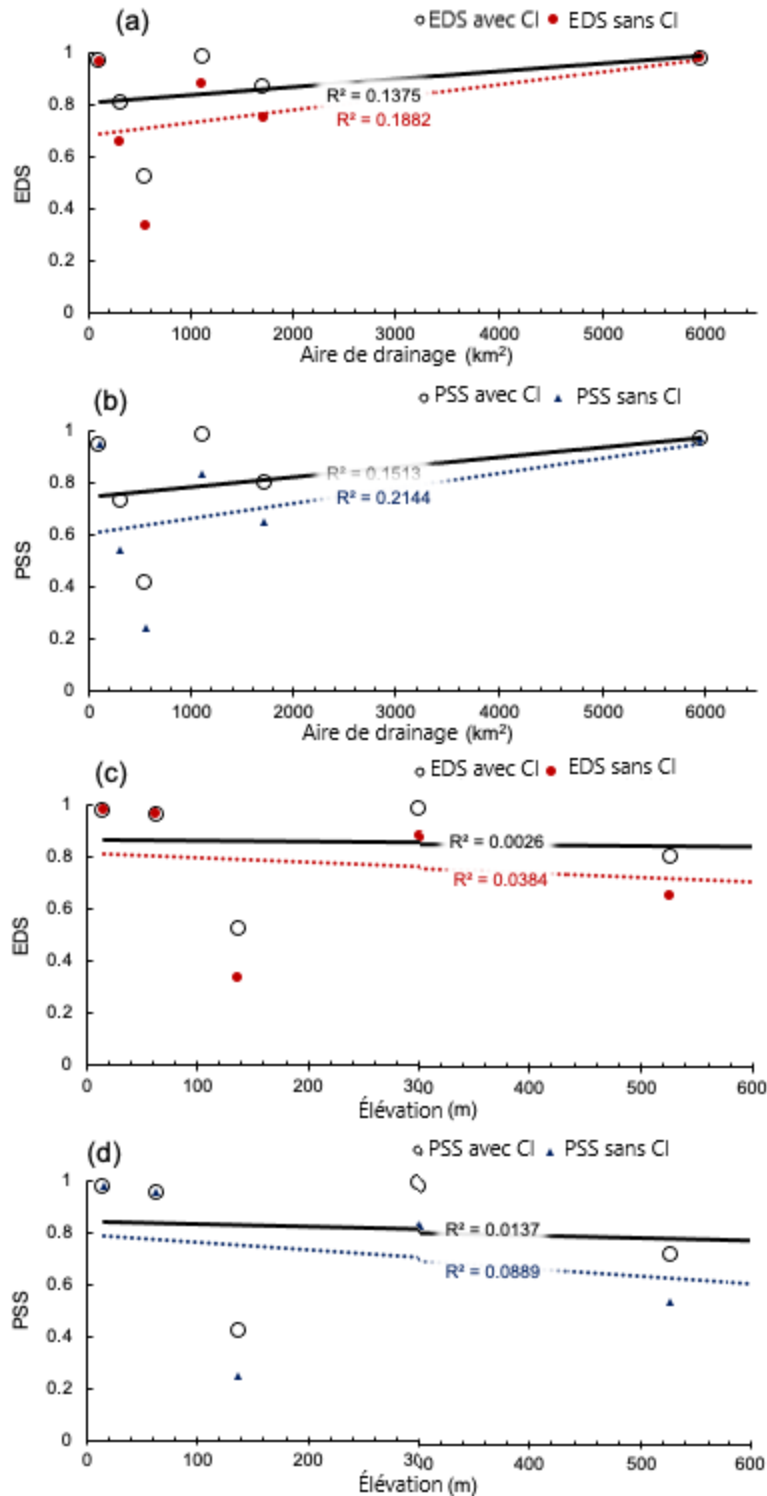


Figure 8. 8. Présentation du score de dépendance extrême (EDS) et score de compétence de Peirce (PSS) pour les débits extrêmes prévus par CNN-GWO avec et sans indices climatiques (CI) en fonction de a) et b) l’aire drainante et c) et d) l’élévation pour la période de validation du modèle.

Nous avons constaté que l'inclusion d'indices de variabilité climatique améliorait les débits extrêmes dans les bassins avec des zones de drainage comprises entre 200 km² et 2000 km², mais pas nécessairement les petits bassins (moins de 200 km²) ou les grands bassins (~6000 km²) (Figure 8.8 a&b). L'utilisation d'indices de variabilité climatique en plus des variables météorologiques obtenues à partir des produits de réanalyse comme entrées du modèle CNN-GWO, a amélioré les prévisions extrêmes avec l'élévation. À l'exception des bassins de basse élévation (Figure 8.8 c&d), les bassins avec des élévations comprises entre 100 m et 600 m ont montré une forte réponse aux indices de variabilité climatique et leurs EDS et PSS ont augmenté de près de 20 %. Ceci est en contradiction avec les conclusions de (Rasouli et al., 2012) qui ont montré que les apports climatiques ne peuvent pas améliorer les compétences de prévision pour les prévisions de débit extrême à court terme, peut-être parce que la variabilité climatique peut influencer le débit extrême à court terme dans les bassins semi-arides et de faible élévation tels que Seybouse en Algérie, mais pas dans les bassins d'amont humides à haute élévation tels que le lac des Esclaves en Colombie-Britannique, au Canada.

Bien que le modèle de CNN se soit avéré puissant et hautement prédictif pour $Q(t)$, il n'a pas été en mesure de prédire les pics de débit avec le même degré de précision que les autres. Cela pourrait être dû à leurs paramètres, qui, comme d'autres modèles de réseaux de neurones, nécessitent une optimisation. Les deux approches méta-heuristiques de l'ICA et de GWO intégrées à CNN pour sélectionner automatiquement les valeurs des paramètres du modèle, ont surpassé CNN autonome pour la prédiction de $Q(t)$ et pourraient parfaitement prévoir les valeurs maximales dans toutes les stations d'étude. Cependant, par rapport à d'autres modèles, le $Q(t)$ horaire prédit à l'aide du modèle CNN-GWO était moins dispersé et correspondait le mieux aux valeurs observées. Il est suivi par CNN-ICA et CNN. Selon la qualité de la catégorisation de l'ajustement pour les statistiques de corrélation R , les deux modèles hybrides (CNN-ICA et CNN-GWO) et le modèle autonome présentaient des ajustements « excellents » pour la prévision $Q(t)$. La valeur maximale est essentielle dans le processus de prédiction car les valeurs élevées de $Q(t)$ sont importantes pour surveiller les ressources en eau, résoudre les problèmes de qualité et de quantité de l'eau tels que la prévision des crues et les interactions écologiques et biologiques dans l'environnement aquatique, et des plans de gestion précis des bassins versants. En conséquence, le plan de gestion échouerait si le modèle anticipait incorrectement les valeurs maximales. Par conséquent, le modèle optimal est celui qui prédit correctement la valeur la plus élevée, en plus d'avoir un niveau de précision élevé. Dans l'ensemble, les résultats ont montré que CNN-GWO était le meilleur et qu'il pouvait prévoir avec précision la valeur maximale pour les six stations d'étude.

La présente recherche a indiqué que CNN peut simuler un processus non linéaire et compliqué en utilisant une variété de variables d'entrée atmosphériques et climatiques. De plus, les modèles

hybrides ont amélioré la capacité de prédiction de l'algorithme CNN autonome en utilisant des méthodes métaheuristiques. Les techniques hybrides sont considérées comme plus appropriées pour la modélisation environnementale ; en raison de la flexibilité accrue du modèle, de la détermination correcte des valeurs des paramètres du modèle et de l'amélioration des impacts combinés de deux modèles indépendants (Pham et al., 2019). Les algorithmes CNN présentent de nombreux avantages par rapport aux algorithmes d'Intelligence Artificiel traditionnels : (i) ils sont performants en termes de calcul ; (ii) ils ont plusieurs couches cachées, qui améliorent la précision des prédictions ; (iii) ils identifient instantanément les principales caractéristiques sans aucune supervision humaine ; (iv) ils mettent en œuvre des opérations spécifiques de convolution et de mutualisation (pooling), ainsi que le partage de paramètres ; et (v) ils utilisent des modèles hiérarchiques dans les données et les organisent. Le modèle CNN-GWO a été classé comme le plus précis pour prédire les valeurs de débit, où GWO était plus efficace pour réduire à la fois la variation et le biais par rapport à l'algorithme ICA. L'algorithme GWO est connu par de nombreux avantages tels que; sa simplicité de mise en œuvre, ses exigences de calcul réduites, sa convergence plus rapide et son potentiel d'éviter les minima locaux (Hameed et al., 2016).

Il s'agit de la première recherche non seulement évaluant la précision des prédictions d'algorithmes d'apprentissage en profondeur améliorés pour la prédiction du débit, mais appliquant également plusieurs variables d'entrée dérivées du Climate Prediction Center et d'ERA5 la réanalyse de cinquième génération de l'ECMWF pour le climat et la météo mondiaux. De nombreuses recherches ont utilisé des algorithmes de RNA pour prédire les processus pluie-débit à l'aide de données in situ, la plupart d'entre elles ont conclu que le RNA est une technique précise (Benzineb & Remaoun, 2018; Machado et al., 2011; Rajurkar et al., 2002b; Srinivasulu & Jain, 2006b). Récemment, certaines études ont montré la supériorité des modèles SVM et ANFIS sur d'autres algorithmes dans la prédiction du débit (Khosravi et al., 2020; Roy et al., 2021; Samantaray & Ghose, 2020b; Tikhamarine et al., 2020b). D'après ce qui précède, il est évident qu'il n'y a pas d'accord universel sur le modèle qui fonctionne le mieux. Ainsi, dans une nouvelle recherche, de nombreux modèles doivent être étudiés pour découvrir le modèle optimal. En conséquence, l'analyse des performances des algorithmes nouvellement créés est essentielle (comme la méthode d'apprentissage en profondeur de CNN dans cette recherche).

Conclusion

La dernière partie de cette étude était consacrée à l'application du modèle CNN pour la prévision des débits de crues horaire. Les paramètres de ce modèle ont été optimisés en utilisant l'algorithme concurrentiel impérialiste (ICA) et l'algorithme de Gray Wolf (GWO). Cette hybridation nous a donné deux modèles; CNN-ICA et CNN-GWO pour améliorer la qualité des prévisions par rapport aux résultats obtenus par les modèles simples de l'intelligence artificielle. Des données horaires atmosphérique, des indices de variabilité climatique et des observations horaires in situ de débit ont été utilisées pour développer tous les modèles proposés.

Les résultats ont révélé que les trois modèles développés sont précis et efficaces pour prévoir le débit horaire. Cependant, les modèles qui utilisent des indices climatiques améliorent nettement la qualité de la prévision, en particulier pour capturer le débit extrême à de multiples échelles spatiales comprises entre 200 km² et 2000 km², et le CNN-GWO intégré a dépassé, en termes de convergence des critères d'efficacité, les algorithmes CNN-ICA et CNN autonome. Cela indique la supériorité de l'algorithme GWO dans l'optimisation de la capacité de prédiction du CNN standard pour améliorer sa précision dans la prévision de débit.

CONCLUSION GÉNÉRALE

Conclusion générale

L'objectif principal de cette étude est de modéliser le processus pluie-débit au pas de temps journalier, et les débits de crues au pas de temps horaire dans un milieu semi-aride. La prévision hydrologique représente un axe de recherche important en hydrologie car elle permet de comprendre les mécanismes de génération des débits et d'anticiper les phénomènes hydrologiques extrêmes tels que les sécheresses et les inondations. Dans cette étude, et dans un premier temps nous avons modéliser la relation pluie-débit par le modèle conceptuel a réservoir GR4J, ensuite, exploré le potentiel et la pertinence des méthodes d'intelligence artificiel (réseau de neurones artificiels RNA et réseau de neurones convolutifs CNN) en utilisant des techniques de prétraitement des données dans la prévision des débits fluviaux en séries chronologiques à six stations de jaugeage du bassin de Seybouse en Algérie ; afin de mieux comprendre son comportement hydrologique.

La première étape de cette thèse, consiste tout d'abord à simuler la transformation de la pluie en débit en utilisant le modèle conceptuel GR4J, et ensuite à tester la faisabilité des réseaux de neurones artificiels (RNA) avec différentes configurations d'entrée. En effet, quatre modèles principaux ont été développés, optimisés et comparés entre eux afin d'estimer le débit journalier, à six stations réparties dans la zone d'étude puis à l'ensemble du bassin. Le modèle à entrée unique RNA I_P considère uniquement les précipitations comme variable d'entrée. Le modèle à deux entrées RNA $II_{P,ETP}$, RNA $II_{P,T}$, RNA $II_{P,HUM}$, RNA $II_{P,VV}$ considère l'évapotranspiration, la température, l'humidité ou la vitesse du vent dans l'entrée du modèle avec les précipitations. Le modèle à trois entrées RNA $III_{P,T,HUM}$ combine la température et l'humidité avec les précipitations. Le dernier (RNA $V_{P,ETP,T,HUM,VV}$) consiste à collationner les différents paramètres météorologiques avec les précipitations comme variable d'entrée. Ensuite, appliquer les quatre configurations précédentes à l'ensemble du bassin.

Les résultats obtenus à partir des différents modèles utilisés sont :

- Le modèle conceptuel GR4J a donnée des mauvais résultats pour les six stations, raison qui nous a encouragés de changer l'axe de recherche vers les modèles boite noire notamment les RNA dans un premier temps.
- Les résultats obtenus par les quatre configurations de RNA sont largement performant que le modèle GR4J,
- Les modèles à deux entrées RNA $II_{P,T}$ et RNA $II_{P,VV}$ ont fournies des meilleures simulations d'écoulement pour les deux stations Medjez-Amar II et Bordj-Sabath, respectivement.

- Le modèle à cinq entrées RNA $V_{P,ETP,T,HUM,Vv}$ a montré des résultats très satisfaisants pour les stations Moulin Rechefort, Bouchegouf, Mirebek et Ain Berda et également pour l'ensemble du bassin.
- les modèles RNA proposés sont recommandés pour la modélisation pluie-débit journalier en région semi-aride, en raison de leurs structures simples et de leur précision qui nous aide à résoudre les problèmes liés à la gestion des ressources en eau.

La deuxième contribution concerne l'élaboration des modèles hybrides de prédiction des débits journalier. Ces modèles combinent le réseau de neurone artificiel et des algorithmes métaheuristiques. Quatre modèles hybrides ont été développés ; réseau de neurone artificiel couplé avec l'optimisation d'essaim de particules amélioré RNA-IPSO, l'algorithme génétique RNA-GA, l'optimisation d'essaim de particules RNA-PSO et l'algorithme de luciole RNA-FFA. La sélection des ensembles de données d'entrées des modèles était constituée des précipitations et des débits antérieurs effectuée à l'aide des fonctions d'autocorrélation (ACF), d'autocorrélation partielle (PACF) et de corrélation croisée (CCF).

Les résultats révélés sont :

- Les modèles hybrides RNA-GA, RNA-PSO et RNA-FFA peuvent être utilisés dans la modélisation du processus pluie-débit.
- Le modèle RNA-IPSO offre des estimations plus fiable comparé aux RNA-GA, RNA-PSO et RNA-FFA.
- L'algorithme IPSO est très efficace dans l'amélioration des paramètres du modèle RNA et le renforcement de ses performances de prévision.
- Le modèle RNA optimisé par IPSO peut ainsi être utilisé dans différentes fonctionnalités et, plus particulièrement en hydrologie et ses disciplines connexes.

La troisième contribution consiste à l'élaboration et au développement d'une nouvelle méthode d'apprentissage en profondeur (DL); réseau de neurones convolutifs autonome (CNN) et amélioré par des algorithmes métaheuristiques. Trois modèles principaux ont été développés ; CNN autonome, CNN couplé avec l'algorithme concurrentiel impérialiste CNN-ICA et CNN avec l'algorithme d'optimisation du loup gris pour la prédiction des débits de crues. L'ensemble des données utilisée, est constituée de données horaires de réanalyse atmosphérique ERA5 telles que les précipitations totales, la température de l'air à 2 m, la pression de surface, la vitesse du vent, la température du sol et l'humidité volumétrique du sol, des indices de variabilité climatique (AAO, AO, NAO, PNA et SST dans la région Niño 3.4) et des observations horaires in situ de débit, et la sélection des entrées est effectuée à l'aide de l'analyse en composante principale.

Les résultats obtenues sont :

- Les trois modèles développés CNN, CNN-ICA et CNN-GWO ont montrés une efficacité importante à la prédiction des débits de crues
- Les modèles qui utilisent les indices climatiques améliore nettement la qualité de prévision, en particulier pour capturer le débit extrême à de multiples échelles spatiales comprises entre 200 km² et 2000 km²,
- Le modèle CNN-GWO a dépassé les algorithmes CNN-ICA et CNN autonome.
- L'algorithme GWO a avérée une supériorité dans l'optimisation de la capacité de prédiction du CNN standard et améliorer sa précision dans la prévision de débit.
- Le modèle CNN a développé un avantage concurrentiel par rapport aux techniques d'apprentissage automatique standard en raison de sa flexibilité accrue et de sa puissance prédictive pour résoudre des problèmes de plus en plus difficiles.

RÉFÉRENCE BIBLIOGRAPHIQUES

Références bibliographiques

- ABH, Décret exécutif N°96-100 du 17 Chaoual 1416 correspondant au 06 mars 1996 portant définition du bassin hydrographiques et fixant le status- type des établissements publics de gestion. [Access 20.07.2020]. <http://extwprlegs1.fao.org/docs/pdf/alg41379.pdf>.
- Adnan, R. M., Liang, Z., Heddam, S., Zounemat-Kermani, M., Kisi, O., & Li, B. (2020). Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology*, 586, 124371. <https://doi.org/10.1016/j.jhydrol.2019.124371>
- Ague, A. I. (2014). ETUDE COMPARATIVE D'UN MODELE CONCEPTUEL GLOBAL (GR4J) ET D'UN MODELE SEMI-DISTRIBUE (GEOSFM) SUR LE BASSIN VERSANT DE L'OUEME A SAVE (BENIN, AFRIQUE DE L'OUEST). *Revue scientifique et technique. LJEE N 24 & 25*.
- Ahmad, A. L., Azid, I. A., Yusof, A. R., & Seetharamub, K. N. (2004). Emission control in palm oil mills using artificial neural network and genetic algorithm. *Computers and Chemical Engineering*, 7.
- Albert H, H., Henry M, H., & Azmoodeh, M. (1993). Predicting runoff from rainfall using neural networks. *Civil engineering database*.
- Alizamir, M., & Sobhanardakani, S. (2018). An Artificial Neural Network—Particle Swarm Optimization (ANN- PSO) Approach to Predict Heavy Metals Contamination in Groundwater Resources. *Jundishapur Journal of Health Sciences*, 10(2). <https://doi.org/10.5812/jjhs.67544>
- Aly, A. H., & Peralta, R. C. (1999). Comparison of a genetic algorithm and mathematical programming to the design of groundwater cleanup systems. *Water Resources Research*, 35(8), 2415–2425. <https://doi.org/10.1029/1998WR900128>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Ambroise, B. (1998). *La dynamique du cycle de l'eau dans un bassin versant—Processus, Facteurs, Modèles HGA*, Bucarest, 200p.
- Amireche, M., (2019). *MODELISATION DE LA RELATION PLUIE-DEBIT A DIFFERENTS PAS DE TEMPS PAR LES MODELES CONCEPTUELS, NEUROFLOUS ET PAR LE FILTRE DE KALMAN*. Thèse de Doctorat. Université Kasdi Merbah- Ouargla.

- Ammar, A., Darwish, Q. A., & Slieman, A. (2018). INFILLING DAILY PRECIPITATION DATA USING FEEDFORWARD BACK-PROPAGATION ARTIFICIAL NEURAL NETWORKS (ANN), HAMA, SYRIA. American Journal of Innovative Research and Applied Sciences. ISSN 2429-5396.
- ANDRÉASSIAN, V. (2002). Impact de l'évolution du couvert forestier sur le comportement hydrologique des bassins versants. Thèse de Doctorat. UNIVERSITE PARIS 6.
- Andries P, E. (2007). Computational Intelligence An introduction second Edition [livre]. University of pretoria south Africa.
- Aqil, M., Kita, I., Yano, A., & Nishiyama, S. (2007). A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. Journal of Hydrology, 337(1), 22–34. <https://doi.org/10.1016/j.jhydrol.2007.01.013>
- Asadnia, M., Chua, L. H. C., Qin, X. S., ASCE, A. M., & Talei, A. (2014). Improved Particle Swarm Optimization–Based Artificial Neural Network for Rainfall-Runoff Modeling. JOURNAL OF HYDROLOGIC ENGINEERING, 19, 1320–1329.
- ASCE. (2000). Artificial Neural Networks in Hydrology. I: Preliminary Concepts | Journal of Hydrologic Engineering | Vol 5, No 2. <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%291084-0699%282000%295%3A2%28115%29>
- Ashraf Vaghefi, S., Mousavi, S. J., Abbaspour, K. C., & Yang, H. (2012). An Imperialist Competitive Algorithm Artificial Neural Network Method to Predict Runoff. Geophysical Research Abstracts Vol. 14, EGU2012-484-2, 2012.
- AZZAZ H., 2001. Impact du climat sur les ressources en eau superficielles et souterraines dans les bassins versants de la haute et la moyenne Tafna. Mémoire de magister, C.U.Mascara, novembre 2001.
- Atashpaz-Gargari, E., & Lucas, C. (2007). Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition. 2007 IEEE Congress on Evolutionary Computation, 4661–4667. <https://doi.org/10.1109/CEC.2007.4425083>
- Balavalikar, S., Nayak, P., Shenoy, N., & Nayak, K. (2018). Particle swarm optimization based artificial neural network model for forecasting groundwater level in Udupi district. INTERNATIONAL CONFERENCE ON ELECTRICAL, ELECTRONICS, MATERIALS AND APPLIED SCIENCE. Secunderabad, India. 020021-8. <https://doi.org/10.1063/1.5031983>.
- Barkhoda, W., & Sheikhi, H. (2020). Immigrant imperialist competitive algorithm to solve the multi-constraint node placement problem in target-based wireless sensor networks. Ad Hoc Networks, 106, 102183. <https://doi.org/10.1016/j.adhoc.2020.102183>

- Barzegar, R., Aalami, M. T., & Adamowski, J. (2020). Short-term water quality variable prediction using a hybrid CNN–LSTM deep learning model. *Stochastic Environmental Research and Risk Assessment*, 34(2), 415–433. <https://doi.org/10.1007/s00477-020-01776-2>
- Bashir, Z. A., & El-Hawary, M. E. (2009). Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks. *IEEE TRANSACTIONS ON POWER SYSTEM*, 24, NO. 1.
- Behzad, M., Asghari, K., Eazi, M., & Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36(4), 7624–7629. <https://doi.org/10.1016/j.eswa.2008.09.053>
- BELARBI, H. (2017). Modélisation et régionalisation de la relation « pluie-débit » face au changement climatique: Impact sur les ressources en eau. Thèse de Doctorat. Université Abou Bekr Belkaid-Tlemcen.
- Benzer, S., & Benzer, R. (2018). Modelling Nitrate Prediction of Groundwater and Surface Water Using Artificial Neural Networks. *Journal of Polytechnic*, 21(2):321-325, ISSN: 2147-9429.
- Benzineb, K., & Remaoun, M. (2016). Daily rainfall-runoff modelling by neural networks in semi-arid zone: Case of Wadi Ouahrane's basin. *Journal of Fundamental and Applied Sciences*, 8(3), 956. <https://doi.org/10.4314/jfas.v8i3.17>
- BENZINEB, K., REMAOUN, M., & RENIMA, M. (2018). MODELISATION PLUIE-DEBIT JOURNALIER PAR UN MODELE CONCEPTUEL LE GR4J ET LES RESEAUX DE NEURONES EN ZONE SEMI-ARIDE«CAS DU BASSIN DE OUED OUAHRANE». 2nd International Conference on Water Resources (ICWR), 6.
- BENZINEB, K., (2017). MODELISATION DES DEBITS DE CRUES DU BASSIN DE OUED OUAHRANE PAR LES RESEAUX DE NEURONES ARTIFICIELS. Thèse de Doctorat. Université Hassiba Benbouali de Chlef.
- Benkaci, T. (2006). Modélisation pluie-débit mensuelle et Journalière par les modèles conceptuels Et les systèmes neuro-flous (application aux bassins algériens). Thèse de doctorat. Institut National Agronomique D'Alger. 221 p.
- Benkaci Ali T. et Dechemi N. (2004) Modélisation pluie-débit journalière par les modèles conceptuels et 'boit noire', test d'un modèle neuroflou. *Journal des sciences hydrologiques* 4(21).
- Berthet, L. (2010). Préviation des crues au pas de temps horaire: Pour une meilleure assimilation de l'information de débit dans un modèle hydrologique. Thèse de doctorat. Institut des Sciences et Industries du Vivant et de l'Environnement. AgroParisTech.
- Berthier, C.-H. (2005). Quantification des incertitudes des débits calculés par un modèle pluie-débit empirique. Mémoire de master. Université Paris-sud 11.

- Birikundavyi, S., Labib, R., Trung, H. T., & Rousselle, J. (2002). Performance of Neural Networks in Daily Streamflow Forecasting. *JOURNAL OF HYDROLOGIC ENGINEERING*, q7, 392–398.
- Bhattacharjya, R. K., & Datta, B. (2009). ANN-GA-Based Model for Multiple Objective Management of Coastal Aquifers. *Journal of Water Resources Planning and Management*, 135(5), 314–322. [https://doi.org/10.1061/\(ASCE\)0733-9496\(2009\)135:5\(314\)](https://doi.org/10.1061/(ASCE)0733-9496(2009)135:5(314))
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition* [livre]. Institute for Adaptive and Neural Computation Division of Informatics Edinburgh University.
- Bois, M. P., Moussa, M. R., de MARSILY, M. G., Michel, M. C., Javelle, M. P., & Duband, M. D. (2005). Nouvelle méthode de prévision de crue utilisant un modèle pluie-débit global. Thèse de doctorat. ECOLE PRATIQUE DES HAUTES ETUDES DE PARIS.
- BOURQUI, M. (2008). Impact de la variabilité spatiale des pluies sur les performances des modèles hydrologiques. Thèse de doctorat. ECOLE NATIONALE DU GENIE RURAL, DES EAUX ET DES FORÊTS. AgroParisTech.
- Bouzeria, H., 2018. Quantification et modélisation des transports solides, cartographie des zones à risques d'érosion hydrique à partir d'une base de données gérée par un SIG : application aux bassins de Bounamoussa et Mellah (Nord-Est algérien). Thèse de Doctorat. Université Abou bakr Belkaïd, Tlemcen.
- BOULFEKHAR, Z., BENDAS, S. (2016). Modélisation pluie – débit : calage et validation des modèles hydrologiques sur le bassin de l'Oued Rhumel-Smendou (Nord-Est Algérien). Mémoire de master. Centre Universitaire Abdelhafid Boussouf – Mila.
- Bozorg-Haddad, O., Zarezadeh-Mehrizi, M., Abdi-Dehkordi, M., Loáiciga, H. A., & Mariño, M. A. (2016). A self-tuning ANN model for simulation and forecasting of surface flows. *Water Resources Management*, 30(9), 2907–2929. <https://doi.org/10.1007/s11269-016-1301-2>
- Bui, D. T., Panahi, M., Shahabi, H., Singh, V. P., Shirzadi, A., Chapi, K., Khosravi, K., Chen, W., Panahi, S., Li, S., & Ahmad, B. B. (2018). Novel Hybrid Evolutionary Algorithms for Spatial Prediction of Floods. *Scientific Reports*, 8(1), 15364. <https://doi.org/10.1038/s41598-018-33755-7>
- Burchard-Levine, A., Liu, S., Vince, F., Li, M., & Ostfeld, A. (2014). A hybrid evolutionary data driven model for river water quality early warning. *Journal of Environmental Management*, 143, 8–16. <https://doi.org/10.1016/j.jenvman.2014.04.017>
- Carlisle, D. (2001). *An Off-The-Shelf PSO*. 6.

- Changjun Zhu, Xiujian Zhao, & Jihong Zhou. (2009). ANN based on PSO for surface water quality evaluation model and its application. 2009 Chinese Control and Decision Conference, 3264–3268. <https://doi.org/10.1109/CCDC.2009.5192292>
- Chau, K. (2004). Rainfall-Runoff Correlation with Particle Swarm Optimization Algorithm. *Advances in Neural Networks*, 3174, 970–975.
- Chau, K. W. (2006). Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. *Journal of Hydrology*, 329, 363–367.
- Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A Review of the Artificial Neural Network Models for Water Quality Prediction. *Applied Sciences*, 10(17), 5776. <https://doi.org/10.3390/app10175776>
- Cheng, C., Niu, W., Feng, Z., Shen, J., & Chau, K. (2015). Daily Reservoir Runoff Forecasting Method Using Artificial Neural Network Based on Quantum-behaved Particle Swarm Optimization. *Water*, 7, 4232–4246.
- Chi Zhou, Liang Gao, Haibing Gao, & Chuanyong Peng. (2006). Pattern Classification and Prediction of Water Quality by Neural Network with Particle Swarm Optimization. 2006 6th World Congress on Intelligent Control and Automation, 2864–2868. <https://doi.org/10.1109/WCICA.2006.1712888>
- Chitsazan, M., Rahmani, G., & Neyamadpour, A. (2013). Groundwater level simulation using artificial neural network: A case study from Aghili plain, urban area of Gotvand, south-west Iran. *JGeope* 3 (1), 2013, P. 35-46.
- Cieniawski, S. E., Eheart, J. W., & Ranjithan, S. (1995). Using Genetic Algorithms to Solve a Multiobjective Groundwater Monitoring Problem. *Water Resources Research*, 31(2), 399–409. <https://doi.org/10.1029/94WR02039>
- CLARKE, R. T. (1973). A REVIEW OF SOME MATHEMATICAL MODELS USED IN HYDROLOGY, WITH OBSERVATIONS ON THEIR CALIBRATION AND USE. *Journal of Hydrology*. Volume 19, Issue 1, May 1973, Pages 1-20. [https://doi.org/10.1016/0022-1694\(73\)90089-9](https://doi.org/10.1016/0022-1694(73)90089-9).
- Cordoba, G. A. C., Tuhovčák, L., & Tauš, M. (2014). Using Artificial Neural Network Models to Assess Water Quality in Water Distribution Networks. *Procedia Engineering*, 70, 399–408. <https://doi.org/10.1016/j.proeng.2014.02.045>
- Cybenkot, G. (1989). Approximation by superpositions of a sigmoidal function. *Math. Control Signals Systems* (1989)2:303-314.
- Danandeh Mehr, A., Nourani, V., Karimi Khosrowshahi, V., & Ghorbani, M. A. (2019). A hybrid support vector regression–firefly model for monthly rainfall forecasting. *International Journal of*

- Environmental Science and Technology, 16(1), 335–346. <https://doi.org/10.1007/s13762-018-1674-2>
- Darbandi, S., & Pourhosseini, F. A. (2018a). River flow simulation using a multilayer perceptron-firefly algorithm model. *Applied Water Science*, 8(3), 85. <https://doi.org/10.1007/s13201-018-0713-y>
- Darbandi, S., & Pourhosseini, F. A. (2018b). River flow simulation using a multilayer perceptron-firefly algorithm model. *Applied Water Science*, 8(3), 85. <https://doi.org/10.1007/s13201-018-0713-y>
- Dawson, C. W., & Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 43(1), 47–66. <https://doi.org/10.1080/02626669809492102>
- Dhange, N. R., Atmapoojya, S. L., & Kadu, M. S. (2012). Genetic Algorithm Driven ANN Model for Runoff Estimation. 2nd International Conference on Communication, Computing & Security [ICCCS-2012]. *Procedia Technology* 6 (2012) 501 – 508.
- Diamantopoulou, M. J., Papamichail, D. M., & Antonopoulos, V. Z. (2005). The use of a Neural Network technique for the prediction of water quality parameters. *Operational Research*, 5(1), 115–125. <https://doi.org/10.1007/BF02944165>
- Djurovic, N., Domazet, M., Stricevic, R., Pocuca, V., Spalevic, V., Pivic, R., Gregoric, E., & Domazet, U. (2015). Comparison of Groundwater Level Models Based on Artificial Neural Networks and ANFIS. *The Scientific World Journal*, 14.
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4), 1015–1031. <https://doi.org/10.1029/91WR02985>
- Ebtehaj, I., & Bonakdari, H. (2016). A support vector regression-firefly algorithm-based model for limiting velocity prediction in sewer pipes. *Water Science and Technology*, 73(9), 2244–2250. <https://doi.org/10.2166/wst.2016.064>
- Ebtehaj, I., Bonakdari, H., Shamshirb, S., I., Z., & Hashim, R. (2016). New Approach to Estimate Velocity at Limit of Deposition in Storm Sewers Using Vector Machine Coupled with Firefly Algorithm. *J. Pipeline Syst. Eng. Pract.*, 12.
- Edijatno, & Michel, C. (1989). Un modèle pluie-débit journalier à trois paramètres. *La Houille Blanche*, 75(2), 113–122. <https://doi.org/10.1051/lhb/1989007>.
- Edijatno, O. (1991). Mise au point d'un modèle élémentaire pluie-débit au pas de temps journalier. Thèse de Doctorat. Université Louis Pasteur/ENGEEES, Strasbourg. 242 p.

- Edijatno, O., Nascimento, N., Yang, X., Makhlof, Z. et Michel, C. (1999). GR3J: a daily watershed model with three free parameters. *Hydrological Sciences Journal* . 44(2), 263-277.
- ELOUISSI A. (2004) : impact des changements climatiques sur les ressources hydriques et la diversité biologique. Mémoire de magister, C.U.Mascara.
- Emami, S., & Parsa, J. (2020). Comparative evaluation of imperialist competitive algorithm and artificial neural networks for estimation of reservoirs storage capacity. *Applied Water Science*, 10(7), 177. <https://doi.org/10.1007/s13201-020-01259-3>
- Fallah Ghalhary, G. A., Mousavi Baygi, M., & Habibi Nokhandan, M. (2009). Seasonal Rainfall Forecasting Using Artificial neural network. *Journal of Applied Sciences*, 9(6), 1098–1105.
- Foram S, P., & Mahesh, P. (2014). Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network. *International Journal of Computer Science and Mobile Computing*, Vol. 3, Issue. 11, 455–464.
- French, M. N., Krajewski, W. F., & Cuykendall, R. R. (1992). Rainfall forecasting in space and time using a neural network. *Journal of Hydrology*, 137, 1–31.
- Gaur, S., Ch, S., Graillot, D., Chahar, B. R., & Kumar, D. N. (2013). Application of Artificial Neural Networks and Particle Swarm Optimization for the Management of Groundwater Resources. *Water Resources Management*, 27(3), 927–941. <https://doi.org/10.1007/s11269-012-0226-7>
- Gaur, S., Chahar, B. R., & Graillot, D. (2011). Analytic elements method and particle swarm optimization-based simulation–optimization model for groundwater management. *Journal of Hydrology*, 402, 217–227.
- Ghachi, A. (1986). *Le bassin de la Seybouse: Hydrologie et utilisation de la ressource en eau en Algérie*. Office des publications universitaires.
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation. 7. University of Texas at El Paso DigitalCommons@UTEP
- Gill, M. K., Kaheil, Y. H., Khalil, A., McKee, M., & Bastidas, L. (2006). Multiobjective particle swarm optimization for parameter estimation in hydrology. *Water Resour*, 42.
- 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 [livre]*.

- Gordan, B., Armaghani, D. J., Hajihassani, M., & Monjezi, M. (2016). Prediction of seismic slope stability through combination of particle swarm optimization and neural network. *Engineering with Computers*, 32, 85–97.
- Grossberg, S. (1982). Processing of expected and unexpected events during conditioning and attention: A psychophysiological theory. *Psychological Review*, 89(5), 529–572. <https://doi.org/10.1037/0033-295X.89.5.529>
- Gupta, R., Singh, A. N., & Singhal, A. (2019). Application of ANN for Water Quality Index. *International Journal of Machine Learning and Computing*, 9(5), 688–693. <https://doi.org/10.18178/ijmlc.2019.9.5.859>
- Hadi, S. J., Abba, S. I., Sammen, S. Sh., Salih, S. Q., Al-Ansari, N., & Yaseen, Z. M. (2019). Non-Linear Input Variable Selection Approach Integrated With Non-Tuned Data Intelligence Model for Streamflow Pattern Simulation. *IEEE Access*, 7, 141533–141548. <https://doi.org/10.1109/ACCESS.2019.2943515>
- Haidar, A., & Verma, B. (2018). Monthly Rainfall Forecasting Using One-Dimensional Deep Convolutional Neural Network. *IEEE Access*, 6, 69053–69063. <https://doi.org/10.1109/ACCESS.2018.2880044>
- Hailegeorgis, T. T., & Alfredsen, K. (2015). Comparative evaluation of performances of different conceptualisations of distributed HBV runoff response routines for prediction of hourly streamflow in boreal mountainous catchments. *Hydrology Research*, 46(4), 607–628. <https://doi.org/10.2166/nh.2014.051>
- Hameed, I. A., Bye, R. T., & Osen, O. L. (2016). Grey wolf optimizer (GWO) for automated offshore crane design. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, 1–6. <https://doi.org/10.1109/SSCI.2016.7849998>
- Hassoun, M. H. (1995). *Fundamentals of Artificial Neural Networks [livre]*. The MIT Press.
- Hayder, G., Solihin, M. I., & Mustafa, H. M. (2020). Modelling of River Flow Using Particle Swarm Optimized Cascade-Forward Neural Networks: A Case Study of Kelantan River in Malaysia. *Applied Sciences*, 10(23), 8670. <https://doi.org/10.3390/app10238670>
- Hebb, D. O. (1949). *The organization of behavior: A neuropsychological theory*. New York: John Wiley and Sons, Inc., 1949. 335 p. \$4.00—1950—Science Education—Wiley Online Library. <https://onlinelibrary.wiley.com/doi/abs/10.1002/sce.37303405110>
- HENINE, H. (2005). *Interfaçage entre un modèle hydrologique / modèle hydrodynamique au sein d'un système d'information intégré sous web incluent les SIG*. Mémoire de magister. Ecole nationale polytechnique d'Alger.

- Hjelmfelt, A. T., & Wang, M. (1993a). "Artificial neural networks as unit hydrograph applications." Proc., Engrg. Hydrol., ASCE, New York, 754–759.
- Hjelmfelt, A. T., & Wang, M. (1993c). "Runoff hydrograph estimation using artificial neural networks." Proc., ASAE Conference, American Society of Agricultural Engineers, St. Joseph, Mich.
- Hjelmfelt, A. T., & Wang, M. (1993b). "Runoff simulation using ANN." Proc., 4th Int. Conf. In the Application of Artificial Intelligence to Civ. And Struct. Engrg.: NN and Combinatorial Optimization in Civ. And Struct. Engrg., B. H. V. Topping and A. I. Khan, eds., Civil-Comp Ltd., Edinburgh, U.K., 517–522.
- Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, 129, 273–285.
<https://doi.org/10.1016/j.eswa.2019.03.029>
- Hsu, K.L., Gupta, H.V. et Sorooshian, S. (1995). Artificial neural network modeling of the rainfall–rainoff process. *Water Resources Research*, 31(10) : 2517–2530.
- Istadi, I., & Amin, N. A. S. (2007). Modelling and optimization of catalytic–dielectric barrier discharge plasma reactor for methane and carbon dioxide conversion using hybrid artificial neural network—Genetic algorithm technique. *Chemical Engineering Science*, 14.
- Jahandideh-Tehrani, M., Jenkins, G., & Helfer, F. (2020). A comparison of particle swarm optimization and genetic algorithm for daily rainfall-runoff modelling: A case study for Southeast Queensland, Australia. *Optimization and Engineering*.
- Jahandideh-Tehrani, M., Jenkins, G., & Helfer, F. (2021). A comparison of particle swarm optimization and genetic algorithm for daily rainfall-runoff modelling: A case study for Southeast Queensland, Australia. *Optimization and Engineering*, 22(1), 29–50. <https://doi.org/10.1007/s11081-020-09538-3>
- Jain, A., & Srinivasulu, S. (2004). Development of effective and efficient rainfall-runoff models using integration of deterministic, real-coded genetic algorithms and artificial neural network techniques: RR MODELS USING REAL-CODED GA AND ANNS. *Water Resources Research*, 40(4).
<https://doi.org/10.1029/2003WR002355>
- Jarraud, M., & Bokova, I. (1990). *International Glossary of Hydrology*. 471.
- John C, R. (1994). *GUIDE TO HYDROLOGICAL PRACTICES*, Fifth edition 1994 [livre]. DATA ACQUISITION AND PROCESSING, ANALYSIS, FORECASTING AND OTHER APPLICATIONS.
- Jr, E. C., Poulton, M., Charles, E., Dustman, J., & Szidarovszky, F. (2003). Application of Artificial Neural Networks to Complex Groundwater Management Problems. *Natural Resources Research*, 18.

- Kabouya, M., 1990. Modélisation pluie-débit aux pas de temps mensuel et annuel en Algérie septentrionale. Thèse de Doctorat, Université Paris SudOrsay, 347 pp.
- Kabouya, M. et Michel, C., 1991. Estimation des ressources en eau superficielle aux pas de temps mensuel et annuel, application à un pays semi-aride. *Revue des Sciences de l'Eau* .
- Kalteh, A. M. (2017). Enhanced Monthly Precipitation Forecasting Using Artificial Neural Network and Singular Spectrum Analysis Conjunction Models. *INAE Lett* (2017) 2:73–81. DOI 10.1007/s41403-017-0025-9 9.
- Kampf, S. K., & Burges, S. J. (2007). A framework for classifying and comparing distributed hillslope and catchment hydrologic models: DISTRIBUTED MODEL REVIEW. *Water Resources Research*, 43(5). <https://doi.org/10.1029/2006WR005370>
- Karl E., T. (2001, April 1). Summarizing multiple aspects of model performance in a single diagram— *Journal of Geophysical Research: Atmospheres*—Wiley Online Library. <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2000JD900719>
- Karunanithi, N., Grenney, W. J., Whitley, D., & Bovee, K. (1994). NEURAL NETWORKS FOR RIVER FLOW PREDICTION. *Journal of Computing in Civil Engineering*, 8, 201–220.
- Kasisviswanathan, K. S., Cibin, R., Sudheer, K. P., & Chaubey, I. (2013). Constructing prediction interval for artificial neural network rainfall runoff models based on ensemble simulations. *Journal of Hydrology*, 499, 275–288. <https://doi.org/10.1016/j.jhydrol.2013.06.043>
- Kavousi-Fard, A., Samet, H., & Marzbani, F. (2014). A new hybrid Modified Firefly Algorithm and Support Vector Regression model for accurate Short Term Load Forecasting. *Expert Systems with Applications*, 41(13), 6047–6056. <https://doi.org/10.1016/j.eswa.2014.03.053>
- Kennedy, J. F., Eberhart, R. C., & Shi, Y. (2001). *Swarm intelligence* [livre]. Morgan Kaufmann Publishers.
- Keshtegar, B., Hao, P., Wang, Y., & Li, Y. (2017). Optimum design of aircraft panels based on adaptive dynamic harmony search. *Thin-Walled Structures*, 118, 37–45. <https://doi.org/10.1016/j.tws.2017.05.004>
- Keshtegar, B., Ozbakkaloglu, T., & Gholampour, A. (2017). Modeling the behavior of FRP-confined concrete using dynamic harmony search algorithm. *Engineering with Computers*, 33(3), 415–430. <https://doi.org/10.1007/s00366-016-0481-y>
- Khatibi, R., Ghorbani, M. A., & Pourhosseini, F. A. (2017). Stream flow predictions using nature-inspired Firefly Algorithms and a Multiple Model strategy – Directions of innovation towards next generation practices. *Advanced Engineering Informatics*, 34, 80–89. <https://doi.org/10.1016/j.aei.2017.10.002>

- Khosravi, K., Panahi, M., Golkarian, A., Keesstra, S. D., Saco, P. M., Bui, D. T., & Lee, S. (2020). Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. *Journal of Hydrology*, 591, 125552. <https://doi.org/10.1016/j.jhydrol.2020.125552>
- Khudair, B. H., Jasim, M. M., & Alsaqqar, A. S. (2018). Artificial Neural Network Model for the Prediction of Groundwater Quality. *Civil Engineering Journal*, 4(12), 13.
- Kisi, Ö. (2008). Constructing neural network sediment estimation models using a data-driven algorithm. *Mathematics and Computers in Simulation*, 79(1), 94–103. <https://doi.org/10.1016/j.matcom.2007.10.005>
- Kişi, Ö. (2009). Neural Networks and Wavelet Conjunction Model for Intermittent Streamflow Forecasting. *JOURNAL OF HYDROLOGIC ENGINEERING*, 14, 773–782.
- Kisi, O., Alizamir, M., & Zounemat-Kermani, M. (2017). Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data. *Natural Hazards*, 87(1), 367–381. <https://doi.org/10.1007/s11069-017-2767-9>
- Kitanidis, P. K., & Bras, R. L. (1980). Real-time forecasting with a conceptual hydrologic model: 1. Analysis of uncertainty. *Water Resources Research*, 16(6), 1025–1033. <https://doi.org/10.1029/WR016i006p01025>
- Kılıçaslan, Y., Tuna, G., Gezer, G., Gulez, K., Arkoc, O., & Potirakis, S. M. (2014). ANN-Based Estimation of Groundwater Quality Using a Wireless Water Quality Network. *International Journal of Distributed Sensor Networks*, 8.
- Klemeš, V. (1982). Empirical and Causal Models in Hydrology. *Resource Management*, 10.
- Koprinska, I., Rana, M., & Agelidis, V. G. (2015). Correlation and instance based feature selection for electricity load forecasting. *Knowledge-Based Systems*, 82, 29–40. <https://doi.org/10.1016/j.knosys.2015.02.017>
- Kuligowski, R. J., & Barros, A. P. (1998). Experiments in Short-Term Precipitation Forecasting Using Artificial Neural Networks. *MONTHLY WEATHER REVIEW*, 126, 13.
- Kumar, S., Roshni, T., & Himayoun, D. (2019). A Comparison of Emotional Neural Network (ENN) and Artificial Neural Network (ANN) Approach for Rainfall-Runoff Modelling. *Civil Engineering Journal*, 5(10), 2120–2130. <https://doi.org/10.28991/cej-2019-03091398>
- Kuok, K. K., Harun, S., & Shamsuddin, S. M. (2009). Particle Swarm Optimization Feedforward Neural Network for Hourly Rainfall-runoff Modeling in Bedup Basin, Malaysia. *International Journal of Civil & Environmental Engineering IJCEE*, 9 No: 10.

- LADJAL, R., (2012). Problématique de la mobilisation et de la préservation des ressources hydriques dans le Sersou (Bassin Cheliff amont Boughzoul). Mémoire de Magister. Université Abou Bekr Belkaid –Tlemcen.
- Lallahem, S., & Mania, J. (2003). Evaluation and forecasting of daily groundwater outflow in a small chalky watershed. *Hydrological Processes*, 17(8), 1561–1577. <https://doi.org/10.1002/hyp.1199>
- Le Clerc, S. (2004). Revisiter la notion de scénario hydrologique de référence pour la caractérisation des inondations. Thèse de doctorat. Université Joseph Fourier Grenoble.
- LeCun, Y., & Bengio, Y. (1995). Convolutional neural network for images, speech and time series.
- Lee, J., Kim, C.-G., Lee, J. E., Kim, N. W., & Kim, H. (2018). Application of Artificial Neural Networks to Rainfall Forecasting in the Geum River Basin, Korea. 14. *Water*, 10(10), 1448. <https://doi.org/10.3390/w10101448>
- Leea, D.-H., & Kanga, D.-S. (2016). The Application of the Artificial Neural Network Ensemble Model for Simulating Streamflow. 12th International Conference on Hydroinformatics, HIC 2016, *Procedia Engineering*, 154, 1217–1224.
- Lewis, S. M., & Cratsley, C. K. (2008). Flash Signal Evolution, Mate Choice, and Predation in Fireflies. *Annual Review of Entomology*, 53(1), 293–321. <https://doi.org/10.1146/annurev.ento.53.103106.093346>
- Liu, Z., Li, Q., Zhou, J., Jiao, W., & Wang, X. (2021). Runoff Prediction Using a Novel Hybrid ANFIS Model Based on Variable Screening. *Water Resources Management*, 35(9), 2921–2940. <https://doi.org/10.1007/s11269-021-02878-4>
- Lo, D.-C., Wei, C.-C., & Tsai, E.-P. (2015). Parameter Automatic Calibration Approach for Neural-Network-Based Cyclonic Precipitation Forecast Models. *Water*, 7(7), 3963–3977. <https://doi.org/10.3390/w7073963>
- Lohani, A. K., Goel, N. K., & Bhatia, K. K. S. (2011). Comparative study of neural network, fuzzy logic and linear transfer function techniques in daily rainfall-runoff modelling under different input domains. *Hydrological Processes*, 25(2), 175–193. <https://doi.org/10.1002/hyp.7831>
- Łukasik, S., & Żak, S. (2009). Firefly Algorithm for Continuous Constrained Optimization Tasks. In N. T. Nguyen, R. Kowalczyk, & S.-M. Chen (Eds.), *Computational Collective Intelligence. Semantic Web, Social Networks and Multiagent Systems* (Vol. 5796, pp. 97–106). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-04441-0_8

- Machado, F., Mine, M., Kaviski, E., & Fill, H. (2011). Monthly rainfall–runoff modelling using artificial neural networks. *Hydrological Sciences Journal*, 56(3), 349–361. <https://doi.org/10.1080/02626667.2011.559949>
- Madsen, H. (2000). Automatic calibration of a conceptual rainfall–runoff model using multiple objectives. *Journal of Hydrology*, 235(3–4), 276–288. [https://doi.org/10.1016/S0022-1694\(00\)00279-1](https://doi.org/10.1016/S0022-1694(00)00279-1)
- Maftai, P. (2002). Etudes concernant les écoulements superficiels: Modélisation spatialisée de l'écoulement sur le bassin versant de Voinesti, Roumanie. Thèse de doctorat, l'Université « Ovidius » de Constanta et à l'Université Montpellier II.
- Maier, H. R., & Dandy, G. (1996). The use of artificial neural networks for the prediction of water quality parameters. *WATER RESOURCES RESEARCH*, 32, NO. 4, 1013–1022.
- Makhlouf, Z. (1994). Compléments sur le modèle pluie-débit GR4J et essai d'estimation de ses paramètres. Thèse de Doctorat. Université Paris XI Orsay, 426 p.
- Malik, A., Tikhamarine, Y., Sammen, S. S., Abba, S. I., & Shahid, S. (2021). Prediction of meteorological drought by using hybrid support vector regression optimized with HHO versus PSO algorithms. *Environmental Science and Pollution Research*, 28(29), 39139–39158. <https://doi.org/10.1007/s11356-021-13445-0>
- Maskey, S., Dibike, Y. B., Jonoski, A., & Solomatine, D. (2000). Groundwater Model Approximation with Artificial Neural Network for Selecting Optimum Pumping Strategy for Plume Removal. Chapter in book: *Artificial Intelligence in Civil Engineering*. Proc. 2nd Joint Workshop, Cottbus, Germany
- Mathevet, T. (2005). Quels modèles pluie-débit globaux au pas de temps horaire? Développements empiriques et comparaison de modèles sur un large échantillon de bassins versants. Thèse de Doctorat. Ecole Nationale du Génie Rural, des Eaux et Forêts (Paris).
- McKinney, D. C., & Lin, M.-D. (1994). Genetic algorithm solution of groundwater management models. *Water Resources Research*, 30(6), 1897–1906. <https://doi.org/10.1029/94WR00554>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Moeeni, H., Bonakdari, H., Fatemi, S. E., & Zaji, A. H. (2017). Assessment of Stochastic Models and a Hybrid Artificial Neural Network-Genetic Algorithm Method in Forecasting Monthly Reservoir Inflow. *INAE Letters*, 2(1), 13–23. <https://doi.org/10.1007/s41403-017-0017-9>
- Mohamad, E. T. (2016). Estimation of air-overpressure produced by blasting operation through a neuro-genetic technique. *Environ Earth Sci*, 15.

- Mohammadi, S., & Shahraki, S. (2017). Simulation of groundwater quality parameters using ANN and ANN+PSO models (Case study: Ramhormoz Plain). *Pollution*, 3(2): 191-200, Spring 2017. DOI: 10.7508/pj.2017.02. 003. Print ISSN: 2383-451X Online ISSN: 2383-4501.
- Mohanty, S., Jha, M. K., Kumar, A., & Sudheer, K. P. (2009). Artificial Neural Network Modeling for Groundwater Level Forecasting in a River Island of Eastern India. *Water Resources Management* volume 24, pages1845–1865 (2010).
- Mohd Romlay, M. R., Mahbubur Rashid, M., Toha, S. F., & Ibrahim, A. M. (2019). Rainfall-Runoff Model Based on ANN with LM, BR and PSO as Learning Algorithms. *International Journal of Recent Technology and Engineering*, 8(3), 971–979. <https://doi.org/10.35940/ijrte.C4115.098319>
- Momeni, E. (2014). Prediction of pile bearing capacity using a hybrid genetic algorithm-based ANN. *journal of Measurement*. Volume 57, November 2014, Pages 122-13110 <https://doi.org/10.1016/j.measurement.2014.08.007>
- 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>
- Morshed, J., & Kaluarachchi, J. J. (2000). Enhancements to Genetic Algorithm for Optimal Ground-Water Management. *Journal of Hydrologic Engineering*, 5(1), 67–73. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:1\(67\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:1(67))
- Morton, F. I. (1983). Operational estimates of areal evapotranspiration and their significance to the science and practice of hydrology. *Journal of Hydrology*, 66(1), 1–76. [https://doi.org/10.1016/0022-1694\(83\)90177-4](https://doi.org/10.1016/0022-1694(83)90177-4)
- Motahari, M., & Mazdaranizadeh, H. (2017). Development of a PSO-ANN Model for Rainfall-Runoff Response in Basins, Case Study: Karaj Basin. *Civil Engineering Journal*, 3, No. 1.
- Moulin, L. (2007). Prévion des crues rapides avec des modèles hydrologiques globaux. Applications aux bassins opérationnels de la Loire supérieure: Évaluation des modélisations, prise en compte des incertitudes sur les précipitations moyennes spatiales et utilisation de prévisions météorologiques. Thèse de doctorat. l'École Nationale du Génie Rural, des Eaux et des Forêts (Agro Paris Tech).
- Muttiah, R. S., Srinivasan, R., & Allen, P. M. (1997). PREDICTION OF TWO-YEAR PEAK STREAM DISCHARGES USING NEURAL NETWORKS'. *JOURNAL OF The AMERICAN WATER RESOURCES ASSOCIATION*, 33 N: 03.
- Nandi, S., Badhe, Y., Lonari, J., Sridevi, U., Rao, B. S., Tambe, S. S., & Kulkarni, B. D. (2004). Hybrid process modeling and optimization strategies integrating neural networks/support vector

- regression and genetic algorithms: Study of benzene isopropylation on Hbeta catalyst. *Chemical Engineering Journal*, 15.
- NASH, J. E., & SUTCLIFFE, I. V. (1970). RIVER FLOW FORECASTING THROUGH CONCEPTUAL MODELS PART I - A DISCUSSION OF PRINCIPLES *.
- Noumon, C. J., Kodja, D. J., Kouhondji, N., Houessou, S., Amoussou, E., Sintondji, L. O., Vissin, E., & Agbossou, E. K. (2020). Utilisation du Modèle GR4J pour la Simulation des Débits d'Étiage du Fleuve Mono (Bénin, Togo) à l'Exutoire d'Athiémé. *International Journal of Progressive Sciences and Technologies (IJPSAT)*. Vol. 23 No. 1 October 2020, pp. 139-144.
- Nourani, V., Mogaddam, A. A., & Nadiri, A. O. (2008). An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrol. Process.*, 13.
- O'Connell, P. E., & Clarke, R. T. (1981). Adaptive hydrological forecasting—A review / Revue des méthodes de prévision hydrologique ajustables. *Hydrological Sciences Bulletin*, 26(2), 179–205. <https://doi.org/10.1080/02626668109490875>
- Oluwatobi, A., Gbenga, O., Joy, A., & Oluwole, A. (2018). MODELING AND SIMULATION OF RIVER DISCHARGE USING ARTIFICIAL NEURAL NETWORKS. *Journal of Science*, 20.
- Oudin, L. (2004). Recherche d'un modèle d'évapotranspiration potentielle pertinent comme entrée d'un modèle pluie-débit global. Thèse de doctorat. Ecole Nationale du Génie Rural, des Eaux et Forêts Centre de : Paris.
- Oudin, L., Hervieu, F., Michel, C., Perrin, C., Andréassian, V., Anctil, F., & Loumagne, C. (2005). Which potential evapotranspiration input for a lumped rainfall-runoff model?: Part 2—Towards a simple and efficient potential evapotranspiration model for rainfall-runoff modelling. *Journal of hydrology* 303 (2005) 290-306.
- Palani, S., Liong, S.-Y., & Tkalich, P. (2008). An ANN application for water quality forecasting. *Marine Pollution Bulletin*, 56(9), 1586–1597. <https://doi.org/10.1016/j.marpolbul.2008.05.021>
- Pan, T., Wang, R., Lai, J., & Yu, H. (2008). Application of Recurrent Neural Networks to Rainfall-runoff Processes. In X. Hu & P. Balasubramaniam (Eds.), *Recurrent Neural Networks*. InTech. <https://doi.org/10.5772/5542>
- Panahi, M., Khosravi, K., Ahmad, S., Panahi, S., Heddami, S., Melesse, A. M., Omidvar, E., & Lee, C.-W. (2021). Cumulative infiltration and infiltration rate prediction using optimized deep learning algorithms: A study in Western Iran. *Journal of Hydrology: Regional Studies*, 35, 100825. <https://doi.org/10.1016/j.ejrh.2021.100825>

- Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D. (2011). Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. *International Journal of Computer Theory and Engineering*, 332–337. <https://doi.org/10.7763/IJCTE.2011.V3.328>
- Paraskevas, T., Dimitrios, R., & Andreas, B. (2014). Use of artificial neural network for spatial rainfall analysis. *J. Earth Syst. Sci.* 123, No. 3, April 2014, pp. 457–465
- Parasuraman, K., & Elshorbagy, A. (2007). Cluster-Based Hydrologic Prediction Using Genetic Algorithm-Trained Neural Networks. *Journal of Hydrologic Engineering*, 12(1), 52–62. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2007\)12:1\(52\)](https://doi.org/10.1061/(ASCE)1084-0699(2007)12:1(52))
- Perrin, C. (2002). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative. *La Houille Blanche*, 88(6–7), 84–91. <https://doi.org/10.1051/lhb/2002089>.
- Perrin, C., Claude, M. et Vazken, A. (2003). Improvement of a parsimonious model for stream flow simulation, *journal hydrologique*, 279, pp 275-289.
- Perrin C., Michel C., Andréassian V. (2007) , *Modèles hydrologiques du Génie Rural (GR)*, Cemagref, Juin 2007.
- Pham, Shirzadi, Shahabi, Omidvar, Singh, Sahana, Asl, Ahmad, Quoc, & Lee. (2019). Landslide Susceptibility Assessment by Novel Hybrid Machine Learning Algorithms. *Sustainability*, 11(16), 4386. <https://doi.org/10.3390/su11164386>
- Pollard, J. F., Broussard, M. R., Garrison, D. B., & San, K. Y. (1992). Process identification using neural networks. *Computers & Chemical Engineering*. Volume 16, Issue 4, April 1992, Pages 253-270. [https://doi.org/10.1016/0098-1354\(92\)80046-C](https://doi.org/10.1016/0098-1354(92)80046-C).
- Rajurkar, M. P., Kothiyari, U. C., & Chaube, U. C. (2002a). Artificial neural networks for daily rainfall—Runoff modelling. *Hydrological Sciences Journal*, 47(6), 865–877. <https://doi.org/10.1080/02626660209492996>
- Rajurkar, M. P., Kothiyari, U. C., & Chaube, U. C. (2002b). Artificial neural networks for daily rainfall—Runoff modelling. *Hydrological Sciences Journal*, 47(6), 865–877. <https://doi.org/10.1080/02626660209492996>
- Randrianarivony, R., Lauret, P., Randriamanantany, Z., & Gatina, J. (2010a). Modélisation du régime annuel des petites rivières en vue d'installation de microcentrales hydroélectriques. *Afrique Science: Revue Internationale des Sciences et Technologie*, 5(1). <https://doi.org/10.4314/afsci.v5i1.61705>
- Randrianarivony, R., Lauret, P., Randriamanantany, Z., & Gatina, J. (2010b). Modélisation du régime annuel des petites rivières en vue d'installation de microcentrales hydroélectriques. *Afrique*

- Science: Revue Internationale des Sciences et Technologie, 5(1).
<https://doi.org/10.4314/afsci.v5i1.61705>
- Rao, S. V. N., Kumar, S., Shekhar, S., & Chakraborty, D. (2006). Optimal Pumping from Skimming Wells. *Journal of Hydrologic Engineering*, 11(5), 464–471. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2006\)11:5\(464\)](https://doi.org/10.1061/(ASCE)1084-0699(2006)11:5(464))
- Rasouli, K., Hsieh, W. W., & Cannon, A. J. (2012). Daily streamflow forecasting by machine learning methods with weather and climate inputs. *Journal of Hydrology*, 414–415, 284–293.
<https://doi.org/10.1016/j.jhydrol.2011.10.039>
- Remesan, R., Cardiff School of Engineering, Cardiff University, Cardiff CF24 3AA, UK, Mathew, J., & Department Computer Science and Engineering, Indian Institute of Technology Patna 801103, India. (2018). Application of PCA and Clustering Methods in Input Selection of Hybrid Runoff Models. *Journal of Environmental Informatics*. <https://doi.org/10.3808/jei.201700378>
- Rezaeianzadeh, M., Stein, A., Tabari, H., Abghari, H., Jalalkamali, N., Hosseinipour, E. Z., & Singh, V. P. (2013a). Assessment of a conceptual hydrological model and artificial neural networks for daily outflows forecasting. *International Journal of Environmental Science and Technology*, 10(6), 1181–1192. <https://doi.org/10.1007/s13762-013-0209-0>
- Rezaeianzadeh, M., Stein, A., Tabari, H., Abghari, H., Jalalkamali, N., Hosseinipour, E. Z., & Singh, V. P. (2013b). Assessment of a conceptual hydrological model and artificial neural networks for daily outflows forecasting. *International Journal of Environmental Science and Technology*, 10(6), 1181–1192. <https://doi.org/10.1007/s13762-013-0209-0>
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Predicting catchment flow in a semi-arid region via an artificial neural network technique. *Hydrological Processes*, 18(13), 2387–2393.
<https://doi.org/10.1002/hyp.1469>
- Ritzel, B. J., Eheart, J. W., & Ranjithan, S. (1994). Using genetic algorithms to solve a multiple objective groundwater pollution containment problem. *Water Resources Research*, 30(5), 1589–1603.
<https://doi.org/10.1029/93WR03511>
- Rogers, L. L., & Dowla, F. U. (1994a). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Water Resources Research*, 30(2), 457–481.
<https://doi.org/10.1029/93WR01494>
- Rogers, L. L., & Dowla, F. U. (1994b). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Water Resources Research*, 30(2), 457–481.
<https://doi.org/10.1029/93WR01494>

- Rogers, L. L., Dowla, F. U., & Johnson, V. M. (1995). Optimal Field-Scale Groundwater Remediation Using Neural Networks and the Genetic Algorithm. *Environmental Science & Technology*, 29(5), 1145–1155. <https://doi.org/10.1021/es00005a003>
- Roshni, T. (2020). Neural network modeling for groundwater-level forecasting in coastal aquifers. *Neural Computing and Applications*, 18.
- Roy, B., Singh, M. P., & Singh, A. (2021). A novel approach for rainfall-runoff modelling using a biogeography-based optimization technique. *International Journal of River Basin Management*, 19(1), 67–80. <https://doi.org/10.1080/15715124.2019.1628035>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Internal Representations by Error Propagation chapter [livre].
- Saemi, M., Ahmadi, M., & Varjani, A. Y. (2007). Design of neural networks using genetic algorithm for the permeability estimation of the reservoir. *Journal of Petroleum Science and Engineering*, 9.
- Salimi, A. H., Samakosh, J. M., Sharifi, E., Hassanvand, M. R., & Noori, A. (2019). Optimized Artificial Neural Networks-Based Methods for Statistical Downscaling of Gridded Precipitation Data. *Water* 2019, 11(8), 1653; <https://doi.org/10.3390/w11081653>.
- Samantaray, S., & Ghose, D. K. (2020a). Modelling runoff in an arid watershed through integrated support vector machine. *H2Open Journal*, 3(1), 256–275. <https://doi.org/10.2166/h2oj.2020.005>
- Samantaray, S., & Ghose, D. K. (2020b). Modelling runoff in an arid watershed through integrated support vector machine. *H2Open Journal*, 3(1), 256–275. <https://doi.org/10.2166/h2oj.2020.005>
- Schalkoff, R. (1997). *Artificial Neural Networks*. McGraw-Hill, demystifying knowledge acquiring black boxes. IEEE Trans. New York.
- Sedki, A., & Ouazar, D. (2010). Hybrid Particle Swarm and Neural Network Approach for Streamflow Forecasting. *Mathematical Modelling of Natural Phenomena*, 5(7), 132–138. <https://doi.org/10.1051/mmnp/20105722>
- Sharma, D. K., Balas, V. E., Son, L. H., Sharma, R., & Cengiz, K. (Eds.). (2020). *Micro-Electronics and Telecommunication Engineering: Proceedings of 3rd ICMETE 2019 (Vol. 106)*. Springer Singapore. <https://doi.org/10.1007/978-981-15-2329-8>
- Shukla, S. K., Koley, E., & Ghosh, S. (2020). Grey wolf optimization-tuned convolutional neural network for transmission line protection with immunity against symmetrical and asymmetrical power swing. *Neural Computing and Applications*, 32(22), 17059–17076. <https://doi.org/10.1007/s00521-020-04938-z>

- Singh, V. P. (Ed.). (1995). Computer models of watershed hydrology (Rev. ed). Water Resources Publications.
- Singh, V. P., & Woolhiser, D. A. (2002). Mathematical Modeling of Watershed Hydrology. *Journal of Hydrologic Engineering*, 7(4), 270–292. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2002\)7:4\(270\)](https://doi.org/10.1061/(ASCE)1084-0699(2002)7:4(270))
- Sivapalan, M., Blöschl, G., Zhang, L., & Vertessy, R. (2003). Downward approach to hydrological prediction: DOWNWARD APPROACH TO HYDROLOGICAL PREDICTION. *Hydrological Processes*, 17(11), 2101–2111. <https://doi.org/10.1002/hyp.1425>
- Smith, J., & Eli, R. N. (1995). Neural-Network Models of Rainfall-Runoff Process. *Journal of Water Resources Planning and Management*, 121(6), 499–508. [https://doi.org/10.1061/\(ASCE\)0733-9496\(1995\)121:6\(499\)](https://doi.org/10.1061/(ASCE)0733-9496(1995)121:6(499))
- Solomatine, D. P. (1999). Two Strategies of Adaptive Cluster Covering with Descent and Their Comparison to Other Algorithms. *Journal of Global Optimization*, 14(1), 20.
- Somvanshi, V. K., Pandey, O. P., Agrawal, P. K., Kalanker, N. V., Prakash, M. R., & Chand, R. (2006). Modelling and prediction of rainfall using artificial neural network and ARIMA techniques. *J. Ind. Geophys. Union* (April 2006) Vol.10, No.2, pp.141-151.
- Srinivasulu, S., & Jain, A. (2006a). A comparative analysis of training methods for artificial neural network rainfall–runoff models. *Applied Soft Computing*, 6(3), 295–306. <https://doi.org/10.1016/j.asoc.2005.02.002>
- Srinivasulu, S., & Jain, A. (2006b). A comparative analysis of training methods for artificial neural network rainfall–runoff models. *Applied Soft Computing*, 6(3), 295–306. <https://doi.org/10.1016/j.asoc.2005.02.002>
- Starrett, S. K., Starrett, S. K., Najjar, Y., Adams, G., & Hill, J. (1998). Modeling pesticide leaching from golf courses using artificial neural networks. *Communications in Soil Science and Plant Analysis*, 29(19), 3093–3106.
- Stefano, O., & Isabella, M. (2000). Artificial neural network estimation of rainfall intensity from Radar observations. *Journal of Geophysical Research*, 105 N0.20, 24,849-24,861.
- Sudheer, K. P., Gosain, A. K., & Ramasastri, K. S. (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models. *Hydrological Processes*, 16(6), 1325–1330. <https://doi.org/10.1002/hyp.554>
- Taormina, R., & Chau, K. (2015). Neural network river forecasting with multi-objective fully informed particle swarm optimization. *Journal of Hydroinformatics*, 17(1), 99–113. <https://doi.org/10.2166/hydro.2014.116>

- Tashekaboud, A. H., & Tashekaboud, Sh. H. (2018). Estimating Suspended Sediment Load in Rivers Using the Imperialist Competitive Algorithm. *Journal of Hydrosiences and Environment*, 3, Issue 5, 45–51.
- Terzi, Ö., & Çevik, E. (2012). RAINFALL ESTIMATION USING ARTIFICIAL NEURAL NETWORK METHOD. *SDU International Journal of Technological Science*. Vol. 4, No 1, June 2012. pp. 10-19.
- Tikhamarine, Y., Souag-Gamane, D., Najah Ahmed, A., Kisi, O., & El-Shafie, A. (2020a). Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm. *Journal of Hydrology*, 582, 124435.
<https://doi.org/10.1016/j.jhydrol.2019.124435>
- Tikhamarine, Y., Souag-Gamane, D., Najah Ahmed, A., Kisi, O., & El-Shafie, A. (2020b). Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm. *Journal of Hydrology*, 582, 124435.
<https://doi.org/10.1016/j.jhydrol.2019.124435>
- Tohma, S., & Igata, S. (1994). Rainfall estimation from GMS imagery data using neural network. *Transactions on Ecology and the Environment*, *Transactions on Ecology and the Environment* vol 7, © 1994 WIT Press, www.witpress.com, ISSN 1743-3541.
- Tokar, A., & Johnson, P. (1999). Rainfall-Runoff Modeling Using Artificial Neural Networks. *Journal of Hydrologic Engineering* /Volume 4 Issue 3 - July 1999.
- van den Bergh, F., & Engelbrecht, A. P. (2002). A new locally convergent particle swarm optimiser. *IEEE International Conference on Systems, Man and Cybernetics*, vol.3, 6.
<https://doi.org/10.1109/ICSMC.2002.1176018>
- Van, S. P., Le, H. M., Thanh, D. V., Dang, T. D., Loc, H. H., & Anh, D. T. (2020). Deep learning convolutional neural network in rainfall–runoff modelling. *Journal of Hydroinformatics*, 22(3), 541–561.
<https://doi.org/10.2166/hydro.2020.095>
- Vidyarthi, V. K., & Chourasiya, S. In D. K. Sharma, V. E. Balas, L. H. Son, R. Sharma, & K. Cengiz (2020). Particle Swarm Optimization for Training Artificial Neural Network-Based Rainfall–Runoff Model, Case Study: Jardine River Basin. *Micro-Electronics and Telecommunication Engineering* (pp. 641–647). Springer. https://doi.org/10.1007/978-981-15-2329-8_65
- Vidyarthi, V. K., Jain, A., & Chourasiya, S. (2020a). Modeling rainfall-runof process using artificial neural network with emphasis on parameter sensitivity. *Modeling Earth Systems and Environment*.

- Vidyarthi, V. K., Jain, A., & Chourasiya, S. (2020b). Modeling rainfall-runoff process using artificial neural network with emphasis on parameter sensitivity. *Modeling Earth Systems and Environment*, 6(4), 2177–2188. <https://doi.org/10.1007/s40808-020-00833-7>
- Vilanova, R. S., Zanetti, S. S., & Cecílio, R. A. (2019). Assessing combinations of artificial neural networks input/output parameters to better simulate daily streamflow: Case of Brazilian Atlantic Rainforest watersheds. *Computers and Electronics in Agriculture*, 167, 105080. <https://doi.org/10.1016/j.compag.2019.105080>
- Vrugt, J. A., Gupta, H. V., Bouten, W., & Sorooshian, S. (2003). A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters: EFFICIENT METHOD FOR ESTIMATING PARAMETER UNCERTAINTY. *Water Resources Research*, 39(8). <https://doi.org/10.1029/2002WR001642>
- WALTER T, S. (1986). Intercomparison of Conceptual Models Used in Operational Hydrological Forecasting [livre]. WORLD METEOROLOGICAL ORGANIZATION Operational Hydrology Report No.7. ISBN 92 " 63 " 10429 " 8.
- Wang, Q., Liu, Y., Yue, Q., Zheng, Y., Yao, X., & Yu, J. (2020). Impact of Input Filtering and Architecture Selection Strategies on GRU Runoff Forecasting: A Case Study in the Wei River Basin, Shaanxi, China. *Water*, 12(12), 3532. <https://doi.org/10.3390/w12123532>
- Weiss, S. M., & Kulikowski, C. A. (1991). *Computer Systems that Learn: Classification and Prediction Methods from Statistics, Neural Nets, Machine Learning, and Expert Systems*. M. Kaufmann Publishers.
- WENDLING, J. (1992). Modélisation pluie-débit: Comparaison d'approches conceptuelles/physico-déterministes, globales/semi-distribuées. Essai de prise en compte de la variabilité spatiale des pluies.(Application au bassin versant du Réal Collobrier). Partie III. Approche Semi-distribuée, utilisation de top model. Thèse de doctorat. Université de Grenoble.
- Xiaomin, M., & Songhao, S. (2002). Groundwater Level Predictions Using Artificial Neural Networks. *Tsinghua Science and Technology* (Volume: 7, Issue: 6, Dec. 2002). 574 - 579
- Xiong, T. (2014). Multiple-output support vector regression with a firefly algorithm for interval-valued stock price index forecasting. *Knowledge-Based Systems*. Volume 55, January 2014, Pages 87-100. <https://doi.org/10.1016/j.knosys.2013.10.012>.
- Yang, C.-C., Prasher, S. O., Lacroix, R., Sreekanth, S., Patni, N. K., & Masse, L. (1997). Artificial Neural Network Model for Subsurface-Drained Farmlands. *Journal of Irrigation and Drainage Engineering*, 123(4), 285–292. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1997\)123:4\(285\)](https://doi.org/10.1061/(ASCE)0733-9437(1997)123:4(285))

- Yang, X.-S. (2010a). Nature-inspired metaheuristic algorithms [livre] (2. ed). Luniver Press.
- Yang, X.-S. (2010b). Firefly Algorithm, Stochastic Test Functions and Design Optimisation. International Journal of Bio-Inspired Computation 2(2). <http://arxiv.org/abs/1003.1409>
- Yang, X.-S. (2010c). Firefly Algorithms for Multimodal Optimization. Proceedings of the 5th international conference on Stochastic algorithms: foundations and applications. DOI: 10.1007/978-3-642-04944-6_14
- Yang, X.-S., & Karamanoglu, M. (2013). Swarm Intelligence and Bio-Inspired Computation. In Swarm Intelligence and Bio-Inspired Computation (pp. 3–23). Elsevier. <https://doi.org/10.1016/B978-0-12-405163-8.00001-6>
- Yapo, P. O., Gupta, H. V., & Sorooshian, S. (1996). Automatic calibration of conceptual rainfall-runoff models: Sensitivity to calibration data. Journal of Hydrology, 181(1–4), 23–48. [https://doi.org/10.1016/0022-1694\(95\)02918-4](https://doi.org/10.1016/0022-1694(95)02918-4)
- Yaseen, Z. M., Ebtehaj, I., Bonakdari, H., Deo, R. C., Danandeh Mehr, A., Mohtar, W. H. M. W., Diop, L., El-shafie, A., & Singh, V. P. (2017). Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. Journal of Hydrology, 554, 263–276. <https://doi.org/10.1016/j.jhydrol.2017.09.007>
- Yaseen, Z. M., Mohtar, W. H. M. W., Ameen, A. M. S., Ebtehaj, I., Razali, S. F. M., Bonakdari, H., Salih, S. Q., Al-Ansari, N., & Shahid, S. (2019). Implementation of Univariate Paradigm for Streamflow Simulation Using Hybrid Data-Driven Model: Case Study in Tropical Region. IEEE Access, 7, 74471–74481. <https://doi.org/10.1109/ACCESS.2019.2920916>
- Zhang, J., Chen, X., Khan, A., Zhang, Y.-K., Kuang, X., Liang, X., Taccari, M., & Nuttall, J. (2021). Daily runoff forecasting by deep recursive neural network. Journal of Hydrology, 596, 126067. <https://doi.org/10.1016/j.jhydrol.2021.126067>
- ZHANG, J., WU, Z., CHENG, C., & ZHANG, S. (2011). Improved particle swarm optimization algorithm for multi-reservoir system operation. Water Science and Engineering, 4(1), 61–73.
- Zurada, J. M. (1992). Introduction to artificial neural systems [livre].