

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE MINISTERE
DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA**



FACULTE DE TECHNOLOGIE

DEPARTEMENT D'HYDRAULIQUE

N°:.....

DOMAINE : SCIENCES ET TECHNOLOGIES

FILIERE : HYDRAULIQUE

OPTION : HYDRAULIQUE URBAINE

**Mémoire présenté pour l'obtention Du diplôme de Master
Académique**

Réalisé par:

ABDELLAOUI Mohamed ELamine et KHADRAOUI Abdallah

Intitulé

**Application des réseaux de neurones artificiels pour
la prévision des débits journaliers : Application sur
le bassin versant de la Soummam**

Soutenu devant le jury composé de :

Mr. Mokhtari Elhadj

Université de M'sila

Président

Mr. Djerbouai Salim

Université de M'sila


Rapporteur

Mr. Ghodbane Messaoud

Université de M'sila

Examineur

Année universitaire : 2022/2023



Remerciement

Tout d'abord, nous tenons à remercier chaleureusement les personnes qui nous ont aidés et qui ont contribué à la préparation de cette thèse ainsi qu'à la réussite de cette année académique. Nous tenons à remercier sincèrement Dr. Djerbouai Galim qui a supervisé la mémoire, s'est toujours montré à l'écoute et a été très disponible tout au long de la réalisation de cette thèse ainsi que pour l'inspiration surnaturelle et le temps qu'il a eu la gentillesse de nous consacrer sans quoi cette thèse n'aurait pu pas vu la lumière. Nous remercions également nos chers parents, tous les professeurs et tous les intervenants, nos respects et notre gratitude



Védicace

Au commencement, exprimons d'abord notre gratitude à Dieu et disons merci Dieu de nous avoir donné la force et la capacité d'écrire et de compléter cette lettre. Tout d'abord, nous tenons à exprimer nos sincères remerciements à notre encadrant, Dr. Djarbouai Salim, qui nous a prodigué de précieux conseils. Je dédie humblement ce travail à mes chers parents, ma chère sœur et mon cher frère, sans oublier mes oncles et oncles, en particulier ma tante Ruqayah, ainsi que mes camarades étudiants et aussi mes chers amis, en demandant à Dieu de les bénir. Je voudrais également exprimer ma gratitude à mon ami M Elamine pour sa présence, son soutien et le partage avec moi de cette expérience inoubliable.

K. Abdallah

Dédicace

Au commencement, Exprimons d'abord notre gratitude à Dieu et disons merci à Dieu de nous avoir donné la force et la capacité d'écrire et de compléter cette lettre.

Tout d'abord, nous tenons à exprimer nos sincères remerciements à notre encadrant, Dr. djarbouai salim, qui nous a prodigué de précieux conseils. Je dédie humblement ce travail à mes chers parents, soeurs Oumm Mahdi, oumm Aissa, oumm Amina et mes deux petites soeurs neveux et nièces, ainsi qu'à mon frère Dr. Abderrahim et sa fiancée, sans oublier Ainsi sont mes camarades étudiants et aussi mes chers amis, A. Lakaria et B. Lakhdar Pour demander que Dieu les bénisse de sa bonté. Je voudrais également exprimer ma gratitude à mon cher ami Abdallah pour sa présence, son soutien et le partage avec moi de cette expérience inoubliable.

A. Med Elamine

Résume :

Ce projet de Mémoire se concentre sur l'utilisation de l'intelligence artificielle, en particulier des réseaux de neurones à perceptron multicouche (MLP), pour prédire les débits d'eau. La prévision précise des débits d'eau est cruciale pour une gestion efficace des ressources en eau dans divers domaines tels que l'agriculture, l'énergie hydroélectrique et l'approvisionnement en eau potable.

Le projet comprendra les étapes suivantes : collecte de données historiques sur les débits d'eau et les variables pertinentes, prétraitement des données pour les rendre adaptées à l'apprentissage du modèle MLP, conception d'un réseau de neurones MLP pour la prédiction, entraînement et optimisation du modèle en ajustant les poids du réseau, évaluation des performances du modèle en utilisant des mesures d'erreur appropriées, validation du modèle en testant sa capacité à prédire les débits d'eau sur des données non utilisées lors de l'entraînement, et enfin, comparaison des résultats du modèle MLP avec les méthodes de prévision traditionnelles.

L'objectif de ce projet est de démontrer que les réseaux de neurones MLP peuvent être des outils puissants pour la prévision des débits d'eau. Les résultats obtenus contribueront à améliorer la gestion des ressources en eau en fournissant des prévisions plus précises, ce qui aura un impact positif sur des secteurs clés dépendant des débits

L'étude a été réalisée dans le bassin versant de l'Oued Al-Soumam, identifié par le numéro (15) selon la numérotation de l'Agence Nationale des Ressources en Eau. Les valeurs des débits enregistrés de septembre 1967 à août 1973 aux stations d'enregistrement ont été utilisées pour cette étude.

Nous avons mené des expériences sur toutes les méthodes en utilisant une perspective multicouche dans les enregistrements quotidiens, et sommes finalement arrivés à la conclusion que le perceptron multicouche donnait des résultats bons et précis.

ملخص :

يركز مشروع المذكرة هذا على استخدام الذكاء الاصطناعي، ولا سيما الشبكات العصبية متعددة الطبقات (MLP) ، للتنبؤ بتدفقات المياه. يعد التنبؤ الدقيق بتدفقات المياه أمرًا بالغ الأهمية للإدارة الفعالة لموارد المياه في مختلف المجالات مثل الزراعة والطاقة الكهرومائية وإمدادات مياه الشرب.

سيتضمن المشروع الخطوات التالية: جمع البيانات التاريخية عن تدفقات المياه والمتغيرات ذات الصلة، والمعالجة المسبقة للبيانات لجعلها مناسبة لتدريب نموذج MLP ، وتصميم شبكة MLP العصبية للتنبؤ والتدريب وتحسين النموذج عن طريق تعديل أوزان الشبكة، وتقييم أداء النموذج باستخدام مقاييس الخطأ المناسبة، والتحقق من صحة النموذج من خلال اختبار قدرته على التنبؤ بتدفقات المياه على البيانات غير المستخدمة أثناء التدريب، وأخيرًا مقارنة نتائج نموذج MLP مع طرق التنبؤ التقليدية.

الهدف من هذا المشروع هو إثبات أن الشبكات العصبية MLP يمكن أن تكون أدوات قوية للتنبؤ بتدفقات المياه. ستساهم النتائج التي تم الحصول عليها في تحسين إدارة الموارد المائية من خلال توفير تنبؤات أكثر دقة، مما سيكون له تأثير إيجابي على القطاعات الرئيسية التي تعتمد على التدفقات.

أجريت الدراسة في مستجمع مياه وادي الصوم المحدد برقم (15) حسب ترقيم الوكالة الوطنية للموارد المائية. تم استخدام قيم التدفق المسجلة من سبتمبر 1967 إلى أغسطس 1973 في محطات التسجيل لهذه الدراسة.

لقد أجرينا تجارب على جميع الطرق باستخدام منظور متعدد الطبقات في التسجيلات اليومية، وتوصلنا أخيرًا إلى استنتاج مفاده أن المستشعر متعدد الطبقات أعطى نتائج جيدة ودقيقة

Abstract :

This Graduation Note project focuses on the use of artificial intelligence, in particular multi layer perceptron neural networks (MLP), to predict water flows. Accurate forecasting of water flows is crucial for effective management of water resources in various fields such as agriculture, hydroelectric power and drinking water supply.

The project will include the following steps: collecting historical data on water flows and relevant variables, pre-processing the data to make it suitable for training the MLP model, designing an MLP neural network for prediction, training and optimization of the model by adjusting the weights of the network, evaluation of the performance of the model using appropriate error measures, validation of the model by testing its ability to predict water flows on data not used during training, and finally, comparing the results of the MLP model with traditional forecasting methods.

The objective of this project is to demonstrate that MLP neural networks can be powerful tools for the prediction of water flows. The results obtained will contribute to improving the management of water resources by providing more accurate forecasts, which will have a positive impact on key sectors dependent on flows.

The study was carried out in the watershed of Oued Al-Soumam, identified by the number (15) according to the numbering of the National Agency for Water Resources. The flow values recorded from September 1967 to August 1973 at the recording stations were used for this study.

We conducted experiments on all methods using a multi-layered perspective in daily recordings, and finally came to the conclusion that the multi-layered perceptron gave good and accurate results.

Sommaire

• Remerciement	
• Dédicace	
• Résumé	
• Liste des Tableaux	
• Liste des figures	
• Introduction Générale.....	1

Chapitre I: Synthèse bibliographique

Introduction	4
I.1 Importance de la prévision des débits.....	18
I.2 Aperçu sur les approches utilisées pour la prévision des débits	20
I.3 Réseaux de neurones artificiels (ANN)	20
I.4 Modèles hybrides	7
Conclusion.....	9

Chapitre II présentation zone d'étude

Introduction	11
II.1 Situation géographique de bassin	11
II .2 Relief et hydrographie du bassin versant.....	12
II .3 La géologie	13
II .4 Topographie de bassin	14
II .4 .1 Les caractéristiques de la disposition dans le plan	14
II.4.1.1 La surface (A).....	14
II.4.1.2 Le périmètre (P).....	14
II.4.1.3 La forme (KG).....	14

II.4.1.4 Le rectangle équivalent.....	15
II.4.2 Courbe hypsométrique.....	16
II.4.3 les altitudes	16
II.4.3.1 Les altitudes maximale et minimale (Hmax et Hmin)	16
II.4.3.2 L'altitude moyenne(Hmoy)	16
II.4.3.3 L'altitude médiane (H50%)	17
II.4.3.4 La dénivelée simple (D)	17
II.4.3.5 Les indices de pentes	17
II.4.3.5.1 La pente moyenne du bassin versant	18
II.4.3.5.2 L'indice de pente Roche (Ip).....	18
II.4.3.5.3 Indice de pente globale (Ig)	19
II.4.3.5.4 Dénivelée spécifique (Ds)	20
II.5 Situation climatique du bassin versant de Soummam	21
II.5.1 les précipitations	21
II.5.2 Le vent	22
II.5.3 Humidité relative	22
II.5.4 Température.....	23
II.6 Flore et faune de Soummam.....	23
II.6.1 La flore	24
II.6.2 La faune	24
Conclusion.....	24

Chapitre III Réseaux des neurones artificiels

Introduction	26
III.1 Définitions	26
III.1.1 intelligence artificielle.....	26
III.1.2 Les réseaux de neurones artificiels.....	26

III.1.2.1 Historique sur les réseaux De neurones	26
III.1.2.1.1 Les premiers succès.....	27
III.1.2.1.2 L'ombre.....	27
III.1.2.1.3 Le Renouveau.....	28
III.1.2.1.4 La levée des limitations.....	28
III.1.2.1.5 Actuellement	28
III.1.2.2 Types des réseaux des neurones.....	28
III.1.2.2.1 Réseaux de fonctions à base radiale.....	28
III.1.2.2.2 Machines Boltzmann restreintes	30
III.1.2.2.3 Réseaux de neurones convolutifs	30
III.1.2.2.4 Les réseaux de neurones feed-forwarded	33
III.1.2.2.5 Les réseaux de neurones à apprentissage profond (Deep Learning)	36
III.1.2.3 Application des réseaux de neurones	37
III.1.2.3.1 Le modèle neurophysiologique	37
III.1.2.3.2 Le modèle mathématique	38
III.1.2.3.3 Prévision des débits.....	39
III.1.2.3.4 Prévision des crues	39
III.1.2.3.5 Modélisation de la qualité de l'eau	40
III.1.2.3.6 Optimisation de l'utilisation de l'eau	40
III.1.2.3.7 Modélisation des processus hydrologiques	40
Conclusion.....	42

Chapitre IV Application du modèle MLP à la prévision des débits dans la région du Soummam

Introduction	44
IV.1 Application des modèles	44
IV.1.1 IV.1.1 Modèle proposé : Perceptron multicouche (MLP)	44


IV.2 Programme utilisé	45
IV.3 Calage des modèles	46
IV.3.1 Le calage manuel	46
IV.3.2 Le calage automatique	46
IV.4 Validation des modèles	47
IV.5 Répartition de la base de données	49
IV.5.1 Paramètres du réseau.....	50
IV.6 Autocorrélation	51
IV.7 Critères de performance	52
IV.7.1 R : Les coefficients de corrélation	52
IV.7.2 MAE : L'erreur moyenne absolue	53
IV.7.3 Nash : Le critère de Nash.....	53
IV.7.4 RMSE : La racine de l'erreur quadratique moyenne	53
IV.8 Interprétations	54
IV.8.1 Interprétations des résultats.....	54
IV.8.2 Interprétations de graphe.....	54
Conclusion.....	57
Conclusion générale	59
Références bibliographiques.	

Liste des Tableaux :

Tableau II.2: L'indice global de pente	19
Tableau II.3: Deuxième classification de l'O.R.S.T.O.M.....	20
Tableau I.1: Caractéristiques physiques de bassin soummam(AMOUR, 2010)	21
Tableau II.4: Vitesse mensuelle moyenne du vent (1994-2003) (O.N.M)	22
Tableau II.5: Humidité relative (en %) enregistrée en 2003 (OMM,2006).....	22
Tableau II.6: Températures moyennes mensuelles.....	23
Tableau IV.1: Répartition de la base de données.....	50
Tableau IV.2: Les résultats des les indicateurs.....	54

Liste des Figure :

Figure II.1 : La situation de la zone d'étude par rapport au bassin hydrographique De l'Algérie du nord (Tebbani, 2016).	12
Figure II.2: Carte du relief du bassin versant d'étude.....	12
Figure II.3: Réseau hydrographique du bassin versant de la Soummam	13
Figure II.4: La courbe hypsométrique du bassin de Soummam	16
Figure II.5: Carte de pentes du BV de la Soummam	17
Figure III.1: Réseaux de fonctions à base radiale.....	29
Figure III.2: L'un des premiers réseaux de neurones convolutifs.....	31
Figure III.3: Réseau Feedforward à trois couches.....	34
Figure III.4: réseau feedback simple.....	36
Figure III.5: Le modèle neurophysiologique.....	38
Figure III.6: Mis en correspondance du neurone biologique et du neurone artificiel.....	39
Figure III.7: Modélisation des processus hydrologiques.....	41
Figure IV.1: Modèle MLP proposé	44
Figure IV.2: Technique d'arrêt prématuré	48
Figure IV.3: Débit moyen journalier	49
Figure IV.4: Fonction d'autocorrélation	50
Figure IV.5: Fenêtre d'apprentissage Du RNA	52



Introduction générale

Introduction générale

La prévision du débit est d'une importance cruciale dans de nombreux domaines, notamment dans la gestion des ressources en eau, la planification de l'énergie, la prévention des inondations, la navigation maritime, la gestion des rivières et la sécurité des barrages. Voici quelques raisons pour lesquelles la prévision du débit est importante :

Gestion des ressources en eau : La disponibilité du débit d'eau est essentielle pour l'agriculture, l'approvisionnement en eau potable, l'industrie et l'écosystème. La prévision du débit permet de planifier l'utilisation de l'eau de manière efficiente et durable, en prenant en compte les variations saisonnières et les événements météorologiques extrêmes.

Planification de l'énergie : De nombreuses sources d'énergie, telles que l'hydroélectricité, dépendent du débit des cours d'eau. La prévision du débit permet aux gestionnaires de centrales électriques de planifier la production d'énergie en fonction des prévisions, en optimisant l'utilisation des ressources disponibles.

Prévention des inondations : Les prévisions précises du débit des rivières et des crues sont essentielles pour prévenir les inondations et prendre des mesures d'urgence appropriées. Les modèles de prévision du débit aident les autorités à évaluer les risques potentiels, à mettre en place des systèmes d'alerte précoce et à prendre des décisions éclairées pour protéger les populations et les infrastructures.

Navigation maritime : Les prévisions du débit sont utilisées pour planifier les itinéraires maritimes, en tenant compte des courants et des marées. Cela permet d'optimiser la navigation, d'économiser du carburant et de garantir la sécurité des navires.

Gestion des rivières : La prévision du débit est essentielle pour la gestion des rivières, en particulier pour maintenir un équilibre écologique, prévenir l'érosion des berges et maintenir la qualité de l'eau. Les informations sur le débit aident les décideurs à prendre des mesures pour préserver les écosystèmes fluviaux et garantir une utilisation durable des ressources en eau.


Sécurité des barrages : Les barrages sont construits pour réguler le débit de l'eau et fournir de l'énergie hydraulique. La prévision précise du débit est essentielle pour garantir la sécurité des barrages, en évitant les débordements ou les ruptures potentielles.

Actuellement les modèles basés sur l'intelligence artificielle sont utilisés dans pratiquement tous les domaines. Comme les autres domaines, les modèles basés sur l'intelligence artificielle sont de plus en plus utilisés dans les prévisions hydrologiques.

L'objectif du présent travail est de tester les modèles basés sur l'intelligence artificielle, en particulier les réseaux de neurones artificiels pour la prévision du débit moyen journalier de la station de sidi Aich , située dans le bassin versant de la Soummam.

Afin de réaliser ces objectifs, ce mémoire a été structuré en quatre principaux chapitres:

- Le travail commence par une introduction générale.
- Le premier chapitre donne un point de connaissance sur les différentes méthodes utilisées pour la prévision des débits.
- Le deuxième chapitre traite la présentation de la zone d'étude.
- Le troisième chapitre présente les modèles réseaux de neurones artificiels.
- Le quatrième chapitre présente l'application de l'approche perceptron multicouche, les résultats de prévision obtenus et leurs interprétations.
- Le travail est terminé par une conclusion générale.



Chapitre I: Synthèse bibliographique

Chapitre I: Synthèse bibliographique

Introduction

Actuellement, les méthodes inspirées de la biologie humaine sont de plus en plus utilisées dans pratiquement tous les domaines. Le domaine d'hydrologie, en particulier les prévisions hydrologiques utilise également plusieurs méthodes de l'intelligence artificielle. La présente partie du mémoire, présente une synthèse bibliographique sur les méthodes de l'intelligence artificielle utilisées dans la prévision des débits.

I.1 Importance de la prévision des débits

La prédiction précise du débit des cours d'eau sur de longues périodes reste un défi majeur dans la gestion de l'eau. Cependant, de nouvelles approches et techniques émergentes ont été développées pour améliorer la précision des prévisions hydrologiques. Voici quelques développements récents dans ce domaine :

Utilisation de l'apprentissage automatique : Les méthodes d'apprentissage automatique, telles que les réseaux de neurones et les réseaux de neurones profonds et les modèles d'apprentissage en ligne, ont montré des résultats prometteurs dans la prédiction des débits des cours d'eau. Ces approches exploitent la puissance des algorithmes d'apprentissage automatique pour capturer les relations complexes entre les variables hydrologiques et fournir des prévisions précises.

Intégration des données satellitaires : L'utilisation de données satellitaires, telles que l'imagerie radar et les mesures d'altimétrie, offre de nouvelles opportunités pour améliorer les prévisions hydrologiques. Ces données peuvent fournir des informations sur l'étendue des bassins versants, l'humidité du sol et d'autres variables clés qui peuvent influencer le débit des cours d'eau.

Chapitre I: Synthèse bibliographique

Modèles hydrologiques distribués : Les modèles hydrologiques distribués permettent de prendre en compte les variations spatiales des caractéristiques du bassin versant, telles que la topographie, les sols et l'utilisation des terres. Ces modèles utilisent des techniques avancées de modélisation géospatiale pour simuler de manière réaliste le comportement hydrologique à l'échelle du bassin versant.

Approches de modélisation hydrométéorologique intégrée : Les prévisions hydrologiques peuvent être améliorées en intégrant des données hydrométéorologiques, telles que les prévisions météorologiques à court terme et les observations en temps réel, dans les modèles hydrologiques. Cela permet de prendre en compte les effets des précipitations et des conditions météorologiques sur le débit des cours d'eau.

Utilisation de l'intelligence artificielle pour la gestion de l'eau : En plus des prévisions hydrologiques, l'intelligence artificielle peut être utilisée pour optimiser la gestion des ressources en eau. Des techniques telles que l'optimisation multi-objectifs, les algorithmes génétiques et les systèmes experts peuvent aider à trouver des solutions efficaces pour maximiser les avantages des systèmes hydroélectriques et atténuer les effets de la sécheresse.

Des prévisions précises du débit des cours d'eau, à une échelle périodique pour de longs termes, sont d'une grande importance dans la gestion de l'eau cherchant à fournir des approvisionnements en eau fiables, à maximiser les avantages des systèmes hydroélectriques et à atténuer la sécheresse. Néanmoins, la prévision des séries chronologiques de débits pose un grand défi et est compliquée en raison de leur forte non-linéarité. Ainsi, depuis la fin des années 1960, de nombreux modèles hydrologiques ont été développés. Presque tous les modèles développés pour la prévision des débits en temps réel sont basés sur des considérations physiques, des fonctions empiriques ou des théories plus analytiques. Chacun d'eux a ses propres avantages et inconvénients.

I.2 Aperçu sur les approches utilisées pour la prévision des débits

Selon un examen des recherches antérieures, il est à ont souligné que plusieurs techniques d'intelligence artificielle, telles que la programmation génétique (GP), la machine à vecteurs de support (SVM), la machine d'apprentissage extrême (ELM) et la forêt aléatoire, ont été étudiées pour prévoir les séries temporelles d'écoulement et leurs performances ont été évaluées.

Cependant, les modèles de réseaux de neurones artificiels ont été les plus largement utilisés et les plus recommandés au cours des deux dernières décennies pour divers domaines de prévisions hydrologiques et de nombreux résultats réussis ont été rapportés dans les prévisions de débit, en particulier lorsqu'ils sont couplés à des transformées en ondelettes (Kisi et Cigizoglu 2007 ; Nalley et al. 2012 ; Akrami et al. (2014) ; Danadeh Mehr et al. 2014, 2015 ; Santos et al. 2014 ; Santos et Silva 2014 ; Makwanana et Tiwari 2014 ; Seo et al. 2015 ; Shoaib et al. 2014, 2017 ; Hadi et Tombul 2018a). Le principal avantage des modèles ANN et WANN est leur capacité à gérer la non-linéarité et les caractéristiques non stationnaires des séries temporelles de flux, tout en nécessitant une quantité relativement faible de données. En effet, cela présente un avantage considérable dans les pays en développement, où l'on manque de données hydrologiques enregistrées à long terme dans la plupart des bassins.

I.3 Réseaux de neurones artificiels (ANN)

Pour surmonter les inconvénients associés aux modèles classiques, depuis plus d'une décennie, les modèles pilotés par les données ont suscité l'intérêt des chercheurs en hydrologie du monde entier. En particulier, les réseaux de neurones artificiels (ANN) ont été considérés comme des modèles hydrologiques et comme des outils très compétents et efficaces pour la prédiction du ruissellement en temps réel (Toth et Brath, 2007). Ceci est principalement lié à leur capacité à reproduire de manière flexible la grande non-linéarité de la relation entre les

variables hydrologiques sans connaissance approfondie et explicite des différents sous-processus internes et sans avoir besoin de grandes quantités d'informations concernant le bassin versant modélisé.

I.4 Modèles hybrides

Le principal inconvénient des modèles de réseaux de neurones artificiels est qu'ils sont incapables d'aborder la question des séries temporelles non linéaires et non stationnaires, qui caractérise les processus hydrologiques, en particulier dans les régions semi-arides. Par conséquent, un prétraitement des données doit être effectué.

La transformation en ondelettes est très utile et puissante pour les besoins d'analyse de données de séries temporelles non stationnaires (Shoaib et al. 2014). Elle permet d'obtenir une description précise et de fournir des informations considérables sur les schémas physiques des données (Daubechies 1992).

Jusqu'à présent, de nombreuses études ont analysé les performances des modèles basés sur les ondelettes de conjonction, couplant les qualités et les avantages de la décomposition en ondelettes et de nombreux modèles basés sur les données (tels que ANN, support vector machine et modèles neuro-flous) (parmi : Kisi 2008, 2009 ; Kisi et Cimen 2011 ; Adamowski et Sun 2010 ; Maheswaran et Khosa 2012). Pour plus de détails, Nourani et al. (2014) ont présenté un article de synthèse sur les modèles hybrides ondelettes-intelligence artificielle et leurs différentes applications dans le domaine de l'hydrologie au cours des 20 dernières années.

La prévision des débits à long terme est une démarche délicate, surtout dans le cas des échelles de temps mensuelles et annuelles. Cependant, la plupart des applications ont été faites pour prédire le débit multi-étapes à des échelles de temps quotidiennes et

Chapitre I: Synthèse bibliographique

hebdomadaires (entre autres : Wang et al. 2006a, b ; Adamowski et Sun 2010 ; Yonaba et al. 2010 ; Karran et al. 2014 ; etc.).

Concernant la prévision des débits à l'échelle mensuelle, à ce jour, plusieurs études ont été réalisées ces dernières années. Un certain nombre de ces études ont utilisé des modèles pilotés par les données et des modèles hybrides pilotés par les données combinant ces derniers avec la décomposition en ondelettes comme technique de prétraitement.

Ces travaux ont montré que cette procédure fournit des prévisions à court terme très précises et fiables dans plusieurs bassins du monde. En effet, on peut citer comme exemples : Kisi et Partal (2011) ont utilisé un modèle couplé ondelettes-neuro-flou pour prévoir les débits journaliers, mensuels et annuels en Turquie ; Kisi et Cimen (2011) ont exploré la précision d'une machine vectorielle à support d'ondelettes pour prévoir le débit à une échelle de temps mensuelle, et ils ont constaté que l'approche fournit une alternative supérieure pour supporter le modèle de régression vectorielle.

Plusieurs autres études ont été menées dans les autres bassins du monde. Cependant, un nombre limité de chercheurs ont exploré l'approche dans les régions semi-arides à écoulement intermittent et pour de longs délais. Dans ce domaine, on peut citer les travaux d'Adamowski et Sun (2010) qui ont développé des réseaux de neurones à ondelettes pour prévoir des débits de 1 à 3 jours d'avance dans des bassins versants semi-arides. Van Ogtrop et al. (2011) ont utilisé un modèle statistique pour prédire le débit jusqu'à un an dans cinq bassins versants semi-arides en Australie. Lui et coll. (2014) ont utilisé trois différentes techniques basées sur les données pour la prévision des débits dans la région montagneuse semi-aride du nord-ouest de la Chine.

D'autre part, malgré le fait que de nombreux problèmes ont été explorés avec l'utilisation des réseaux de neurones artificiels à ondelettes, il semble qu'il existe de nombreux

Chapitre I: Synthèse bibliographique

autres problèmes qui ne sont pas encore explorés en profondeur. À notre connaissance, peu de chercheurs ont abordé les questions de l'effet des variables d'entrée dans la prévision des performances de ces modèles dans les régions semi-arides et de leur précision pour les prévisions à long terme. Les quelques études récemment publiées qui ont abordé le problème se sont concentrées sur la modélisation et la prévision des débits à une échelle de temps quotidienne (Abda et Chettih 2018 ; Zakhrouf et al. 2018).

Conclusion

En conclusion, les méthodes d'intelligence artificielle inspirées de la biologie humaine jouent un rôle crucial et en constante augmentation dans divers domaines, y compris l'hydrologie et les prévisions hydrologiques. Les résultats obtenus jusqu'à présent démontrent l'efficacité de ces approches, offrant de nouvelles perspectives pour améliorer la précision et la fiabilité des prévisions hydrologiques. Cependant, il est important de souligner qu'il est nécessaire de poursuivre les efforts de recherche et de développement afin de perfectionner ces méthodes, en tenant compte des spécificités des différents bassins hydrographiques et des défis auxquels ils font face. En résumé, l'intégration de l'intelligence artificielle dans le domaine de l'hydrologie ouvre des opportunités passionnantes et prometteuses pour améliorer notre compréhension et notre gestion des ressources en eau.



Chapitre II: Présentation de la zone d'étude

Chapitre II : Présentation de la zone d'étude

Introduction

Dans ce chapitre, nous présentons une description générale du bassin versant de la Soummam. Nous abordons les aspects géographiques, géomorphologiques et géologiques qui sont essentiels pour comprendre les mécanismes hydrologiques de la région.

II.1 Situation géographique de bassin

D'une superficie de 9125Km², le bassin versant de la Soummam est situé dans la partie Nord-est de l'Algérie à mi-chemin entre la ville d'Alger et la ville de Constantine, exactement entre les méridiens 3° 38' et 5° 38' et les parallèles 35° et 36° 45'. Il est limité au nord par les chaînes montagneuses du Djurdjura et ses contreforts qui s'étendent jusqu'à la mer Méditerranée, au Sud par les contreforts des monts du Hodna, à l'Est par les chaînes des Babors et le plateau de Sétif et à l'Ouest par le plateau de Bouira (Tebbani, 2016).

Le bassin versant de la Soummam porte selon la codification de l'ANRH le numéro N°15. Il est limitrophe de plusieurs bassins versants (Figure I.1). Limité au Nord, par le bassin de l'Oued Sebaou(code 02b) et par celui du côtier Algérois (code 02a), au Nord-est par le bassin versant de l'Oued Kébir Rhumel (code 10) et par le bassin versant du côtier Constantinois (code 03), à l'Est par les basses hauts plateaux Constantinois (code 07) ; au Sud par le bassin de Chott El Hodna (code 05) .

Le bassin est composé de trois grands sous bassins versants (figure I.2), répartie comme suit (Khemissa et Bouab, 2016) :

- Sous bassin d'oued Sahel, qui s'étend de Sour El-Ghozlane (Bouira) à Akbou sur une superficie de 3 741 km² ;
- Sous bassin d'ouedBoussellam, qui s'étend d'Aïn Oulmane (Sétif) à Akbou sur une superficie de 4313 km² ;
- Sous bassin de la Soummam, au sens strict, d'Akbou à Bejaia et couvre une superficie de 1068km². et à l'Ouest par le bassin de l'Oued Isser (code 09) (Tebbani, 2016).

Chapitre II : Présentation de la zone d'étude




Figure II.1 : La situation de la zone d'étude par rapport au bassin hydrographique De l'Algérie du nord (Tebbani, 2016).

II.2 Relief et hydrographie du bassin versant




Figure II.2 : Carte du relief du bassin versant d'étude (AMOUR, 2010)

De Bouira à Akbou, la chaîne de Djurdjura n'est en aucun endroit inférieure à 1500 m, d'Akbou en allant vers La mer, la hauteur diminue graduellement.

Chapitre II : Présentation de la zone d'étude

Le bassin de la Soummam est hydrographiquement très développé, trois rivières et leurs affluents constituent son squelette :

Le Sahel affluent venant du nord-ouest, le Bousellam venant du nord-est, la Soummam qui se forme à Akbou au confluent du Sahel et de Bousellam et coule du nord-est vers la mer.

Le sahel étant l'affluent le plus important, il est formé à partir d'Oued Zaiane et de Oued Eddous.

Le réseau hydrographique du bassin versant de la Soummam est illustré dans la (Figure I.3).




Figure II.3 : Réseau hydrographique du bassin versant de la Soummam

II.3 La géologie

La répartition des formations géologiques de bassin versant de l'oued Soummam est comme suit:

Sur la rive gauche par l'oligocène traversée par des formations du crétacé inférieur; du miocène inférieur apparait dans la partie aval, à côté de l'oued de terrasses alluviales qui

Chapitre II : Présentation de la zone d'étude

recouvrent en général le pied des pentes sauf dans la région de Sidi Aich où le crétacé apparaît dans le lit.

Sur la rive droite est formée par le crétacé inférieur moyen et supérieur, les terrasses alluviales sont beaucoup plus restreinte (Bouchellah et Mazoua, 2020).

II.4 Topographie de bassin

II.4.1 Les caractéristiques de la disposition dans le plan

II.4.1.1 La surface (A) :

La surface du bassin versant est la première et la plus importante des caractéristiques. Ses limites dans un bassin sont formées par les lignes de partage des eaux qui le séparent des autres bassins adjacents. Elle peut être mesurée par superposition d'une grille dessinée sur papier transparent, par l'utilisation d'un planimètre ou par des techniques de digitalisation (logiciel Arc Gis ...).

Dans notre cas, la surface du bassin versant de la Soummam est égale à **9125 km²**.

II.4.1.2 Le périmètre (P) :

Le périmètre du bassin versant est la longueur de la ligne de partage des eaux, il représente le contour limitant la surface du bassin versant. Le périmètre peut être mesuré par un curvimètre ou par des techniques de digitalisation (logiciel ArcGis ...). Le périmètre du bassin versant de la Soummam est égal à **655 km**.

II.4.1.3 La forme (KG)

L'indice de compacité de Gravelius (1914) KG, défini comme le rapport du périmètre du bassin au périmètre du cercle ayant la même surface :

$$K_G = \frac{p}{2 \cdot \sqrt{\pi \cdot A}} = 0,28 \cdot \frac{P}{\sqrt{A}} \dots\dots\dots(1)$$

Il est établi en comparant le périmètre du bassin à celui d'un cercle ayant la même surface du bassin $K_G = 2,17$ (le bassin de la Soummam est de forme allongée).

La forme d'un bassin versant influence l'allure de l'hydrogramme à l'exutoire du bassin versant.

- Lorsque $K_G = 1$, Le BV est de forme circulaire.

Chapitre II : Présentation de la zone d'étude

- Lorsque $KG = 1,12$: le BV est un carré.
- Lorsque KG se rapproche de 1 : le bassin est de forme compacte ou arrondi.
- Lorsque KG est supérieur à 1 : le bassin est de forme allongée.

II.4.1.4 Le rectangle équivalent

C'est une notion qui a été introduite par Roche (en 1963) qui permet de comparer facilement des bassins entre eux du point de vue de l'influence de leurs caractéristiques sur l'écoulement. On suppose que l'écoulement sur un bassin donné est approximativement le même, à conditions climatologiques égales, que sur un rectangle de même superficie, ayant même coefficient de Gravelius et même répartition hypsométrique, étant entendu que la distribution des sols et de la végétation et la densité de drainage sont respectées dans les différentes aires comprises entre les courbes de niveaux. Il s'agit donc d'une transformation purement géométrique dans laquelle le contour du bassin devient un rectangle de même périmètre, les courbes de niveaux des droites parallèles aux petits côtés du rectangle et l'exutoire un des petits côtés du rectangle que nous avons appelé rectangle équivalent.

Soit l et L la largeur et la longueur du rectangle. P et A le périmètre et la surface du bassin versant. On a, d'après les définitions ci-dessus :

$$P = 2 \cdot (L_{rec} + l_{rec}), A = L_{rec} \cdot l_{rec} \text{ et } K_G = \frac{P}{2 \cdot \sqrt{\pi \cdot A}} = 0,28 \cdot \frac{P}{\sqrt{A}} \dots\dots\dots (2)$$

En combinant ces 3 relations, on obtient respectivement L_{rec} et l_{rec} la longueur et la largeur du rectangle équivalent.

$$L_{rec} = \frac{K_G \sqrt{A}}{1,12} \left[1 + \sqrt{1 - \left(\frac{1,12}{K_G} \right)^2} \right] \dots\dots\dots (3)$$

$$l_{rec} = \frac{K_G \sqrt{A}}{1,12} \left[1 - \sqrt{1 - \left(\frac{1,12}{K_G} \right)^2} \right] \dots\dots\dots (4)$$

II.4.2 Courbe hypsométrique :




Figure II.4. La courbe hypsométrique du bassin de Soummam (OUANAS,2022)

II.4.3 les altitudes

II.4.3 .1 Les altitudes maximale et minimale (Hmax et Hmin) :

Elles sont obtenues directement à partir de cartes topographiques. L'altitude maximale représente le point le plus élevé du bassin tandis que l'altitude minimale considère le point le plus bas, généralement à l'exutoire.

- L'altitude maximale=2287m.
- L'altitude minimale = 0 m..

II.4.3.2 L'altitude moyenne(Hmoy) :

L'altitude moyenne se déduit directement de la courbe hypsométrique ou de la lecture d'une carte topographique. On peut la définir comme suit :

$$H_{moy} = \sum_1^i \frac{A_i \cdot h_i}{A} \cdot \dots \dots \dots (5)$$

Chapitre II : Présentation de la zone d'étude

Avec :

Hmoy : altitude moyenne du bassin [m] ;

Ai : aire comprise entre deux courbes de niveau [km²] ;

hi : altitude moyenne entre deux courbes de niveau [m] ;

A : superficie totale du bassin versant [km²].

Hmoy du bassin versant de Soummam égal à 820 m.

II.4.3.3 L'altitude médiane (H50%) :

L'altitude médiane correspond à l'altitude lue au point d'abscisse 50% de la surface totale du bassin, sur la courbe hypsométrique. Cette grandeur se rapproche de l'altitude moyenne dans le cas où la courbe hypsométrique du bassin concerné présente une pente régulière.

L'altitude médiane dans le bassin de Soummam est égale à 950

II.4.3.4 La dénivelée simple (D) :

On définit la "dénivelée D" comme étant la différence de côte entre H5 % et H95 % :
Celles –ci sont lues sur la courbe hypsométrique.

$$D = H_{5\%} - H_{95\%} \dots\dots\dots D=970 \text{ m} \dots\dots\dots (6)$$

II.4.3.5 Les indices de pentes :

L'objectif de ces indices est de caractériser les pentes d'un bassin versant et de permettre des comparaisons et des classifications.




Figure II.5 Carte de pentes du BV de la Soummam (Toumiat et al 2021)

II.4.3.5.1 La pente moyenne du bassin versant :

La pente moyenne est une caractéristique importante qui renseigne sur la topographie du bassin. Elle est considérée comme une variable indépendante. Elle donne une bonne indication sur le temps de parcours du ruissellement direct - donc sur le temps de concentration t_c et influence directement le débit de pointe lors d'une averse.

Plusieurs méthodes ont été développées pour estimer la pente moyenne d'un bassin. Toutes se basent sur une lecture d'une carte topographique réelle ou approximative. La méthode proposée par Carlier et Leclerc (1964) consiste à calculer la moyenne pondérée des pentes de toutes les surfaces élémentaires comprises entre deux altitudes données. Une valeur approchée de la pente moyenne est alors donnée par la relation suivante :

$$Im = \frac{D.L}{A} \dots\dots\dots (7)$$

L : longueur totale de courbes de niveau [km],

D : équidistance entre deux courbes de niveau [m],

A : surface du bassin versant [km²].

II.4.3.5.2 L'indice de pente Roche (Ip)

Cet indice se calcule à partir du rectangle équivalent. Il est égal à la somme des racines carrées des pentes moyennes de chacun des éléments pondérés par la surface intéressée, soit :

$$Ip = \frac{1}{\sqrt{L_{rec}}} \sum_{i=1}^n (Xi \sqrt{\frac{d}{xi}}) \dots\dots\dots (8)$$

Où :

Ip : indice de pente [%].

Lrec : longueur du rectangle [m].

xi : distance qui sépare deux courbes sur le rectangle [m] (la largeur du rectangle étant constante, cette distance est égale au facteur de pondération).

Chapitre II : Présentation de la zone d'étude

d : distance entre 2 courbes de niveau successives (peut être variable) [m].

d/xi: pente moyenne d'un élément [%].

II.4.3.5.3 Indice de pente globale (Ig)

L'indice de Roche étant cependant trop long à évaluer pour des études rapides, il a été proposé, par Laborde, un indice encore plus simple : la pente globale

$$Ig = \frac{D}{L_{rec}} \dots \dots \dots (9)$$

$$Ig = 2,82\%$$

Relief assez fort

Où :

D : étant la dénivelée H5% - H95%, définie sur la courbe hypsométrique ou même directement à l'œil sur la carte topographique ;

L : étant la longueur du rectangle équivalent.

Cet indice, très facile à calculer, est des plus utilisés. Il sert de base à une des classifications (O.R.S.T.O.M. actuellement IRD) pour des bassins versants dont la surface est dès l'ordre de 25 km² :

Tableau II.2 L'indice global de pente.

R1	Relief très faible	$Ig < 0,002$
R2	Relief faible	$0,002 < Ig < 0,005$
R3	Relief assez faible	$0,005 < Ig < 0,01$
R4	Relief modéré	$0,01 < Ig < 0,02$
R5	Relief assez fort	$0,02 < Ig < 0,05$

Chapitre II : Présentation de la zone d'étude

R6	Relief fort	$0,05 < I_g < 0,1$
R7	Relief très fort	$0,1 < I_g$

II.4.3.5.4 Dénivelée spécifique (Ds)

L'indice I_g décroît pour un même bassin lorsque la surface augmente, il était donc difficile de comparer des bassins de tailles différentes.

La dénivelée spécifique D_s ne présente pas cet inconvénient : elle dérive de la pente globale I_g en la corrigeant de l'effet de surface admis étant inversement proportionnel à A :

$$D_s = I_g \cdot \sqrt{A} = \frac{D}{L} \sqrt{L \cdot l} = D \sqrt{\frac{l}{L}} \dots \dots \dots (10)$$

$$D_s = 269,66 \text{ m}$$

La dénivelée spécifique ne dépend donc que de l'hypsométrie ($D = H_{5\%} - H_{95\%}$) et de la forme du bassin (l/L). Elle donne lieu à une deuxième classification de l'O.R.S.T.O.M., indépendante des surfaces des bassins.

Tableau II.3 Deuxième classification de l'O.R.S.T.O.M

R1	Relief très faible	$D_s < 10 \text{ m}$
R2	Relief faible	$10 \text{ m} < D_s < 25 \text{ m}$
R3	Relief assez faible	$25 \text{ m} < D_s < 50 \text{ m}$
R4	Relief modéré	$50 \text{ m} < D_s < 100 \text{ m}$
R5	Relief assez fort	$100 \text{ m} < D_s < 250 \text{ m}$
R6	Relief fort	$250 \text{ m} < D_s < 500 \text{ m}$
R7	Relief très fort	$D_s > 500 \text{ m}$

❖ Caractéristiques physiques de bassin versant soummam

Le suivant présente les caractéristiques physiques de bassin versant Soummam, objets de la présente étude.

Tableau II.1Caractéristiques physiques de bassin versant soummam(AMOUR, 2010)

Aire	9125 km²
Périmètre	655 km
Indice de compacité (Gravelius, 1914)	1,9
Altitude maximale	2308
Altitude minimale	2 m
Altitude moyenne	776 m
Altitude médiane	900 m
Largeur du rectangle équivalent (l_e)	31 km
Longueur du rectangle équivalent (L_e)	290 km

II.5. Situation climatique du bassin versant de Soummam :

Le climat peut être défini comme étant l'ensemble des phénomènes météorologiques qui caractérisent l'état de l'atmosphère et de son évolution en un lieu donné. Les principales composantes du climat sont : les précipitations, la température, le vent, et l'humidité relative.

II.5.1 les précipitations :

La pluviométrie dans le bassin de la Soummam est déterminée grâce à l'existence de 41 stations pluviométriques représentatives prises en compte par l'ANRH dans le cadre du projet PNUD/ALG/88/021, pour l'étude de la pluviométrie de l'Algérie du Nord.

Chapitre II : Présentation de la zone d'étude

Le régime de la pluviométrie moyenne annuelle est connu grâce à l'interprétation de la carte pluviométrique à l'échelle 1/500 000 éditée par l'ANRH en 1993 dans le cadre du projet suscité.

Il en ressort d'après cette carte que la pluviométrie moyenne annuelle pour l'ensemble du bassin oscillant entre 300 et 1000 mm en augmentant d'Ouest vers l'Est.

II.5.2 Le vent :

Le phénomène est habituellement accompagné d'une part d'une évaporation accentuée de la surface du sol et de la végétation et d'autre part du dessèchement du sol et de la couverture végétale. Des vents chauds et secs brûlent les champs de blé par suite d'une réduction d'humidité dans les plantes et de l'évaporation de la couche superficielle du sol.

Dans le bassin versant de la Soummam est canalisé par les massifs montagneux voisins sa direction prédominante est nord-est et sud-ouest. (ONM)

Les moyennes mensuelles des vitesses du vent moyen sur dix ans sont données par le Tableau suivant :

Mois	Jan	Fév	Mars	Avr	Mai	Juin	Juil	Aout	Sep	Oct	Nov	Déc
V(m/s)	4,7	4,28	3,92	3,52	3,58	3,47	3,63	3,38	3,54	4,13	4,4	4,91

Tableau II.4. Vitesse mensuelle moyenne du vent (1994-2003) (O.N.M)

La vitesse du vent la plus faible a été enregistrée le mois d'aout de l'ordre de 3,38 m/s contrairement à la période hivernale où les vents sont froids et violents surtout dans le mois de décembre et janvier dont la vitesse du vent varie entre 4,91 et 4,7 m/s.

II.5.3 Humidité relative

D'une manière générale, le bassin de la Soummam est caractérisé par une humidité élevée sur l'ensemble de son territoire à l'exception de la partie Est du bassin (Bordj Bou Arréridj-Sétif). Le tableau II.2 présente l'humidité relative des 4 stations.

Tableau II.5. Humidité relative (en %) enregistrée en 2003 (OMM, 2006)

Chapitre II : Présentation de la zone d'étude

Station	Sept	Oct	Nov	Déc	Jan	Fév	Mars	Avr	Mai	Juin	Juil	Août
Bouira	91	87	79	77	75	50	45	48	67	78	81	86
Béjaia	78	77	79	82	82	72	73	70	79	81	77	76
B.B.A	78	78	70	68	59	43	32	40	56	73	72	79
Sétif	83	82	73	71	65	49	38	43	64	73	78	86

Source : ONM

L'examen du tableau ci-dessous montre que les moyennes mensuelles de l'humidité relatives sont plus élevées en hiver qu'en été; cela est certainement dû à la température plus élevée en été qu'en hiver. Les valeurs relativement grandes de l'humidité indiquent une grande possibilité de condensation de la vapeur, ce qui pourrait contribuer à l'amélioration du bilan hydrique en hiver par rapport à l'été.

II.5.4 Température

Le bassin de la Soummam est caractérisé généralement par deux saisons:

- Une saison chaude allant du mois de Juin au mois de Septembre.
- Une saison froide nettement plus longue, allant du mois d'Octobre au mois de mai.

Les valeurs de la température moyenne mensuelle enregistrées aux niveaux de 04 stations climatiques représentatives dans le bassin sont mentionnées dans le tableau II.1. La période d'observation est de 1993 à 2003.

Tableau II.6 Températures moyennes mensuelles :

Station	Sept	Oct	Nov	Déc	Jan	Fév	Mar	Avr	Mai	Juin	Juil	Août
Bouira	22,3	18,1	12,6	9,2	8,3	8,8	11,7	13,7	18,6	28,9	37,1	37,5
Béjaia	23,3	20,1	16,0	13,2	11,4	11,5	12,9	15,2	18,9	29,4	33,9	36,3
B.B.A	22,1	16,6	10,6	7,0	6,3	7,2	10,4	12,8	17,9	27,0	36,6	37,2
Sétif	20,3	15,7	9,8	6,4	5,4	6,2	9,4	11,6	17,7	29,8	35,4	36,1
Moy Mensuelle	22,0	17,6	12,2	9,0	7,8	8,4	11,1	13,3	18,3	28,8	34,5	36,7

Chapitre II : Présentation de la zone d'étude

D'après le tableau II.1, on peut constater que les mois les plus froids sont Décembre, Janvier et Février tandis que les mois les plus chauds sont Juillet et Août. (Toumiat ,2021) .

II.6 Flore et faune de Soummame :

Le bassin du Soummam est caractérisée par sa richesse en flore et faune. Voici un aperçu de la flore et de la faune que l'on peut trouver dans cette région :

II.6.1 La flore

Forêts de chênes-lièges (*Quercus suber*) : Ces forêts sont très répandues dans la région de la Soummam. Les chênes-lièges sont des arbres à feuilles persistantes qui fournissent un habitat important pour de nombreuses espèces animales.

Maquis méditerranéen : La région de la Soummam abrite des maquis méditerranéens, qui sont des formations végétales caractérisées par une grande diversité d'arbustes et de plantes aromatiques, tels que le thym, le romarin, et la lavande.

Oliviers (*Olea europaea*) : Les oliviers sont également présents dans la région de la Soummam, contribuant à la beauté et à l'agriculture de la région.

II.6.2 La faune

Oiseaux : La Soummam est un lieu de passage important pour de nombreuses espèces d'oiseaux migrateurs. On peut y observer des rapaces tels que les aigles et les faucons, ainsi que des oiseaux chanteurs comme les rouges-gorges et les merles.

Mammifères : La région abrite une variété de mammifères, notamment des sangliers, des renards, des lièvres, et des hérissons.

Reptiles et amphibiens : On peut également trouver divers reptiles et amphibiens dans la région, tels que les lézards, les serpents et les grenouilles.

Il convient de noter que cette liste n'est pas exhaustive et qu'il existe de nombreuses autres espèces de flore et faune dans la région de la Soummam. La diversité biologique de cette zone en fait un lieu d'intérêt pour les amateurs de nature et les chercheurs en écologie.

Conclusion

Chapitre II : Présentation de la zone d'étude

Dans ce chapitre, nous avons présenté une description générale du bassin versant de la Soummam, en abordant les aspects géographiques, géomorphologiques, géologiques et essentiels pour comprendre les mécanismes hydrologiques de la région. Cette description complète met en évidence l'interconnexion des différents facteurs qui influencent le cycle de l'eau dans la région, offrant ainsi une compréhension plus approfondie des interactions hydriques et des facteurs qui affectent la distribution et le flux de l'eau dans le bassin versant de la Soummam.



Chapitre III: Les réseaux de neurones artificiels

Chapitre III : Les réseaux de neurones artificiels

Introduction

De nos jours, les réseaux de neurones artificiels, en raison de leurs performances, sont utilisés dans plusieurs domaines.

Dans ce chapitre, nous présentons les réseaux de neurones artificiels, leur historique ainsi que leurs domaines d'application.

III.1 Définitions

III.1.1 intelligence artificielle

L'intelligence artificielle est un domaine de l'informatique qui se concentre sur la résolution de problèmes pratiques en utilisant des méthodes inspirées de la biologie humaine.

Une intelligence artificielle est une technologie capable de produire des résultats similaires à ceux issus du cerveau humain. Il s'agit d'un outil informatique qui effectue des actions ou exécute des tâches qui, il y a peu, étaient le propre des êtres vivants, humains ou animaux. Cet outil repose notamment sur des algorithmes, c'est-à-dire des suites de formules mathématiques et de traitements statistiques".

III.1.2 Les réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des modèles de traitement de l'information inspirés par le fonctionnement du cerveau humain. et sont une forme de l'apprentissage automatique, une branche de l'intelligence artificielle." Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau (Claude Touzet, 1992).

III.1.2.1 Historique des réseaux de neurones artificiels

Les réseaux de neurones sont une catégorie de modèles qui cherchent à reproduire certaines fonctions du cerveau humain et à imiter certaines de ses structures de base. Cette

Chapitre III : Les réseaux de neurones artificiels

discipline a des origines variées dans l'histoire.

En 1890 : W. James, célèbre psychologue américain introduit le concept de mémoire associative, et propose ce qui deviendra une loi de fonctionnement pour l'apprentissage sur les réseaux de neurones connue plus tard sous le nom de loi de Hebb.

En 1943 : J. Mc Culloch et W. Pitts laissent leurs noms à une modélisation du neurone biologique (un neurone au comportement binaire). Ceux sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique).

En 1949, D. Hebb initie dans son ouvrage "The Organization of Behavior", la notion d'apprentissage. Deux neurones entrant en activité simultanément vont être associés (c'est-à dire que leurs contacts synaptiques vont être renforcés). On parle de loi de Hebb et d'associationnisme.

III.1.2.1.1 Les premiers succès

En 1958, F. Rosenblatt développe le modèle du Perceptron. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance de formes. Notons qu'à cet époque les moyens à sa disposition sont limités et c'est une prouesse technologique que de réussir à faire fonctionner correctement cette machine plus de quelques minutes.

En 1960, B. Widrow, un automaticien, développe le modèle Adaline (Adaptative Linear Element). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente.

Celle-ci est à l'origine de l'algorithme de rétro-propagation de gradient très utilisé aujourd'hui avec les Perceptrons multicouches.

En 1969, Minsky et Papert publient un ouvrage qui met en exergue les limitations théoriques du perceptron. Limitations alors connues, notamment concernant l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils étendent implicitement ces limitations à tous modèles de réseaux de neurones artificiels. Après leur ouvrage, il y a abandon financier des recherches dans le domaine (surtout aux U.S.A.), les chercheurs se tournent principalement vers l'intelligence artificielle et les systèmes à bases de règles.

III.1.2.1.2 L'ombre

Entre 1967 et 1982, Toutes les recherches ne sont, bien sûr, pas interrompues. Elles se poursuivent, mais déguisées, sous le couvert de divers domaines comme : le traitement

Chapitre III : Les réseaux de neurones artificiels

adaptatif du signal, la reconnaissance de formes, la modélisation en neurobiologie, etc. De grands noms travaillent durant cette période, tels : S. Grossberg, T. Kohonen, ...

III.1.2.1.3 Le renouveau

En 1982, J. J. Hopfield est un physicien, Présente une théorie du fonctionnement et des possibilités des réseaux de neurones. Il explique notamment dans un ouvrage la structure et loi d'apprentissage d'un réseau de neurones correspondant à un résultat escompté. Ce modèle est encore très utilisé aujourd'hui pour des problèmes d'optimisation.

Bien que les limitations du Perceptron mise en avant par M. Minsky ne soient pas levées par le modèle d'Hopfield, les recherches sont relancées.

III.1.2.1.4 La levée des limitations

En 1983, La Machine de Boltzmann est le premier modèle connu apte à traiter de manière satisfaisante les limitations recensées dans le cas du perceptron. Mais l'utilisation pratique s'avère difficile, la convergence de l'algorithme étant extrêmement longue (les temps de calcul sont considérables).

En 1985, La rétropropagation de gradient apparaît. C'est un algorithme d'apprentissage adapté aux réseaux de neurones multicouches (aussi appelés Perceptrons multicouches). Sa découverte a été réalisée par trois groupes de chercheurs indépendants.

III.1.2.1.5 Actuellement

De nos jours, l'utilisation des réseaux de neurones dans divers domaines ne cesse de croître. Les applications en sont multiples et variées.

III.1.2.2 Types des réseaux des neurones

Il existe plusieurs types d'architectures neuronales couramment utilisées dans diverses machines. applications d'apprentissage. Cette section fournira un bref aperçu de certaines de ces architectures, qui seront abordées plus en détail dans les chapitres suivants.

III.1.2.2.1 Réseaux de fonctions à base radiale

Chapitre III : Les réseaux de neurones artificiels

Les réseaux à fonction de base radiale (RBF) représentent l'architecture oubliée des riches histoire des réseaux de neurones. Ils ne sont pas couramment utilisés à l'ère moderne, bien qu'il sont un potentiel significatif pour des types de problèmes spécifiques. Un problème limitant est que ces réseaux ne sont pas profonds et n'utilisent généralement que deux couches.

La première couche est construite de manière non supervisée, tandis que la deuxième couche est entraînée à l'aide de méthodes supervisées. Ces réseaux sont fondamentalement différents des réseaux feed-forward, et tirent leur puissance le plus grand nombre de nœuds dans la couche non supervisée. Les principes de base de l'utilisation de RBF Les réseaux sont fondamentalement très différents de ceux des réseaux à anticipation, en ce sens que les premiers tirent leur puissance de l'expansion de la taille de l'espace des fonctionnalités plutôt que de profondeur.




Figure III.1 : Réseaux de fonctions à base radiale

Cette approche est basée sur le théorème de Cover sur la séparabilité des motifs.
(T. Coorjans, N. Ballas, C. Laurent, C. Gulcehre, et A. Courville, 2016)

Qui indique que les problèmes de classification de modèles sont plus susceptibles d'être linéairement séparables lorsque projeté dans un espace de grande dimension avec une transformation non linéaire. La deuxième couche du réseau contient un prototype dans chaque nœud et l'activation est définie par la similarité des données d'entrée du prototype. Ces activations sont ensuite combinées avec des poids entraînés de la couche suivante pour créer

Chapitre III : Les réseaux de neurones artificiels

une prédiction finale. Cette approche est très similaire à celle des classificateurs les plus proches, sauf que les poids dans la deuxième couche fournissent un niveau supplémentaire de tutelle. En d'autres termes, l'approche est une méthode supervisée du plus proche voisin.

III.1.2.2.2 Machines Boltzmann restreintes

Les machines Boltzmann restreintes (RBM) utilisent la notion de minimisation d'énergie afin de créer des architectures de réseaux de neurones pour modéliser des données de manière non supervisée. Ces sont particulièrement utiles pour créer des modèles génératifs des données, et ils sont étroitement liés aux modèles graphiques probabilistes (D. Koller et N. Friedman, 2009).

Les machines Boltzmann restreintes doivent leurs origines à l'utilisation des réseaux de Hopfield. (J. J. Hopfield, 1982), qui peuvent être utilisés pour stocker des souvenirs.

Des variantes stochastiques de ces réseaux ont été généralisées aux machines de Boltzmann, dans lesquelles les couches cachées ont modélisé les aspects génératifs des données.

Les machines Boltzmann restreintes sont souvent utilisées pour la modélisation non supervisée et la réduction de la dimensionnalité, bien qu'elles puissent également être utilisées pour la modélisation supervisée. Cependant, depuis ils n'étaient pas naturellement adaptés à la modélisation supervisée, la formation supervisée était souvent précédée d'une phase non supervisée. Cela a naturellement conduit à la découverte de la notion de la préformation, qui s'est avérée extrêmement bénéfique pour l'apprentissage supervisé. Les RBM étaient parmi les premiers modèles utilisés pour l'apprentissage en profondeur, en particulier dans le cadre non supervisé.

L'approche de préformation a finalement été adoptée par d'autres types de modèles. Donc, Les GAN ont également une importance historique en termes de motivation de certaines méthodologies de formation pour les modèles profonds.


Le processus d'entraînement d'une machine Boltzmann restreinte est assez différent de celui d'un réseau d'alimentation en aval. En particulier, ces modèles ne peuvent pas être formés en utilisant la rétro propagation, et ils nécessitent un échantillonnage de Monte Carlo pour effectuer la formation. L'algorithme particulier couramment utilisé pour former un RBM

est l'algorithme de divergence contrastive.(C. Aggarwal,2018).

III.1.2.2.3 Réseaux de neurones convolutifs

Les réseaux de neurones convolutifs sont des réseaux d'inspiration biologique utilisés en informatique.vision pour la classification d'images et la détection d'objets. La motivation de base du réseau de neurones convolutifs a été obtenue à partir de la compréhension de Hubel et Wiesel (D. Hubel and T. Wiesel,1959).

de lafonctionnement du cortex visuel du chat, dans lequel des parties spécifiques du champ visuelsemblaientexciter certains neurones. Ce principe plus large a été utilisé pour concevoir une architecture parcimonieuse pour les réseaux de neurones convolutifs. La première architecture de base basée sur cette inspiration biologique fut le néocognitron, qui fut ensuite généralisée à l'architecture LeNet-5 (Y. LeCun, L. Bottou, Y. Bengio, et P. Haffner,1998) .Dans l'architecture de réseau neuronal convolutif, chaque couche du réseau est tridimensionnelle,qui a une étendue spatiale et une profondeur correspondant au nombre d'entités.



Figuer III.2: L'un des premiers réseaux de neurones convolutifs

La notion de profondeur d'une seule couche dans un réseau neuronal convolutif est distinct de la notion de 4Il s'agit d'une surcharge de la terminologie utilisée dans les réseaux de neurones convolutifs. Le sens de profondeur en termes de nombre de couches. Dans la couche d'entrée, ces entités correspondent aux canaux de couleur comme RVB (c'est-à-dire

Chapitre III : Les réseaux de neurones artificiels

rouge, vert, bleu), et dans les canaux cachés ces fonctionnalités représentent des cartes d'entités cachées qui encodent divers types de formes dans l'image.

Si l'entrée est en niveaux de gris (comme LeNet-5), alors la couche d'entrée aura une profondeur de 1, mais les couches ultérieure seera toujours en 3 dimensions. L'architecture contient deux types de couches, appelées couches de convolution et de sous-échantillonnage, respectivement.

Pour les couches de convolution, une opération de convolution est définie, dans laquelle un filtre est utilisé pour mapper les activations d'une couche à la suivante. Une opération de convolution utilise un filtre de poids avec la même profondeur que la couche actuelle mais avec une étendue spatiale plus petite. Le produit scalaire entre tous les poids du filtre et tout choix de région spatiale (de la même taille que le filtre) dans un calque définit la valeur de l'état masqué dans le calque suivant (après avoir appliqué une fonction d'activation comme ReLU). L'opération entre le filtre et les régions spatiales dans une couche est effectuée à chaque position possible afin de définir la prochaine couche (dans laquelle les activations conservent leurs relations spatiales de la couche précédente). Les connexions dans un réseau neuronal convolutif sont très rares, car toute activation dans une couche particulière n'est fonction que d'une petite région spatiale dans la couche précédente.

Toutes les couches autres que l'ensemble final de deux des trois couches conservent leur structure spatiale. Par conséquent, il est possible de visualiser dans l'espace quelles parties de l'image affectent des parties particulières des activations dans une couche. Les entités des couches de niveau inférieur capturent des lignes ou d'autres formes primitives, tandis que les entités des couches de niveau supérieur capturent des formes plus complexes comme des boucles (qui se produisent généralement dans de nombreux chiffres). Par conséquent, les couches ultérieures peuvent créer des chiffres en composant les formes dans ces fonctions intuitives. C'est un exemple classique de la façon dont quelles informations sémantiques sur des domaines de données spécifiques sont utilisées pour concevoir des architectures intelligentes.

De plus, une couche de sous-échantillonnage fait simplement la moyenne des valeurs dans les régions locales de taille 2×2 afin de compresser les empreintes spatiales des couches d'un facteur 2. Une illustration de l'architecture de LeNet-5 est montrée les premières années,

Chapitre III : Les réseaux de neurones artificiels

LeNet-5 a été utilisé par plusieurs banques pour reconnaître les numéros manuscrits sur les chèques.

Les réseaux de neurones convolutifs ont toujours été les plus réussis de tous les types du réseau de neurones. Ils sont largement utilisés pour la reconnaissance d'images, la détection/localisation d'objets, et même le traitement de texte.

Les performances de ces réseaux ont récemment dépassé celles des humains dans le problème de la classification des images (K. He, X. Zhang, S. Ren, and J. Sun, 2016). Les réseaux de neurones convolutifs fournissent un très bon exemple du fait que les choix de conception architecturale dans un réseau de neurones doivent être effectuée avec un aperçu sémantique sur le domaine de données à portée de main. Dans le cas particulier du réseau de neurones convolutifs, cet aperçu a été obtenu en observant les fonctionnements du cortex visuel d'un chat, et en utilisant fortement les relations spatiales entre les pixels. Ce fait fournit également des preuves qu'une meilleure compréhension des neurosciences pourrait également être utile pour le développement de méthodes en intelligence artificielle. Réseaux de neurones convolutifs pré-entraînés à partir de ressources accessibles au public comme ImageNet sont souvent disponibles pour une utilisation prête à l'emploi pour d'autres applications et ensembles de données. Ceci est réalisé en utilisant la plupart des poids pré-entraînés dans le réseau convolutif sans aucun changement à l'exception de la couche de classification finale.

Les poids du classement final couche sont apprises à partir de l'ensemble de données disponible. La formation de la dernière couche est nécessaire car les étiquettes de classe dans un cadre particulier peuvent être différentes de celles d'ImageNet. Néanmoins, les poids dans les premières couches sont toujours utiles car ils apprennent différents types de formes dans les images qui peuvent être utiles pour pratiquement n'importe quel type d'application de classification.

De plus, les activations de fonctionnalités dans l'avant-dernière couche peuvent même être utilisées pour des applications non supervisées. Par exemple, on peut créer une représentation multidimensionnelle d'un ensemble de données d'image arbitraires en faisant passer chaque image à travers le réseau neuronal convolutif et extraire les activations de l'avant-dernière couche. Par la suite, tout type d'indexation peut être appliqué à cette représentation pour récupérer des images similaires à une image cible. Une telle approche fournit souvent des résultats étonnamment bons dans la récupération d'image en raison de la

nature sémantique des fonctionnalités apprises par le réseau.

II.1.2.2.4 Les réseaux de neurones feed-forwarded

Dans ce type de réseaux (figure II.3), l'information se propage dans un sens unique, sans aucune rétroaction (des entrées vers les sorties). Si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les « connexions » entre ceux-ci, le graphe est acyclique.

Ce genre de réseaux utilise un apprentissage supervisé, par correction des erreurs (Lippmann, 1987) ou le signal d'erreur est rétro propagé vers les entrées afin de mettre à jour les poids des neurones.




Figure III.3: Réseau Feedforward à trois couches

Le terme de « connexions » doit être pris dans un sens métaphorique, car le réseau de neurones n'est pas donc, en général un objet physique tel un circuit électrique, et les «connexions » n'ont pas de réalité matérielle ; néanmoins le terme de connexion, issu des origines biologiques des réseaux de neurones, et passé dans l'usage, car il est commode quoique trompeur. Il a même donné naissance au terme de connexionnisme (Dreyfus, 2004). On distingue dans cette catégorie :

❖ Le perceptron multicouche MLP

Les perceptrons multicouches sont une amélioration du perceptron. Ils sont, en effet, les plus employés et les plus étudiés. Une abréviation anglaise est utilisée dans la littérature pour

Chapitre III : Les réseaux de neurones artificiels

les nommer : MLP pour Multi Layer Perceptrons (Bishop, 1995; Haykin, 1994).

Ils disposent d'une ou plusieurs couches cachées. Les neurones y sont arrangés en couches successives : la première couche qui forme le vecteur des données d'entrée est appelée couche d'entrée tandis que la dernière couche qui produit les résultats est appelée couche de sortie. Toutes les autres couches qui se trouvent au milieu sont appelées couches cachées (Lippmann 1987, Hagan et al. 1996).

Chaque couche est composée d'un certain nombre de neurones. Les connexions sont établies entre les neurones appartenant à des couches successives mais les neurones d'une même couche ne peuvent pas communiquer entre eux.

Contrairement au perceptron monocouche la présence d'une couche cachée dans le perceptron multicouche facilite la modélisation des relations non linéaires entre les entrées et la sortie.

Le choix du nombre de couches cachées dépend généralement de la complexité du problème à résoudre, en théorie une seule couche cachée peut être suffisante pour résoudre un problème donné mais il se peut que le fait de disposer de plusieurs couches cachées permette de résoudre plus facilement un problème complexe.

Construire un réseau de neurone à couche (perceptron multicouche) pour un problème quelconque revient à faire un choix judicieux de la taille du réseau, du nombre total de couches et de neurones, distribution des données et des fonctions de transfert (Baum et Haussier 1989). Le choix de ces paramètres dépend de l'utilisateur.

Il n'existe pas dans la littérature pour le moment des données suffisantes qui peuvent déterminer clairement les paramètres à adopter pour résoudre un problème donné (Coulibaly et al 1998).

❖ Réseaux à RBF (fonction radiale de base)

Les réseaux RBF sont très semblables aux perceptrons multicouches. Ils sont utilisés dans les mêmes genres de problèmes que les perceptrons multicouches à savoir, en classification et en prédiction, à travers une combinaison linéaire de fonctions non linéaires à base radiale.

Chapitre III : Les réseaux de neurones artificiels

Parmi ces fonctions, la fonction gaussienne, (présentée plus haut), qui est la plus utilisée.

Réseaux récurrents ce genre de réseaux est caractérisé par le pouvoir de laisser l'information circuler récursivement d'une manière partielle ou bien total (Kasabov, 1996; Elman, 1990).

L'architecture la plus générale pour un réseau de neurones est le « réseau récurrent », dont le graphe des connexions est cyclique : lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de « cycle »).

La sortie d'un neurone du réseau peut donc être fonction d'elle-même; cela n'est évidemment concevable que si la notion de temps est explicitement prise en considération.

Ainsi, à chaque connexion d'un réseau de neurones bouclé (ou à chaque arête de son graphe) est attaché, outre un poids comme pour les réseaux non bouclés, un retard, multiple entier (éventuellement nul) de l'unité de temps choisie. Une grandeur, à un instant donné, ne pouvant pas être fonction de sa propre valeur au même instant, tout cycle du graphe du réseau doit avoir un retard non nul (Dreyfus, 2004).




Figure III.4: réseau feedback simple

III.1.2.2.5 Les réseaux de neurones à apprentissage profond (Deep Learning)

Les réseaux de neurones à apprentissage profond, également connus sous le nom de réseaux de neurones profonds, sont des modèles de réseaux de neurones artificiels composés

Chapitre III : Les réseaux de neurones artificiels

de plusieurs couches cachées. Ces réseaux sont capables d'apprendre des représentations de plus en plus abstraites et complexes à partir des données d'entrée.

L'apprentissage profond repose sur le principe de l'apprentissage par couche, où chaque couche du réseau de neurones traite les informations transmises par la couche précédente et extrait des caractéristiques de plus en plus abstraites et de plus haut niveau. Les premières couches sont généralement responsables de la détection des caractéristiques de base, tandis que les couches supérieures combinent ces caractéristiques pour former des représentations plus complexes.

Les réseaux de neurones à apprentissage profond sont souvent utilisés pour des tâches de traitement de l'information complexe, telles que la reconnaissance d'images, la traduction automatique, la reconnaissance vocale, la compréhension du langage naturel, la génération de contenu, etc. Ils sont capables d'apprendre directement à partir des données brutes, sans nécessiter une ingénierie manuelle de caractéristiques.

L'une des architectures les plus connues de réseaux de neurones à apprentissage profond est le réseau de neurones à convolution profonde (deep convolutional neural network - DCNN), utilisé avec succès dans le domaine de la vision par ordinateur pour la classification d'images. D'autres architectures populaires incluent les réseaux de neurones récurrents profonds (deep recurrent neural network - DRNN) pour le traitement des séquences et les réseaux de neurones générateurs antagonistes profonds (deep generative adversarial network - DCGAN) pour la génération de données réalistes.

Grâce à leur capacité à modéliser des données complexes et à apprendre des représentations hautement abstraites, les réseaux de neurones à apprentissage profond ont connu des avancées significatives dans de nombreux domaines de l'intelligence artificielle et ont permis des avancées majeures dans des applications telles que la vision par ordinateur, le traitement du langage naturel et la reconnaissance de la parole.

III.1.2.3 Application des réseaux de neurones

III.1.2.3.1 Le modèle neurophysiologique

L'élément de base du système nerveux central est le neurone. Le cerveau se compose d'environ mille milliards de neurones, avec 1000 à 10000 synapses (connexions) par neurone. Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. Celles-ci sont parfois si nombreuses

Chapitre III : Les réseaux de neurones artificiels

que l'on parle alors de chevelure dendritique ou d'arborisation dendritique.

C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma (corps du neurone). L'information est traitée alors par le corps cellulaire. Si le potentiel d'action dépasse un certain seuil, le corps cellulaire répond par un stimuli Le signal transmis par le neurone chemine ensuite le long de l'axone (unique) pour être transmis aux autres neurones.

La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée synapse (ZEMOURI,2004)





Figure 8. Un neurone avec son arborisation dendritique



Fuigur III.5 : Le modèle neurophysiologique

–a– Un potentiel d'action. –b– Fonctionnement au niveau synaptique :

a) Arrivée' un potentiel d'action.

b) Libération du neurotransmetteur dans l'espace synaptique.

c) Ouvertures des canaux ioniques dues au neurotransmetteur.

d) Génération d'un potentiel évoqué inhibiteur. Les synapses inhibitrices empêchent la génération de potentiel d'action.

Chapitre III : Les réseaux de neurones artificiels


e) Fermeture des canaux, élimination du neuromédiateur.

III.1.2.3.2 Le modèle mathématique

Les réseaux de neurones biologiques réalisent facilement un certain nombre d'applications telles que la reconnaissance des formes, le traitement du signal, l'apprentissage par l'exemple, la mémorisation et la généralisation. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau, que les réseaux de neurones artificiels se sont développés.

La Figure 6 montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amont.

A chacune de ces entrées est associée un poids w , abréviation de Wight (poids en anglais), représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones aval. A chaque connexion est associée un poids. (ZEMOURI,2004)



Figuer III.6: Mis en correspondance du neurone biologique et du neurone artificiel

III.1.2.3.3 Préviation des débits

Les RNA sont largement utilisés pour prédire les débits des rivières. Les RNA sont entraînés sur des données historiques de précipitations, d'évapotranspiration et de débits pour apprendre les relations complexes entre ces variables et les sorties de débit. Une fois

Chapitre III : Les réseaux de neurones artificiels

entraînés, les RNA peuvent être utilisés pour prédire les débits futurs en fonction des conditions météorologiques actuelles et prévues. Les modèles basés sur les RNA peuvent fournir des prévisions précises de débit pour la gestion des ressources en eau et des situations d'urgence telles que les inondations.

III.1.2.3.4 Prévision des crues

La prévision des crues consiste à estimer en temps réel le niveau d'eau, le 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 (W.M.O., 1974).

Le développement récent des techniques des télécommunications, des ordinateurs et de la modélisation hydrologique a bien enrichi la prévision hydrologique. De ce point de vue, la prévision de crue d'aujourd'hui est non seulement une technique particulière en hydrologie, mais aussi une activité profitant des derniers développements technologiques. La modélisation hydrologique et la mise au point des méthodes de prévision composent cependant le noyau de n'importe quel système de prévision hydrologique.

Pour une prévision, qui est émise maintenant, le résultat sera comparé à la réalité quelques heures plus tard, et les professionnels même comme les profanes peuvent aisément la critiquer. La prévision de crue est donc parfois ressentie comme une activité intellectuelle assez risquée (Klemeš, 1982).

III.1.2.3.5 Modélisation de la qualité de l'eau

Les RNA sont utilisés pour modéliser la qualité de l'eau des rivières, des lacs et des réservoirs. Les modèles basés sur les RNA peuvent prendre en compte une variété de facteurs tels que les niveaux de pH, les niveaux d'oxygène dissous et les niveaux de nutriments, ainsi que des données météorologiques et hydrologiques.

Ces modèles peuvent être utilisés pour prédire les niveaux de qualité de l'eau futurs en réponse à différents scénarios de gestion de l'eau et de développement.

III.1.2.3.6 Optimisation de l'utilisation de l'eau

Les RNA peuvent être utilisés pour optimiser l'utilisation de l'eau dans les systèmes d'irrigation et de distribution d'eau. Les modèles basés sur les RNA peuvent prendre en compte une variété de facteurs tels que les précipitations, les niveaux de l'eau souterraine, les besoins en eau des cultures et les caractéristiques des systèmes d'irrigation pour

déterminer la quantité d'eau optimale à utiliser. Ces modèles peuvent aider les gestionnaires des ressources en eau à optimiser l'utilisation de l'eau et à réduire les gaspillages.

III.1.2.3.7 Modélisation des processus hydrologiques

Les RNA sont également utilisés pour modéliser les processus hydrologiques tels que l'infiltration, la recharge des eaux souterraines et l'écoulement de surface. Les modèles basés sur les RNA peuvent être utilisés pour prédire les effets de différents scénarios de gestion de l'eau sur les processus hydrologiques et pour développer des stratégies de gestion des ressources en eau durables.




Figure III.7: Modélisation des processus hydrologiques (USGS Georgia Water Science Centre, 2013)

L'image représente un cycle de l'eau dessiné à la main, illustrant les différentes étapes du cycle de l'eau dans la nature. Le cycle de l'eau commence par l'évaporation de l'eau de la surface de la terre due à la chaleur du soleil.

Cette vapeur d'eau s'élève dans l'atmosphère où elle se condense pour former des nuages. Les nuages se déplacent avec les vents et se transforment en précipitations, qui peuvent être sous forme de pluie, de neige, de grêle, etc. L'eau des précipitations s'infiltré dans le sol et est absorbée par les racines des plantes. Elle peut également couler en surface pour former des

Chapitre III : Les réseaux de neurones artificiels

ruisseaux, des rivières, des lacs et des océans. Cette eau peut être réutilisée par les plantes et les animaux, évaporée par le soleil ou pompée pour la consommation humaine. L'image est utile pour illustrer le cycle de l'eau dans l'hydrologie, la science qui étudie la répartition et le mouvement de l'eau sur Terre, ainsi que son interaction avec l'environnement et la vie.

Conclusion

Dans ce chapitre, nous avons vu un ensemble d'idées et de méthodes liées à l'intelligence artificielle, en particulier , les réseaux de neurones artificiels, qui seront mises en pratique dans le chapitre suivant.

Dans la présente étude, et vue les différents avantages des réseaux de neurones de type perceptron multi couche (MLP), nous allons les utiliser pour effectuer des prévision des débits.

Chapitre III : Les réseaux de neurones artificiels

**Chapitre IV: Application du modèle MLP à
la prévision des débits dans la région du
Soummam**

Chapitre IV : Application du modèle MLP à la prévision des débits dans la région du Soummam

Introduction

Dans cette section, et comme il a été indiqué dans le chapitre précédent, nous appliquerons le modèle réseaux de neurones artificiels de type perceptron multicouche (MLP) aux données des débits moyens journaliers enregistrées dans la station Sidi Aich, située dans le bassin versant de la Soummam.

Afin de juger la performance du modèle proposé, nous utiliserons les critères de comparaison, analytiques et graphiques les plus reconnus.

IV.1 Application des modèles

IV.1.1 Modèle proposé : Perceptron multicouche (MLP)

Notre utilisation de perceptron multicouche (MLP) pour la prévision du débit s'appuie sur plusieurs avantages, dont les plus importants sont : Flexibilité, Adaptabilité, Traitement des données complexes, Apprentissage à partir des données, et possibilité d'incorporer des variables météorologiques.




Figure IV.1 : Modèle MLP proposé

Le MLP proposé est constitué de trois couches réparties comme suit :

1. Une couche d'entrée : Elle est constituée de neurones d'entrée, qui sont en fait, les observations passées du débit journalier.
2. Une couche cachée : Constituée de plusieurs neurones cachés.
3. Une couche de sortie : Constitué d'un seul neurone, qui représente la prévision.

IV.2 Programme utilisé

L'application a été faite en utilisant le programme Matlab. Les réseaux neuronaux dans MATLAB offrent la possibilité de construire et d'entraîner des réseaux neuronaux, une technique puissante utilisée pour la prédiction et la prévision basée sur des données historiques. Les réseaux neuronaux reposent sur l'apprentissage automatique et l'adaptation des poids et des connexions entre les éléments pour effectuer des analyses et des prévisions précises.

Dans MATLAB, il est possible de construire des réseaux neuronaux en utilisant différents types de réseaux, tels que les réseaux neuronaux artificiels (ANN) et les réseaux neuronaux profonds (DNN). Ces réseaux sont définis par des couches différentes contenant des neurones et des connexions de données.

MATLAB peut être utilisé pour entraîner des réseaux neuronaux en utilisant des données historiques et en surveillant en continu les performances. Il est possible de personnaliser et d'ajuster l'architecture du réseau et ses paramètres pour obtenir les meilleures performances possibles. MATLAB permet également de vérifier la validité du réseau et d'évaluer ses performances en analysant les résultats et en les comparant aux données réelles.

MATLAB permet également d'appliquer les réseaux neuronaux à la prédiction en leur fournissant de nouvelles données et en utilisant le modèle entraîné pour générer des résultats attendus. Ils peuvent être utilisés dans divers domaines tels que la prévision météorologique, l'analyse des données financières, les prévisions de marché, le diagnostic médical, et bien d'autres. En utilisant MATLAB et les réseaux neuronaux, il est possible d'améliorer la précision des prédictions et de fournir des modèles d'analyse puissants pour la prise de décision.

Chapitre IV: Application du modèle MLP à la prévision des débits dans la région du Soummam

Dans notre application, nous avons utilisé version.... Du Matlab Nous choisis le Feedforward, qui est un perceptron multi –couches dont la syntaxe Matlab est la suivante :

La commande : `net = feedforwardnet (hiddenSizes,trainFcn)`, renvoie un réseau de neurones multicouches avec une taille de couche cachée de (hiddenSizes) et une fonction d'apprentissage, spécifiée par (trainFcn).

Les réseaux feedforward sont constitués d'une série de couches. La première couche a une connexion depuis l'entrée du réseau. Chaque couche suivante a une connexion à partir de la couche précédente. La couche finale produit la sortie du réseau.

Pour la fonction d'apprentissage (train Fcn) , plusieurs algorithmes peuvent être utilisés. Dans notre cas, l'algorithme de Levenberg-Marquardt (LM) a été utilisé. L'algorithme LM est une amélioration de la méthode classique de Gauss-Newton dans la résolution des problèmes de régression non-linéaire des moindres carrés. Il s'agit de la méthode recommandée pour les problèmes (de régression) non-linéaires des moindres carrés, car il est plus efficace par rapport aux algorithmes d'optimisation plus généraux (telles que les méthodes Quasi-Newton ou Simplexe).

IV.3 Calage du modèle

Le calage consiste en l'ajustement numérique des entrées afin de reproduire les observations. Ce processus d'ajustement des variables d'entrée et des paramètres du modèle est établi dans le but de reproduire certains aspects de la réalité en comparant des variables de sortie à des données observées. Il s'agit de l'une des étapes les plus consommatrices en temps de travail lors de la construction du modèle. Elle est fondamentale dans la mesure où elle détermine la qualité du modèle (Sétra,2010).

IV.3.1 Le calage manuel

La détermination d'un jeu de paramètres aléatoirement permettant d'obtenir un optimum, qui est atteint lorsque l'erreur est minimisée entre les données simulées et observées, l'inconvénient du calage manuel est qu'il nécessite un temps relativement long.

IV.3.2 Le calage automatique

En utilisant un programme (Matlab dans notre cas) informatique, les données simulées sont ajustées aux données observées. Malgré les avantages que cette méthode propose mais

elle est influencée par certaines critères qui ont été proposés par (Benkaci, 2006), citées ci-dessous :

- L'indépendance des paramètres (autocorrélation) : le changement de la valeur d'un paramètre peut être compensé par la modification d'autres paramètres, ce qui entraîne des solutions équivalentes en terme de valeur du critère d'optimisation.
- La faible sensibilité de la fonction objective.
- La présence d'optima locaux, ou également la présence de plusieurs zones de convergences. La qualité de l'estimation des paramètres d'un modèle dépend notamment de la puissance de l'algorithme utilisé.

IV.4 Validation des modèles

La validation consiste à utiliser les données restantes pour s'assurer que le modèle réagit correctement à des variations de données d'entrée et qu'il est apte à fonctionner. Elle permet également de vérifier la sensibilité du système aux changements à analyser afin de s'assurer que les écarts entre résultats obtenus et observés sont raisonnables.

Les données de validation sont utilisées aussi pour éviter le problème de sur-apprentissage. Le problème de sur-apprentissage se produit lorsque le modèle donne de très bonnes performances sur la partie de données réservées pour son apprentissage, cependant, le modèle possède de faible performance pour des données autres que celles utilisées pour son apprentissage. On dit alors que le modèle a de faible capacité de généralisation.

Afin d'éviter ce phénomène, nous avons utilisé la méthode d'arrêt prématuré (Early stopping point)

❖ Technique d'arrêt prématuré (Early stopping point)

La technique d'arrêt prématuré, ou "Early stopping point" en anglais, est une stratégie courante lors de l'entraînement de modèles neuronaux. Elle est utilisée pour éviter le surapprentissage (overfitting) et améliorer les performances du modèle. Le point d'arrêt anticipé est appliqué lorsque l'amélioration des performances du modèle sur l'ensemble d'entraînement cesse et commence à se détériorer sur l'ensemble de validation.

Lors de l'entraînement d'un modèle neuronal, les données sont généralement divisées en ensembles d'entraînement et de validation. Le modèle est entraîné sur l'ensemble d'entraînement et ses performances sont évaluées sur l'ensemble de validation.

Habituellement, une fonction de perte (loss function) est utilisée pour mesurer les performances du modèle.




Figure IV.2. Technique d'arrêt prématuré

Pendant l'entraînement, les paramètres du modèle (tels que les poids et les connexions entre les éléments) sont optimisés pour réduire l'erreur ou la perte sur l'ensemble d'entraînement. Cependant, il peut arriver que le modèle apprenne de manière excessive des détails très spécifiques de l'ensemble d'entraînement et ne parvienne pas à généraliser sur de nouvelles données.

Pour éviter le surapprentissage, les performances du modèle sur l'ensemble de validation sont surveillées après chaque cycle d'entraînement. Si les performances du modèle ne s'améliorent pas pendant plusieurs cycles d'entraînement consécutifs, cela peut être

considéré comme un point d'arrêt anticipé. Après le point d'arrêt anticipé, le processus d'entraînement est arrêté pour éviter une sur-optimisation excessive.

Le point d'arrêt anticipé contribue à obtenir un modèle qui généralise de manière optimale plutôt que d'apprendre de manière excessive les spécificités des données d'entraînement. Cela peut conduire à de meilleures performances du modèle lorsqu'il est utilisé pour la prédiction ou d'autres tâches.

❖ Données utilisées

Les données utilisées dans ce travail, sont les des débits moyens journaliers (Figure IV.2), enregistrés dans la station hydrométrique de Sidi Aich dont le code ANRH est le 151001, situé dans le bassin versant de la Soummam.




Figure IV.3 : Débit moyen journalier

IV.5 Répartition de la base de données

Le nombre total d'observations du débit moyen journalier est de 2190 observations, enregistrées durant la période du 01 Sep 1967 au 29 Août 1973. Cette base de données a été répartie sur trois ensembles, apprentissage, validation et test.

Le tableau IV.1 présente les détails de chaque partition.

Tableau IV.1: Répartition de la base de données

	Apprentissage	Validation	Test(Prévision)
Pourcentage	40%	30%	30%
Période	10 Sep 1967 au 29 Jan 1970	30 Jan 1970 au 14 Nov 1971	15 Nov 1971 au 29 august 1973
Nombre d'observations	873	654	654

IV.5.1 Paramètres du réseau

Après avoir base la base de données en trois parties, apprentissage, validation et test. Les paramètres suivant sont à déterminer :

1. Le nombre de neurone dans la couche d'entrée
2. Le nombre de neurone dans la couche cachée.
3. Le nombre de neurone dans la couche sortie.

La structure du modèle proposé (voir figure IV.1), consiste en un seul neurone dans la couche de sortie qui représente la valeur prévue du débit moyen journalier.

S'agissant du nombre de neurone dans la couche d'entrée, il est déterminé sur la base de l'étude de la fonction d'autocorrélation (voir figure IV.3) de la série chronologique du débit moyen journalier de station de Sidi Aich objet de la présente étude.




Figure IV.4 : Fonction d'autocorrélation

IV.6 Autocorrélation

L'autocorrélation dans les réseaux de neurones fait référence à la corrélation entre les sorties d'un neurone et ses entrées à différents décalages temporels. Dans le contexte des réseaux de neurones récurrents, tels que les réseaux de neurones à mémoire à court terme (LSTM) ou les réseaux de neurones récurrents (RNN), l'autocorrélation est importante car elle permet de capturer les dépendances temporelles dans les données séquentielles. En calculant l'autocorrélation entre les sorties du réseau et les valeurs d'entrée précédentes, on peut identifier les motifs et les relations récurrentes dans les données. Cela permet au réseau de neurones de mieux comprendre la structure temporelle des séquences d'entrée et d'apprendre des représentations plus riches et plus significatives.

L'autocorrélation dans les réseaux de neurones est un outil essentiel pour la modélisation et la prédiction de séquences temporelles, ainsi que pour des tâches telles que la traduction automatique, la génération de texte et la reconnaissance de la parole. Elle contribue à améliorer les performances des modèles en capturant les relations complexes entre les éléments séquentiels et en fournissant des prédictions plus précises. Sur la base de la fonction d'auto corrélation, nous avons pris un nombre de neurone d'entrée égale à neuf **(09 inputs)**.

Pour le nombre de neurones dans la couche cachée, nous avons utilisé la règle suivante : $N_{nc}=2*n$, Où n : est nombre de variables d'entrée.

❖ Apprentissage du modèle

Chapitre IV: Application du modèle MLP à la prévision des débits dans la région du Soummam

L'auto-apprentissage se fait grâce à la rétro propagation pour initialiser les poids et les biais et les réajuster à chaque fois et pour l'algorithme de Levenberg-Marquardt, rappelons que dans notre cas nous avons divisé les données en 3 blocs, une partie pour l'apprentissage (apprentissage), une partie pour la validation, et une autre partie pour les tests.

Avec un nombre de neurone d'entrée égale à neuf(09), et un nombre de neurones dans la couche caché égale à dix-huit(18).




Figure IV.5 : Fenêtre d'apprentissage Du RNA

❖ Résultats et interprétations

Après avoir développé le modèle de prévision du débit moyen journalier, en suivant les différentes étapes discutées précédemment. Nous passons, dans cette partie du mémoire, à la discussion des résultats obtenus.

IV.7 Critères de performance

La performance du modèle développé est évaluée sur la base de quatre critères de performance, à savoir le coefficient de corrélation R, l'erreur moyenne absolue (MAE), le critère de Nash (Ns), et l'erreur moyenne quadratique RMSE ou sur un critère graphique.

IV.7.1 Le coefficient de corrélation (R)

Le coefficient de corrélation mesure la relation entre deux variables. Le coefficient de corrélation de Pearson mesure la corrélation linéaire entre deux variables continues, tandis que le coefficient de corrélation de Spearman mesure la corrélation monotone entre deux variables (continues ou ordinales). Ces coefficients varient entre -1 et 1, où -1 représente une corrélation négative parfaite, 0 indique aucune corrélation linéaire ou monotone, et 1 indique une corrélation positive parfaite.

$$r = \frac{\sum_{i=1}^n (Q_{abs} - \overline{Q_{obsé}})(Q_{abs} - \overline{Q_{obsé}})}{\sqrt{\sum_{i=1}^n (Q_i - \overline{Q})^2 \sum_{i=1}^n (Q_i - \overline{Q})^2}} \dots\dots\dots (1)$$

IV.7.2 L'erreur moyenne absolue (MAE)

L'erreur moyenne absolue mesure la différence moyenne entre les valeurs réelles et les valeurs prédites d'un modèle de régression. Elle est calculée en prenant la différence absolue entre chaque prédiction et la valeur réelle, puis en calculant la moyenne de ces différences. Le MAE est utilisé pour évaluer la performance d'un modèle de régression en fournissant une mesure de l'erreur absolue moyenne commise par le modèle. Une valeur plus faible de MAE indique une meilleure performance du modèle.

$$MAE = \frac{1}{n} \sum_{i=1}^n |(\hat{Q}_i - Q_i)| \dots\dots\dots (2)$$

IV.7.3 Le critère de Nash(Nash)

Le critère de Nash, également connu sous le nom de critère de Nash-Sutcliffe, est une mesure statistique qui évalue l'ajustement d'un modèle par rapport aux observations réelles. Il est calculé en comparant les différences entre les valeurs prédites par le modèle et les valeurs réelles observées. Un critère de Nash égal à 1 indique un ajustement parfait, tandis qu'une valeur inférieure à 1 indique un écart par rapport aux observations réelles.

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \overline{Q})^2} \dots\dots\dots (3)$$

IV.7.4 La racine de l'erreur quadratique moyenne (RMSE)

La racine de l'erreur quadratique moyenne est une mesure statistique qui quantifie l'écart moyen entre les valeurs prédites par un modèle et les valeurs réelles observées. Elle est calculée en prenant la racine carrée de la moyenne des carrés des différences entre les

prédictions et les observations. Le RMSE est souvent utilisé pour évaluer la précision d'un modèle de régression, et une valeur plus faible indique une meilleure performance du modèle.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Q}_i - Q_i)^2} \dots\dots\dots(4)$$

IV.8 Interprétations

IV.8.1 Interprétations des résultats

Après l'application du modèle de perceptron multicouche pour prédire les débits moyens journaliers dans le bassin du Soummam, les indicateurs tels que R, Ns, RMSE et MAE ont montré des performances satisfaisantes.

Tableau IV.2: Les résultats des les indicateurs



Critère	Apprentissage	Validation	Test
R	0.7673	0.758	0.7123
Ns	0.5881	0.574	0.5056
RMSE	28.2111	38.7537	60.9185
MAE	6.4912	13.2366	17.2618

Cela suggère que le modèle est capable de fournir des prédictions précises et fiables des débits dans cette région. Les résultats obtenus indiquent que le modèle est capable de capturer les schémas et les variations observés dans les débits, ce qui peut être extrêmement utile pour la gestion des ressources en eau et la prise de décisions dans le bassin du Soummam.



IV.8.2 Interprétations de graphe

Si les points du nuage de points sont répartis de manière aléatoire sur le graphique, cela indique qu'il y a peu ou pas de lien entre les deux variables. En revanche, si les points présentent une tendance à se rassembler ou à suivre un motif spécifique, cela suggère qu'il existe une corrélation entre les variables, pouvant être positive, négative ou non linéaire.

Chapitre IV: Application du modèle MLP à la prévision des débits dans la région du Soummam




Chapitre IV: Application du modèle MLP à la prévision des débits dans la région du Soummam



Conclusion

Les résultats obtenus lors de l'application du modèle de perception multicouche (MLP) pour prédire le débit journalier dans le bassin de Soummam ont été très encourageants. Les prédictions faites par le modèle se sont avérées satisfaisantes et fiables, ce qui indique que le modèle a réussi à capturer les schémas et les fluctuations de débit observés dans cette région.



Conclusion générale

Conclusion générale

Conclusion générale

La prévision du débit revêt une importance cruciale dans de nombreux domaines tels que la gestion des ressources en eau, la planification de l'énergie, la prévention des inondations, la navigation maritime, la gestion des rivières et la sécurité des barrages.

Actuellement, Les méthodes basées sur l'intelligence artificielle sont de plus en plus utilisées dans tous les domaines

Le machine Learning est d'une importance fondamentale car il permet aux machines d'apprendre à partir des données et de réaliser des tâches complexes. Il a un impact significatif dans de nombreux domaines, améliorant la prise de décision, l'automatisation, la personnalisation, la détection des anomalies, les prévisions et l'optimisation des processus.

Les modèles basés sur l'intelligence artificielle, notamment les réseaux de neurones artificiels, offrent de nouvelles opportunités pour améliorer la précision des prévisions hydrologiques.

Ce mémoire s'est concentré sur l'application des réseaux de neurones artificiels pour la prévision du débit moyen journalier de la station de Sidi Aich, située dans le bassin versant de la Soummam. Dans ce contexte, différentes méthodes de prévision du débit ont été étudiées et le choix s'est porté sur l'approche du perceptron multicouche.

L'application de l'approche du perceptron multicouche a permis d'obtenir des résultats encourageants en termes de prévision du débit. Les modèles basés sur l'intelligence artificielle ont démontré leur capacité à capturer les relations complexes entre les variables hydrologiques et à fournir de bons résultats de prévisions avec un coefficient de corrélation R égale à 0.71 et un critère de Nash égale à 0.51, ce qui est un indicateur d'un modèle de prévision performant.

Cependant, il convient de noter que la prévision du débit reste un défi complexe en raison de la variabilité naturelle des conditions hydrologiques et des incertitudes liées aux données. Il est donc important de continuer à améliorer les modèles existants et à explorer de nouvelles approches pour une prévision encore plus précise.


Conclusion générale

En conclusion, ce mémoire a permis d'explorer l'utilisation des modèles basés sur l'intelligence artificielle, en particulier les réseaux de neurones artificiels, pour la prévision du débit. Les résultats obtenus ouvrent la voie à de futures recherches et applications dans le domaine de la prévision hydrologique, contribuant ainsi à une gestion plus efficace et durable des ressources en eau.

Enfin, il est important de souligner que la prévision du débit est un domaine en constante évolution, avec de nouvelles avancées technologiques et des approches novatrices. Il reste donc encore beaucoup à découvrir et à explorer dans ce domaine passionnant, et ce travail ne représente qu'une étape vers une meilleure compréhension et utilisation de l'intelligence artificielle pour la prévision hydrologique.

Sur la base cette étude nous recommandons les axes de travail suivants :

1. Application d'autres modèles de prévisions basés sur l'intelligence artificielle, tels que les réseaux de neurones à apprentissage profonds, les modèles hybrides réseaux de neurones-ondelette ...etc
2. Utilisation d'autres variables d'entrée autres que les débits, telles que les températures et les évapotranspirations.
3. Application des ces modèles dans d'autres régions de climats différents.



Références bibliographiques

Références bibliographiques

- Kisi O, Cigizoglu HK (2007) Comparison of different ANN techniques in river flow prediction. *Civ Eng Environ Syst* 24:211–231
- Nalley D, Adamowski J, Khalil B (2012) Using discrete wavelet transforms to analyze trends in streamflow and precipitation in Quebec and Ontario (1954–2008). *J Hydrol* 475:204–228
- Akrami SA, El-Shafe A, Naseri M, Santos CAG (2014) Rainfall data analyzing using moving average (MA) model and wavelet multiresolution intelligent model for noise evaluation to improve the forecasting accuracy. *Neural Comput Appl* 25:1853–1861
- Danadeh Mehr A, Kahya E, Şahin A, Nazemosadat MJ (2014) Successive-station monthly streamflow prediction using different artificial neural network algorithms. *Int J Environ Sci Technol* 12:2191–2200
- Santos CAG, Freire PKMM, Silva GBL, Silva RM (2014) Discrete wavelet transform coupled with ANN for daily discharge forecasting into Três Marias reservoir. *Proc Int Assoc Hydrol Sci* 364:100–105
- Makwanana JJ, Tiwari MK (2014) Intermittent streamflow forecasting and extreme event modelling using wavelet based artificial neural networks. *Water Resour Res* 28:4857–4873
- Seo Y, Kim S, Kisi O, Singh VP (2015) Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. *J Hydrol* 520:224–243. <https://doi.org/10.1016/j.jhydr.2014.11.050>
- Shoaib M, Shamseldin AY, Melville BW (2014) Comparative study of different wavelet based neural network models for rainfall runoff modelling. *J Hydrol* 515:47–58
- Shoaib M, Shamseldin AY, Khan S, Khan MM, Khan ZM, Sultan T, Melville BW (2017) A comparative study of various hybrid wavelet feed forward neural network models for runoff forecasting. *Water Resour Res*. <https://doi.org/10.1007/s11269-017-1796-1>

Références bibliographiques

- Hadi SJ, Tombul M (2018a) Streamflow forecasting using four wavelet transformation combinations approaches with data-driven models: a comparative study. *Water Resour Manag.* <https://doi.org/10.1007/s11269-018-2077-3>
- Toth E, Brath A (2007) Multistep ahead streamflow forecasting: role of calibration data in conceptual and neural network modelling. *Water Resour Res.* <https://doi.org/10.1029/2006WR005383>
- Daubechies I (1992) Ten lectures on wavelets. In: CSBM-NSF series on applied mathematics, vol 61. SIAM Publication
- Nourani V, Bagahnam A, Adamowski J, Kisi O (2014) Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *J Hydrol* 514:358–377
- Maheswaran R, Khosa R (2012) Comparative study of different wavelets for hydrologic forecasting. *Comput Geosci* 46:284–295
- Adamowski J, Sun K (2010) Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semiarid watersheds. *J Hydrol* 390:85–91
- Kisi O (2008) Streamflow forecasting using neuro-wavelet technique. *Hydrol Process* 22:4142–4152
- Kisi O (2009) Neural networks and wavelet conjunction model for intermittent streamflow forecasting. *J Hydrol Eng* 14(8):773–782
- Kisi O, Cimen M (2011) A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *J Hydrol* 399:132–140
- Yonaba H, Anctil F, Fortin V (2010) Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. *J Hydrol Eng* 15:275–283
- Zakhrouf M, Bouchelkia H, Stamboul M, Kim S, Heddami S (2018) Time series forecasting of river flow using an integrated approach of wavelet multi-resolution analysis and evolutionary data-driven models. A case study: Sebaou river (Algeria). *Phys Geogr.* <http://doi.org/10.1080/02723646.2018.1429245>
- Abda Z, Chettih M (2018) Forecasting daily flow rate-based intelligent hybrid models combining wavelet and Hilbert–Huang transforms in the mediterranean basin in northern Algeria. *Acta Geophys.* <https://doi.org/10.1007/s11600-018-0188-0>
- Chen, D., et al. (2018). Machine Learning: The Future of Hydrological Models and Water Resources Systems Analysis. *Water Resources Research.*

Références bibliographiques

- Zhang, Y., et al. (2019). Satellite Remote Sensing in Hydrological Modeling: Advances and Challenges. Remote Sensing.
- Pechlivanidis, I. G., et al. (2020). Advances in distributed hydrological modelling and data assimilation. Journal of Hydrology
- Hu, H., et al. (2021). Integration of meteorological forecasts in hydrological modelling for improved flood forecasting: A review. Journal of Hydrology.
- Araya, A. A., et al. (2020). Artificial intelligence in water resources management: A review of methods and applications. Water Resources Management.
- Roche, Hydrologie de surface, Ed. Gauthier-Villars, Paris (1963)
- A. Amour, Caractérisation des crues pluviales des sous bassins versants de la Soummam, Mémoire de magister, Université de Béjaia (2010).
- Tebbani, R, 2016.Etude du transport solide à l'estuaire du bassin versant de la Soummam par le logiciel HEC-RAS Mémoire de Master en Hydraulique Université Mohamed Boudiaf de M'sila.
- A. Bechroune, Elaboration d'une base de données hydrologique du bassin versant de la Soummam via le
- modèle hydrologique HEC-HMS, Mémoire présenté pour l'obtention du diplôme de Magister, (2011).
- F. Nalouf, Estimation du bilan hydrologique à l'échelle du bassin versant de la Soummam, Mémoire présenté pour l'obtention du diplôme de Master II, (2010-2011).
- OMM, 2006. Suivi de la sécheresse, progrès et enjeu futur.
- O.N.M (office nationale de météorologie).
- Mémoire présenté pour Application des réseaux de neurones artificiels pour l'estimation des lacunes dans les enregistrements de précipitation : Application sur le bassin versant de la Soummam (OUANAS,2022)
- Mémoire présenté pour Analyse et cartographie de la variabilité spatio-temporelle des précipitations dans le Bassin versant de l'Oued Soummam (Toumiat ,2021) .
- C. Aggarwal. Machine learning for text. Springer, 2018.
- T. Cover. Geometrical and statistical properties of systems of linear inequalities with applications to pattern recognition. IEEE Transactions on Electronic Computers, pp. 326–334,1965.

Références bibliographiques

- K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. IEEE Conference on Computer Vision and Pattern Recognition, pp. 770–778, 2016.
- J. J. Hopfield. Neural networks and physical systems with emergent collective computational abilities. National Academy of Sciences of the USA, 79(8), pp. 2554–2558, 1982.
- D. Hubel and T. Wiesel. Receptive fields of single neurones in the cat's striate cortex. The Journal of Physiology, 124(3), pp. 574–591, 1959.
- D. Koller and N. Friedman. Probabilistic graphical models: principles and techniques. MITPress, 2009.
- Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), pp. 2278–2324, 1998.
- H. Siegelmann and E. Sontag. On the computational power of neural nets. Journal of Computer and System Sciences, 50(1), pp. 132–150, 1995
- Mémoire présenté pour Mémoires du Service géologique de l'Algérie, 1111-1291 ; 12 (ZEMOURI,2004)
- Physically Based Stochastic Hydrologic Analysis (1978)
- BENKACI A T., 2006. Modélisation pluie-debit mensuelle et journalière par les modèles
- BENKACI A T., 2006. Modélisation pluie-débit mensuelle et journalière par les modèles conceptuels et les systèmes neuro-flous (application aux bassins algériens). Thèse doctorat, INA. EL-Harrach.