

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Mémoire de Master

Présenté à l'Université 08 Mai 1945 de Guelma

Faculté des Sciences et de la Technologie

Département de : Génie Civil & Hydraulique

Spécialité : Hydraulique

Option : Hydraulique Urbaine

Présenté par : RIANI MOUSLIM


Appliquer un modèle hybride intelligent combinant réseaux de neurones artificiels et algorithmes génétiques pour la prévision des débits

Sous la direction de : Pr. Dr Abda Zaki

Juin 2025

Remerciements

Avant tout, nous remercions Dieu de nous avoir accordé la santé et le bien-être nécessaires pour mener à bien ce travail du début à la fin. Nous exprimons notre gratitude à nos parents pour leur soutien tout au long de notre séjour. Nous adressons également nos sincères remerciements à mon directeur de thèse, le professeur Z.Abda, qui m'a guidé par ses conseils et son encadrement. Ses critiques constructives tout au long de cette recherche m'ont permis de progresser librement. Je lui suis reconnaissant, notamment pour ses qualités intellectuelles et humaines. Nous remercions également le membre du jury pour cet honneur. Avec votre accord, nous évaluerons ce projet et participerons à sa discussion. Enfin, nous adressons nos sincères remerciements à tous nos professeurs de l'Université du 8 mai 1945 à Guelma pour leur contribution à notre formation, ainsi qu'à nos collègues et amis pour leur aide précieuse.



Dédicaces

Je dédie cette thèse à :

Mes chers parents, pour tous leurs sacrifices, leur amour, leur affection et leur soutien tout au long de mes études.

À ma tante, qui m'a accompagnée à chaque étape de mon travail, et à mes chers amis, proches et lointains, pour leurs encouragements constants et leur soutien moral.

Merci à tous.

Dieu soit loué pour tout ce que j'ai accompli dans ce modeste travail, et je le dédie chaleureusement à :

Mes chers parents, qui m'ont encouragé et soutenu tout au long de mes études, et pour leur patience. Que Dieu les protège, eux et moi.

À mes chers frères et sœurs.

À mes chers amis et collègues, pour tous les moments d'échanges et de dialogue, à ceux qui m'ont toujours soutenu et encouragé, sans oublier mes cousins...

Table des matières

Remerciements	I
Dédicaces	II
Liste des figures	V
LISTE DES TABLEAUX	VIII
RESUME :	IX
ABSTRACT	IX
ملخص:	X
LISTE DES ABREVIATIONS	XI
INTRODUCTION GENERALE	1

Chapitre 01 : Synthèse Bibliographique

1.1 INTRODUCTION :	3
1.2 DEFINITION DE L'HYDROLOGIE :	3
1.3 COMPOSANTE DU CYCLE HYDROLOGIQUE :	4
1.4 LA REPARTITION DES EAUX :	4
1.5 LE BILAN HYDRIQUE :	5
1.6 LES EXTREMES HYDROLOGIQUES :	6
1.6.1 La sécheresse :	7
1.7 CONCLUSION	8

CHAPITRE 02 : RESEAUX DE NEURONES ARTIFICIELS

2.1. INTRODUCTION :	10
2.2. DEFINITION :	10
2.3. LE NEURONE :	10
2.3.1. Le Neurone biologique :	10
2.3.2. Le neurone formel :	11
2.3.2.1. Définition et représentation :	11
2.4. LES FONCTIONS D'ACTIVATION :	13
2.4.1. La fonction linéaire et La fonction sigmoïde :	14
2.5. APPRENTISSAGE DE RNA :	16
2.6. METHODES D'OPTIMISATION :	17
2.6.1. Méthode de Newton	18
2.6.2. Méthode de Gauss-Newton :	18

2.6.3. Méthode de descente de gradient :	18
2.6.4. Méthode de Levenberg-Marquardt :	18
2.7. LES DIFFERENTES ARCHITECTURES DE RESEAUX DE NEURONES ARTIFICIELS :	19
2.7.1. Les réseaux de neurones à couche unique :	19
2.7.2. Le Perceptron Multi Couche (PMC)	19
2.7.3. Réseau à connexions locales :	20
2.7.4. Réseau à connexions récurrentes :	21
2.7.3. Réseau à connexion complète :	22
2.7.4. Réseau de Kohonen :	22
2.8 PROBLEME DE SURAJUSTEMENT:	23
2.9. METHODES POUR LIMITER LE SURAJUSTEMENT :	23
2.10 OPTIMISATION PAR ESSAIM DE PARTICULES ::	24
2.11 CONCLUSION :	27

CHAPITRE 03: ZONE D'ETUDE ET DESCRIPTION DES DONNEES

3.1 INTRODUCTION :	29
3.2 SITUATION GEOGRAPHIQUE :	29
3.3 LE BARRAGE :	30
3.4. GEOMORPHOLOGIE ET PHYSIOGRAPHIE DU MILIEU ETUDIE :	33
3.5 COEFFICIENT DE COMPACITE :	33
3.6 HYDROGRAPHIE :	33
3.7 SITUATION TOPOGRAPHIQUE :	33
3.8 SITUATION CLIMATIQUE :	34
3.8 CONCLUSION :	36

Chapitre 04 : Résultats Et Discussion

4.1. DEVELOPPEMENT DES MODELES :	38
4.2 : CHOIX DES CRITERES DE PERFORMANCE :	42
4.3 : RESULTATS ET DISCUSSION :	43
4.3.1 : Meilleurs modèles en phase de validation:	43
4.3.2 : Meilleur équilibre global :	44
4.3.3 : Modèle les moins performants :	44
4.3.4 : Performances stables mais moyennes :	44
4.3.5 : Pour le modèle RNA-PSO :	44
CONCLUSION GENERALE	65

REFERENCE	67
-----------------	----

Liste des figures

Chapitre 01 : Synthèse Bibliographique

Figure 1.1: Schéma de la manière dont, dans le cycle hydrologique, l'eau est transférée entre la surface terrestre, l'océan et l'atmosphère	3
Figure 1. 2: Répartition des eaux dans le monde	5
Figure 1. 3: Bassin hydrologique, bassin hydrogéologique et aquifère	6

Chapitre 02 : Réseaux de Neurones Artificiels

Figure 2. 1: Morphologie d'un neurone biologique.	11
Figure 2. 2: Modèle du neurone formel.	12
Figure 2. 3: La fonction seuil	13
Figure 2. 4: La fonction linéaire.....	13
Figure 2. 5: La fonction saturation	13
Figure 2. 6: La fonction sigmoïde	13
Figure 2. 7: La fonction a valeurs discrètes	14
Figure 2. 8: La fonction linéaire et la fonction à seuil	14
Figure 2. 9: Classification des réseaux de neurones suivant leur apprentissage	16
Figure 2. 10: Schéma représentant le mécanisme d'un superviseur dans le cas d'Apprentissage supervisé de perceptron multi couche	17
Figure 2. 11: Exemple de perceptron multicouche	20
Figure 2. 12: Réseau à connexions locales.	20
Figure 2. 13: Exemple d'un réseau à connexions récurrentes	21
Figure 2. 14: Réseau neuronal récurrent	21
Figure 2. 15: Réseau à connexion complète	22
Figure 2. 16: Schéma d'un réseau de Kohonen	23
Figure 2. 17: Schéma qui représente l'évolution de l'erreur d'apprentissage et de validation d'un RNA en fonction de nombre d'itération	24
Figure 2. 18: Particle Swarm Optimization Architecture Illustration	25
Figure 2. 19: Organigramme de l'algorithme d'optimisation par essaim de particules	27

CHAPITRE 03: ZONE D'ETUDE ET DESCRIPTION DES DONNEES

Figure 3. 1: Situation géographique de la zone d'étude.	30
Figure 3. 2: Localisation du barrage réservoir de Boukourdane	31
Figure 3. 3: Les limites du bassin versant à l'amont du barrage de Boukourdane.	32
Figure 3. 4: Bassin Hydrographique Algérois- Soummam- Hodna.	32
Figure 3. 5: Températures moyennes des minima, des maxima et des moyennes mensuelles.....	35
Figure 3. 6: vitesses mensuelles du vent au niveau de la station météorologique du barrage de Boukerdene (1987-2011).....	35

Chapitre 04 : Résultats Et Discussion

Figure 4. 1: Organigramme expliquant le développement des RNA.	41
Figure 4. 2: représentant le modèle hybride ANN–PSO appliqué à la prévision des débits... ..	42
Figure 4. 3: Résultats statistiques du modèle RNA dans les phases d'apprentissage, validation et test.	47
Figure 4. 4: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 1 dans les phases d'apprentissage et validation.	54
Figure 4. 5: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 2 dans les phases d'apprentissage et validation.	55
Figure 4. 6: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 3 dans les phases d'apprentissage et validation.	55
Figure 4. 7: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 4 dans les phases d'apprentissage et validation.	56
Figure 4. 8: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 5 dans les phases d'apprentissage et validation.....	56
Figure 4. 9: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 6 dans les phases d'apprentissage et validation.	57
Figure 4. 10: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 7 dans les phases d'apprentissage et validation.	57
Figure 4. 11: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 8 dans les phases d'apprentissage et validation.	58
Figure 4. 12: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 9 dans les phases d'apprentissage et validation.	58
Figure 4. 13: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 10 dans les phases d'apprentissage et validation.	59

Figure 4. 14: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 11 dans les phases d'apprentissage et validation.	59
Figure 4. 15: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 12 dans les phases d'apprentissage et validation.	60
Figure 4. 16: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 13 dans les phases d'apprentissage et validation.	60
Figure 4. 17: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 14 dans les phases d'apprentissage et validation.	61
Figure 4. 18: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 15 dans les phases d'apprentissage et validation.	61
Figure 4. 19: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 16 dans les phases d'apprentissage et validation.	62
Figure 4. 20: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 17 dans les phases d'apprentissage et validation.	62
Figure 4. 21: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 18 dans les phases d'apprentissage et validation.	63
Figure 4. 22: Comparaison entre les débits observés et les débits simulés par RNA-PSO dans les phases d'apprentissage et validation.	63

LISTE DES TABLEAUX

Chapitre 02 : Réseaux de Neurones Artificiels

Tableau 2. 1: Différentes fonctions d'activations utilisées dans les RNA :.....	15
--	----

Chapitre 03 : Zone D'étude Et Description Des Données

Tableau 3. 1: Les caractéristiques physiographiques du bassin versant de l'oued El Hachem.....	34
---	----

Tableau 3. 2: Précipitations Moyennes Mensuelles à la station de Boukerdane (période : 1980/2012)	35
---	----

Chapitre 04 : Résultats Et Discussion

Tableau 4. 1 : Les structures des modèles ont été développés avec les vecteurs d'entrée pour estimer le débit prévu avec RNA.	39
---	----

Tableau 4. 2: Les paramètres caractéristiques statistiques des débits observés et simulés par RNA....	50
--	----

RESUME :

Les modèles hydrologiques simulent la transformation des précipitations en écoulements au sein des bassins versants naturels. Ils trouvent de nombreuses applications concrètes dans le domaine de la gestion des ressources en eau. Ce travail vise à modéliser ce processus à l'aide d'un réseau de neurones artificiels (RNA) combiné à un algorithme d'optimisation par essaim de particules (PSO), pour une application spécifique au bassin versant de l'oued El Hachem, situé dans la wilaya de Tipaza. Une première partie de cette étude a été consacrée à une synthèse des principes fondamentaux de l'hydrologie. Celle-ci a été suivie par la présentation détaillée des modèles RNA et PSO, ainsi que de leur implémentation sur la zone d'étude. Enfin, l'efficacité du modèle a été évaluée à travers la prévision des débits journaliers, démontrant sa pertinence et sa capacité de généralisation.

Mots clés : modélisation ; pluie-débit ; RNA ; PSO ; prévision ; débit.

ABSTRACT:

Hydrological models simulate the transformation of precipitation into runoff within natural river basins. They find numerous practical applications in the field of water resource management. This work aims to model this process using an artificial neural network (ANN) combined with a Particle Swarm Optimization (PSO) algorithm, for a specific application to the Oued El Hachem watershed, located in the wilaya of Tipaza. A first part of this study was dedicated to a synthesis of the fundamental principles of hydrology. This was followed by a detailed presentation of the ANN and PSO models, as well as their implementation in the study area. Finally, the model's effectiveness was evaluated through the prediction of daily discharges, demonstrating its relevance and generalization capacity.

Keywords: modeling; rainfall-runoff; ANN; PSO; prediction; discharge.

ملخص:

تُحاكي النماذج الهيدرولوجية تحوّل الأمطار إلى جريان سطحي داخل مستجمعات المياه الطبيعية. وتُستخدم هذه النماذج في تطبيقات عملية عديدة في مجال إدارة الموارد المائية. يهدف هذا العمل إلى نمذجة هذه العملية باستخدام شبكة عصبية ، وذلك لتطبيق مُحدد على مستجمع وادي (PSO) مُدمجة مع خوارزمية تحسين سرب الجسيمات (ANN) اصطناعية الهاشم، الواقع بولاية تيبازة. خُصص الجزء الأول من هذه الدراسة لتلخيص المبادئ الأساسية لعلم الهيدرولوجيا. تبع ذلك ، بالإضافة (PSO) وخوارزمية تحسين سرب الجسيمات (ANN) عرض مُفصّل لنموذجي الشبكة العصبية الاصطناعية إلى تطبيقهما في منطقة الدراسة. وأخيرًا، تم تقييم فعالية النموذج من خلال التنبؤ بالتدفقات اليومية، مع إثبات ملاءمته وقدرته على التعميم.

الكلمات المفتاحية: التنبؤ؛ التدفق؛ PSO؛ RNA؛ النمذجة؛ أمطار-جريان؛

LISTE DES ABREVIATIONS

H :	Matrice Hessienne de la fonction d'erreur.
g :	Matrice de gradient de la fonction d'erreur.
J :	Matrice de Jacobien de la fonction d'erreur.
RNA :	Réseaux de neurones artificiels.
RLM :	Régression linéaire multiple.
ASE :	Average Squared Error.
R :	Le coefficient de corrélation.
E :	Le coefficient d'efficacité nash-sutcliffe.
Qt_i :	La valeur mesurée du débit.
$\hat{Q}t_i$:	La valeur du débit calculé par le modèle.
$\bar{Q}t_i$:	La valeur du débit moyen mesuré.
$\tilde{Q}t_i$:	La valeur du débit moyen calculé.
N :	Le nombre de données.
PSO :	Particule Swart Optimisation.

Introduction Générale

INTRODUCTION GENERALE :

La prévision des débits dans les bassins versants constitue un enjeu majeur pour la gestion durable des ressources en eau, la prévention des inondations et la planification des ouvrages hydrauliques. Avec l'évolution des techniques de modélisation, les méthodes classiques basées sur des formulations physiques sont de plus en plus complétées, voire remplacées, par des approches issues de l'intelligence artificielle, notamment les **réseaux de neurones artificiels (RNA)**. Ces derniers offrent une capacité remarquable à capturer les relations non linéaires entre les variables hydrologiques à partir de données historiques.

Dans ce contexte, ce travail vise à développer un modèle de prévision des débits journaliers en utilisant les RNA, avec l'intégration de l'algorithme **d'optimisation par essaim de particules (PSO : Particle Swarm Optimization)** afin d'améliorer la précision et la stabilité des résultats. Le bassin versant de l'oued El Hachem, situé dans la wilaya de Tipaza, a été retenu comme zone d'étude en raison de ses caractéristiques géographiques et hydrologiques pertinentes.

Le mémoire est structuré en quatre chapitres complémentaires :

- Le **premier chapitre** présente une synthèse bibliographique sur le cycle hydrologique, ses composantes, et les phénomènes extrêmes liés à l'eau.
- Le **deuxième chapitre** traite des réseaux de neurones artificiels, de leurs principes, architectures et méthodes d'apprentissage, ainsi que des techniques d'optimisation utilisées.
- Le **troisième chapitre** est consacré à la description détaillée de la zone d'étude et des données collectées.
- Enfin, le **quatrième chapitre** expose le développement des modèles, les résultats obtenus et leur analyse critique à travers des critères statistiques.

Ce travail ambitionne ainsi de contribuer à l'amélioration des outils de prévision hydrologique, en mettant en œuvre une approche hybride intelligente adaptée aux spécificités locales du bassin étudié.

Chapitre 01 : Synthèse Bibliographique

1.1 INTRODUCTION :

L'eau, source de toute vie, se présente dans la nature sous trois états : solide : neige et glace, liquide : eau chimiquement pure ou chargée en solutés, gazeux : à différents degrés de pression et de saturation.

Les changements de phase de l'eau dépendent essentiellement de la température et de la pression. Dans l'atmosphère terrestre, l'eau se retrouve sous ses trois formes. Les eaux circulent en permanence sur la terre et subissent des changements d'état. L'importance de ces modifications fait de l'eau le principal agent de transport d'éléments physiques, chimiques et biologiques.

1.2 DEFINITION DE L'HYDROLOGIE :

C'est une science de la Terre qui étudie le cycle de l'eau, c'est-à-dire les échanges entre l'atmosphère, la surface et le sous-sol. Elle s'intéresse aux précipitations (pluie, neige), à la transpiration des plantes et à l'évaporation du sol. La partie de surface étudie le ruissellement, l'érosion, l'écoulement des rivières et les inondations. La zone non saturée analyse l'infiltration, le flux d'eau et le transport de polluants. Elle relie les eaux de surface à celles du sous-sol. La branche souterraine s'occupe des ressources en eau dans le sol : captage, protection et renouvellement. En milieu urbain, elle traite la production et la distribution d'eau potable, ainsi que la collecte et le traitement des eaux usées et pluviales. [1]




Figure 1.1: Schéma de la manière dont, dans le cycle hydrologique, l'eau est transférée entre la surface terrestre, l'océan et l'atmosphère [2]

1.3 COMPOSANTE DU CYCLE HYDROLOGIQUE :

- **Les précipitations** : eaux météoriques qui tombent sur la surface de la terre, sous forme liquide (bruine, pluie, averse) et / ou solide (neige, grésil, grêle) ainsi que les précipitations déposées ou occultes (rosée, gelée blanche, givre,...).
- **L'évaporation** : passage de la phase liquide à la phase vapeur, il s'agit de l'évaporation physique.
- **L'évapotranspiration** : englobe les processus d'évaporation et de transpiration de la végétation
- **L'interception** : processus selon lequel la pluie (ou dans certains cas la neige) est retenue par la végétation, puis redistribuée en une partie qui parvient au sol et une autre qui s'évapore.
- **Le ruissellement ou écoulement de surface** : mouvement de l'eau sur ou dans les premiers horizons du sol (écoulement de su surface), consécutif à une précipitation.
- **Le stockage dans les dépressions** : processus au cours duquel l'eau est retenue dans les creux et les dépressions du sol pendant une averse.
- **L'infiltration** : mouvement de l'eau pénétrant dans les couches superficielles du sol.
- **La percolation** : mouvement de l'eau en profondeur dans les sols faisant suite à l'infiltration. [3]

1.4 LA REPARTITION DES EAUX :

La répartition des eaux sur Terre peut être étudiée à la fois de manière quantitative et qualitative, en tenant compte des différentes composantes du cycle hydrologique et à l'échelle globale.




Figure 1. 2: Répartition des eaux dans le monde [3]

Bien que la Terre soit surnommée « la planète bleue » en raison de l'abondance apparente de l'eau, cette ressource est répartie de façon très inégale à sa surface. Les océans recouvrent environ 70 % de la surface terrestre et contiennent près de 97 % de la masse totale d'eau présente dans la biosphère. La part restante se trouve sur les continents, sous forme de neige, de glace, d'eaux courantes ou souterraines.

À l'échelle des continents, de fortes disparités apparaissent entre les zones qui manquent cruellement d'eau et celles qui en disposent en excès. Une quantité très faible d'eau se trouve dans l'atmosphère sous forme de vapeur. En ce qui concerne l'eau douce, plus des trois quarts sont stockés dans les glaces polaires, ce qui limite considérablement la part accessible pour les besoins humains et les écosystèmes. [3]

1.5 LE BILAN HYDRIQUE :

Le cycle de l'eau peut être analysé schématiquement selon les trois éléments suivants :

- Les précipitations,
- le ruissellement ou écoulement de surface et l'écoulement souterrain,
- l'évaporation.

Dans chacune des phases on retrouve respectivement un transport d'eau, un emmagasinement temporaire et parfois un changement d'état. L'estimation des quantités d'eau passant par

chacune des étapes du cycle hydrologique peut donc se faire à l'aide d'une équation de bilan appelée "bilan hydrologique" qui représente le bilan des quantités d'eau entrant et sortant d'un système défini dans l'espace (entité naturelle en générale) et dans le temps, à savoir l'année hydrologique (période d'une année très souvent différente de l'année civile). [3]




Figure 1. 3: Bassin hydrologique, bassin hydrogéologique et aquifère [4]

1.6 LES EXTREMES HYDROLOGIQUES :

Les extrêmes hydrologiques sont des phénomènes hydro climatiques observés aussi bien en Afrique que dans d'autres régions du monde. Ils se distinguent par des contrastes saisonniers marqués et une variabilité temporelle significative. Autrement dit, ces phénomènes traduisent des fluctuations cycliques du régime hydrologique à travers le temps. [36,10]

Parmi ces extrêmes, la **sécheresse** se manifeste par un déficit temporaire des précipitations. Il ne s'agit pas nécessairement d'une caractéristique intrinsèque du climat local, mais d'une anomalie prolongée suffisamment marquée pour engendrer des impacts notables sur l'environnement, l'agriculture ou les ressources en eau.

À l'inverse, l'**aridité** correspond à une condition climatique permanente. Elle se définit par un niveau moyen de précipitations très faible (inférieur à 250 mm par an), associé à une évapotranspiration potentielle élevée (souvent supérieure à 2000 mm). Dans ces zones arides,

la rareté des précipitations et les températures élevées constituent des traits climatiques constants. [10]

1.6.1 La sécheresse :

La sécheresse est un phénomène climatique caractérisé par un manque prolongé de précipitations, entraînant un déficit d'eau et des conditions arides. Cela peut avoir un impact négatif sur les ressources en eau, l'agriculture, la végétation et les activités humaines. Il existe diverses formes de sécheresse. [10,37]

a. La sécheresse météorologique :

La sécheresse météorologique est facilement observable et est la forme de sécheresse que tout le monde connaît : elle se produit lorsqu'il y a une absence de pluie pendant une période prolongée.

Cette sécheresse est relative, car le déficit hydrique est mesuré par rapport aux valeurs normales des précipitations. Ainsi, une absence de pluie pendant trois semaines ne sera pas nécessairement considérée comme une sécheresse en zone méditerranéenne, alors que la même durée sans pluie en Bretagne pourrait l'être.

La sécheresse météorologique est évidente pendant l'été, mais peut passer inaperçue en hiver, car la végétation est en repos et n'est pas directement affectée. Cependant, elle a des conséquences, même en hiver, car elle empêche le rechargement des nappes phréatiques en eau. [10]

b. La sécheresse agricole ou sécheresse des sols :

La sécheresse des sols est un déficit hydrique superficiel, sur 1 à 2 mètres de profondeur. Ce type de sécheresse est lié à l'absence de pluies mais aussi à la végétation : en hiver, lorsque la végétation est au repos, un manque de pluie n'entraîne pas forcément une sécheresse du sol, puisque les racines n'absorbent que très peu d'eau. En revanche, au printemps ou en été, lorsque la végétation est active et puise l'eau du sol pour la rejeter dans l'atmosphère par évapotranspiration, le sol s'assèche plus rapidement. [10,37]

c. La sécheresse hydrologique :

La sécheresse hydrologique se produit lorsque les nappes phréatiques, les lacs, les rivières et les fleuves présentent des niveaux bas. Cette forme de sécheresse peut être causée par plusieurs facteurs, tels qu'un manque de précipitations et/ou une absence d'infiltration profonde dans le sol jusqu'aux nappes phréatiques. Cela peut être dû au ruissellement de l'eau

de pluie au lieu de son absorption par le sol en raison de sols imperméables ou compactés, ou parce que l'eau est captée par la végétation avant d'atteindre les couches souterraines. [10,37]

Lorsqu'une sécheresse hydrologique est constatée (et non une sécheresse météorologique), des mesures de restriction de l'utilisation de l'eau peuvent être mises en place par des arrêtés préfectoraux, tels que l'interdiction de remplir les piscines, d'arroser les jardins, de nettoyer les véhicules, etc. [10,37]

1.7 CONCLUSION

Dans ce chapitre, nous avons posé les fondations théoriques nécessaires à la compréhension des phénomènes hydrologiques, en mettant en évidence la complexité du cycle de l'eau et la diversité de ses composantes. L'hydrologie, en tant que science multidisciplinaire, permet d'analyser les interactions entre l'atmosphère, la surface terrestre et le sous-sol, en intégrant des processus tels que les précipitations, l'évaporation, l'infiltration ou encore le ruissellement.

Nous avons également souligné l'importance de l'eau dans les équilibres naturels et son inégale répartition à travers le globe, tout en insistant sur la vulnérabilité croissante des ressources hydriques face aux phénomènes extrêmes comme les sécheresses. Ces notions sont fondamentales pour aborder les enjeux liés à la gestion durable de l'eau et à la modélisation hydrologique.

Ce cadre bibliographique servira ainsi de référence pour les chapitres suivants, dans lesquels nous explorerons les approches méthodologiques et les outils de modélisation, notamment les réseaux de neurones artificiels et les techniques d'optimisation, appliqués à la prévision des débits.

CHAPITRE 02 : RESEAUX DE NEURONES ARTIFICIELS

2.1. INTRODUCTION :

Aujourd'hui de nombreux termes sont utilisés dans la littérature pour désigner le domaine des réseaux de neurones artificiels, comme connexionnisme ou neuromimétique. Pour notre part, il nous semble qu'il faut associer à chacun de ces noms une sémantique précise. Ainsi, les réseaux de neurones artificiels ne désignent que les modèles manipulés ; ce n'est ni un domaine de recherche, ni une discipline scientifique. Connexionnisme et neuromimétique sont tous deux des domaines de recherche à part entière, qui manipulent chacun des modèles de réseaux de neurones artificiels, mais avec des objectifs différents. L'objectif poursuivi par les ingénieurs et chercheurs connexionnistes est d'améliorer les capacités de l'informatique en utilisant des modèles aux composants fortement connectés. Pour leur part, les neuromiméticiens manipulent des modèles de réseaux de neurones artificiels dans l'unique but de vérifier leurs théories biologiques du fonctionnement du système nerveux central. Notons qu'en France, dès 1982, des réunions de ces deux communautés ont été organisées, ce sont les Journées Neurosciences et Sciences de l'Ingénieur (cf. chp. Informations pratiques). Le titre même de cet ouvrage ne laisse aucun doute, nous nous plaçons du point de vue de l'ingénieur à la recherche d'une connaissance connexionniste. Ceci nous oblige cependant à aborder au chapitre suivant des notions de neurosciences utiles à notre projet. [5]

2.2. DEFINITION :

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. [5]

2.3. LE NEURONE :

2.3.1. Le Neurone biologique :

1. Anatomie du neurone :

Un neurone est une cellule constituée principalement de 3 parties (Figure 1) ayant chacune un rôle fonctionnel bien défini : Ce sont les dendrites, le corps cellulaire et l'axone. Les dendrites reçoivent l'information au niveau des points de contact avec les autres neurones. L'information est ensuite acheminée vers le corps cellulaire.

- Le corps cellulaire, outre son rôle concernant le métabolisme de la cellule, recueille et concentre l'ensemble des informations reçues par les dendrites et en effectue une transformation.
- L'axone, ramification unique et plus longue que les dendrites sert à transporter les signaux émis par le neurone. [6]




Figure 2. 1: Morphologie d'un neurone biologique. [7]

2. Synapses :

Le système nerveux forme un réseau de neurones. Ces derniers sont abondamment connectés entre eux. Une cellule nerveuse réalise, par l'intermédiaire de son axone, plusieurs milliers de connections (appelées synapses) avec d'autres cellules. Le nombre de connections entre un neurone et ses voisins varie entre 10^3 et 10^4 . Par conséquent, le cortex humain contient entre 10^{14} et 10^{15} connections. [6]

2.3.2. Le neurone formel :

2.3.2.1. Définition et représentation :

Le neurone formel (Figure 2), appelé aussi unité, nœud, automate ou élément de processus est un processeur élémentaire. Il a été conçu pour la première fois par McCulloch et Pitts en 1943.




Figure 2. 2: Modèle du neurone formel. [8]

Ce neurone formel est un élément binaire à seuil. Autrement dit ses entrées et sa sortie sont booléennes. Il reçoit de ses voisins des entrées binaires (X_j). Après une sommation pondérée de ces entrées ($\sum W_{ij}X_j$) suivie d'une transformation par une fonction de transfert, le neurone formel envoie des sorties (Y_i) binaires aux neurones voisins. L'activation du neurone formel dépend d'un certain seuil (θ), propre au neurone. Si la somme de ses entrées dépasse ce seuil, il se met dans son état actif (+1) sinon, il se met dans son état inactif (-1). Malgré l'évolution des neurones formels, le modèle de McCulloch et Pitts constitue, à quelques variantes près, la base des modèles RNA conçus jusqu'à aujourd'hui. Cette évolution concerne non seulement l'état de neurone qui peut être binaire ou continu mais aussi la fonction de transfert.

Dans le modèle du neurone de McCulloch et Pitts on trouve [6] :

$$Y_i = \begin{cases} +1 & \text{Si } \sum_j W_{ij} X_j \geq \theta \text{ (seuil)} \quad \leftarrow \text{état actif} \\ -1 & \text{Sinon} \quad \leftarrow \text{état inactif} \end{cases} \quad (1)$$





2.3.2.2. Poids des connections :

Les entrées X_j au neurone i sont des sorties des neurones j du même réseau, ou d'un autre réseau, ou encore des entrées extérieures. Les connections traduisent l'influence de l'environnement extérieur au neurone et permettent de calculer son entrée globale. À chacune de ces entrées j est associé un poids W_{ij} qui détermine l'intensité de cette influence. L'entrée d'un neurone est fonction des signaux provenant des autres neurones et des intensités des connections. La fonction liant ces quantités est la somme des entrées pondérées de leurs poids correspondants. La fonction d'entrée totale peut donc s'écrire comme suit [6] :

$$S_i = \sum_j W_{ij} X_j \quad (2)$$

2.4. LES FONCTIONS D'ACTIVATION :

Jusqu'à présent, nous n'avons pas précisé quelle fonction d'activation était utilisée dans notre modèle, mais il existe plusieurs options possibles. Le tableau (2.1) présente différentes fonctions de transfert qui peuvent être utilisées comme fonction d'activation pour les neurones. Les fonctions d'activation les plus courantes sont les fonctions "seuil" (appelées "hard limite" en anglais), "linéaire" et "sigmoïde". La fonction seuil applique un seuil à l'entrée du neurone. Plus précisément, si l'entrée est négative, la fonction retourne 0 (ce qui peut être interprété comme "faux"), tandis qu'une entrée positive ou nulle retourne 1 (ce qui peut être interprété comme "vrai"). Lorsqu'elle est utilisée dans le contexte d'un neurone, cette fonction est illustrée à la Figure (2.4.) On peut observer que le biais b dans l'expression de $y = \text{hard Lim}(w^t x - b)$ (équation 2.1) détermine l'emplacement du seuil sur l'axe $w^t x$, où la fonction passe de 0 à 1. Nous verrons plus tard que cette fonction permet de prendre des décisions binaires [9,10]

**Figure 2. 3:** La fonction seuil**Figure 2. 4:** La fonction linéaire**Figure 2. 5:** La fonction saturation**Figure 2. 6:** La fonction sigmoïde




Figure 2. 7: La fonction a valeurs discrètes

2.4.1. La fonction linéaire et La fonction sigmoïde :




Figure 2. 8: La fonction linéaire et la fonction à seuil

La fonction linéaire est très simple, elle affecte directement son entrée à sa sortie : $y = x$

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à la figure 2.7 b Dans ce cas, la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $\mathbf{w}^t \mathbf{x} = \mathbf{b}$

La fonction de transfert sigmoïde est quant à elle illustrée à la figure 2.7.c. Son équation est donnée par :

$$y = \frac{1}{1 + \exp^{-s}} \quad (3)$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que l'on est loin ou près de $\mathbf{b}$, respectivement. La fonction seuil est très non linéaire car il y a une discontinuité lorsque $\mathbf{w}^t \mathbf{x} = \mathbf{b}$. De son côté, la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes.

Notons finalement, que la fonction « tangente hyperbolique (tanh)» est une version symétrique de la sigmoïde [9,10].

Tableau 2. 1: Différentes fonctions d'activations utilisées dans les RNA :

	Relation entrée/sortie	Icône	Nom MATLAB
Seuil	$y = 0 \quad \text{si} \quad s < 0$ $y = 1 \quad \text{si} \quad s \geq 0$		hardlim
Seuil symétrique	$y = -1 \quad \text{si} \quad s < 0$ $y = 1 \quad \text{si} \quad s \geq 0$		Hardlims
Linéaire	$y = s$		Purelin
Linéaire saturée	$y = 0 \quad \text{si} \quad s \leq 0$ $y = s \quad \text{si} \quad 0 \leq s \leq 1$ $y = 1 \quad \text{si} \quad s \geq 1$		Satlin
Linéaire saturée symétrique	$y = -1 \quad \text{si} \quad s < -1$ $y = s \quad \text{si} \quad -1 \leq s \leq 1$ $y = 1 \quad \text{si} \quad s > 1$		Satlins
Linéaire positive	$y = 0 \quad \text{si} \quad s \leq 0$ $y = s \quad \text{si} \quad s \geq 0$		Poslin
Sigmoïde	$y = \frac{1}{1 + \exp^{-s}}$		Logsig
Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$		tansig
Compétitive	$y = 1 \quad \text{si} \quad s \text{ maximum}$ $y = 0 \quad \text{autrement}$	C	compet

2.5. APPRENTISSAGE DE RNA :

L'apprentissage implique l'ajustement de la connaissance stockée dans un réseau neuronal à un problème spécifique. Cette connaissance comprend les pondérations des liens entre les neurones ainsi que la topologie du réseau (Figure 2.9). Ainsi, l'apprentissage est étroitement lié au réglage précis des poids synaptiques interconnectant les neurones et à l'adaptation de la topologie du réseau. L'apprentissage peut être réalisé de différentes manières, notamment de manière supervisée ou non supervisée. Lorsque l'apprentissage est supervisé, le réseau dispose d'une série d'exemples contenant des paires de valeurs d'entrée et de valeurs de sortie souhaitées (ou cibles). L'objectif est de modifier les paramètres (poids synaptiques) pour que la sortie du réseau se rapproche de la cible pour chaque entrée donnée. En revanche, dans le cas de l'apprentissage non supervisé, le réseau détermine lui-même les sorties appropriées, guidé par un objectif interne exprimant une configuration idéale à atteindre en fonction des exemples présentés. Les cartes auto-organisatrices de Kohonen représentent un exemple de réseau neuronal non supervisé [9,11].




Figure 2. 9: Classification des réseaux de neurones suivant leur apprentissage [9,12]

En se basant sur la Figure (2.9) dans le contexte de ce travail, l'apprentissage supervisé est le seul type d'apprentissage qui nous intéresse. Pour réaliser cet apprentissage, un "superviseur" est requis, comme illustré dans la Figure (2.9). Ce processus implique la

minimisation d'une fonction appelée fonction de coût (ou fonction d'erreur), qui est calculée à partir des exemples de la base d'apprentissage et de la sortie du réseau de neurones. Cette fonction permet de définir l'objectif à atteindre [12].

L'apprentissage du perceptron multicouche suit également un processus supervisé selon la règle de correction de l'erreur. La formule générale du superviseur est itérative et s'écrit comme suit [9] :

$$W_i^{k+1} = W_i^k \Delta w_i \quad (4)$$

W_i^{k+1} : Nouveau poids

W_i^k : Ancien poids

Δw_i : Incrément




Figure 2. 10: Schéma représentant le mécanisme d'un superviseur dans le cas d'Apprentissage supervisé de perceptron multi couche [9,12]

2.6. METHODES D'OPTIMISATION :

Nous avons plusieurs méthodes d'optimisation pour calculer l'incrément Δw_i .

Parmi ces méthodes on peut citer

2.6.1. Méthode de Newton

La méthode de Newton utilise la courbure (dérivée seconde) de la fonction de coût pour atteindre le minimum. La modification des paramètres s'écrit [9] :

$$H * \Delta W_i = -g \quad (5)$$

Ou :

H : Matrice Hessienne de la fonction d'erreur.

g : Matrice de gradient de la fonction d'erreur.

Cet algorithme converge en une seule itération pour une fonction quadratique. C'est donc un algorithme qui est inefficace loin du minimum de la fonction et très efficace près du minimum [9,12].

2.6.2. Méthode de Gauss-Newton :

Les méthodes de Gauss-Newton consistent à approcher l'inverse de la matrice Hessienne plutôt que de calculer sa valeur exacte. La modification des paramètres s'écrit [9,13] :

$$2 * \Delta w_i = -g \quad (6)$$

g : Matrice de Jacobien de la fonction d'erreur.

2.6.3. Méthode de descente de gradient :

L'algorithme le plus simple consiste à choisir comme direction de descente l'opposé du gradient de la fonction de coût. Cette méthode est efficace loin du minimum et permet uniquement de s'en approcher. Pour cette raison, la détermination du pas n'est pas cruciale : loin du minimum, il faut seulement vérifier que le pas n'est ni trop petit ni trop grand [12].

En pratique, on utilise :

$$\gamma \Delta * w_i = -g \quad (7)$$

γ : Constant.

2.6.4. Méthode de Levenberg-Marquardt :

C'est la méthode qui associe la méthode de descente de gradient avec la méthode de Gauss-Newton dans la forme suivante : γ est nul, la direction est celle d'un algorithme de Gauss-

Newton. Quand γ tenders l'infini, la direction est celle de la plus forte pente. γ est calculé à chaque itération et favorise la direction de la plus forte pente dans les cas ou' la méthode de Gauss-Newton n'est pas adaptée. On peut par exemple : Diminuer γ si tout se passe bien (la fonction objective diminue) et l'augmenter si γ il y a divergence (la fonction objective augmente). La méthode de Levenberg- Marquardt est particulièrement robuste et efficace. Elle est devenue l'algorithme de référence pour la minimisation de problèmes de moindres carrés non linéaires [12].

2.7. LES DIFFERENTES ARCHITECTURES DE RESEAUX DE NEURONES ARTIFICIELS :

Il existe plusieurs architectures de réseaux de neurones artificiels, chacune adaptée à des tâches spécifiques. Nous allons en examiner quelques-unes ci-dessous :

2.7.1. Les réseaux de neurones à couche unique :

Les réseaux de neurones à couche unique sont les réseaux de neurones les plus simples. Ils sont composés d'une seule couche de neurones artificiels. Ils sont souvent utilisés pour la classification binaire ou la régression linéaire.

2.7.2. Le Perceptron Multi Couche (PMC)

Le perceptron est un des premiers réseaux de neurones, conçu en 1958 par Rosenblatt .Il est linéaire et monocouche. Les sorties des neurones ne peuvent prendre que deux états (-1 et 1 ou 0 et 1). La règle de modification des poids est celle de Widrow-Hoff. En 1969, Papert & Minsky ont démontré ses limites. Le perceptron multicouche est une amélioration du perceptron comprenant une ou plusieurs couches intermédiaires dites couchent cachées [14].




Figure 2. 11: Exemple de perceptron multicouche [15]

Pour modifier les poids, l'algorithme de rétro propagation du gradient est le plus utilisé. La sigmoïde représente la fonction de base de ces réseaux. [14]

2.7.3. Réseau à connexions locales :

Il s'agit d'une structure multicouche, mais qui à l'image de la rétine, conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche avale (fig.2.12). Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique [17].




Figure 2. 12: Réseau à connexions locales. [17]

2.7.4. Réseau à connexions récurrentes :

Les réseaux de neurones récurrents (RNN) sont un type de NN largement utilisé pour effectuer le processus d'analyse de séquence car le RNN est conçu pour extraire les informations contextuelles en définissant les dépendances entre les différents horodatages. RNN se compose de nombreuses couches récurrentes successives, et ces couches sont séquentiellement modélisées afin de cartographier la séquence avec d'autres séquences.




Figure 2. 13: Exemple d'un réseau à connexions récurrentes [17]

RNN à une forte capacité à capturer les données contextuelles de la séquence. Cependant, les indices contextuels dans la structure du réseau sont stables et sont efficacement utilisés pour réaliser le processus de classification des données. La caractéristique principale et la plus importante du RNN est son état caché, qui mémorise certaines informations sur une séquence. L'état est également appelé état mémoire car il mémorise l'entrée précédente du réseau. Il utilise les mêmes paramètres pour chaque entrée car il exécute la même tâche sur toutes les entrées ou couches cachées pour produire la sortie. Cela réduit la complexité des paramètres, contrairement aux autres réseaux neuronaux [16]




Figure 2. 14: Réseau neuronal récurrent [16].

2.7.3. Réseau à connexion complète :

C'est la structure d'interconnexion la plus générale (fig.2.15). Chaque neurone est connecté à tous les neurones du réseau (et à lui-même).




Figure 2. 15: Réseau à connexion complète [17].

Il existe de nombreuses autres topologies possibles, mais elles n'ont pas eu à ce jour la notoriété des quelques-unes que nous avons décrites ici [17].

2.7.4. Réseau de Kohonen :

On les appelle aussi les cartes auto-organisatrices de Kohonen [18,23]. Dans le réseau de Kohonen, on peut parler de deux couches dont une seule active [19,23]. Schématiquement, cette couche se présente sous forme d'une grille de neurones [20,23]. Chaque neurone de cette grille est connecté à toutes les entrées (Figure 2.14). Un des aspects caractéristiques du réseau de Kohonen est qu'il accomplit seulement une rétroaction locale (local feedback) [19,23]. Ceci vient du fait que chaque neurone n'est connecté qu'à quelques neurones topologiquement proches de lui. On définit ainsi un voisinage du neurone. Il en découle que les neurones voisins agissent de la même façon vis-à-vis des entrées similaires. Le changement d'état de ce type de réseaux se base sur un mécanisme de concurrence entre les neurones. Cette compétition a pour but d'élire un neurone gagnant [19,23]. C'est le neurone le plus activé et celui qui minimise l'erreur avec la sortie souhaitée qui va subir une modification des poids.

La capacité de découvrir automatiquement des catégories dans un ensemble de données fait de ces réseaux des techniques efficaces de classification [21, 22,23].




Figure 2. 16: Schéma d'un réseau de Kohonen [23]

2.8 PROBLEME DE SURAJUSTEMENT:

Lors de l'apprentissage, les réseaux neuronaux ajustent leurs sorties pour correspondre aux exemples appris. Toutefois, leur principal atout est la généralisation, c'est-à-dire leur capacité à traiter correctement des données nouvelles. Pour y parvenir, il faut sélectionner des entrées pertinentes et représentatives de la fonction cible, sans ajouter d'informations inutiles qui pourraient compliquer inutilement le modèle et nuire à sa performance. [27]

Lorsqu'une séquence d'apprentissage est sélectionnée, il est important de s'assurer qu'elle représente correctement la fonction que nous cherchons à approximer, et que les ensembles que nous essayons de prédire appartiennent à la même classe que l'ensemble d'apprentissage. L'objectif de la modélisation par les réseaux de neurones est d'obtenir un modèle capable d'apprendre les données et d'assurer une bonne généralisation en évitant le sur-apprentissage. Ce phénomène est causé par un ajustement excessif des paramètres (poids synaptiques) (Figure 2.16). [10]

2.9. METHODES POUR LIMITER LE SURAJUSTEMENT :

On peut distinguer deux familles de méthodes pour prévenir le sur-ajustement : les méthodes passives et les méthodes actives. Ces deux approches ont des philosophies différentes.

Les méthodes passives visent à détecter le sur-ajustement a posteriori afin d'éliminer les modèles incorrects. Parmi les méthodes les plus courantes, on retrouve l'utilisation d'une base de validation pendant l'apprentissage et l'utilisation de mesures de critères d'information.

Les méthodes actives interviennent pendant la phase d'apprentissage pour empêcher le modèle de tomber dans le sur

-ajustement. Les techniques de régularisation, telles que l'arrêt prématuré ou la pénalisation, font partie de cette catégorie. [10]

Pour mettre en œuvre ces méthodes, il est nécessaire de déterminer le nombre d'itérations à utiliser lors de l'apprentissage. La méthode la plus courante consiste à suivre l'évolution de la fonction de coût sur une base de validation et à arrêter les itérations lorsque le coût calculé sur cette base commence à augmenter [12]. Cependant, cela peut être observé dans (la Figure 2.16)




Figure 2. 17: Schéma qui représente l'évolution de l'erreur d'apprentissage et de validation d'un RNA en fonction de nombre d'itération [12,10]

2.10 OPTIMISATION PAR ESSAIM DE PARTICULES :

La méthode de calcul PSO vise à optimiser un problème de manière itérative, en partant d'un ensemble, ou population, de solutions candidates, appelé dans ce contexte essaim de particules. Chaque particule connaît sa meilleure position globale au sein de l'essaim (et sa valeur correspondante dans le contexte du problème), ainsi que sa meilleure position individuelle (et sa valeur de fitness) trouvée jusqu'à présent lors de la recherche dans l'espace des solutions du problème [24].




Figure 2. 18: Particle Swarm Optimization Architecture Illustration [25].

La vitesse de chaque particule i dans l'essaim, à chaque itération t , est mise à jour selon l'équation suivante [24,26] :

$$\vec{V}_{it+1} = \vec{V}_{it} + \varphi_1 R_1(\vec{p}_{it} - \vec{x}_{it}) + \varphi_2 R_2(\vec{g}_t - \vec{x}_{it}) \quad (8)$$

Où φ_1 et φ_2 sont des coefficients d'accélération réels, appelés respectivement poids cognitif et social, qui contrôlent l'influence des meilleures positions globales et individuelles sur la vitesse et la trajectoire de la particule.

Dans l'algorithme PSO original [2], φ_1 et φ_2 sont tous deux égaux à 2, ce qui donne en moyenne 1 aux poids des composantes sociale et cognitive.

Dans les problèmes multimodaux, où plusieurs zones de l'espace de recherche sont prometteuses, l'ajustement fin de ces paramètres est encore plus crucial pour éviter une convergence prématurée.

R_1 et R_2 sont des vecteurs aléatoires d -dimensionnels uniformément distribués, utilisés pour maintenir un niveau de diversité adéquat dans la population de l'essaim. Enfin, $\vec{p}_i$ et $\vec{g}$ sont respectivement la meilleure position personnelle ou individuelle de la particule i à l'itération t , et la meilleure position globale actuelle de l'essaim.

À son tour, la position de chaque particule i , à chaque itération t , varie selon l'équation suivante [26,24]

$$\vec{x}_{it+1} = \vec{x}_{it} + \vec{V}_{it+1} \quad (9)$$

Sur cette base, l'algorithme PSO peut être résumé comme suit : il s'agit d'un processus de recherche basé sur un essaim, dans lequel chaque individu est appelé une particule, définie comme une solution potentielle du problème optimisé dans un espace de recherche à D dimensions. Il peut mémoriser la position optimale de l'essaim et la sienne, ainsi que sa vitesse. À chaque génération, les informations sur les particules sont combinées pour ajuster la vitesse de chaque dimension, ce qui permet de calculer la nouvelle position de la particule. Les particules changent constamment d'état dans l'espace de recherche multidimensionnel, jusqu'à atteindre l'équilibre ou l'état optimal, ou au-delà des limites de calcul. Une connexion unique entre les différentes dimensions de l'espace du problème est introduite via les fonctions objectives. De nombreuses preuves empiriques ont démontré que cet algorithme est un outil d'optimisation efficace. L'organigramme de l'algorithme PSO est présenté à la (figure 2.16).

Ce qui suit donne une présentation relativement complète de l'algorithme PSO. Dans le système de coordonnées de l'espace continu, l'algorithme PSO peut être décrit mathématiquement. [31]




Figure 2. 19: Organigramme de l'algorithme d'optimisation par essaim de particules [31]

2.11 CONCLUSION :

Ce chapitre a présenté les principes fondamentaux des réseaux de neurones artificiels (RNA), leurs architectures, fonctions d'activation et méthodes d'apprentissage. Il a également mis en évidence l'intérêt des techniques d'optimisation, notamment l'algorithme PSO, pour améliorer les performances des RNA. L'intégration des deux approches permet de concevoir des modèles hybrides efficaces, particulièrement adaptés à la prévision hydrologique.

CHAPITRE 03: ZONE D'ETUDE ET DESCRIPTION DES DONNEES

3.1 INTRODUCTION :

Notre zone d'étude, le bassin de l'Oued El Hachem est situé dans la Wilaya de Tipaza, qui fait partie de la région nord de l'Algérie. C'est une zone fortement urbanisée. Elle s'étend sur une superficie de 1707 km², située à 68 km à l'Ouest de la capitale Alger. Elle est limitée au Nord par la mer méditerranée, à l'Est par la Wilaya d'Alger, au Sud-est par la wilaya de Blida, au Sud par la Wilaya de Ain-Defla et à l'Ouest par la Wilaya de Chlef. La Wilaya de Tipaza est composée de 10 daïras et 28 communes ; Notre zone d'étude, plaine de L'Oued El Hachem, fait partie de la daïra de Sidi Amar, commune de Menacer. Ce chapitre est consacré à une présentation de la zone d'étude axée sur les caractéristiques géographiques et administratives, les aspects hydrologiques et hydrographiques, ainsi que ses potentialités en termes de ressources hydriques et socio-économiques.

3.2 SITUATION GEOGRAPHIQUE :

La vallée de l'Oued El Hachem située dans le sous bassin Côtier Cherchell (0203), appartient au bassin versant Côtier Algérois (02a) selon la nomenclature de l'Agence Nationale des Ressources Hydriques (ANRH). Elle fait partie de l'Atlas tellien. L'Oued El Hachem se situe au Sud-est de la ville de Cherchell, au pied du versant Sud-ouest du massif de Chenoua.

Elle est limitée au Sud par Djebel Boumâad, au Nord par la mer méditerranéenne et à l'Est par le massif de Gouraya. [28,30]




Figure 3. 1: Situation géographique de la zone d'étude. [28]

3.3 LE BARRAGE :

Réalisé sur l'oued El Hachem dans la wilaya de Tipaza, le barrage réservoir de Boukourdane est situé à 70 km à vol d'oiseau à l'ouest d'Alger (Figure 3.2). Avec un apport moyen annuel de 35 millions de m³ et d'une capacité initiale égale à 108 millions de m³, le barrage réservoir de Boukourdane a été mis en exploitation en 1996. [29]




Figure 3. 2: Localisation du barrage réservoir de Boukourdane [32,34]

Le barrage réservoir de Boukourdane a été réalisé à l'exutoire du bassin versant d'oued El Hachem d'une superficie de 243 km². Il est alimenté par les oueds : Boukadir, Tegdza, Nachef et Fedjena pour former l'oued El Hachem. Selon [28,33] le bassin versant possède un taux d'érosion de 446 t/km². an. Le bassin versant de Boukourdane appartient au bassin hydrographique Algérois-Soummam-Hodna et plus exactement le bassin Algérois. Contrairement aux autres bassins hydrographiques qui sont au nombre de 5, le taux d'envasement de l'Algérois -Soummam -Hodna enregistrent un faible taux de comblement qui avoisine la valeur de 9% de la capacité totale des barrages. [29]




Figure 3. 3: Les limites du bassin versant à l'amont du barrage de Boukourdane. [32]

Vie de ces ouvrages dépassera les 220 ans. [35] Ce faible taux de comblement est la conséquence d'une faible érosion des sols dû au boisement et à l'aménagement des bassins versants. [29]




Figure 3. 4: Bassin Hydrographique Algérois- Soummam- Hodna. [32]

3.4. GEOMORPHOLOGIE ET PHYSIOGRAPHIE DU MILIEU ETUDIE :

En raison de l'importance des caractéristiques physiques du bassin versant vis-à-vis de l'hydrologie de surface, nous présentons les paramètres les plus importants.

3.5 COEFFICIENT DE COMPACITE :

Le contour d'un bassin versant est sa délimitation initiale, qui peut avoir une forme spécifique et occuper une superficie donnée "A". Cette forme aura une influence sur l'écoulement global des eaux et en particulier sur la forme de l'hydro gramme résultant d'une précipitation donnée. Un bassin versant allonger réagira différemment d'un bassin versant de forme arrondie. La connaissance de cet indice permet de comparer le périmètre du bassin versant à celui d'un cercle ayant la même superficie. [10,29]

3.6 HYDROGRAPHIE :

La configuration du réseau hydrographique est largement influencée par l'évolution des phénomènes structuraux qui ont marqué la région au fil des ères géologiques. Le réseau hydrographique suit généralement les principales structures géologiques qui ont affecté les formations carbonatées du Jurassique, et il se transforme au fur et à mesure de l'évolution de la tectonique. Dans notre zone d'étude, le bassin versant est drainé par Oued Hachem. [10,29]

3.7 SITUATION TOPOGRAPHIQUE :

La variation des paramètres physiques et géomorphologiques au sein d'un bassin versant influe sur son comportement hydrologique. L'analyse de ces différents paramètres permet de rechercher les causes des variations du régime hydrologique. Les caractéristiques physiographiques du bassin versant de l'oued El Hachem sont portées dans le tableau n° 02 ci-dessous [38] :

Tableau 3. 1: Les caractéristiques physiographiques du bassin versant de l'oued El Hachem [38]

PARAMETRES PHYSIOGRAPHIQUES	VALEURS
Altitude maximum (m)	1417
Altitude minimum (m)	0
Altitude de fréquence 50% (m)	420
Altitude moyenne (m)	410
Surface (Km^2)	218.75
Périmètre (Km)	80
Longueur du rectangle équivalent (Km)	33.46
Largeur du rectangle équivalent (Km)	6.53
Indice de compacité (K_c)	1.51
Indice de pente globale (%)	2.43
Densité de drainage (D_d) (Km/Km^2)	3.42
Coefficient de torrentialité ($1/\text{Km}^3$)	25.48
Rapport de confluence (R_{oc})	4.71
Longueur de l'oued El Hachem (Km)	34

Le bassin versant de l'oued El Hachem dont le code est 02-03 (ANRH), occupe une superficie de 218,75 Km^2 et un périmètre de 80Km. Il présente une forme rectangulaire allongée d'orientation Sud -Nord, suggérant à priori le ruissellement des eaux superficielles aux dépends de l'infiltration, ceci est montré visiblement par la valeur de K_c et les dimensions du rectangle équivalent (L , l). Les altitudes extrêmes du bassin versant sont comprises entre 0 m à l'embouchure et 1417m sur les bordures Sud- Ouest du djebel Boumâad et l'altitude moyenne de la plaine est de 37m [38].

3.8 SITUATION CLIMATIQUE :

La zone d'étude jouit d'un climat de type sec

- 1- **Pluviométrie** : Cherchell classée dans l'étage subaride, reçoit plus de 500 mm/an

Tableau 3. 2: Précipitations Moyennes Mensuelles à la station de Boukerdane (période : 1980/2012) [38]

Mois	S	O	N	D	J	F	M	A	M	J	J	O	Total
Pluies moyenne (mm)	27.9	45.9	91.3	95.3	76.1	73.7	50.7	46.6	36.5	6.8	2.6	5	558.4

2- Température

La température est parmi les facteurs climatiques les plus importants qui ont une grande influence sur la croissance du végétal.



Figure 3. 5: Températures moyennes des minima, des maxima et des moyennes mensuelles. [38]

3- Vent :

Il est nécessaire de connaître la vitesse du vent avant d'installer un système d'irrigation



Figure 3. 6: vitesses mensuelles du vent au niveau de la station météorologique du barrage de Boukerdene (1987-2011). [38]

3- Humidité relative

Concernant l'humidité relative, le mois le plus humide est le mois de janvier avec 72,8%. Alors que le mois le moins humide coïncide avec le mois de juin avec 60,2%.

3.8 CONCLUSION :

Ce chapitre a permis de présenter en détail la zone d'étude, à savoir le bassin versant de l'oued El Hachem situé dans la wilaya de Tipaza. À travers l'analyse de ses caractéristiques géographiques, topographiques, géomorphologiques et climatiques, nous avons pu mieux comprendre les spécificités physiques et hydrologiques de ce territoire. L'étude du barrage de Boukourdane, élément central du système hydrique local, ainsi que les données climatiques et morpho métriques du bassin, constituent une base essentielle pour toute démarche de modélisation hydrologique.

Ces informations sont fondamentales pour la mise en œuvre d'un modèle prédictif fiable, notamment à travers l'utilisation de techniques comme les réseaux de neurones artificiels et les algorithmes d'optimisation. Elles seront exploitées dans les chapitres suivants pour calibrer, entraîner et valider les modèles développés dans le cadre de ce travail.

Chapitre 04 : Résultats Et Discussion

4.1. DEVELOPPEMENT DES MODELES :

Dans ce travail, les vecteurs d'entrée sont constitués des précipitations et des débits observés à différents intervalles de temps antérieurs. Toutefois, seule la précipitation du jour suivant (P_{t+1}) est considérée comme variable d'entrée principale du modèle. L'objectif est de prédire les débits du jour suivant (Q_{t+1}), qui constituent la sortie du réseau.

La base de données utilisée a été scindée en trois ensembles distincts afin d'optimiser les paramètres du modèle et d'en améliorer les performances. Un premier ensemble a été dédié à l'apprentissage, tandis que les deux autres ont servi respectivement à la validation et au test du modèle.

La répartition des données s'est faite comme suit : 70 % ont été affectés à la phase d'apprentissage, 30 % ont été utilisés pour la validation, et un ensemble distinct, contenant l'ensemble de la série temporelle, a été réservé pour la phase de test.

Au total, 15 architectures de réseaux de neurones artificiels (RNA) ont été proposées (voir Tableau 4.1), chacune se distinguant par les vecteurs d'entrée employés. Ces modèles ont été évalués et comparés en termes de performance afin d'identifier celui offrant les meilleurs résultats.

Tableau 4. 1 : Les structures des modèles ont été développés avec les vecteurs d'entrée pour estimer le débit prévu avec RNA.

Modèle	Entrées du réseau	Sortie du réseau
1	P_{t+1} and Q_t	Q_{t+1}
2	P_{t+1} , P_t and Q_t	Q_{t+1}
3	P_{t+1} , P_t , P_{t-1} and Q_t	Q_{t+1}
4	P_{t+1} , Q_t and Q_{t-1}	Q_{t+1}
5	P_{t+1} , P_t , Q_t and Q_{t-1}	Q_{t+1}
6	P_{t+1} , P_t , P_{t-1} , Q_t and Q_{t-1}	Q_{t+1}
7	P_{t+1} , Q_t , Q_{t-1} and Q_{t-2}	Q_{t+1}
8	P_{t+1} , P_t , Q_t , Q_{t-1} and Q_{t-2}	Q_{t+1}
9	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} and Q_{t-2}	Q_{t+1}
10	P_{t+1} , Q_t , Q_{t-1} , Q_{t-2} and Q_{t-3}	Q_{t+1}
11	P_{t+1} , P_t , Q_t , Q_{t-1} , Q_{t-2} and Q_{t-3}	Q_{t+1}
12	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} , Q_{t-2} and Q_{t-3}	Q_{t+1}
13	P_{t+1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} and Q_{t-4}	Q_{t+1}
14	P_{t+1} , P_t , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} and Q_{t-4}	Q_{t+1}
15	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} and Q_{t-4}	Q_{t+1}
16	P_{t+1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} , Q_{t-4} and Q_{t-5}	Q_{t+1}
17	P_{t+1} , P_t , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} , Q_{t-4} and Q_{t-5}	Q_{t+1}
18	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} , Q_{t-4} and Q_{t-5}	Q_{t+1}

Pour développer des modèles de réseaux de neurones artificiels (RNA), la détermination du nombre optimal de neurones dans la couche cachée est une étape cruciale. Cette étape vise à garantir que le modèle atteigne les meilleures performances possibles lors de la prédiction des données. Ce processus a été mis en œuvre pour différents modèles de vecteurs d'entrée proposés, comme indiqué dans le tableau 4.1.

Pour déterminer le nombre optimal de neurones dans la couche cachée, nous avons mené une série d'expériences testant les performances du modèle avec différents nombres de neurones. Ces expériences ont débuté avec un seul neurone dans la couche cachée, puis ont progressivement augmenté ce nombre jusqu'à 50 neurones. À chaque fois, le modèle a été entraîné sur l'ensemble de données d'apprentissage, puis évalué par rapport à un ensemble de données de validation afin de calculer l'erreur et de déterminer la précision de la prédiction. Les résultats de performance ont été enregistrés pour chaque cas et comparés afin de déterminer l'architecture optimale du modèle.

Sur la base des résultats obtenus lors de la phase de validation, l'architecture présentant la plus faible erreur et la meilleure capacité de généralisation a été sélectionnée ; autrement dit, le modèle a obtenu de bons résultats non seulement sur les données d'apprentissage, mais aussi sur des données qu'il n'avait pas vues auparavant lors de l'apprentissage.

La figure 4.1 illustre de manière visuelle et simplifiée les différentes étapes impliquées dans le développement d'un modèle de réseau neuronal artificiel, en commençant par la sélection des vecteurs d'entrée, puis en déterminant le nombre de cellules dans la couche cachée, et en terminant par la phase d'évaluation et la sélection du meilleur modèle.




Figure 4. 1: Organigramme expliquant le développement des RNA. [8]

Dans le cadre du développement d'un modèle hybride associant un Réseau de Neurones Artificiels (RNA) à l'Optimisation par Essaims de Particules (PSO), nous avons mené une série d'expérimentations visant à tester différentes configurations du réseau ANN. L'objectif était d'identifier l'architecture la plus performante pour la prévision des débits. À l'issue de cette phase d'évaluation, un modèle s'est démarqué par sa robustesse, sa capacité de généralisation et la précision de ses prédictions.

Afin de renforcer encore les performances du réseau sélectionné, nous avons ensuite intégré l'algorithme PSO. Cet algorithme d'optimisation, inspiré du comportement collectif des essaims dans la nature, a été utilisé pour ajuster de manière optimale les poids et biais du réseau de neurones. Grâce à cette approche, il a été possible d'explorer efficacement l'espace des solutions, en évitant les minima locaux et en améliorant la convergence du modèle.

L'approche hybride ainsi mise en place a montré une nette amélioration des résultats, tant en termes de précision que de stabilité. Ces travaux soulignent la synergie entre les méthodes d'apprentissage profond et les techniques d'optimisation évolutionnaires, et ouvrent des perspectives prometteuses pour la modélisation avancée des processus hydrologique.




Figure 4. 2: représentant le modèle hybride ANN–PSO appliqué à la prévision des débits

4.2 : CHOIX DES CRITERES DE PERFORMANCE :

L'évaluation des performances du modèle de réseau de neurones artificiels (RNA) repose principalement sur la comparaison entre les valeurs simulées par le modèle et les valeurs observées. Pour ce faire, plusieurs critères statistiques sont utilisés afin de quantifier l'écart entre les prédictions du réseau et les données réelles.

Dans le cadre de ce travail, l'évaluation du modèle a été effectuée durant les trois phases essentielles du développement : l'apprentissage, la validation et le test. Pour mesurer la qualité des prédictions du RNA à chaque étape, nous avons eu recours à des indicateurs statistiques couramment utilisés dans le domaine de la modélisation hydrologique.

Les trois critères retenus sont les suivants :

- **L'erreur moyenne quadratique (ASE, *Average Squared Error*)**, qui permet d'évaluer la dispersion des erreurs entre les valeurs prévues et observées, en pénalisant davantage les grandes erreurs ;
- **Le coefficient d'efficacité de Nash-Sutcliffe (E)**, qui mesure l'aptitude du modèle à reproduire la variabilité des données observées. Une valeur proche de 1 indique une excellente performance du modèle ;
- **Le coefficient de corrélation linéaire (R)**, qui quantifie la force et la direction de la relation linéaire entre les données observées et simulées. Une valeur élevée de R traduit une forte corrélation entre les deux séries.

Ces indicateurs ont permis de comparer objectivement les différentes configurations du modèle RNA et de sélectionner celle offrant les meilleures performances globales.

Les valeurs efficaces d'ASE sont rapprochées à 0 et les valeurs efficaces de E et R à 1. Ces critères sont définis par les équations suivantes :

$$ASE = \frac{\sum_{i=1}^N (Qt_i - \hat{Q}t_i)^2}{N} \quad (9)$$

$$E = 1 - \frac{\sum_{i=1}^N (Qt_i - \hat{Q}t_i)^2}{\sum_{i=1}^N (Qt_i - \bar{Q}t_i)^2} \quad (10)$$

$$R = \frac{(\hat{Q}t_i - \bar{\hat{Q}}t_i)(Qt_i - \bar{Q}t_i)}{\sqrt{(\sum_{i=1}^N (\hat{Q}t_i - \bar{\hat{Q}}t_i)^2)(\sum_{i=1}^N (Qt_i - \bar{Q}t_i)^2)}} \quad (11)$$

Où : Qt_i est la valeur mesurée du débit; $\hat{Q}t_i$ est la valeur du débit calculé par le modèle; $\bar{Q}t_i$ est la valeur du débit moyen mesuré $\bar{\hat{Q}}t_i$ est la valeur du débit moyen calculé et N est le nombre de données.

4.3 : RESULTATS ET DISCUSSION :

L'analyse du tableau révèle une variabilité notable dans les performances des différents modèles de réseaux de neurones artificiels (RNA) selon la configuration des vecteurs d'entrée.

4.3.1 : Meilleurs modèles en phase de validation:

Les modèles 3, 9, 11, 12, 14, 15, 17 et 18 présentent des valeurs d'ASE relativement faibles en phase de validation, traduisant une bonne capacité à généraliser sur des données non vues. En particulier, le modèle 11 affiche l'une des meilleures combinaisons de critères avec une

ASE = 6.49, un coefficient d'efficacité $E = 0.6016$ et un coefficient de corrélation $R = 77.58$ %. Ce modèle maintient également de bonnes performances en phase d'apprentissage et de test.

4.3.2 : Meilleur équilibre global :

Le **modèle 9** montre des performances équilibrées dans les trois phases :

- Apprentissage : ASE = 6.52 | $E = 0.7849$ | $R = 89.26$ %
- Validation : ASE = 6.93 | $E = 0.5743$ | $R = 76.19$ %
- Test : ASE = 6.64 | $E = 0.7458$ | $R = 86.71$ %

Cela indique une bonne stabilité du modèle et une forte capacité de généralisation.

4.3.3 : Modèle les moins performants :

Les modèles 12, 14 et 17 affichent les plus grandes valeurs d'ASE ainsi que les valeurs les plus faibles de E et R , notamment :

- **Modèle 14 :**
 - Apprentissage : ASE = 12.34 | $E = 0.5931$ | $R = 79.61$ %
 - Test : ASE = 10.67 | $E = 0.5918$ | $R = 79.11$ %
- **Modèle 12 :**
 - Test : ASE = 10.37 | $E = 0.6031$ | $R = 78.20$ %

Ces résultats traduisent une faible aptitude de ces modèles à reproduire avec précision les données, aussi bien pendant l'entraînement que lors de la généralisation.

4.3.4 : Performances stables mais moyennes :

Certains modèles comme le modèle 1, 4, 5, et 6 présentent une stabilité entre les différentes phases, mais sans atteindre des niveaux de performance particulièrement élevés. Ils peuvent être considérés comme fiables, mais pas optimaux.

Et enfin, nous concluons Parmi l'ensemble des modèles testés, les modèles 9, 11 et 18 se démarquent par leurs performances solides et équilibrées. En revanche, les modèles 12, 14 et 17 affichent des résultats insuffisants, ce qui remet en question leur pertinence pour une application prédictive fiable.

Pour mesurer l'efficacité de prévision de modèle RNA en utilisant Trois critères statistiques ASE, E, et R dans les phases apprentissage, validation et test. Les résultats optimaux obtenus par le modèle de RNA sont résumés dans le tableau (4.3).

Le tableau (4.3) illustre les résultats statistiques du modèle RNA pour les différentes combinaisons de vecteurs d'entrées proposées dans les phases d'apprentissage, validation et test.

4.3.5 : Pour le modèle RNA-PSO :

- *Phase d'apprentissage :*

Les résultats pour cette phase sont excellents : une valeur de 4.2542 pour ASE, une valeur de 0.8597 pour E, et un pourcentage de 92.7244% pour R. Cela indique que le modèle a très bien appris les motifs présents dans les données sur lesquelles il a été entraîné.

- *Phase de validation :*

Les performances sont moins bonnes en validation qu'en apprentissage. L'erreur ASE passe à 5.8287, le coefficient E diminue à 0.6421, et le pourcentage de R chute à 80.1542%.

- *Phase de Test :*

Les résultats sur l'ensemble de test sont très importants car ils reflètent la capacité du modèle à généraliser à de nouvelles données complètement inconnues. Ici, l'erreur ASE est de 4.7264, le coefficient E de 0.8192, et le pourcentage R de 90.5114%.

Ces performances sont meilleures qu'en phase de validation pour les deux dernières métriques ($0.8192 > 0.6421$ et $90.5114\% > 80.1542\%$), et l'erreur est plus faible qu'en validation. Bien que légèrement inférieures aux performances d'apprentissage initiales, ces valeurs sont très solides.

Le modèle RNA-PSO montre de très bonnes performances sur l'ensemble d'apprentissage. La légère dégradation observée en phase de validation indique un certain surapprentissage, ce qui est courant. Cependant, la performance sur l'ensemble de test, qui est le critère le plus fiable pour évaluer la capacité de généralisation du modèle, est très bonne (avec un taux de succès de plus de 90%). Cela signifie que le modèle est capable de faire des prédictions fiables sur de nouvelles données non vues.

Pour mesurer l'efficacité de prévision de modèle RNA et RNA-PSO en utilisant Trois critères statistiques ASE, E, et R dans les phases apprentissage, validation et test. Les résultats optimaux obtenus par le modèle de RNA sont résumés dans le tableau (4.3).

Le tableau (4.3) illustre les résultats statistiques du modèle RNA pour les différentes combinaisons de vecteurs d'entrées proposées et le modèle hybride RNA-PSO dans les phases d'apprentissage, validation et test.

Figure 4. 3: Résultats statistiques du modèle RNA dans les phases d'apprentissage, validation et test.

Modèle	Phase	ASE (m3/s)	E	R
1	Apprentissage	3.6231	0.8805	93.8348
	Validation	7.3597	0.5481	74.7058
	Test	4.7437	0.8185	90.4910
2	Apprentissage	9.5754	0.6842	83.0791
	Validation	7.3222	0.5504	75.0419
	Test	8.8997	0.6596	81.3729
3	Apprentissage	9.4337	0.6888	84.8744
	Validation	6.6696	0.5905	76.8603
	Test	8.6048	0.6708	83.0424
4	Apprentissage	8.8297	0.7088	85.0536
	Validation	7.3674	0.5476	74.5506
	Test	8.3912	0.6790	82.7633
5	Apprentissage	9.0694	0.7009	84.1059
	Validation	7.0693	0.5659	75.4782
	Test	8.4696	0.6760	82.4056
6	Apprentissage	9.8661	0.6746	82.8537
	Validation	7.3950	0.5459	74.0542
	Test	9.1250	0.6509	81.0625
7	Apprentissage	9.6978	0.6801	82.9860
	Validation	7.5430	0.5368	73.4084
	Test	9.0516	0.6537	81.1247
8	Apprentissage	9.6288	0.6824	83.6904
	Validation	7.0621	0.5664	75.4010
	Test	8.8591	0.6611	82.1230

9	Apprentissage	6.5214	0.7849	89.2647
	Validation	6.9334	0.5743	76.1874
	Test	6.6450	0.7458	86.7120
10	Apprentissage	8.5774	0.7171	84.8318
	Validation	7.3273	0.5501	75.1828
	Test	8.2025	0.6862	82.8597
11	Apprentissage	8.7242	0.7122	85.1527
	Validation	6.4881	0.6016	77.5809
	Test	8.0537	0.6919	83.6410
12	Apprentissage	11.8326	0.6097	78.7321
	Validation	6.9717	0.5719	75.8377
	Test	10.3749	0.6031	78.1993
13	Apprentissage	9.9799	0.6708	82.6072
	Validation	7.4623	0.5418	73.7394
	Test	9.2250	0.6471	80.8164
14	Apprentissage	12.3357	0.5931	79.6151
	Validation	6.7852	0.5834	77.2907
	Test	10.6712	0.5918	79.1062
15	Apprentissage	9.1939	0.6967	83.7553
	Validation	6.7246	0.5871	77.6089
	Test	8.4534	0.6766	82.5631
16	Apprentissage	9.1453	0.6983	84.0369
	Validation	7.3761	0.5471	74.1480
	Test	8.6148	0.6705	82.1112
17	Apprentissage	12.2385	0.5963	77.2910
	Validation	6.8854	0.5772	76.7705

	Test	10.6332	0.5932	77.1208
18	Apprentissage	8.4606	0.7209	85.0147
	Validation	6.7411	0.5861	76.8539
	Test	7.9450	0.6961	83.4875
PSO	Apprentissage	4.2542	0.8597	92.7244
	Validation	5.8287	0.6421	80.1542
	Test	4.7264	0.8192	90.5114

La comparaison entre les caractéristiques des débits observées et simulées par le modèle de RNA pour les différentes combinaisons de vecteurs d'entrées proposées et le modèle hybride RNA-PSO dans les phases d'apprentissage, validation et test, sont résumés dans le tableau(4.3).

Tableau 4. 2:Les paramètres caractéristiques statistiques des débits observés et simulés par RNA.

Modèle	Phase	Débit	Moyenne	Ecat-type	CV	Min	Max
1	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4503	5.1659	3.5620	0.0070	92.3108
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	0.9870	3.4134	3.4584	0.0067	41.5783
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.3113	4.7134	3.5943	0.0069	92.3108
2	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6609	4.1969	2.5270	0.0052	46.1905
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.2563	3.4458	2.7428	0.0024	36.1828
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.5395	3.9902	2.5918	0.0024	46.1905
3	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.3664	3.7012	2.7087	0.0019	44.4502
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0297	3.1609	3.0698	0.0019	32.5325
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.2654	3.5506	2.8058	0.0019	44.4502
4	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.3858	4.0220	2.9023	0.0019	46.5399
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0480	3.3750	3.2205	0.0095	33.6275
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.2845	3.8419	2.9910	0.0019	46.5399

5	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5851	4.2050	2.6528	0.0161	43.5776
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1550	3.2810	2.8407	0.0257	31.2114
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.4561	3.9549	2.7160	0.0161	43.5776
6	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4961	3.9636	2.6493	0.0022	38.9721
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1531	3.1734	2.7521	0.0025	25.4456
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.3932	3.7468	2.6893	0.0022	38.9721
7	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4099	4.0641	2.8827	0.0007	56.7998
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0186	3.1405	3.0832	0.0022	31.2781
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.2925	3.8143	2.9511	0.0007	56.7998
8	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.3706	3.8758	2.8278	0.0011	36.9327
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	0.9347	2.9123	3.1157	0.0062	28.6645
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.2399	3.6189	2.9187	0.0011	36.9327
	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6298	4.3393	2.6624	0.0043	57.8742

9	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.2288	3.3512	2.7273	0.0034	33.0730
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.5096	4.0717	2.6973	0.0034	57.8742
10	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5325	4.4029	2.8731	0.0002	54.3256
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1045	3.5322	3.1979	0.0041	31.5776
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.4041	4.1649	2.9662	0.0002	54.3256
11	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4581	4.0653	2.7880	0.0005	36.9133
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0524	3.1981	3.0390	0.0001	30.3256
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.3364	3.8298	2.8657	0.0001	36.9133
12	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6334	3.8086	2.3317	0.0025	28.2684
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1623	2.8528	2.4544	0.0014	25.9968
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.4921	3.5551	2.3826	0.0014	28.2684
13	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5162	3.9598	2.6116	0.0013	33.6824
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1125	3.1516	2.8330	0.0001	28.9369

	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.3951	3.7398	2.6806	0.0001	33.6824
14	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4352	3.2735	2.2809	0.0004	25.9164
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0362	2.6440	2.5515	0.0044	24.2519
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.3155	3.1031	2.3588	0.0004	25.9164
15	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.8381	4.5739	2.4883	0.0020	37.4991
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.3752	3.5270	2.5648	0.0041	34.5985
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.6993	4.2914	2.5254	0.0020	37.4991
16	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5357	4.1456	2.6995	0.0015	40.3363
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0993	3.2025	2.9133	0.0019	27.0685
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.4048	3.8914	2.7700	0.0015	40.3363
17	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6407	4.2527	2.5920	0.0001	33.8431
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.2050	3.5241	2.9246	0.0015	31.7129
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.5100	4.0522	2.6835	0.0001	33.8431

18	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6478	4.5406	2.7556	0.0001	43.8629
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1354	3.3687	2.9668	0.0004	31.2409
	Test	Observée	1.3431	5.1139	3.8074	0	91.9000
		Simulée	1.4942	4.2293	2.8306	0.0001	43.8629
PSO	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5122	5.0854	3.3630	0.0016	91.5696
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0401	3.3101	3.1825	0.0004	28.2176
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3706	4.6295	3.3777	0.0004	91.5696

Les figures (Figure 4.3-21) offrent la comparaison entre les débits observés et les débits simulés par RNA pour les différentes combinaisons optimales de vecteurs d'entrées proposées et le modèle hybride RNA-PSO dans les phases d'apprentissage et validation.

Modèle 01




Figure 4. 4: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 1 dans les phases d'apprentissage et validation.

Modèle 02




Figure 4. 5: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 2 dans les phases d'apprentissage et validation.

Modèle 03




Figure 4. 6: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 3 dans les phases d'apprentissage et validation.

Modèle 04




Figure 4. 7: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 4 dans les phases d'apprentissage et validation.

Modèle 05




Figure 4. 8: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 5 dans les phases d'apprentissage et validation.

Modèle 06




Figure 4. 9: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 6 dans les phases d'apprentissage et validation.

Modèle 07




Figure 4. 10: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 7 dans les phases d'apprentissage et validation.

Modèle 08




Figure 4. 11: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 8 dans les phases d'apprentissage et validation.

Modèle 09




Figure 4. 12: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 9 dans les phases d'apprentissage et validation.

Modèle 10




Figure 4. 13: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 10 dans les phases d'apprentissage et validation.

Modèle 11




Figure 4. 14: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 11 dans les phases d'apprentissage et validation.

Modèle 12




Figure 4. 15: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 12 dans les phases d'apprentissage et validation.

Modèle 13




Figure 4. 16: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 13 dans les phases d'apprentissage et validation.

Modèle 14




Figure 4. 17: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 14 dans les phases d'apprentissage et validation.

Modèle 15




Figure 4. 18: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 15 dans les phases d'apprentissage et validation.

Modèle 16




Figure 4. 19: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 16 dans les phases d'apprentissage et validation.

Modèle 17




Figure 4. 20: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 17 dans les phases d'apprentissage et validation.

Modèle 18




Figure 4. 21: Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 18 dans les phases d'apprentissage et validation.




Figure 4. 22: Comparaison entre les débits observés et les débits simulés par RNA-PSO dans les phases d'apprentissage et validation.

Conclusion Générale

CONCLUSION GENERALE

Ce travail a permis de développer une approche de modélisation hydrologique basée sur les **réseaux de neurones artificiels (RNA)**, enrichie par l'**algorithme d'optimisation par essaim de particules (PSO)**, dans le but d'améliorer la prévision des débits journaliers dans un bassin versant naturel. À travers une démarche progressive, nous avons d'abord établi les fondements théoriques liés à l'hydrologie et aux systèmes neuronaux, avant d'appliquer ces concepts à un cas concret : le **bassin versant de l'oued El Hachem**, situé dans la wilaya de Tipaza.

L'expérimentation de différentes architectures de RNA, en fonction de la combinaison des variables d'entrée, a permis d'identifier les modèles les plus performants selon des critères statistiques objectifs (ASE, coefficient d'efficacité de Nash-Sutcliffe et coefficient de corrélation). Les résultats ont démontré la capacité des RNA à modéliser efficacement le comportement hydrologique du bassin, avec des performances accrues grâce à l'intégration du PSO, qui a contribué à une meilleure optimisation des poids et biais du réseau.

L'approche hybride **RNA-PSO** s'est avérée robuste, stable et précise, offrant une solution prometteuse pour les problématiques de prévision en hydrologie. Elle pourrait être étendue à d'autres bassins et contextes, avec une perspective d'intégration dans des systèmes d'aide à la décision pour la gestion proactive des ressources en eau.

En perspective, des pistes d'amélioration peuvent être envisagées, notamment en explorant d'autres algorithmes d'optimisation ou en intégrant des données supplémentaires (comme l'humidité des sols ou l'occupation du sol), afin d'accroître encore la précision et la généralisation des modèles.

Références bibliographiques

REFERENCE

- [1] : https://www.actu-environnement.com/ae/dictionnaire_environnement/definition/hydrologie.php4
- [2] : <https://www.britannica.com/science/hydrology/images>
- [3] : <https://coursgeologie.com/cycle-et-bilan-hydrologique-290/>
- [4] : <https://www.u-picardie.fr/beauchamp/cours.qge/du-7.htm>
- [5] : TOUZET, Claude. Les réseaux de neurones artificiels, introduction au connexionnisme. Ec2, 1992.
- [6] : DOUALI, L., SCHMITZER, A. R., VILLEMIN, D., *et al.* Neural Networks and their applications in chemistry and biology Réseaux de neurones artificiels et leurs applications en chimie-biologie.
- [7] : WIRA, Patrice. Réseaux de neurones artificiels: architectures et applications. *Cours en ligne, Université de Haute-Alsace*, 2009.
- [8] : Abda, Z., Zerouali, B., Elbeltagi, A., Chettih, M., Guimarães Santos, C. A., & Farias, C. A.S. D. (2022). Assessing machine learning models for streamflow estimation: A case study in Oued Sebaou watershed (Northern Algeria). *Hydrological Sciences Journal*, (just-accepted).
- [9] : Youcef Djeriri 2017 Les Réseaux de Neurones Artificiels University of Sidi-Bel-Abbes
- [10] : ZENATI, Mouiz. Modélisation de la relation pluie-débit par les réseaux de neurones artificiels pour la prévision des débits. 2023.
- [11]: Kohonen, T, (1984): Self-Organization and Associative Memory, Berlin: Springer-Verlag.
- [12] : ZAKHROUF Mousaab , Modélisation pluie-débit a l'aide des systèmes d'inférence neuro-flous adaptatifs de quelques bassins versants représentatifs d'ALGERIE, Mémoire de Magister, Université Ammar Telidji - Laghouat
- [13] : www.gerbeaud.com Le 1er mars 2018 par Clémentine Desfemmes
- [14] : Bouziane, H., Messabih, B., & Chouarfia, A. (2008). Prédiction de la structure 2D des protéines par les réseaux de neurones. *Communications of the IBIMA*, 6, 201-207.
- [15] : Dahou, S. O., & Berrakem, F. Z. (2024). *Détection des rumeurs dans les réseaux publics* (Doctoral dissertation).

- [16] : Dahou, S. O., & Berrakem, F. Z. (2024). *Détection des rumeurs dans les réseaux publics* (Doctoral dissertation).
- [17] : Touzet, Claude. Les réseaux de neurones artificiels, introduction au connexionnisme. Ec2, 1992.
- [18]: T. Kohonen, "Self-Organization and Associative Memory", Springer Verlag, New York (1984).
- [19]: J. Zupan, J. Gasteiger, "Neural Networks for Chemists", VCH-Wiley, Weinheim (1993).
- [20]: E. Masson, Y. Wang, Eu. J. Oper. Res., 47 (1990) 1-28
- [21]: P. Aguilera, A. Frenich, J. Torres, H. Castro, J. Vidal, M. Canton, Water Res., 35 (2001) 4053-4062
- [22]: Y. Cai, Y. Li, K. Chou, Advances in Engineering Software, 30 (1999) 347-352.
- [23]: Douali, L., et al. "Neural Networks and their applications in chemistry and biology Réseaux de neurones artificiels et leurs applications en chimie-biologie."
- [24]: Freitas, Diogo, Luiz Guerreiro Lopes, and Fernando Morgado-Dias. "Particle swarm optimisation: a historical review up to the current developments." *Entropy* 22.3 (2020): 362.
- [25]: AL-SMADI, Yazan, ESHTAY, Mohammed, AL-QEREM, Ahmad, *et al.* Reliable prediction of software defects using Shapley interpretable machine learning models. *Egyptian Informatics Journal*, 2023, vol. 24, no 3, p. 100386.
- [26]: BONYADI, Mohammad Reza et MICHALEWICZ, Zbigniew. Particle swarm optimization for single objective continuous space problems: a review. *Evolutionary computation*, 2017, vol. 25, no 1, p. 1-54.
- [27]: Yonaba, Harouna, (2009) : Modélisation Hydrologique Hybride Réseau De Neurones - Modèle Conceptuel. Thèse Doctor (Ph.D) université laval québec. 97p
- [28]: Mekkour, A., & Takourabt, K. (2024). *Le Bassin de l'Oued el Hachem: caractérisation hydrologique et hydroclimatologique (W. Tipaza)* (Doctoral dissertation, Université Mouloud Mammeri).
- [29]: M. Belmadani Djalel et M. Harbouche Abd el Hamid, Caractérisation des crues dans le bassin versant de Oued El Hachem pour la gestion du barrage de Boukerdane en situation d'évènements extrêmes, Memoire de master , Université Saad Dahleb – Blida
- [30]: Étude hydrologique et hydrogéologique de la plaine de l'Oued El Hachem.

- [31]: Kennedy, J., & Eberhart, R. (1995, November). Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks* (Vol. 4, pp. 1942-1948). ieee.
- [32]: Remini, B., & Mokeddem, F. Z. (2018). Boukourdane (Algeria): a reservoir dam with low siltation rate. *LARHYSS Journal P-ISSN 1112-3680/E-ISSN 2521-9782*, (35), 29-44.
- [33]: Le transport solide dans l'oued el- Hachem et l'impact des lâchers du barrage Boukourdane sur l'hydraulique de l'oued et la nappe.
- [34]: Envasement des barrages dans les régions arides Exemples Algériens. *Larhyss Journal*, ISSN 1112-3680, n°27, Sept, pp. 63-90.
- [35]: Studying Sediment. *Revue International Water Power et Dam construction*. Octobre, pp. 42-45.
- [36] : Nguimalet, C. (2017). Changements enregistrés sur les extrêmes hydrologiques de l'Oubangui à Bangui (République centrafricaine) : analyse des tendances. *Revue des sciences de l'eau/Journal of Water Science*, 30(3), 183-196.
- [37] : www.gerbeaud.com Le 1er mars 2018 par Clémentine Desfemmes
- [38] : Ourad, Youcef. *Dimensionnement du réseau d'irrigation du périmètre d'Oued el Hachem (w. Tipaza) à partir du barrage Boukerdene*. Diss. 2014.