

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 8 Mai 1945 GUELMA

Faculté des Sciences et de la Technologie

Département de : Génie Civil & Hydraulique

Spécialité : Hydraulique

Option : HYDRAULIQUE URBAINE

Présenté par : Zenati Mouiz

**Thème : Modélisation de la relation pluie-débit
par les réseaux de neurones artificiels pour la
prévision des débits.**

Sous la Direction de : Dr Abda Zaki

Juin 2023

Remerciement

Après de longs efforts, ce modeste travail est enfin achevé. Nous tenons à exprimer notre profonde gratitude envers tous ceux qui ont soutenu ce mémoire tout au long de son parcours. La contribution de certains a été décisive pour le succès de ce travail, que nous sommes heureux de présenter avec une reconnaissance particulière :

Nous remercions sincèrement Dieu tout-puissant de nous avoir accordé le courage et la patience nécessaires pour mener à bien cette tâche.

En premier lieu, nous souhaitons exprimer notre profonde gratitude et notre plus grand respect envers notre promoteur, M. Zaki Abda, pour la clarté de ses enseignements, son soutien infaillible et sa patience inébranlable qui ont permis la réalisation de cette mémoire. Nous adressons également nos sincères remerciements aux membres du jury d'avoir accepté d'évaluer notre travail.

Nous remercions les enseignants du département d'hydraulique qui ont partagé leur savoir.

Un grand merci à l'ensemble du personnel de la détection des ressources en eau de Guelma.

Enfin, nous exprimons notre sincère reconnaissance à toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail.

Dédicace

Je souhaite dédier ce travail à mes précieux parents, dont aucune dédicace ne peut suffire à exprimer l'immense reconnaissance que je ressens à votre égard. Vous méritez toute ma gratitude pour les innombrables sacrifices que vous avez consentis depuis ma naissance, tout au long de mon enfance et jusqu'à mon âge adulte.

J'adresse également cette dédicace à tous la famille Zenati et Medjeldi et plus particulièrement à mes grands-parents, pour leur soutien inconditionnel.

Mes amis jouent un rôle essentiel dans ma vie, et je souhaite les inclure dans cette dédicace spéciale. À Hichem, Heytem, Walid, Badri, Raouf, Sasi, Iheb, Aymen, Rami et Islem, je vous suis reconnaissant pour votre amitié sincère.

Enfin, je tiens à dédier ce travail à toute la promotion de l'hydraulique 2022/2023. Votre engagement et votre dévouement ont contribué à rendre cette expérience éducative exceptionnelle.

Sincèrement,

Mouiz

Résumé

Les modèles hydrologiques simulent la transformation des précipitations en écoulements dans les bassins versants naturels et ont de nombreuses applications pratiques dans la gestion des ressources en eau. Ce travail consiste à modéliser de la transformation des précipitations en écoulements à l'aide d'un modèle de réseaux neuronaux artificiels appliqué aux bassins versants de la région d'Oued Hachem à Tipaza. Nous avons présenté une vue d'ensemble de l'hydrologie, puis décrit le modèle de réseaux neuronaux artificiels et son application au bassin versant d'Oued Hachem, et on a vérifié l'efficacité du modèle pour la prévision des débits journalières.

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

Abstract

Hydrological models simulate the transformation of precipitation into runoff in natural watersheds and have many practical applications in water resource management. This work consists of modeling the transformation of precipitation into runoff using an artificial neural network model applied to the watersheds of the region of Oued Hachem in Tipaza. We presented an overview of hydrology, and then described the artificial neural network model and its application to the Oued Hachem watershed, and we verified the effectiveness of the model for forecasting daily flow rates.

Keywords: modeling; rainfall-runoff; RNA; prediction; flow.

ملخص

النماذج الهيدرولوجية تحاكي تحويل هطول الأمطار إلى جريان في مستجمعات المياه الطبيعية ولها العديد من التطبيقات العملية في إدارة الموارد المائية. يتكون هذا العمل من نمذجة تحويل هطول الأمطار إلى جريان باستخدام نموذج شبكة عصبية اصطناعية مطبق على مستجمعات المياه في منطقة واد هاشم في تيبازة. قدمنا لمحة عامة عن الهيدرولوجيا، ثم وصفنا نموذج الشبكة العصبية الاصطناعية وتطبيقه على مستجمع مياه واد هاشم، وتحققنا من فعالية النموذج في التنبؤ بالتدفقات اليومية.

كلمات مفتاحية: النمذجة؛ تدفق الأمطار؛ المشبك العصبي الاصطناعي؛ التنبؤ؛ التدفق.

Sommaire

Liste des figures

Liste des tableaux

Liste des abréviations

Introduction générale.....	1
Chapitre I : Synthèse Bibliographique.....	3
I.1. Introduction	3
I.2. Définition de l'hydrologie	3
I.3. Le bassin versant.....	4
I.4. Le Bilan hydrologique.....	4
I.5. Le cycle de l'eau	6
I.5.1 L'évaporation	6
I.5.2 La transpiration.....	6
I.5.3 La condensation	6
I.5.4 Les précipitations	7
I.5.5 Le ruissellement	7
I.5.6 L'infiltration	7
I.5.7 La circulation souterraine	8
I.6 Les extrêmes hydrologiques	9
I.6.1 la sécheresse	9
a. La sécheresse météorologique	9
b. La sécheresse agricole ou sécheresse des sols	10
c. La sécheresse hydrologique	10
I.6.2 Crues et inondation	10

Chapitre II : Réseaux de neurones artificiels.....	13
II.1 Introduction	13
II.2 Le neurone Biologique	13
II.3 Neurones artificiels	14
II.4 Fonctions d'activation	17
II.5 Apprentissage de RNA	20
II.6 Méthodes d'optimisation	22
II.6.1 Méthode de Newton	22
II.6.2 Méthode de Gauss-Newton	23
II.6.3 Méthode de descente de gradient	23
II.6.4 Méthode de Levenberg-Marquardt	23
II.7 Réseaux de neurones	24
II.7.1 Perceptron multi-couche	24
II.7.2 Réseau à connexions récurrentes	25
II.7.3 Réseau à connexion complète	26
II.7.4 Réseau de Kohonen	26
II.8 Problème de surajustement	26
II.9 Méthodes pour limiter le surajustement	27
Chapitre III : Zone d'étude et description des données.....	29
III.1 Introduction.....	29
III.2 Situation géographique.....	29
III.3 Le barrage.....	30
III.4 Géomorphologie et physiographie du milieu étudié.....	31
III.5 Coefficient de compacité	31
III.6 Hydrographie	32
III.7 Les caractéristiques	32
III.8 Climatologie.....	33
III.9 Température.....	33
III.10 Humidité relative.....	33
III.11 Les vents	33

III.12 Bassin d'Oued Hachem	34
Chapitre IV : Résultats et Discussion	37
IV.1 Développement des modèles	37
IV.2 Choix des Critères de performance	39
IV.3 Résultats et discussions	40
Conclusion	61

Liste des figures

Figure I.1 : Cycle de l'eau et les phénomènes naturels.....	3
Figure I.2 : Les composantes d'un bassin versant.....	4
Figure I.3 : Le bilan hydrologique	5
Figure I.4 : Quelques inondations dans l'Algérie.....	12
Figure.II.1 : Les éléments constituant le neurone biologique.....	14
Figure. II.2 : Un modèle mathématique d'un neurone formel.....	15
Figure II.3. : Un perceptron multicouche (PMC).....	17
FigureII.4 : La fonction de transfert "seuil" (a), "linéaire" (b) et "sigmoïde" (c).....	18
Figure II.5 : Classification des réseaux de neurones suivant leur apprentissage.....	21
Figure.II.6 : Schéma représentant le mécanisme d'un superviseur dans le cad'Apprentissage supervisé de perceptron multi couche.....	22
Figure II.7 : Structures des réseaux de neurone de type perceptron. (a)Perceptron mono couche et (b) le perceptron multi-couche à deux couches cachées.....	25
Figure.II.8 : Exemple d'un réseau à connexions récurrentes.....	25
FigureII.9 : Exemple d'un réseau à connexion complète.....	26
Figure.II.10 : Exemple d'un réseau de Kohonen.....	26
FigureII.11 : Schéma qui représente l'évolution de l'erreur d'apprentissage et de validation d'un RNA en fonction de nombre d'itération.....	28
Figure III.1 : Carte de situation de la zone d'étude et le bassin versant	30
Figure III.2 : Les limites du bassin versant à l'amont du barrage de Boukourdane	31
FigIII.3 : Bassin d'Oued Hachem	35
FigIII.4 : Les séries des pluies cumulés journalières et les débits moyens journaliers mesurés à la période 1983-1989 dans le bassin d'Oued Hachem.....	35
FigIII.5 : Corrélogramme des pluies et débits du bassin Oued Hachem.	36
FigIII.6 : Le spectre de densité de variance des pluies et débits du bassin Oued Hachem.....	36

Figure IV.1 Organigramme expliquant le développement des RNA	39
Figure IV.2 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 1.	41
Figure IV.3 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 2.....	42
Figure IV.4 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 3.....	42
Figure IV.5 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 4.....	43
Figure IV.6 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 5.	43
Figure IV.7 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 6.....	44
Figure IV.8 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 7.....	44
Figure IV.9 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 8.....	45
Figure IV.10 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 9.....	45
Figure IV.11 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 10.....	46
Figure IV.12 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 11.....	46
Figure IV.13 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 12.....	47
Figure IV.14 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 13.	47
Figure IV.15 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 14.....	48
Figure IV.16 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 15.	48
Figure. IV.17 : 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.	52
Figure IV.18 : 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.....	52
Figure.IV.19 : 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.....	53
FigureIV.20 : 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	53

Figure IV.21. : 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	54
Figure IV.22 : 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.....	54
Figure IV.23 : 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	55
Figure IV.24 : 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.....	55
Figure.IV.25 : 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	56
Figure IV.26 : 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	56
Figure IV.27 : 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.....	57
Figure IV.28 : 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	57
Figure IV.29 : 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	58
Figure IV.30 : 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	58
Figure IV.31 : 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	59

Liste des tableaux

Tableau II.1 - Différentes fonctions d'activations utilisées dans les RNA	19
Tableau III.1 : Principales caractéristiques du bassin versant	32
Tableau III.2 : Température moyenne interannuelles en °C	33
Tableau III.3 : Les caractéristiques statistiques des pluies et débits pour le bassin d'Oued Hachem	34
Tableau IV.1 Les structures des modèles ont été développés avec les vecteurs d'entrée pour estimer le débit prévu avec RNA.	38
Tableau IV.2 : Résultats statistiques du modèle RNA dans les phases d'apprentissage, validation et test.	49
Tableau IV.3 Les paramètres caractéristiques statistiques des débits observés et simulés par RNA	50
Tableau IV.4 Comparaison entre les résultats obtenus par RNA par rapport à RLM sur la phase de test.....	59

Liste des abréviations

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

Q_{t_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.

Introduction générale

Les bassins versants sont des systèmes complexes en raison des nombreux processus qui s'y déroulent. Ainsi, la simulation des débits à l'exutoire d'un bassin versant est essentielle pour de nombreuses applications en ingénierie et en gestion des ressources en eau, telles que la conception et la gestion d'ouvrages, la prévision des crues ou des étiages, la détection des impacts, etc.

Pour comprendre le fonctionnement du bassin et le rôle des processus impliqués, une approche dynamique est nécessaire. Une méthode courante consiste à remonter jusqu'à la cause première des débits, à savoir les précipitations, pour construire des modèles permettant de représenter de manière simplifiée et facilement utilisable la relation entre les pluies et les débits.

Comme de nombreuses autres disciplines étudiant les systèmes naturels, l'hydrologie continentale et la modélisation pluie-débit sont confrontées à la difficulté d'appréhender la complexité intrinsèque des systèmes étudiés. Les modèles pluie-débit ont commencé à émerger dans les années 1960, mais leur développement a été limité par cette complexité.

Malgré les nombreuses recherches qui ont été effectuées à leur sujet, les modèles sont encore difficiles à utiliser avec certitude. Cependant, dans le monde réel, les variations temporelles des données ne suivent pas de régularités simples et sont ardues à analyser et à prédire avec exactitude. La conversion des précipitations en ruissellement dans les bassins versants est un phénomène hydrologique complexe qui présente des caractéristiques fortement non linéaires, variables dans le temps et distribuées géographiquement [1].

Au cours des années récentes, les outils de modélisation et les techniques d'intelligence artificielle ont été largement adoptés dans différents secteurs de l'hydrologie. Cette tendance a été corroborée par diverses études [2, 3, 4, 5, 6, 7].

Pour notre étude, nous avons choisi d'appliquer un modèle conceptuel basé sur un réseau de neurones artificiels (RNA) pour simuler les prévisions des débits journalières du bassin Oued Hachem qu'est situé dans le côtier Algérois (02 a) à région de Tipaza.

L'objectif de cette mémoire est de déterminer les paramètres optimaux du modèle afin d'améliorer la précision de la simulation des débits, ce qui est essentiel pour la prévision. Pour atteindre cet objectif, la recherche est organisée en quatre chapitres :

Le premier chapitre vise à présenter quelques notions fondamentales sur le climat, en mettant particulièrement l'accent sur la circulation atmosphérique et les indices climatiques de circulation.

Le deuxième chapitre de notre mémoire, nous présentons une formulation mathématique concise de l'algorithme de réseaux de neurones artificiels. Cette méthode a été appliquée tout au long de notre recherche afin de modéliser la relation pluie-débit et d'obtenir des prévisions optimales des débits journalières.

Le troisième chapitre, nous avons abordé une présentation détaillée des caractéristiques géographiques, morphologiques, géologiques et hydrogéologiques du bassin versant de l'oued Hachem. De plus, nous avons également fourni une description des données hydro-climatiques utilisées dans notre étude.

Le quatrième chapitre, nous avons consacré notre discussion aux résultats obtenus en appliquant les réseaux de neurones artificiels pour les 15 différents modèles des vecteurs d'entrée proposés. L'objectif était d'optimiser et de sélectionner la meilleure structure de réseau de neurones qui nous a données les prévisions optimales des débits journalières dans le bassin versant d'oued Hachem.

Chapitre I : Synthèse Bibliographique

I.1. Introduction

Ce chapitre a pour objectif de présenter quelques concepts fondamentaux du climat, de la météo et de la circulation atmosphérique, en se concentrant spécifiquement sur les différentes composantes du cycle hydrologique, en mettant l'accent sur les précipitations.

I.2. Définition de l'hydrologie

L'hydrologie est un domaine scientifique qui se consacre à l'analyse des eaux de notre planète, en étudiant leur provenance, leur circulation, leur distribution, leurs caractéristiques physiques et chimiques, leurs interactions avec l'environnement naturel et biologique, ainsi que leur impact sur les activités humaines.

Le cycle hydrologique est un ensemble de processus de transformation de l'eau. En effet, une infime partie de l'eau de la troposphère parvient à atteindre la stratosphère, où la radiation solaire sépare la molécule d'eau et l'hydrogène léger s'évapore dans l'espace extra-atmosphérique. De la même manière, une quantité minimale d'eau émise lors des éruptions volcaniques parvient à s'élever dans l'atmosphère, mais cela peut être considéré comme insignifiant [8].

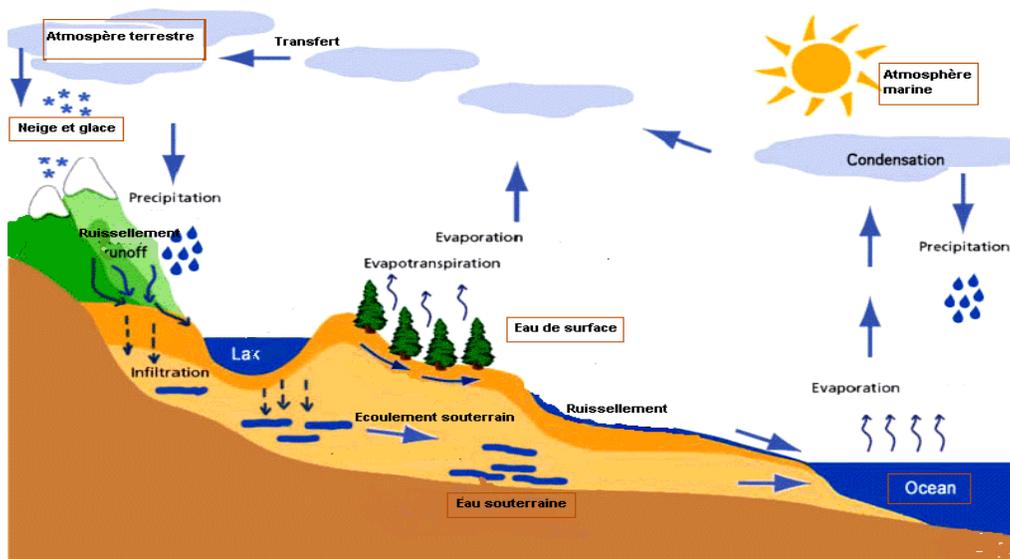


Figure I.1 : Cycle de l'eau et les phénomènes naturels [9]

I.3. Le bassin versant

Le bassin versant est considéré comme l'unité spatiale fondamentale en hydrologie, représentant la zone drainée par un cours d'eau et ses affluents, délimitée par une ligne de partage des eaux. Bien que cette définition semble simple, la notion de bassin versant est en réalité beaucoup plus complexe. En effet, en tant qu'unité géographique clé pour l'étude du cycle hydrologique, sa définition doit être précise et sans ambiguïté. De plus, la compréhension du bassin versant va au-delà de sa définition stricte et peut être interprétée de différentes manières. Ce qui ajoute une couche de complexité supplémentaire [10].

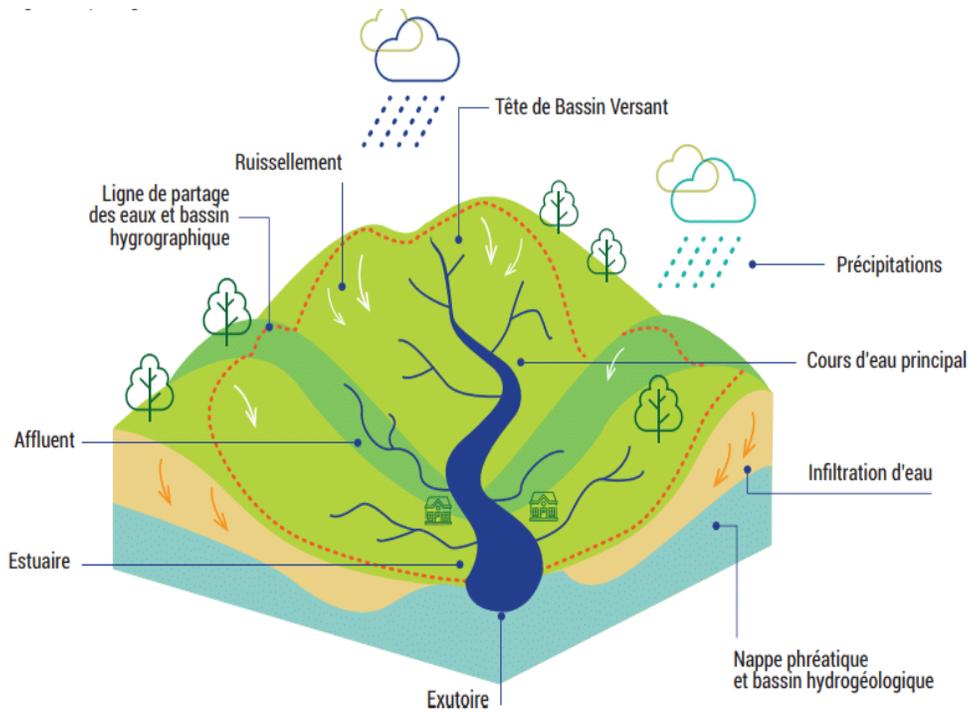


Figure I.2 : Les composantes d'un bassin versant [11]

I.4. Le Bilan hydrologique

Le bilan hydrologique désigne la répartition des différents volumes d'eau compris dans chacune des parties du cycle de l'eau, pour une période et un bassin donné. On parle aussi de bilan hydrique. Le bilan hydrologique annuel calculer par : $ETR = (R / RU) * ETP$. Calculer réserve R fin de mois

= réserve début mois + P – ETR (plafonner R à RU). Calculer déficit agronomique = ET – ETR.
 Calculer excédent hydrique = P – ETR – (RU – R début de mois) (Fig. I. 3). Vue schématique du bilan hydrique à trois échelles interdépendantes, le bassin hydrologique ou bassin versant, le bassin hydrogéologique et à l'échelle de l'aquifère [12].

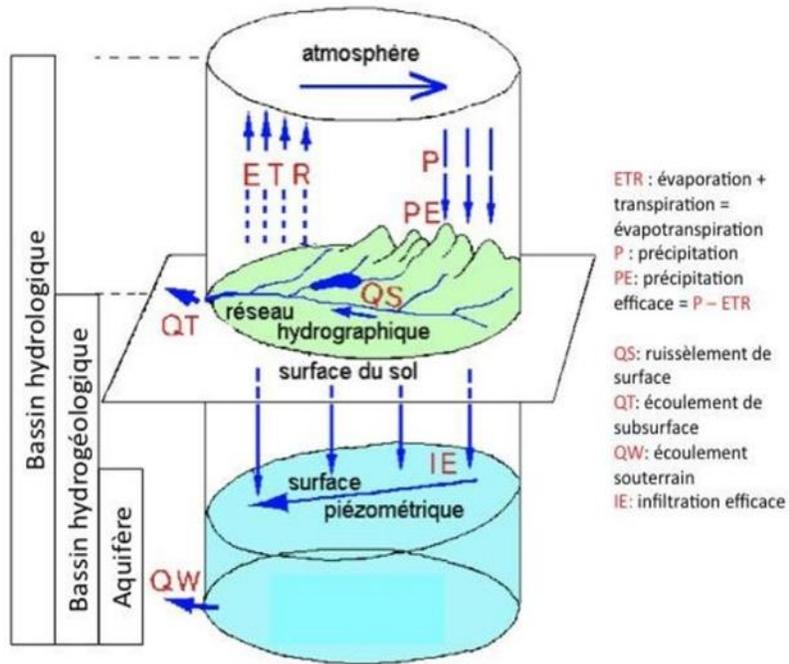


Figure I.3 : Le bilan hydrique [13]

I.5. Le cycle de l'eau

Également appelé cycle hydrologique, est un processus naturel qui décrit la circulation de l'eau sur la Terre. Il comprend plusieurs étapes clés (United States Geological Survey (USGS)), qui sont les suivantes [14] :

- L'évaporation
- La transpiration
- La condensation
- Les précipitations
- Le ruissellement
- L'infiltration
- La circulation souterraine

I.5.1 L'évaporation

La première étape du cycle de l'eau est l'évaporation, qui consiste en la transformation de l'eau de l'état liquide à l'état gazeux. Ce processus se produit principalement dans les océans grâce à la chaleur du soleil et aux gaz présents dans l'atmosphère. Le vent favorise également la dispersion de la vapeur d'eau. De plus, la présence de cours d'eau multiples contribue également à l'évaporation de l'eau [14].

I.5.2 La transpiration

De manière similaire à la transpiration qui s'échappe du corps humain et des animaux, l'eau circulant à travers les végétaux passe de l'état gazeux à l'état d'évaporation. Dans le cas des végétaux, cela est appelé évapotranspiration. En effet, les racines des plantes absorbent l'eau du sol avant de la libérer partiellement dans l'atmosphère [14].

I.5.3 La condensation

L'étape de condensation est le processus au cours duquel la vapeur d'eau, sous forme gazeuse, se transforme en nuages. Cependant, la condensation ne se produit pas seulement dans le ciel, elle se produit également au niveau du sol. Par exemple, lors des journées ensoleillées, la rosée se forme sous la forme de petites gouttelettes d'eau sur les plantes, tandis qu'en hiver, le givre se forme. Un autre exemple courant de condensation se produit dans nos salles de bains, après une douche

chaude, lorsque notre miroir se couvre de buée. Cela est dû au refroidissement de la vapeur d'eau au contact du miroir, ce qui provoque cet effet de condensation [14].

I.5.4 Les précipitations

Après la condensation, les précipitations se produisent généralement sous forme de pluie, terme que nous utilisons le plus fréquemment. Ces précipitations surviennent lorsque les minuscules gouttelettes d'eau présentes dans les nuages deviennent trop lourdes et s'en échappent sous forme de gouttes, de flocons de neige ou de grêlons, selon les conditions météorologiques [14].

I.5.5 Le ruissellement

La prochaine étape du cycle de l'eau est le processus de ruissellement. Lorsqu'il pleut, la majeure partie de l'eau provenant des nuages tombe sur les océans et les mers, ce qui marque la fin du cycle de l'eau à ce stade. Quant à l'eau qui atteint la terre, elle peut être absorbée par les plantes ou s'écouler à travers les roches. Par la suite, elle finit par rejoindre un cours d'eau tel qu'un ruisseau, une rivière, un lac ou un fleuve, et finalement atteindre l'océan ou la mer, donnant ainsi le coup d'envoi d'un nouveau cycle de l'eau [14].

I.5.6 L'infiltration

Lorsque l'eau pénètre dans le sol, on passe à la phase d'infiltration. En effet, si le sol est poreux (perméable), l'eau peut alors s'infiltrer à l'intérieur du sol. En fonction de l'abondance des précipitations, des cours d'eau souterrains peuvent se former. Par ailleurs, l'infiltration permet aux racines des plantes de pomper l'eau dont elles ont besoin [15].

❖ Paramètres descriptifs de l'infiltration :

- Le régime d'infiltration : (taux d'infiltration) il désigne le flux d'eau pénétrant dans le sol en surface généralement exprimé en mm/h.
- L'infiltration cumulative : C'est le volume total d'eau infiltrée pendant une période donnée. Elle s'exprime en mm.
- La capacité d'infiltration ou capacité d'absorption : qui représente le flux d'eau maximal que le sol est capable d'absorber à travers sa surface, lorsqu'il reçoit une pluie efficace ou est recouvert d'eau. Cette capacité varie durant l'averse.
- La conductivité hydraulique à saturation K_s : il représente la valeur limite du taux d'infiltration

[¹⁵].

❖ **Facteurs influençant l'infiltration :**

- Type de sol (Structure, Texture, Hydrodynamique)
- Couverture du sol (type de végétation)
- Topographie (pente, orientation, morphologie)
- Alimentation (précipitation, irrigation)
- Etat du sol (humidité antécédente, degré de compaction) [¹⁵].

❖ **Le processus d'infiltration il dépend d'une multitude de paramètres qui sont les suivants**

- Le type de sol.
- L'intensité de la pluie.
- La compaction de la surface du sol.
- La couverture du sol.
- La topographie et la morphologie du terrain.
- Le débit d'alimentation (intensité de la pluie ou débit d'irrigation) [¹⁵].

I.5.7 La circulation souterraine

La dernière étape du cycle de l'eau est la circulation souterraine, qui représente le mouvement de l'eau à l'intérieur du sol. Généralement, l'eau qui s'infiltré dans les sols parvient à rejoindre un cours d'eau. Cependant, dans certaines situations où l'eau souterraine s'accumule, une nappe phréatique peut se former. On peut prélever cette eau en utilisant des puits ou des forages, ce qui constitue une source d'eau propre, car elle est naturellement filtrée par les roches [¹⁴].

I.6. Les extrêmes hydrologiques

Les extrêmes hydrologiques sont des phénomènes hydroclimatiques qui se produisent à la fois en Afrique et dans d'autres régions, caractérisés par des contrastes saisonniers et de longueur relative. En d'autres termes, ils représentent des variations cycliques du régime hydrologique au fil du temps [16].

La sécheresse est expliquée par un déficit temporaire des précipitations, qui n'est pas propre au climat de la zone touchée mais qui dure suffisamment longtemps pour causer des dommages. L'aridité, quant à elle, est caractérisée par des précipitations moyennes constamment faibles (moins de 250 mm/an) combinées à une évapotranspiration élevée (plus de 2000 mm). Le manque de pluie est une caractéristique permanente du climat de ces zones, où les précipitations sont rares et les températures élevées.

I.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 [17].

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.

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 [17].

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 [17].

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 [17].

I.6.2 Crues et inondation

Une inondation est caractérisée par la submersion temporaire d'une zone habituellement sèche, causée par des eaux douces ou salées. Ce phénomène peut être régulier ou avoir des conséquences catastrophiques, et peut se produire de manière progressive ou rapide. Il y a deux types d'inondations, en fonction de la source de l'eau : les inondations terrestres qui se produisent à l'intérieur des terres et les inondations marines qui affectent les régions côtières [8].

En raison de sa position dans la zone de transition entre les régimes tempérés et subtropicaux du bassin méditerranéen, l'Algérie est sujette aux changements climatiques et aux catastrophes naturelles [18]. On a révélé que l'Algérie a connu deux périodes de sécheresse depuis 1881 : une première pénurie de 1943 à 1948 ayant eu des conséquences significatives sur les récoltes et

l'élevage, et une seconde durant les années 1980 et 1990. Ce déficit pluviométrique a été estimé à 50 % pour les régions du centre et de l'ouest de l'Algérie, et à 30 % pour la région de l'est [¹⁹], l'année la plus sèche en Algérie a été 1988/89 [²⁰].

De nombreuses inondations ont été marquées sur tout le territoire Algérien (Khoualdia2009) :

Les précipitations exceptionnelles survenues le 28 au 31 mars 1974 sur plusieurs régions du centre ont causés uniquement dans la wilaya de Tizi-Ouzou 52 morts, 4570 maisons détruites, 130 villages isolés et plus de 18000 sinistrés. Les dégâts matériels ont été estimés à l'époque à 27 millions de Dinars, 13 ponts et quelques Kilomètres de route ont été emportés par les crues.

La plus forte crue historique de Oued El Hammam dans le bassin de la MACTA, enregistrée le 27 Novembre 1927(estimé à environ de 5000 m³/s) à amener la rupture totale de l'ancien Barrage Fergoug près de Mascara ;

Oued Rhiou dans l'Ouest algérien le 20 Octobre 1993 : 22 décès et 14 blessés ;

Dix jours d'inondations dans plusieurs régions du pays en Octobre 1994 : 60 décès et des dizaines de disparus ;

Bab El Oued-Alger le 10-11 Novembre 2001 : 733 victimes, 30000 habitants sans abris et importants dégâts matériels ;

Souk-Ahras dans l'Est de l'Algérie, le 22 Août 2002 : 02 décès et dégâts matériels importants ;

Ghardaïa au sud d'Alger le 10 Octobre 2008 : 60 décès, 48 blessés et des dégâts considérables.

El Bayadh au Sud d'Alger le 1er Octobre 2011 : 710 décès, 115 disparus et Dégâts matériels de 30 milliards de DA ;

El Taref à Est de l'Algérie le Février 2012 : 70% de la population de la wilaya touchée et dégâts matériels touchant tous les secteurs

Tindouf à 1744 km au Sud d'Alger le 20-21 septembre 2014 : des dégâts matériels résultat de plus de 40 millimètres de précipitations ont été enregistrées ;

Djelfa et Constantine Août 2015 : 3 décès et des dégâts matériels.

Batna, Tébessa, Constantine, Ouargla, Alger Septembre et Octobre 2018 : 2 décès et des dégâts matériels.

Tipaza et Guelma 25 Mai 2023 : 3 décès et importants dégâts.



Figure I.4 : Quelques inondations dans l'Algérie

Chapitre II : Réseaux de neurones artificiels

II.1 Introduction

Les techniques d'intelligence artificielle sont couramment utilisées dans une grande variété de domaines, tels que la régulation de processus industriels, le traitement d'image, le diagnostic, la médecine, la technologie spatiale et les systèmes de gestion de données informatiques. Les réseaux de neurones artificiels (RNA) sont considérés comme ayant un impact significatif dans le domaine de l'électronique de puissance et de la commande de machines électriques, comme en témoigne le nombre important de publications dans la littérature scientifique. Le RNA est une technique de traitement de données bien comprise et maîtrisée, qui peuvent être intégrées efficacement dans les stratégies de commande. En effet, ils peuvent réaliser des tâches d'identification, de contrôle et de filtrage, améliorant ainsi les techniques classiques de l'automatique non linéaire et offrant des solutions plus robustes et efficaces.

II.2 Le neurone Biologique

Le système nerveux est constitué de cellules spécialisées appelées neurones. Dans le corps humain, il y a environ cent milliards de neurones, qui sont connectés par environ mille billions de synapses. La figure (II.1) présente les éléments de base d'un neurone biologique.

Chaque neurone a trois parties principales : le corps cellulaire, qui effectue les réactions biochimiques nécessaires à la survie du neurone, les dendrites, qui s'étendent autour du corps cellulaire et permettent au neurone de recevoir les signaux provenant d'autres neurones, et l'axone, une fibre nerveuse qui transporte les signaux émis par le neurone vers les synapses où il se ramifie en terminaisons. L'influx nerveux se propage de la dendrite vers le corps cellulaire, puis vers l'axone. Les dendrites reçoivent des signaux excitateurs ou inhibiteurs, qui sont pondérés et combinés dans le corps cellulaire. Si le potentiel résultant dépasse le seuil interne, le neurone émet un train d'impulsions le long de l'axone vers les synapses ; sinon ,il reste inactif [21].

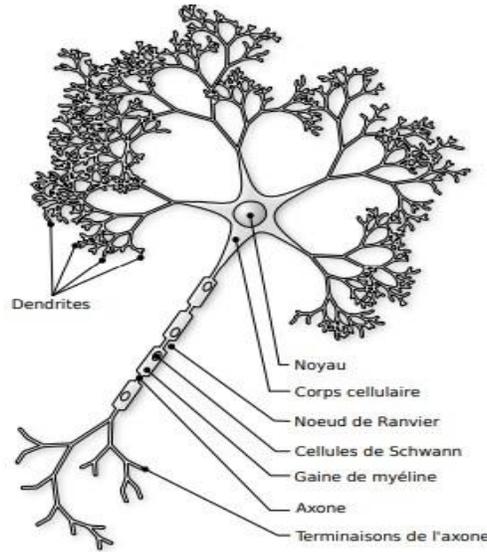


Figure II.1 : Les éléments constituant le neurone biologique [21]

II.3. Neurones artificiels

L'objectif d'un réseau de neurones artificiels est de reproduire le fonctionnement du cerveau humain à travers des neurones artificiels intégrés dans des logiciels. Cette technologie d'intelligence artificielle (IA) permet aux machines de devenir autonomes.

Le "neurone formel" ou simplement "neurone" est une fonction algébrique non linéaire et bornée, dont la valeur de sortie dépend des poids ou coefficients associés à ses entrées. Les variables d'entrée de cette fonction sont communément appelées les "entrées" du neurone.

En premier lieu, un neurone est un opérateur mathématique dont la valeur numérique peut être calculée en quelques lignes de code. Il est communément représenté sous forme graphique [21], comme illustré dans la figure (II.2).

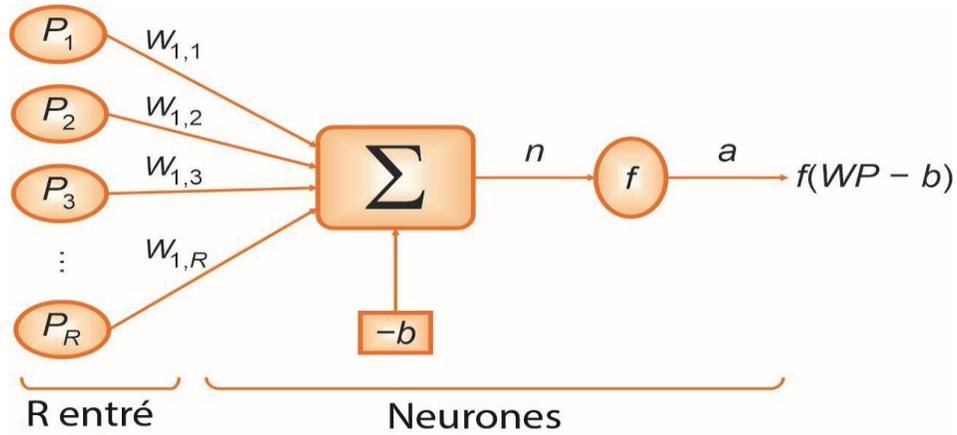


Figure II.2 : Un modèle mathématique d'un neurone formel [22]

La Figure II.2 traite la somme pondérée des prédicteurs d'entrée par une fonction paramétrée et à valeur limitée. L'équation suivante représente la sortie d'un neurone :

$$a = f \left(\sum_{j=1}^R (w_{1j} p_j) - b \right) \quad (\text{II.1})$$

Où w_{1j} est le poids entre le neurone 1 et l'entrée p_j , b est le biais du neurone 1, R est le nombre d'entrées, f est la fonction de transfert, et a est la sortie du neurone.

Largement utilisé pour résoudre des problèmes de prédiction [22], le perceptron multicouche (MLP) était le type de réseau neuronal utilisé pour cette étude. Le MLP est un réseau feedforward composé d'au moins trois couches (entrée, caché et sortie) de neurones ou de nœuds. Chaque neurone envoie des informations en transmettant des signaux d'une couche à la suivante. La figure 2 montre la structure d'un réseau MLP. L'apprentissage est un processus essentiel pour les neurones réseaux. L'algorithme utilise des échantillons d'entrées et de sorties souhaitées dans l'apprentissage supervisé pour ajuster le réseau paramètres (pondérations et biais). L'apprentissage MLP est supervisé et basé sur l'algorithme de rétropropagation, qui améliore les performances du réseau en réduisant l'erreur quadratique de la fonction de perte entre le calcul et

l'observation données [23, 24, 25, 26]. L'équation suivante représente la quadratique fonction de perte pour N échantillons d'apprentissage :

$$\sum_{i=1}^N (c_i - o_i)^2 \quad (\text{II.2})$$

Où c_i et o_i sont les valeurs calculées et observées pour le i ème échantillon d'apprentissage, respectivement.

Lors de la formation des modèles ANN, plusieurs écueils courants dans l'optimisation peuvent être rencontrés, y compris l'instabilité, les minima multiples qui conduisent à une fonction de coût non convexe et le surajustement en raison de la quantité et de la qualité des données utilisées et de la structure du modèle représentée dans le nombre de couches et de nœuds cachés. Si trop de données étaient ajoutées, les performances du modèle se dégraderaient et causeraient du bruit supplémentaire [27]. Dans cette étude, nous avons utilisé la fonction d'activation dans la couche cachée avec des fonctions sigmoïdes non linéaires pour éviter ces problèmes. La méthode d'arrêt précoce a également été utilisée pour éviter le problème de sur apprentissage pendant le processus d'apprentissage [22].

Dans le domaine des réseaux de neurones, il existe divers types qui se distinguent par leur fonction d'activation et la manière dont les neurones sont interconnectés. Parmi ces types, les Perceptrons Multicouches (PMC) sont particulièrement employés dans notre travail. En effet, les PMC sont les réseaux de neurones les plus couramment utilisés, comme l'ont montré plusieurs études [28, 29, 30, 31, 32, 33]. Les PMC sont des réseaux non bouclés qui comportent plusieurs couches : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque couche est constituée de neurones qui propagent des signaux dans une direction allant de la couche d'entrée jusqu'à la couche de sortie, sans qu'il y ait de connexions entre les neurones d'une même couche.

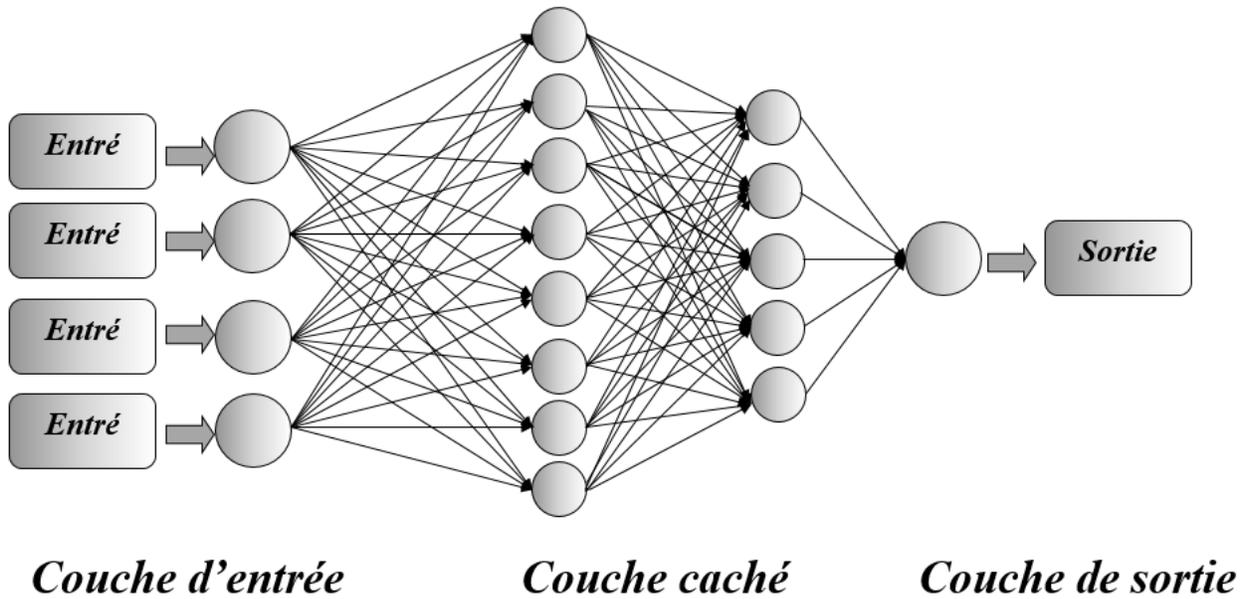


Figure II.3. : Un perceptron multicouche (PMC) [22]

II.4 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 (II.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 limit" 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 (II.4.) On peut observer que le biais b dans l'expression de $y = \text{hard lim}(w^T x - b)$ (équation II.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 [21].

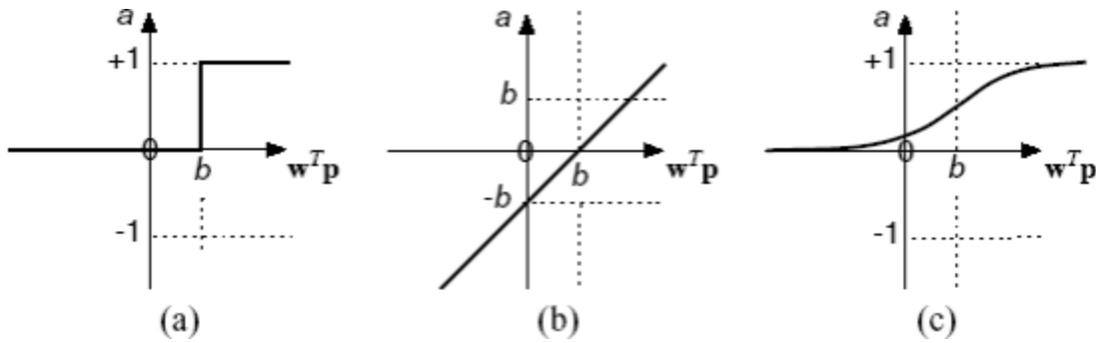


Figure II.4 : La fonction de transfert "seuil" (a), "linéaire" (b) et "sigmoïde" (c)

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

$$Y = s \tag{II.3}$$

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à la figure II.4 b Dans ce cas, la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $w^T x = b$

La fonction de transfert sigmoïde est quant à elle illustrée à la figure II.4.c. Son équation est donnée par :

$$y = \frac{1}{1+\exp^{-s}} \tag{II.4}$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que l'on est loin ou près de b, respectivement. La fonction seuil est très non linéaire car il y a une discontinuité lorsque $w^T x = b$. 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 [21].

Tableau.II.1 - Différentes fonctions d'activations utilisées dans les RNA [21]

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

II.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 II.5). 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 [34].

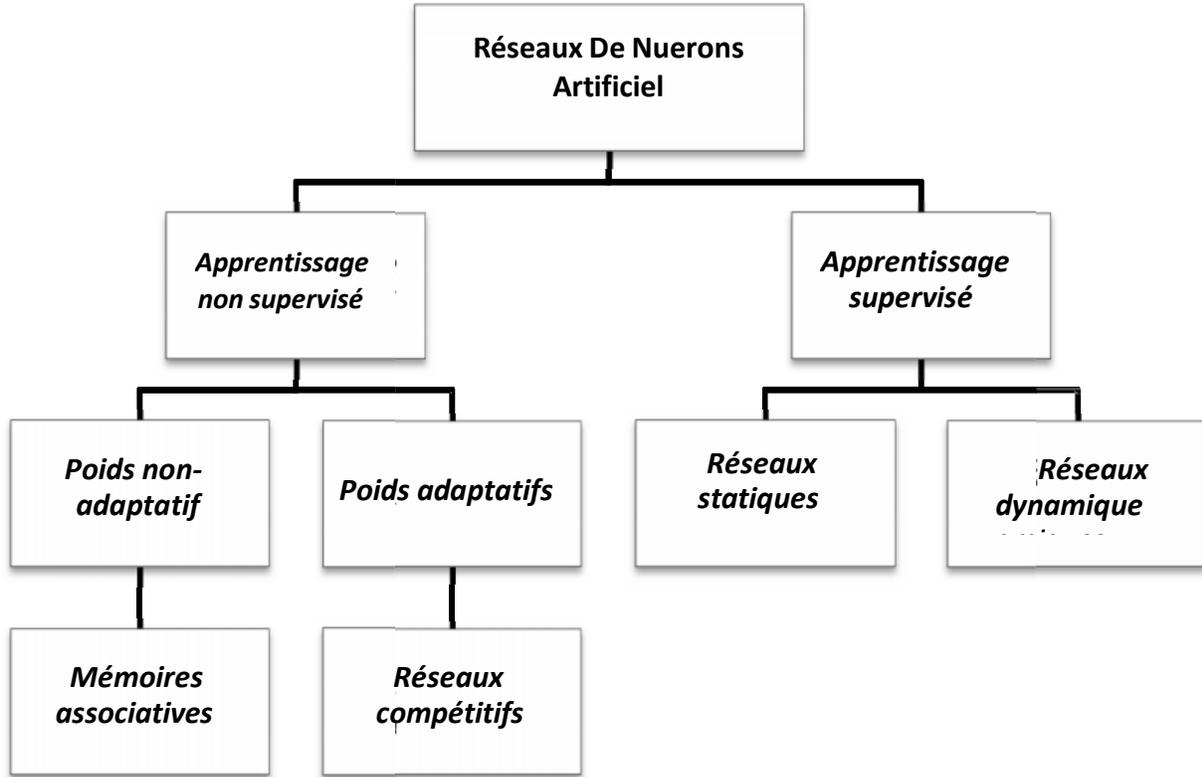


Figure II.5 : Classification des réseaux de neurones suivant leur apprentissage [35]

En se basant sur la Figure (II.5) 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 (II.6). 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 [35]

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 :

$$W_i^{k+1} = w_i^k + \Delta w_i \quad (II.5)$$

W_i^{k+1} : Nouveau poids

w_i^k : Ancien poids

Δw_i : Incrément

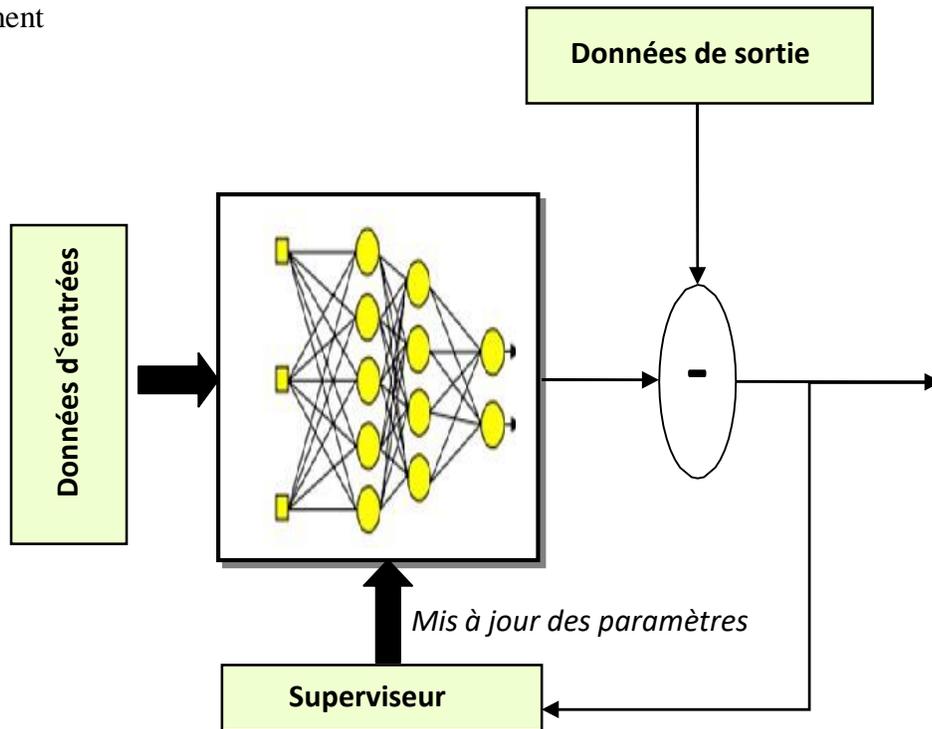


Figure II.6 : Schéma représentant le mécanisme d'un superviseur dans le cas d'Apprentissage supervisé de perceptron multi couche [35]

II.6 Méthodes d'optimisation

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

Parmi ces méthodes en peut citer

II.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 :

$$H \cdot \Delta w_i = -g \quad (II.6)$$

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 [35]

II.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 [17]

$$2. \Delta \mathbf{w}_i = -\mathbf{g} \quad (\text{II.7})$$

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

II.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 [35]. En pratique, on utilise :

$$\gamma \Delta . w_i = -g \quad (\text{II.8})$$

γ : Constant.

II.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 où 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 [35].

II.7 Réseaux de neurones

Le terme général utilisé pour décrire la disposition et les connexions des neurones d'un réseau est l'architecture. On utilise également le terme de topologie, emprunté à la théorie des graphes. Au niveau des neurones eux-mêmes, on parle plutôt de voisinage, qui fait référence à la façon dont un neurone est connecté à d'autres neurones. Le voisinage d'un neurone représente l'ensemble des neurones qui y sont connectés. Ce concept est directement lié à l'architecture du réseau.

En examinant de plus près la signification du terme "voisinage" dans le contexte de l'architecture des réseaux de neurones, il désigne les neurones connectés à un neurone donné. On parle de voisinage d'ordre n pour un neurone i , ce qui signifie qu'il y a n autres neurones connectés à celui-ci, et les connexions entre les neurones ont généralement une direction.

Une connexion représente un lien explicite entre deux neurones. On les appelle également synapses, en référence aux connecteurs des neurones réels. Chaque connexion entre deux neurones possède une valeur numérique associée, appelée poids de connexion. Les poids de connexion W_{ij} entre les neurones i et j peuvent prendre des valeurs discrètes dans l'ensemble des entiers (\mathbb{Z}) ou des valeurs continues dans un autre ensemble. L'information qui circule à travers la connexion est influencée par la valeur du poids correspondant. Une connexion avec un poids

$W_{ij} = 0$ équivaut à l'absence de connexion.

Les connexions entre les neurones qui composent le réseau déterminent la topologie du modèle. Cette topologie peut être arbitraire, mais souvent on observe une certaine régularité. Il existe une grande variété de configurations possibles pour les neurones artificiels [36].

II.7.1 Perceptron multi-couche

Cette architecture est une extension du Perceptron Monocouche (Figure II.7.a), qui est une topologie couramment utilisée dans les réseaux neuronaux. Dans ce type d'architecture, les neurones sont organisés en couches. Les informations d'entrée sont transmises de couche en couche, jusqu'à obtenir le résultat en sortie [37, 38, 39]. Dans cette topologie, les neurones sont divisés en trois catégories : les neurones d'entrée, les neurones cachés et les neurones de sortie (les neurones cachés étant situés entre les neurones d'entrée et les neurones de sortie).

Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie), et il n'y a pas de connexions entre les neurones d'une même couche (Figure II.7.b). Cette architecture est capable de résoudre des problèmes non linéairement séparables et des problèmes logiques plus complexes [40].

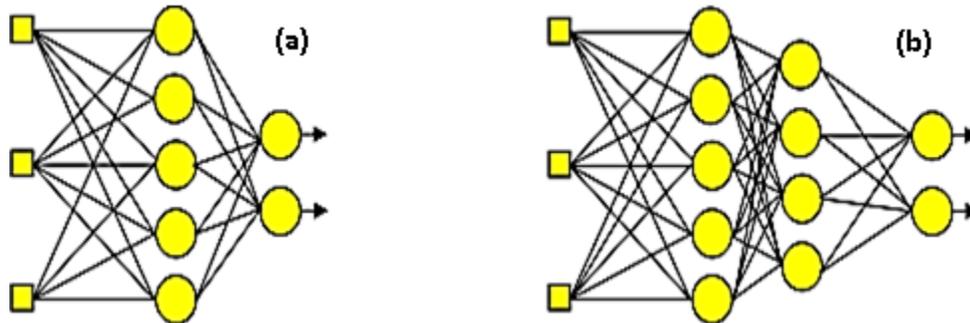


Figure 2.7: Structures des réseaux de neurone de type perceptron. (a) Perceptron mono couche et (b) le perceptron multi-couche à deux couches cachées [40].

II.7.2 Réseau à connexions récurrentes

Les connexions récurrentes permettent à l'information de circuler en sens inverse par rapport à la direction de propagation définie dans un réseau multicouche. Ces connexions sont généralement de nature locale (Figure II.8).

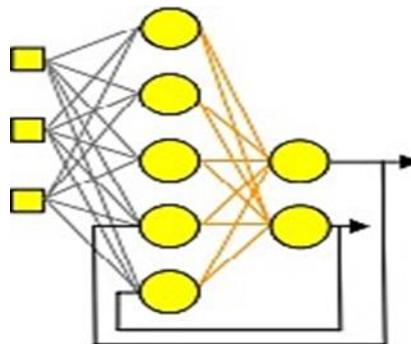


Figure II.8: Exemple d'un réseau à connexions récurrentes [40].

II.7.3 Réseau à connexion complète

C'est la structure d'interconnexion la plus générale (Figure.II.9). Chaque neurone est connecté à tous les neurones du réseau (et à lui-même).

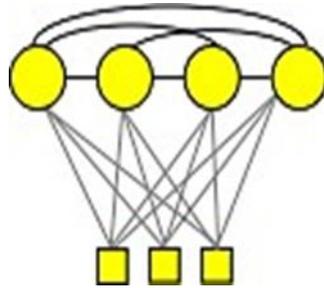


Figure II.9: Exemple d'un réseau à connexion complète [40].

II.7.4 Réseau de Kohonen

Un réseau de Kohonen est une carte auto-organisatrice (self-organizingmap) qui permet de reconnaître des similarités dans les données. Ce réseau est composé d'une carte de sortie bidimensionnelle constituée de plusieurs neurones et d'une couche d'entrées où les entrées sont liées aux neurones de la carte de sortie (Figure. II.10).

Dans le contexte de ce travail, seul Le perceptron multi couche nous intéresse parce qu'il est le type de réseau le plus utilisé pour la prévision de phénomènes hydrologiques [41].

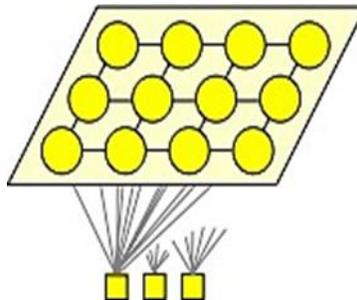


Figure II.10: Exemple d'un réseau de Kohonen [41].

II.8 Problème de surajustement

Pendant le processus d'apprentissage, les sorties d'un réseau non bouclé ont tendance à se rapprocher des sorties fournies dans l'ensemble d'apprentissage. Cependant, l'intérêt principal des réseaux réside dans leur capacité de généralisation, c'est-à-dire leur capacité à fournir des valeurs pour des entrées inconnues qui ne font pas partie de l'ensemble d'apprentissage. Pour obtenir une bonne généralisation, il est important de respecter certaines règles, sans lesquelles les réseaux

neuronaux artificiels donneront des résultats erronés. Les entrées choisies pour le réseau doivent être pertinentes et représentatives de la fonction recherchée. Il n'est pas nécessaire d'inclure toutes les entrées sans lien avec les sorties fournies, car cela augmenterait artificiellement la complexité du modèle recherché [42].

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 II.11).

II.9 Méthodes 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.

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 [35]. Cependant, cela peut être observé dans (la Figure II.11)

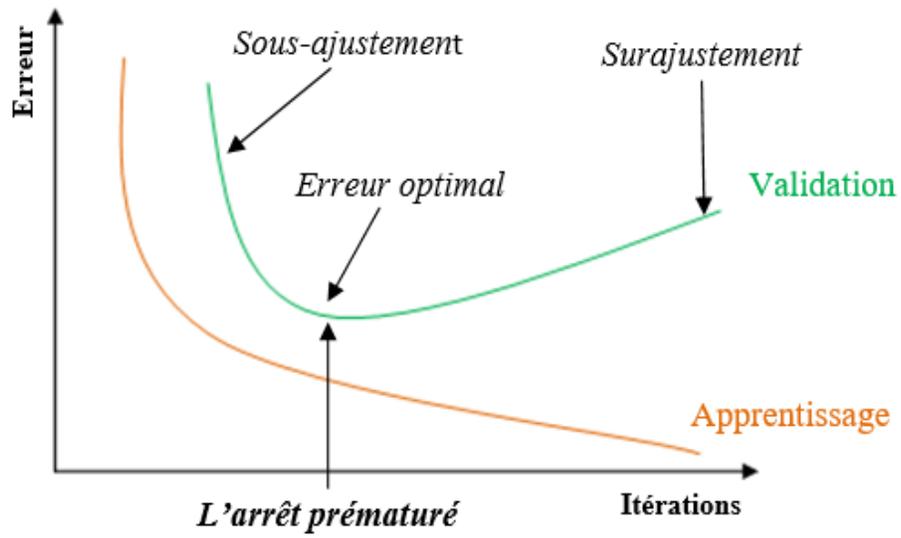


Figure II.11: Schéma qui représente l'évolution de l'erreur d'apprentissage et de validation d'un RNA en fonction de nombre d'itération [35]

Chapitre III : Zone d'étude et description des données

III.1 Introduction

Le but essentiel de cette section est d'obtenir une compréhension générale des principales caractéristiques du bassin versant de l'Oued Hachem. Ce chapitre se concentre sur la description géographique du bassin, ses réseaux hydrographiques, les conditions climatiques qui y prévalent, ainsi que les caractéristiques hydrauliques spécifiques du bassin de l'Oued Hachem.

III.2 Situation géographique

Le bassin d'Oued Hachem situé dans le bassin côtier de Cherchell, également connu sous le nom de sous-bassin "03" dans le grand bassin Algérois, est délimité au nord par la mer Méditerranée, à l'est et au sud par le sous-bassin hydrographique de l'Oued Djer Bou-Roumi et le sous-bassin côtier de Tenes qui le borde à l'ouest ^[43].

Ce bassin d'étude est situé dans la wilaya de Tipaza, qui est une subdivision administrative récente. Le chef-lieu de cette wilaya est une ville côtière située à 70 km à l'ouest de la capitale Alger. La présence de la mer, des reliefs du Mont Chenoua et du Sahel confèrent à la région un paysage particulier d'un grand attrait touristique. De nombreux vestiges puniques, romains, chrétiens et africains témoignent de la richesse de son histoire ^[43].

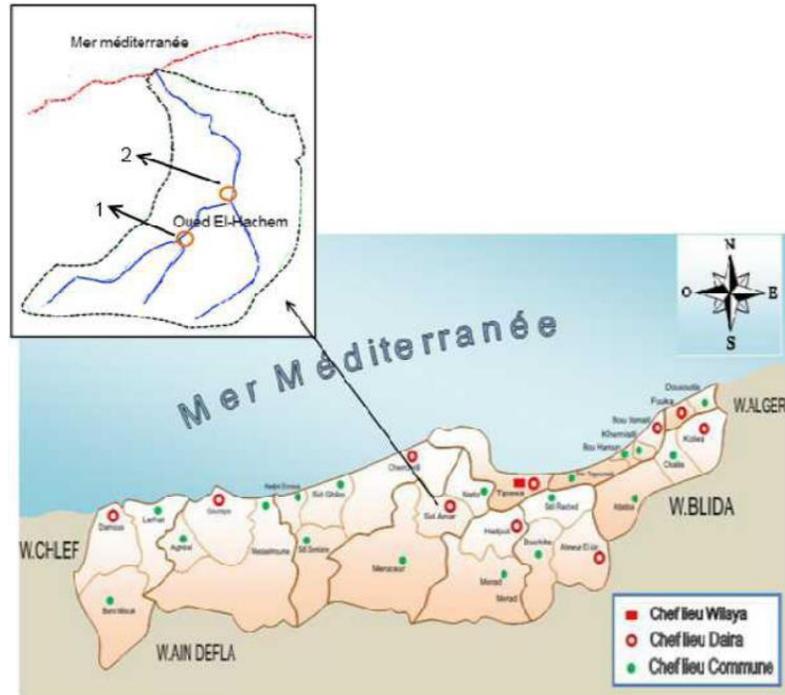


Figure III.1 : Carte de situation de la zone d'étude et le bassin versant [43]

III.3 Le barrage

Le barrage-réservoir de Boukourdane a été construit à l'embouchure du bassin versant de l'Oued Hachem, qui couvre une superficie de 243 km². Il est alimenté par les cours d'eau suivants Boukadir, Tegdza, Nachef et Fedjena, qui se rejoignent pour former l'oued El Hachem. Selon) [44]. Le bassin versant présente un taux d'érosion de 446 tonnes par kilomètre carré par an.

Le bassin versant de Boukourdane fait partie du bassin hydrographique Algérois-Soummam-Hodna, plus précisément du bassin Algérois. Contrairement aux autres bassins hydrographiques qui en comptent 5, le taux d'envasement de l'Algérois-Soummam-Hodna présente un faible taux de comblement, estimé à environ 9% de la capacité totale des barrages [45]. La durée de vie de ces ouvrages dépassera les 220 ans. Cette faible sédimentation est le résultat d'une érosion réduite des sols due à la végétation et à l'aménagement des bassins versants.

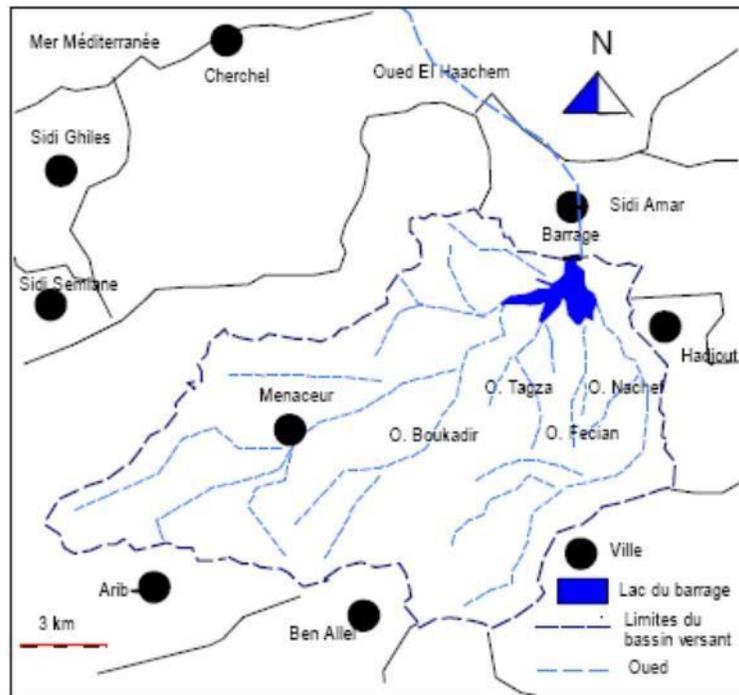


Figure III.2 : Les limites du bassin versant à l'amont du barrage de Boukourdane [46]

III.4 Géomorphologie et physiographie du milieu étudié

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.

III.5 Coefficient de compacité

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'hydrogramme résultant d'une précipitation donnée. Un bassin versant allongé 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 [43].

III.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^[43]

III.7 Les caractéristiques

L'ensemble des caractéristiques physiographique et morphométriques du bassin versant sont présentés dans le tableau (III.1).

Tableau III.1 : Principales caractéristiques du bassin versant ^[43]

Désignation		Symbole	Unités	Valeur
Superficie		S	Km ²	156
Périmètre		P	Km	58
Longueur du thalweg principal		L	Km	24
Indice de compacité		Kc	/	1.28
Coefficient d'allongement		Ca	/	3.69
Rectangle équivalent	longueur	L	Km	22.19
	largeur	L	Km	7.03
Altitude	max	Hmax	m	1417
	moyenne	Hmoy	m	420
	min	Hmin	m	78
Indice de pente de roche		Ip	%	2.88
Indice de pente globale		Ig	m/km	62.36
Indice de pente moyenne		Ipm	%	10.33
Densité de drainage		Dd	Km/Km ²	4.7
Coefficient de torrentialité		Ct	/	70.9
Temps de concentration		Tc	h	6
Vitesse de ruissellement		Vr	Km/h	2.03

III.8 Climatologie

L'étude climatologique et l'étude hydrologique sont étroitement liées. Il est important de prendre en compte les paramètres tels que la température, le vent, l'humidité, le gel, etc., dans la modélisation des phénomènes complexes liés au comportement des sols, tels que l'infiltration, la saturation, le ruissellement, ainsi que dans l'évaluation de la réserve d'eau du sol, du pouvoir d'humidification et de l'évapotranspiration potentielle [47].

Notre zone d'étude est classée dans la zone Cs selon la classification climatique de Köppen [48]. Cette zone correspond à un climat méditerranéen avec des étés chauds et arides, et des hivers pluvieux et plus doux.

III.9 Température

La station météorologique située au Barrage de Boukerdane, sur Oued El Hachem, qui est la principale rivière de notre zone d'étude (code de la station 020329), est utilisée comme référence. Cette station se trouve à une altitude de 110 mètres. Les températures moyennes annuelles enregistrées sur une période de 19 ans (1988-2007) sont présentées dans le tableau suivant.

Tableau III.2 : Température moyenne interannuelles en °C [46]

mois	sept	oct.	nov.	déc.	janv.	fév.	mars	avril	mai	Juin.	Juil.	Aout
T moy	23.5	20	14.8	12.3	11	11.6	13.7	15.2	19.3	23.8	26.6	26.5
T min	19.2	15	11.5	9.2	6.5	7.8	9.7	11.3	14.9	19.7	21.4	21.6
T max	27.9	25.1	18.1	15.3	15.5	15.5	17.6	19.1	23.7	27.9	31.9	31.3
Amplitude	8.7	10.1	6.6	6.1	8.9	7.8	7.9	7.8	8.9	8.1	10.5	9.7

III.10 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%.

III.11 Les vents

La zone est sujette aux vents marins chargés en sel. Par ailleurs, les vents prédominants proviennent du nord-est et de l'ouest, avec une vitesse moyenne d'environ 2,5 à 3 m/s. Les vents

du nord sont généralement froids et persistent tout au long de l'année. En ce qui concerne les vents du sud, comme le Sirocco, ils sont souvent chauds et secs et soufflent en moyenne pendant 13 jours par an, principalement en juillet et en août [⁴³].

III.12 Bassin d'Oued Hachem

Le bassin d'Oued Hachem est situé dans la région côtière algérienne du Centre Nord, plus précisément dans la région de Cherchell de la wilaya de Tipaza. Il est drainé par Oued El Hachem. Pour étudier ce bassin, nous avons utilisé les données pluie-débit de deux stations : la station pluviométrique de Sidi Amar (codée 020310) de l'Agence Nationale des Ressources en Eau (ANRH) et la station hydrométrique de Bordj Ghobrini (codée 020301) de l'ANRH. La figure (III.3) illustre l'emplacement de ces deux stations dans le bassin d'Oued Hachem [⁴⁹].

Les données utilisées couvrent une période de sept ans, du 1er septembre 1983 au 31 août 1989, et comprennent des observations quotidiennes des précipitations et de l'écoulement (voir Figure III.3). Les principales caractéristiques statistiques de ces données sont résumées dans le tableau (III.3) ci-dessous.

Tableau III.3 : Les caractéristiques statistiques des pluies et débits pour le bassin d'Oued Hachem

Paramètres statistiques	Moyen	E-type	CV	Min	Max
Pluie (mm)	1.5126	5.7549	3.8046	0	127.3000
Débit (m ³ /s)	1.3400	5.1083	3.8123	0	91.9000

Selon la figure (III.5), les corrélogrammes des pluies et des débits diminuent rapidement à partir du deuxième jour, avec des valeurs de 0,0959 pour les pluies et de 0,0454 pour les débits. Cela indique un système à mémoire faible. De plus, la figure (III.6) révèle que les spectres de densité de variance des pluies et des débits ne présentent pas de structure à court terme.

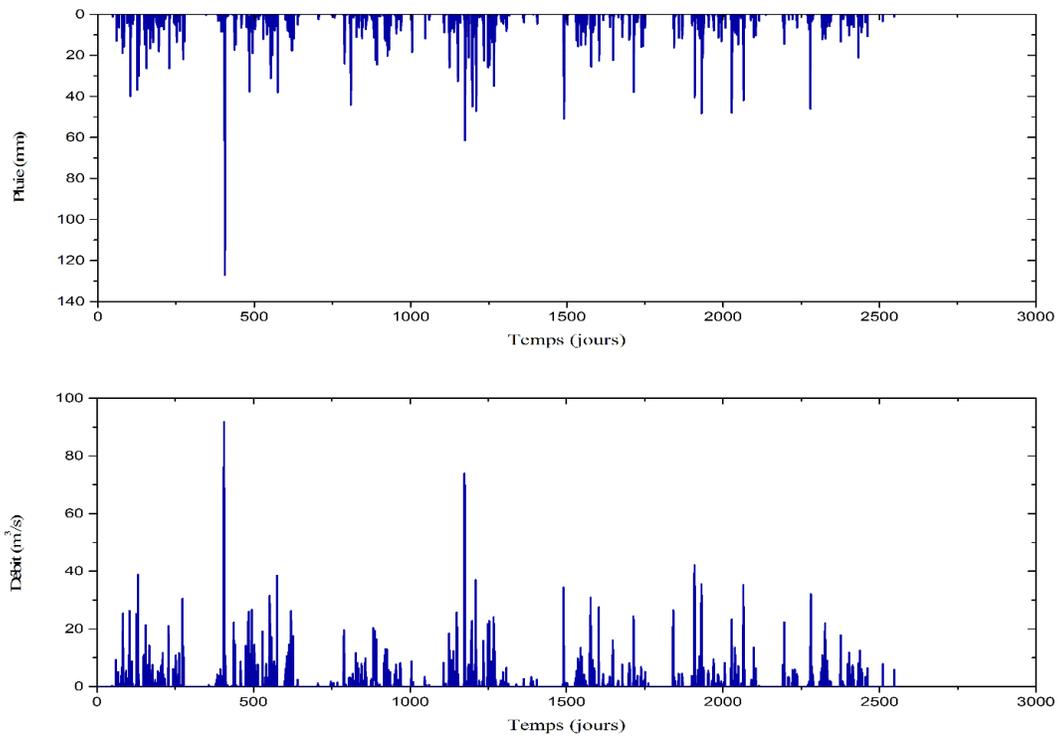
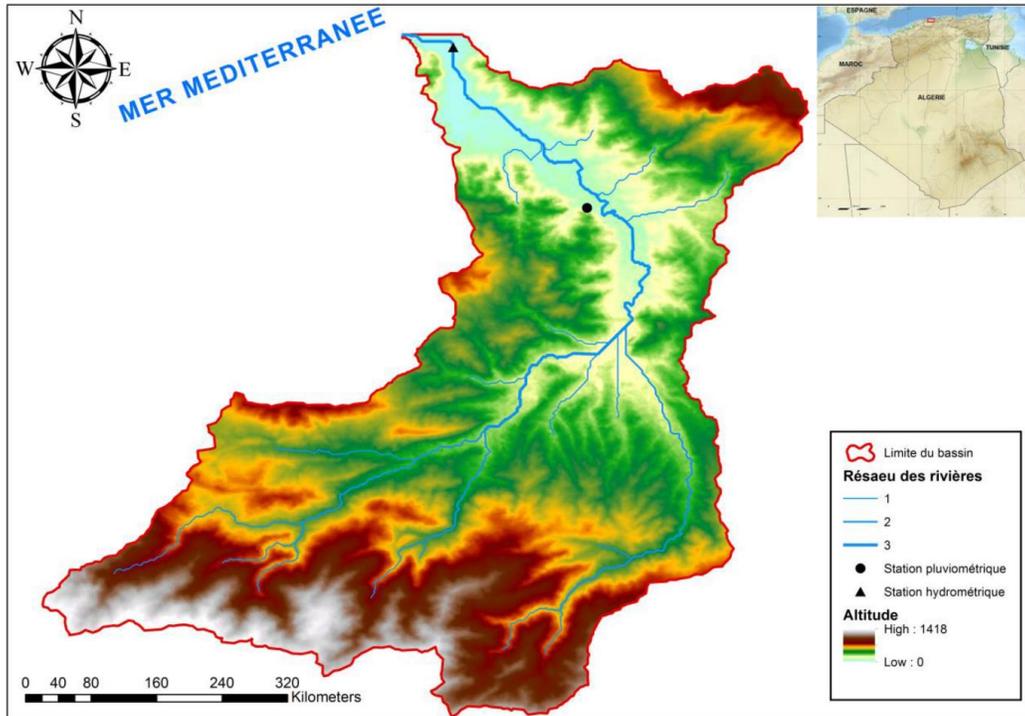


Figure III.4 : Les séries des pluies cumulés journalières et les débits moyens journaliers mesurés à la période 1983-1989 dans le bassin d'Oued Hachem.

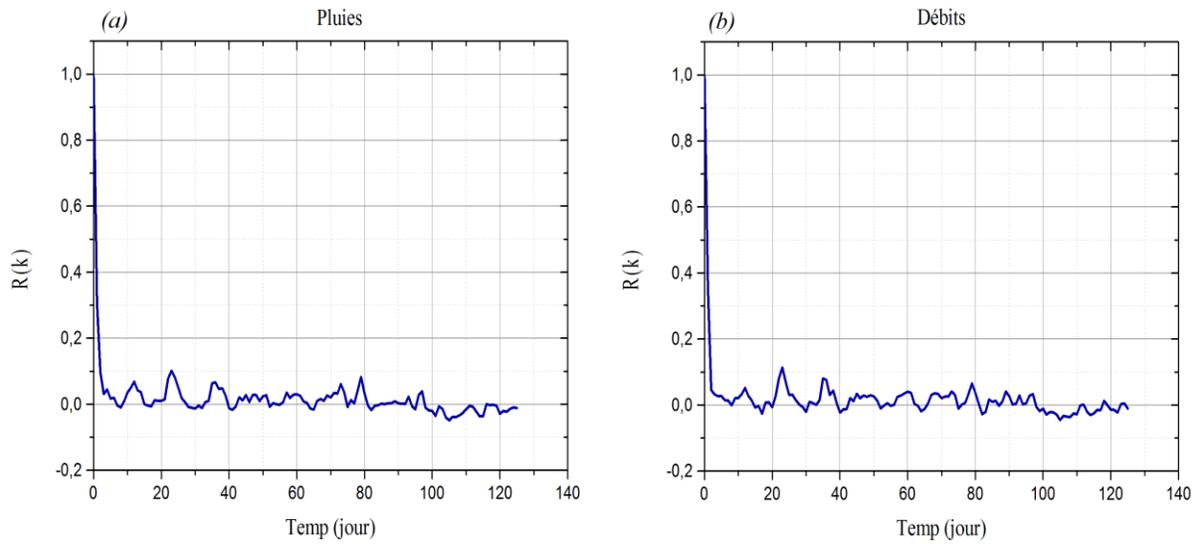


Figure III.5 : Corrélogramme des pluies et débits du bassin Oued Hachem.

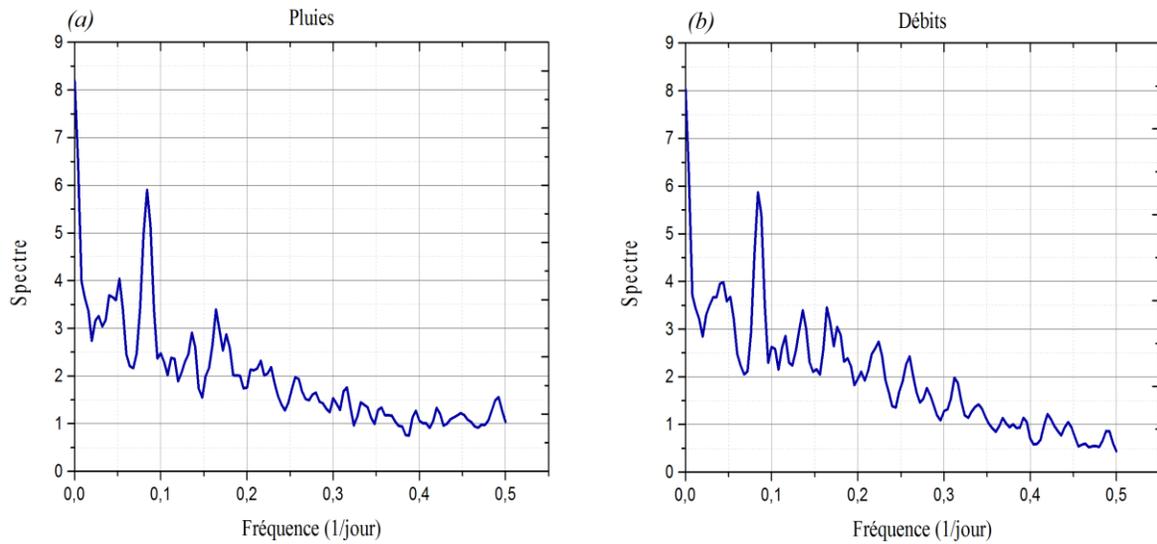


Figure III.6 : Le spectre de densité de variance des pluies et débits du bassin Oued Hachem.

Chapitre IV : Résultats et Discussion

IV.1. Développement des modèles

Dans ce travail, on utilise des vecteurs d'entrée représentant les précipitations et les débits observés à des intervalles de temps précédents. Cependant, seule la précipitation du jour suivant (P_{t+1}) correspond à l'entrée du modèle. Par conséquent, la sortie du réseau est un vecteur qui prédit les débits pour le jour suivant ($t+1$), notés Q_{t+1} .

La base de données disponible a été divisée en trois ensembles distincts dans le but d'ajuster les paramètres du modèle et d'obtenir les meilleures performances. Un ensemble a été utilisé pour la phase d'apprentissage, tandis que les deux autres ensembles ont été utilisés pour les phases de validation et de test du modèle.

Les données ont été subdivisées en trois ensembles de la manière suivante : 70 % des données ont été utilisées pour la phase d'apprentissage du modèle, 30 % des données ont été réservées pour la phase de validation, et un ensemble distinct contenant l'intégralité de la série de données a été utilisé pour la phase de test du modèle.

Un total de 15 modèles différents (Tableau IV.1) a été proposé pour le développement des RNA, en fonction des vecteurs d'entrée utilisés. Ces modèles ont été évalués et comparés en termes de performances afin de déterminer le meilleur modèle.

Tableau IV.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
<i>1</i>	P_{t+1} et Q_t	Q_{t+1}
<i>2</i>	P_{t+1} , P_t et Q_t	Q_{t+1}
<i>3</i>	P_{t+1} , P_t , P_{t-1} et Q_t	Q_{t+1}
<i>4</i>	P_{t+1} , Q_t et Q_{t-1}	Q_{t+1}
<i>5</i>	P_{t+1} , P_t , Q_t et Q_{t-1}	Q_{t+1}
<i>6</i>	P_{t+1} , P_t , P_{t-1} , Q_t et Q_{t-1}	Q_{t+1}
<i>7</i>	P_{t+1} , Q_t , Q_{t-1} et Q_{t-2}	Q_{t+1}
<i>8</i>	P_{t+1} , P_t , Q_t , Q_{t-1} et Q_{t-2}	Q_{t+1}
<i>9</i>	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} et Q_{t-2}	Q_{t+1}
<i>10</i>	P_{t+1} , Q_t , Q_{t-1} , Q_{t-2} et Q_{t-3}	Q_{t+1}
<i>11</i>	P_{t+1} , P_t , Q_t , Q_{t-1} , Q_{t-2} et Q_{t-3}	Q_{t+1}
<i>12</i>	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} , Q_{t-2} et Q_{t-3}	Q_{t+1}
<i>13</i>	P_{t+1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} et Q_{t-4}	Q_{t+1}
<i>14</i>	P_{t+1} , P_t , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} et Q_{t-4}	Q_{t+1}
<i>15</i>	P_{t+1} , P_t , P_{t-1} , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3} et Q_{t-4}	Q_{t+1}

Pour développer les RNA, une étape clé consiste à déterminer le nombre optimal de neurones dans la couche cachée pour les différents modèles de vecteurs d'entrée proposés dans le Tableau (IV.1). Cette procédure a été réalisée en testant l'erreur en faisant varier le nombre de neurones cachés. Nous avons commencé avec un seul neurone dans la couche cachée, puis avons progressivement augmenté ce nombre jusqu'à atteindre 50. Ensuite, nous avons sélectionné l'architecture qui offrait les meilleures performances possibles sur la base des résultats de validation. La Figure (IV.1) illustre le processus de développement du modèle RNA.

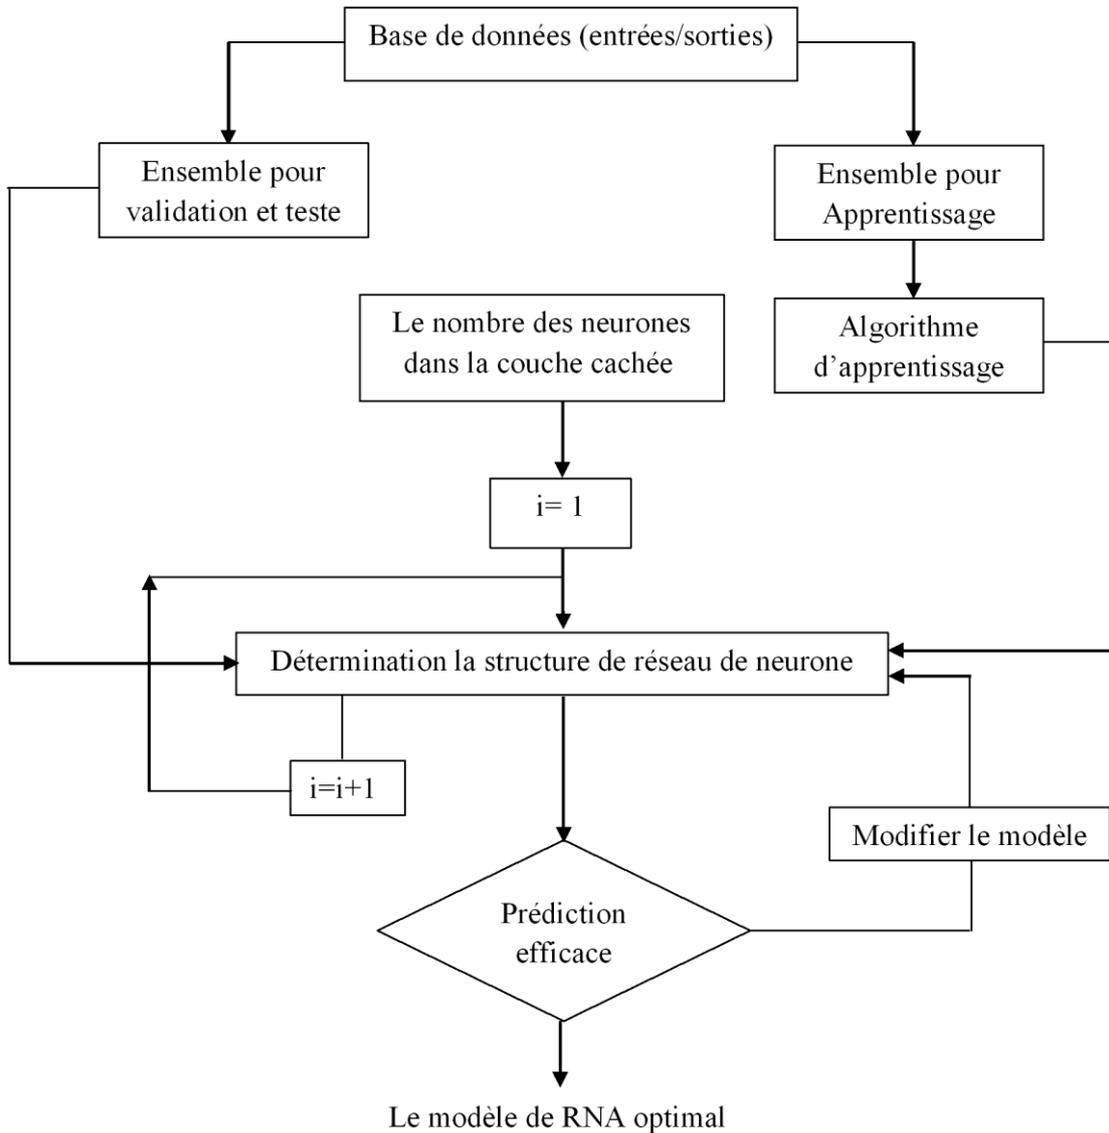


Figure IV.1 Organigramme expliquant le développement des RNA^[22].

IV.2 Choix des Critères de performance

Pour évaluer les performances du modèle RNA, les critères de performance sont généralement basés sur le calcul de l'erreur entre les valeurs simulées par le réseau et les valeurs observées. La validation du modèle RNA repose sur l'utilisation de paramètres statistiques lors des phases d'apprentissage, de validation et de test.

Dans le cadre de notre travail, on a utilisé l'erreur moyenne des carrés (ASE) (Average Squared Error), le coefficient d'efficacité Nash-Sutcliffe (E) et le coefficient de corrélation (R). Les

valeurs efficaces de **ASE** sont rapprochés à 0 et les valeurs efficaces de **E** et **R** à 1. Ces critères sont définis par les équations suivantes :

$$ASE = \frac{\sum_{i=1}^N (Q_{t_i} - \hat{Q}_{t_i})^2}{N} \quad (IV.1)$$

$$E = 1 - \frac{\sum_{i=1}^N (Q_{t_i} - \hat{Q}_{t_i})^2}{\sum_{i=1}^N (Q_{t_i} - \bar{Q}_{t_i})^2} \quad (IV.2)$$

$$R = \frac{\sum_{i=1}^N (\hat{Q}_{t_i} - \bar{\hat{Q}}_{t_i})(Q_{t_i} - \bar{Q}_{t_i})}{\sqrt{\left(\sum_{i=1}^N (\hat{Q}_{t_i} - \bar{\hat{Q}}_{t_i})^2\right)\left(\sum_{i=1}^N (Q_{t_i} - \bar{Q}_{t_i})^2\right)}} \quad (IV.3)$$

Où : Q_{t_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.

IV.3 Résultats et discussion

Dans cette partie, les meilleurs modèles sont sélectionnés sur la base la phase de validation. D'après les figures (IV.2) à (IV.16) et les résultats de tableau 8. La modélisation des combinaisons des vecteurs d'entrées par RNA montre des résultats très similaires d'ASE dans la phase de validation pour les modèles des vecteurs d'entrées 6, 7, 9, 12 et 14. Il a également donné des valeurs très faibles de ASE et des valeurs très élevées de E et R dans la phase d'apprentissage et la phase de test pour le modèle des vecteurs d'entrées 7. En revanche les

grandes valeurs de ASE et faibles valeurs de E et R dans le modèle 13 pour la phase de validation et dans le modèle 14 pour la phase d'apprentissage et la phase de test.

Après analyse des résultats, on peut dire que le modèle 7 (P_{t+1} , Q_t , Q_{t-1} et Q_{t-2}) avec nombre de neurones cachées = 20 a donné les meilleures performances possibles avec des valeurs très faibles de ASE (dans la phase d'apprentissage = 3.0236, la phase de validation = 6.9323 et la phase de test = 4.1957) et des valeurs très élevées de E et R (dans la phase d'apprentissage E = 0.9003 et R = 94.8863, la phase de validation E = 0.5743 et R = 75.8475 et la phase de test E = 0.8395 et R = 91.6244).

Les figures (IV.2 à IV.16) présentent l'optimisation d'ASE en fonction de nombre de neurones de la couche cachée pour chaque combinaison de vecteurs d'entrées proposées dans la phase de validation pour le bassin versant d'oued Hachem.

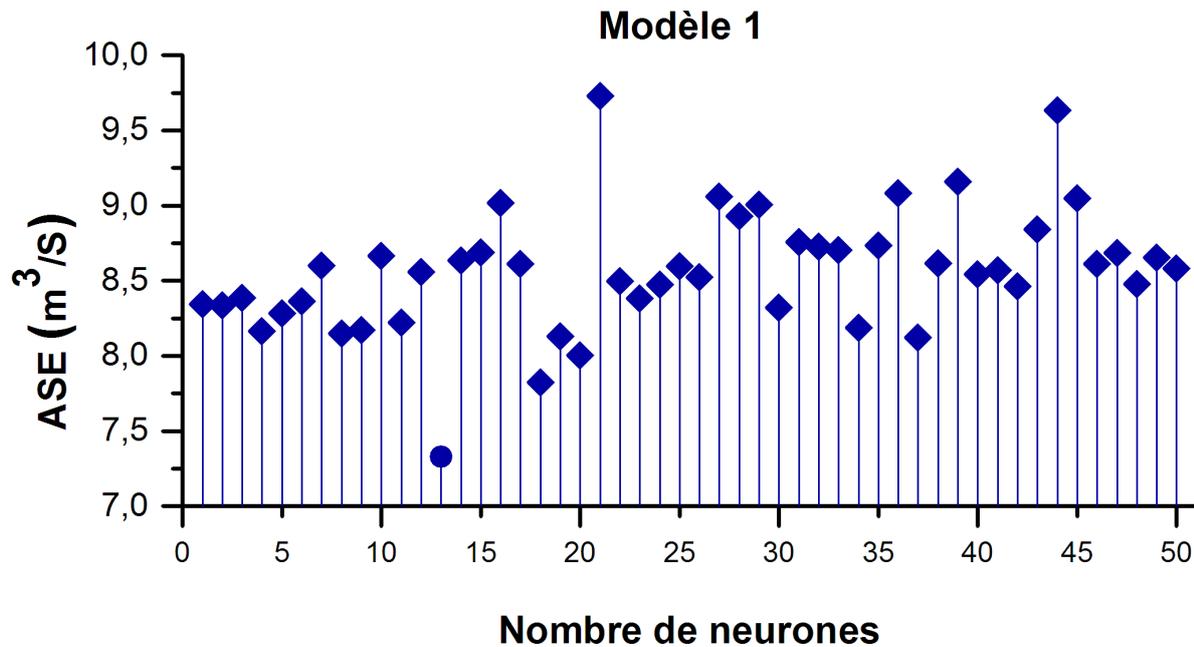


Figure IV.2 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 1.

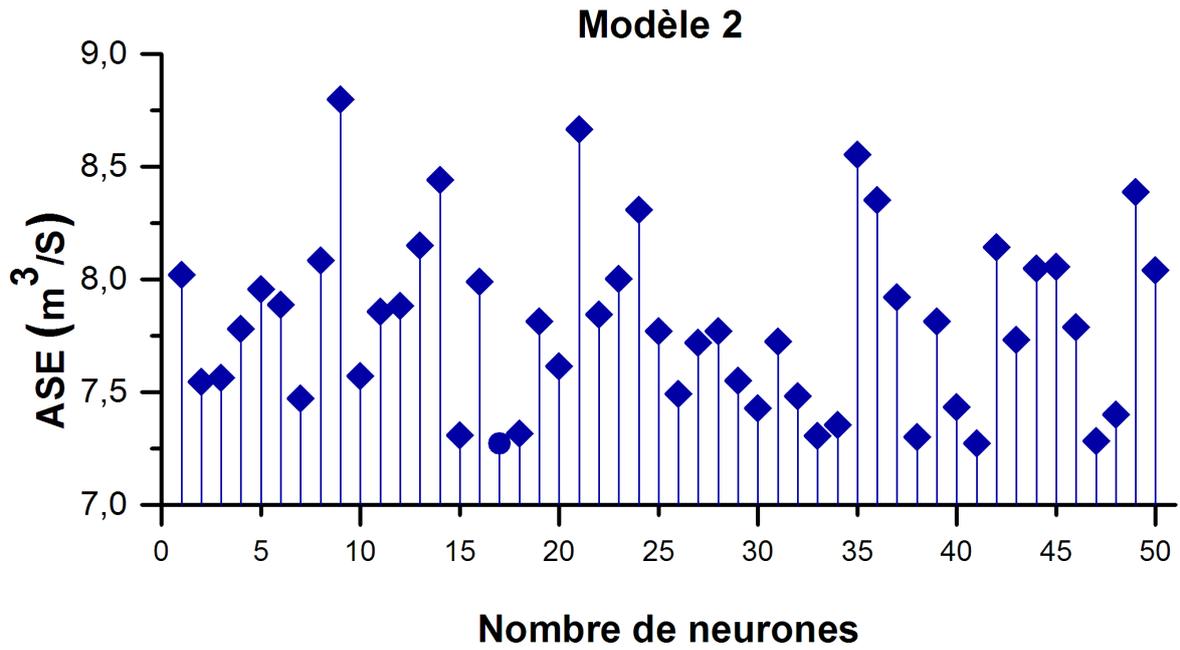


Figure IV.3 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 2.

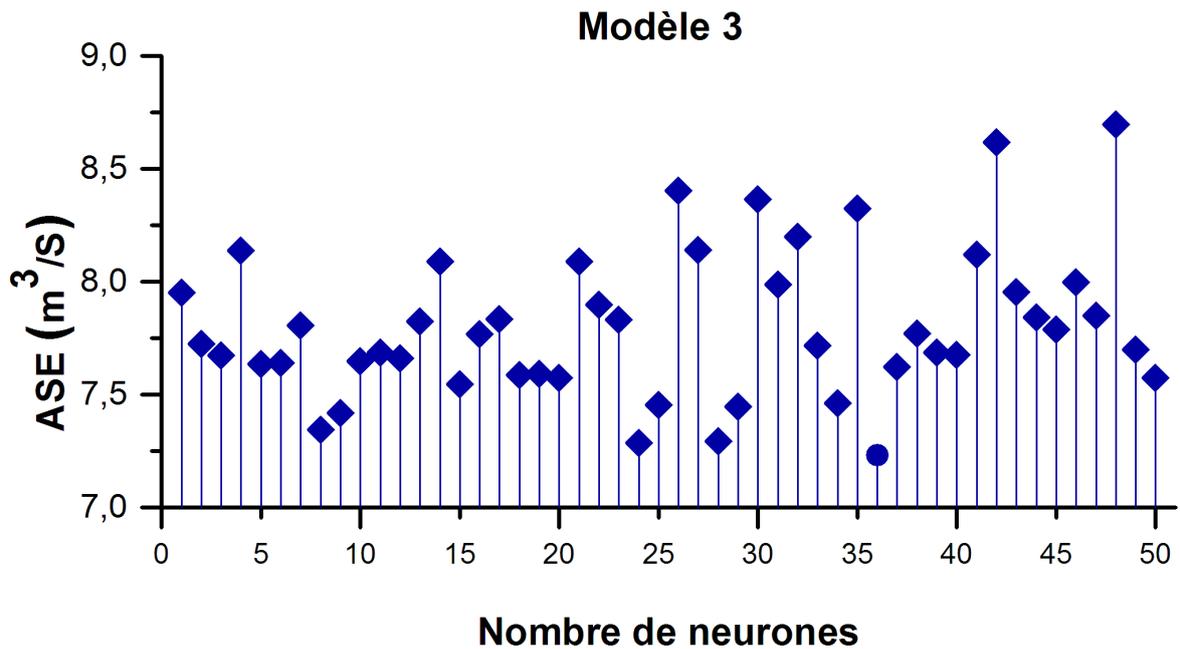


Figure IV.4 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 3.

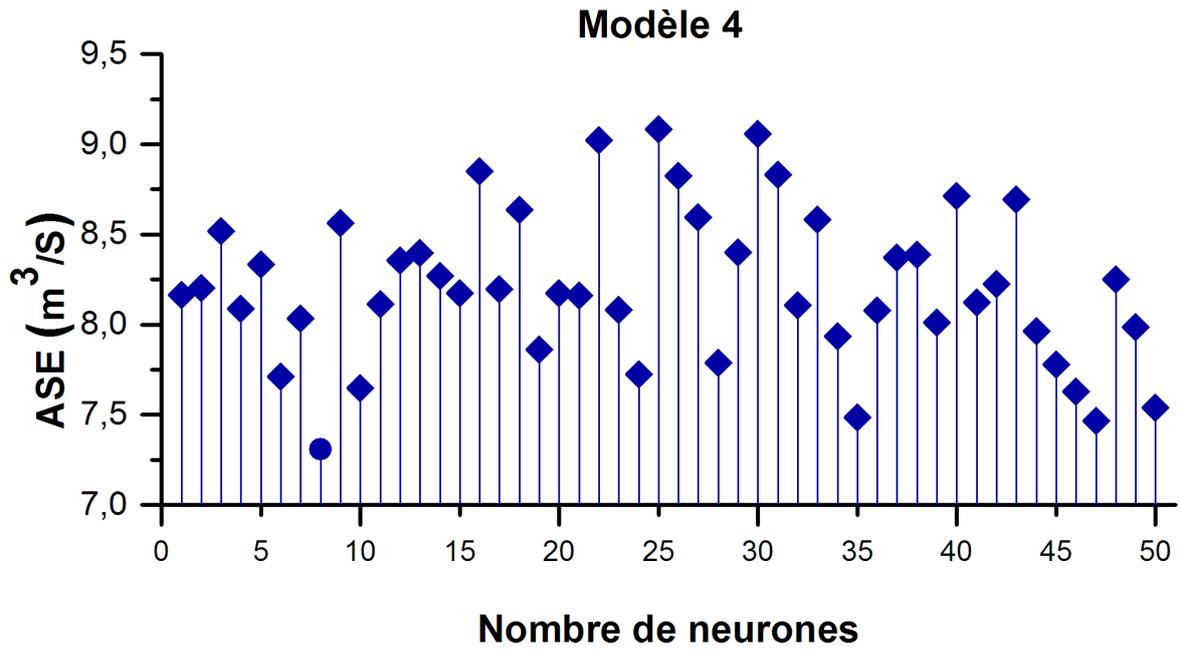


Figure IV.5 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 4.

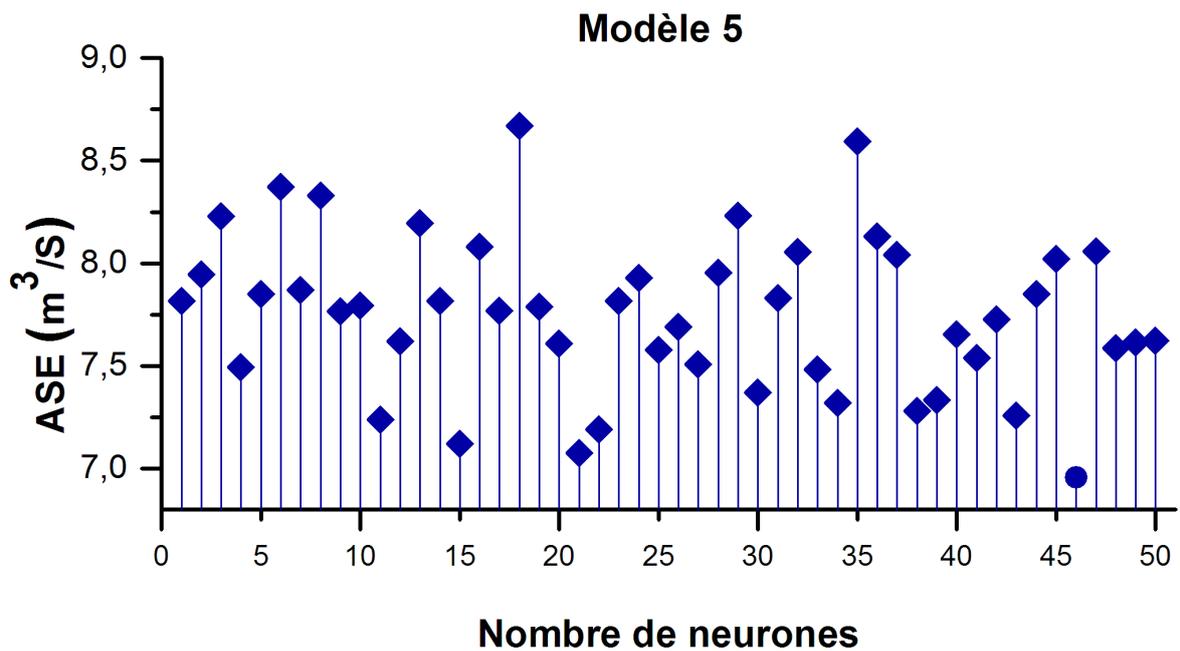


Figure IV.6 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 5.

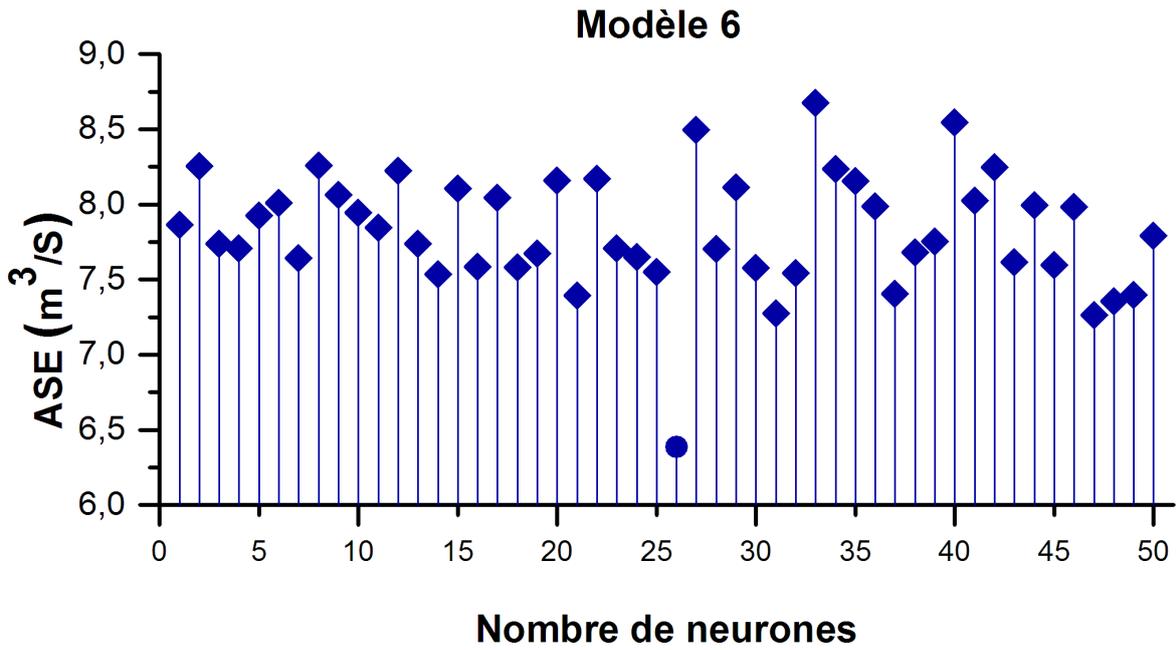


Figure IV.7 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 6.

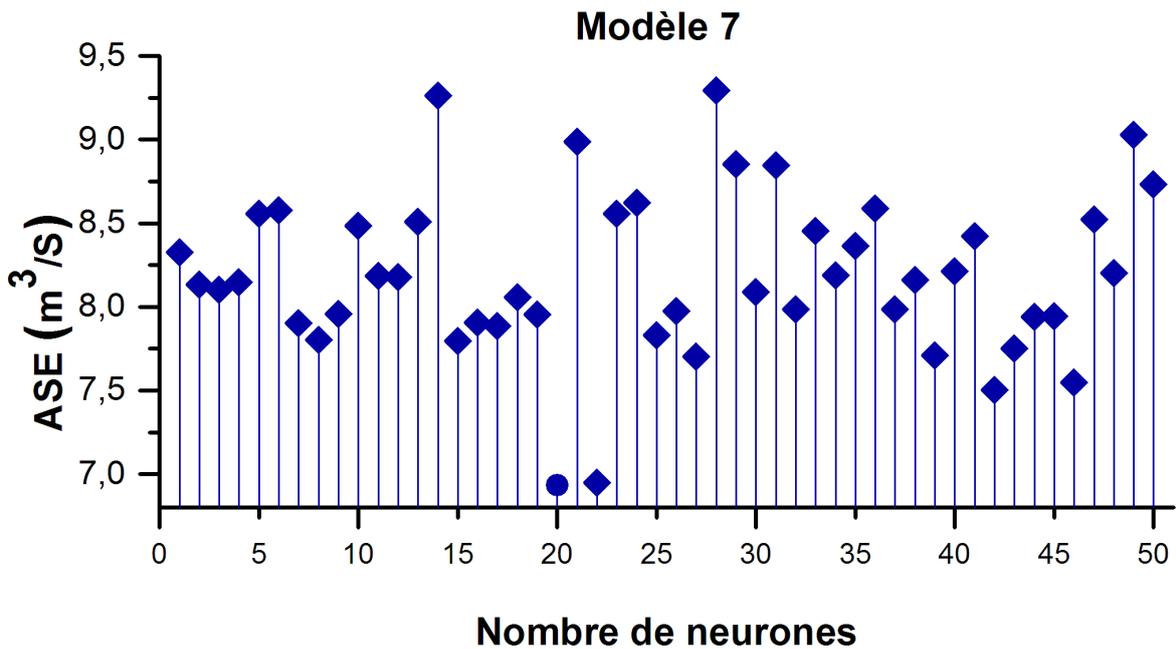


Figure IV.8 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 7.

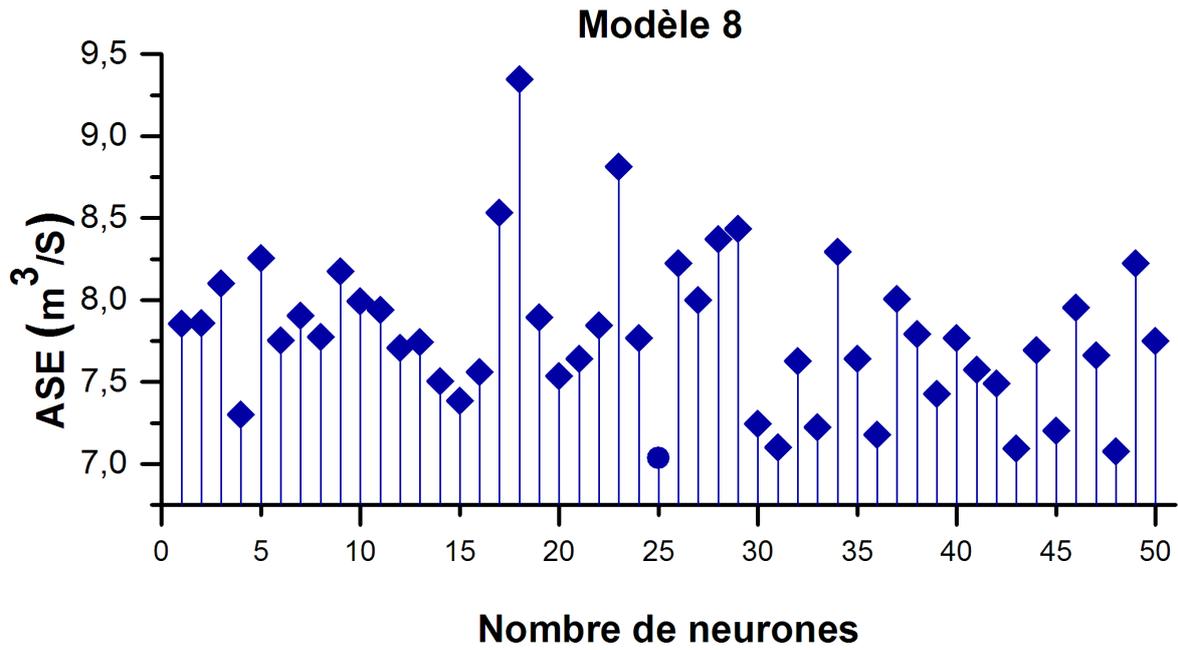


Figure IV.9 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 8.

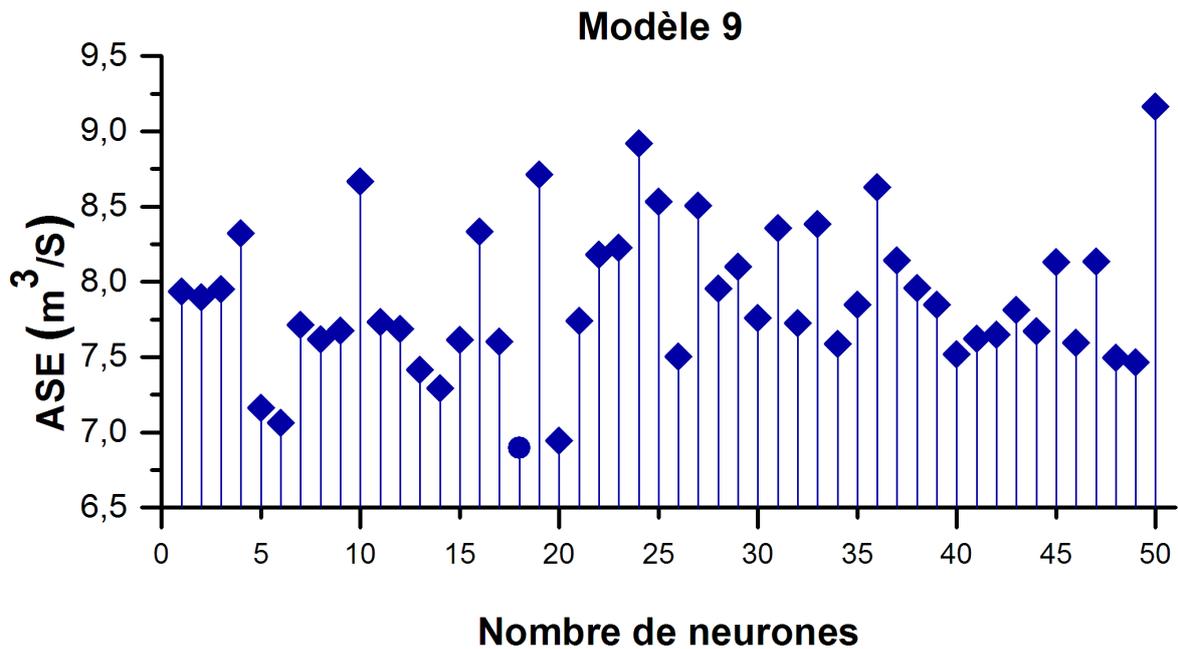


Figure IV.10 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 9.

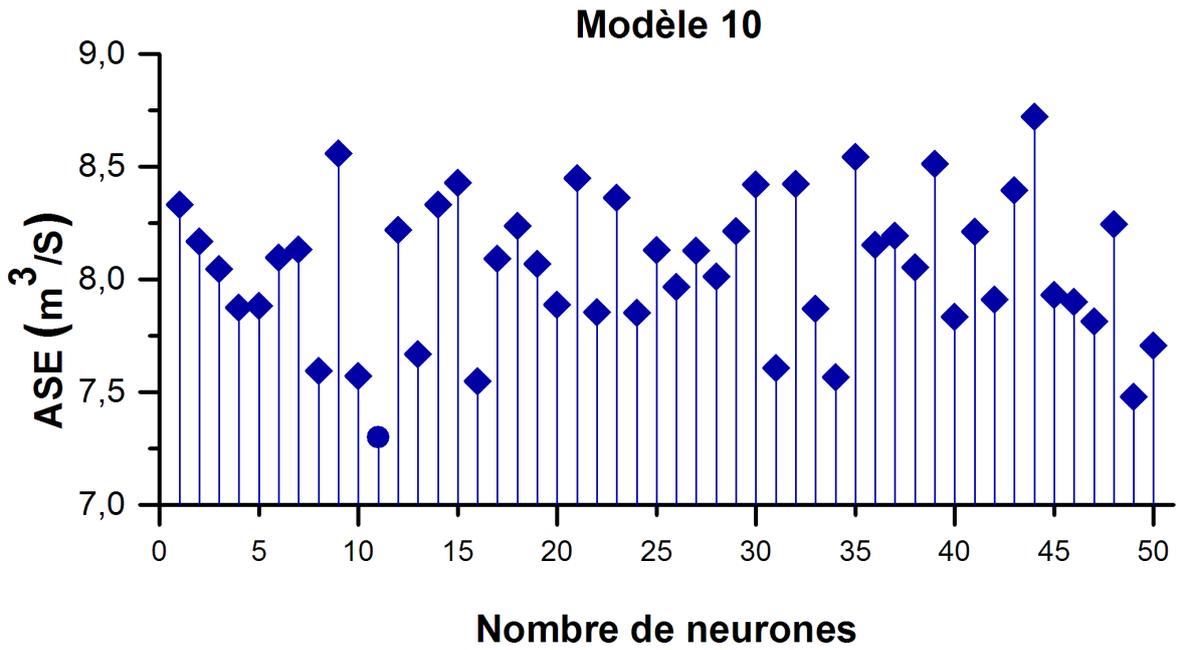


Figure IV.11 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 10.

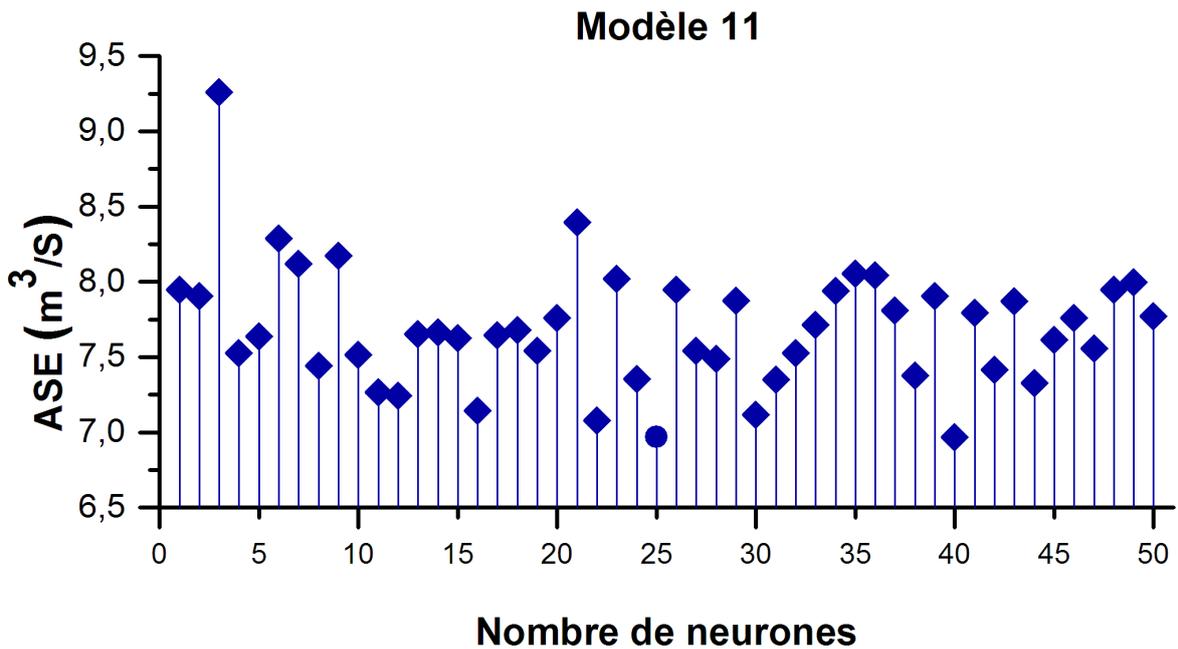


Figure IV.12 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 11.

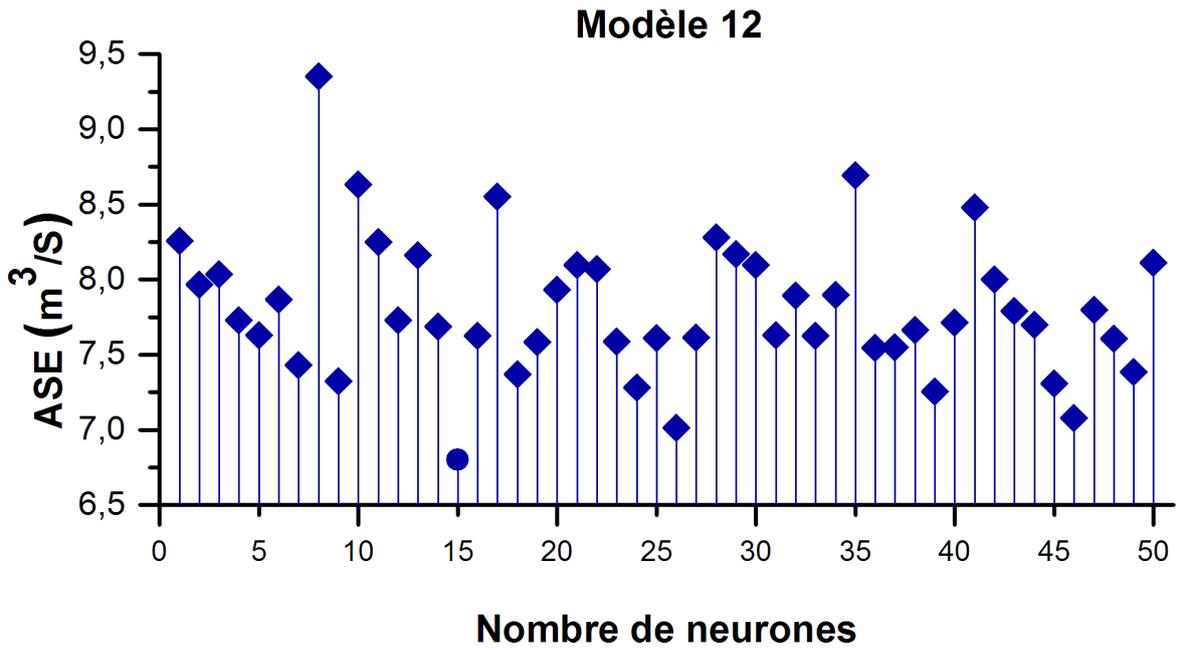


Figure IV.13 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 12.

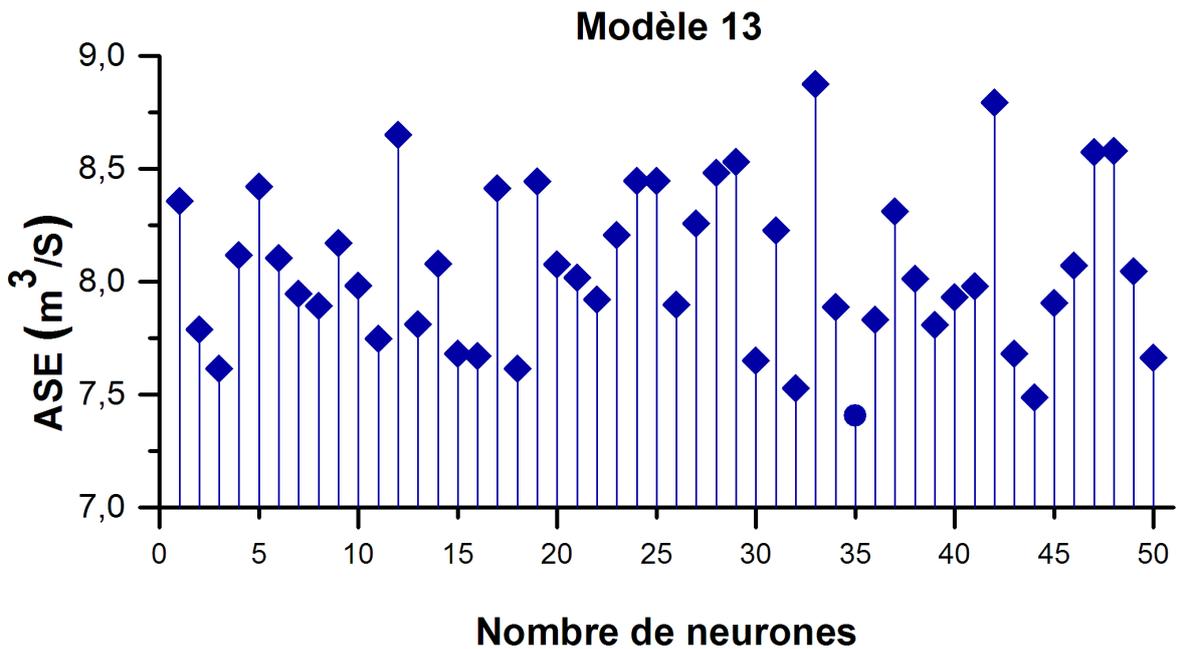


Figure IV.14 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 13.

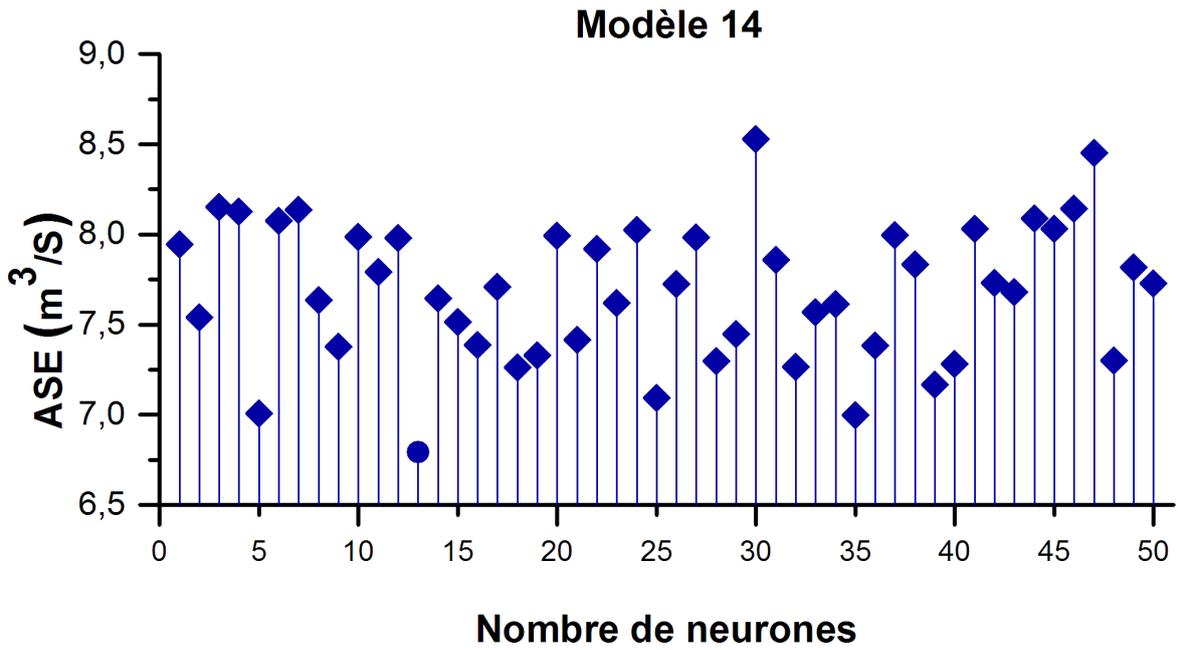


Figure IV.15 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 14.

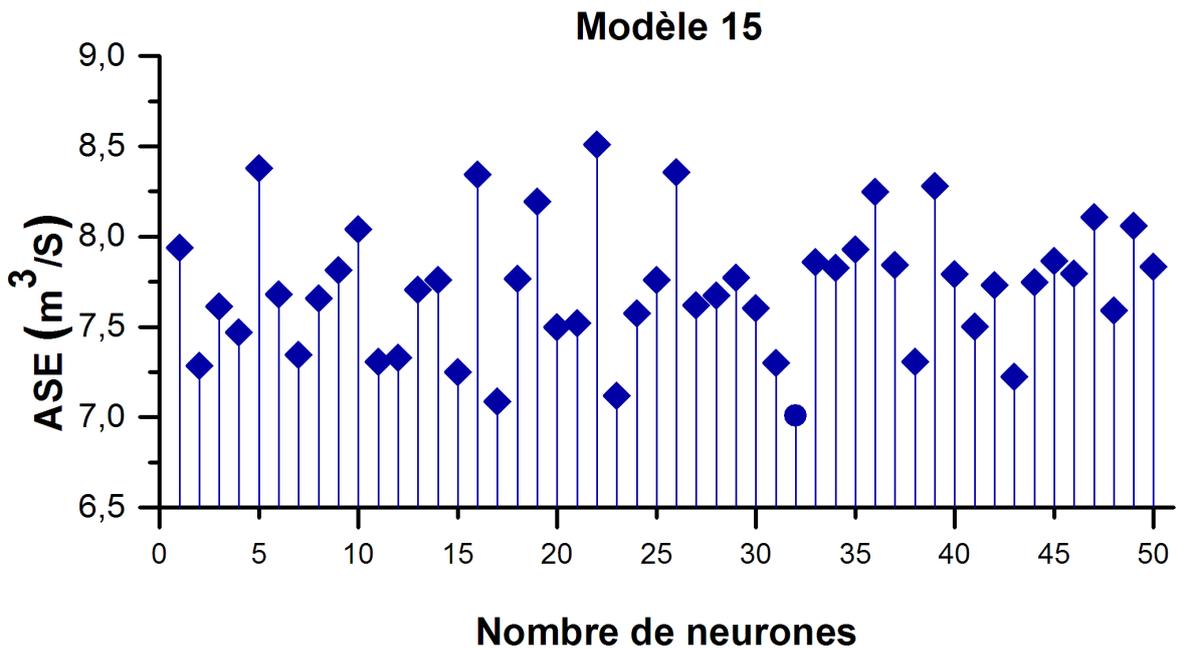


Figure IV.16 Evaluation d'ASE en fonction du nombre de neurones dans la couche cachée pour le modèle des vecteurs 15.

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 (IV.2).

Le tableau (IV.2) illustre les résultats statistiques du modèle RNA pour les différentes combinaisons de vecteurs d'entrées proposées dans les phases d'apprentissage, validation et test.

Tableau IV.2 : Résultats statistiques du modèle RNA dans les phases d'apprentissage, validation et test.

Modèle	Phase	ASE (m ³ /s)	E	R
1	Apprentissage	9.2125	0.6961	83.4723
	Validation	7.3287	0.5500	74.6242
	Test	8.6475	0.6692	81.8227
2	Apprentissage	8.6514	0.7146	85.0615
	Validation	7.2714	0.5535	75.6467
	Test	8.2375	0.6849	82.9398
3	Apprentissage	9.8360	0.6756	84.4207
	Validation	7.2319	0.5559	74.9212
	Test	9.0551	0.6536	82.4095
4	Apprentissage	3.6989	0.8780	93.7030
	Validation	7.3090	0.5512	76.6415
	Test	4.7815	0.8171	90.4596
5	Apprentissage	8.6210	0.7156	84.7720
	Validation	6.9562	0.5729	77.6256
	Test	8.1218	0.6893	83.0358
6	Apprentissage	11.5793	0.6181	79.3826
	Validation	6.3871	0.6078	78.0949
	Test	10.0222	0.6166	79.1217
7	Apprentissage	3.0236	0.9003	94.8863
	Validation	6.9323	0.5743	75.8475
	Test	4.1957	0.8395	91.6244
8	Apprentissage	8.7103	0.7127	84.7212
	Validation	7.0643	0.5662	75.7174
	Test	8.2167	0.6857	82.9014
9	Apprentissage	7.1049	0.7656	87.8361
	Validation	6.8954	0.5766	76.4630
	Test	7.0421	0.7306	85.6126
10	Apprentissage	8.9408	0.7051	84.9658
	Validation	7.3013	0.5517	74.5492
	Test	8.4492	0.6768	82.9181
11	Apprentissage	6.7980	0.7758	88.6583
	Validation	6.9684	0.5721	76.1020
	Test	6.8491	0.7380	86.1475
12	Apprentissage	10.7606	0.6451	83.5169
	Validation	6.8010	0.5824	76.6566
	Test	9.5732	0.6338	81.9792
13	Apprentissage	11.0699	0.6349	81.9446
	Validation	7.4072	0.5452	73.9071
	Test	9.9715	0.6186	80.2238
14	Apprentissage	13.0888	0.5683	76.4715
	Validation	6.7928	0.5829	77.0551
	Test	11.2008	0.5715	76.6002
15	Apprentissage	7.8466	0.7412	86.3201
	Validation	7.0080	0.5697	76.3026
	Test	7.5951	0.7095	84.4734

La comparaison entre les caractéristiques des débits observées et simulées par le modèle de RNA pour les différentes combinaisons de vecteurs d'entrées proposées dans les phases d'apprentissage, validation et test, sont résumés dans le tableau (IV.3).

Tableau IV.3 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	1.5614	4.5031	2.8840	0.1984	52.6098
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1219	3.3445	2.9810	0.1984	37.6820
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.4296	4.1936	2.9334	0.1984	52.6098
2	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6172	4.1893	2.5905	0.0013	53.1106
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.2636	3.5720	2.8268	0.0080	34.5469
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.5112	4.0167	2.6580	0.0013	53.1106
3	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.6908	3.6138	2.1373	0.0247	36.1275
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.3599	2.9699	2.1839	0.0003	32.0632
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.5916	3.4362	2.1590	0.0003	36.1275
4	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4892	5.1481	3.4570	0	94.7306
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0691	3.8632	3.6137	0.0055	49.7916
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3632	4.8022	3.5227	0	94.7306
5	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5231	4.3744	2.8720	0.0019	42.1944
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1328	3.8278	3.3790	0.0039	36.4839
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.4061	4.2210	3.0020	0.0019	42.1944
6	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4739	3.7666	2.5555	0.0001	30.5740
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0872	2.9704	2.7322	0.0182	24.6560
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3580	3.5505	2.6146	0.0001	30.5740
7	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5009	5.2028	3.4665	0.0003	90.0757
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	0.9929	3.1621	3.1847	0.0013	36.0172
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3485	4.6902	3.4780	0.0003	90.0757
8	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5116	4.2773	2.8297	0.0013	38.5233
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0468	3.3971	3.2450	0.0014	32.5121
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3722	4.0385	2.9431	0.0013	38.5233

9	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.5955	4.4379	2.7815	0.0037	57.6692
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.1762	3.4341	2.9196	0.0024	30.8186
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.4698	4.1661	2.8346	0.0024	57.6692
10	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.7174	4.0130	2.3367	0.0080	45.0587
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.3010	3.1235	2.4009	0.1067	30.0479
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.5925	3.7726	2.3689	0.0080	45.0587
11	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4872	4.3259	2.9087	0	49.3268
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0720	3.4120	3.1829	0.0021	35.3701
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3627	4.0772	2.9920	0	49.3268
12	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.2912	3.3501	2.5946	0.0001	32.8800
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	0.9732	2.8193	2.8971	0.0009	24.4820
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.1958	3.2029	2.6785	0.0001	32.8800
13	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.4587	3.4592	2.3714	0.0067	26.3134
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.0993	2.8563	2.5983	0.0301	26.6364
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.3509	3.2936	2.4380	0.0067	26.6364
14	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.9499	4.7231	2.4222	0.0001	31.6844
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.3380	3.4349	2.5671	0.0020	28.1514
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.7664	4.3851	2.4825	0.0001	31.6844
15	Apprentissage	Observée	1.4606	5.5077	3.7707	0	91.9000
		Simulée	1.8057	4.7432	2.6268	0.0007	52.2996
	Validation	Observée	1.0688	4.0382	3.7784	0	42.3000
		Simulée	1.3220	3.4556	2.6140	0.0063	30.6291
	Test	Observée	1.3431	5.1139	3.8075	0	91.9000
		Simulée	1.6606	4.4018	2.6506	0.0007	52.2996

Les figures (Figure IV.17 a IV.31) offrent la comparaison entre les débits observés et les débits simulés par RNA pour les différentes combinaisons optimales de vecteurs d'entrées proposées dans les phases d'apprentissage et validation.

Modèle 1

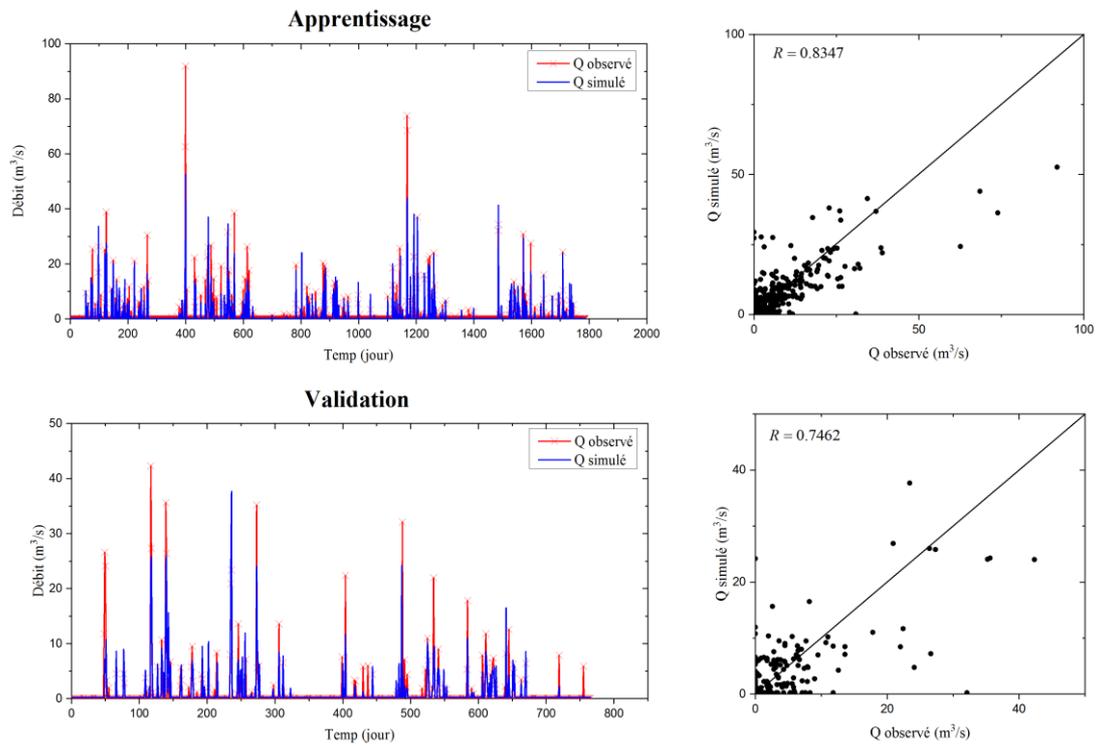


Figure IV.17 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 1 dans les phases d'apprentissage et validation.

Modèle 2

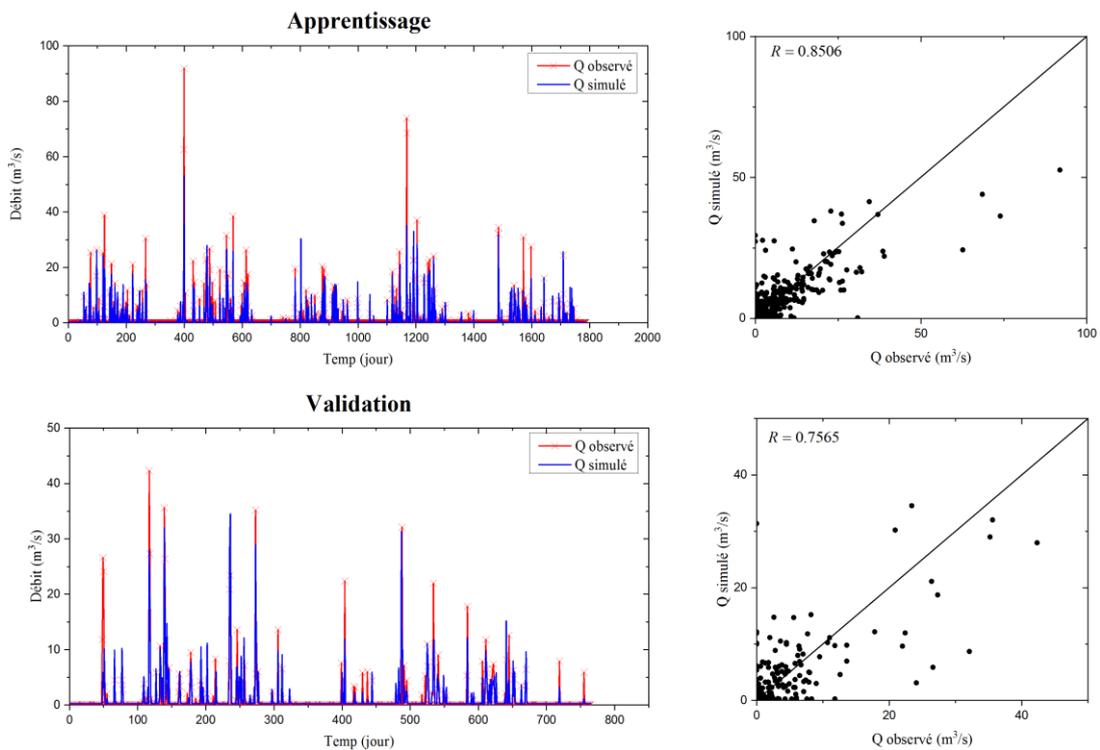


Figure IV.18 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 2 dans les phases d'apprentissage et validation.

Modèle 3

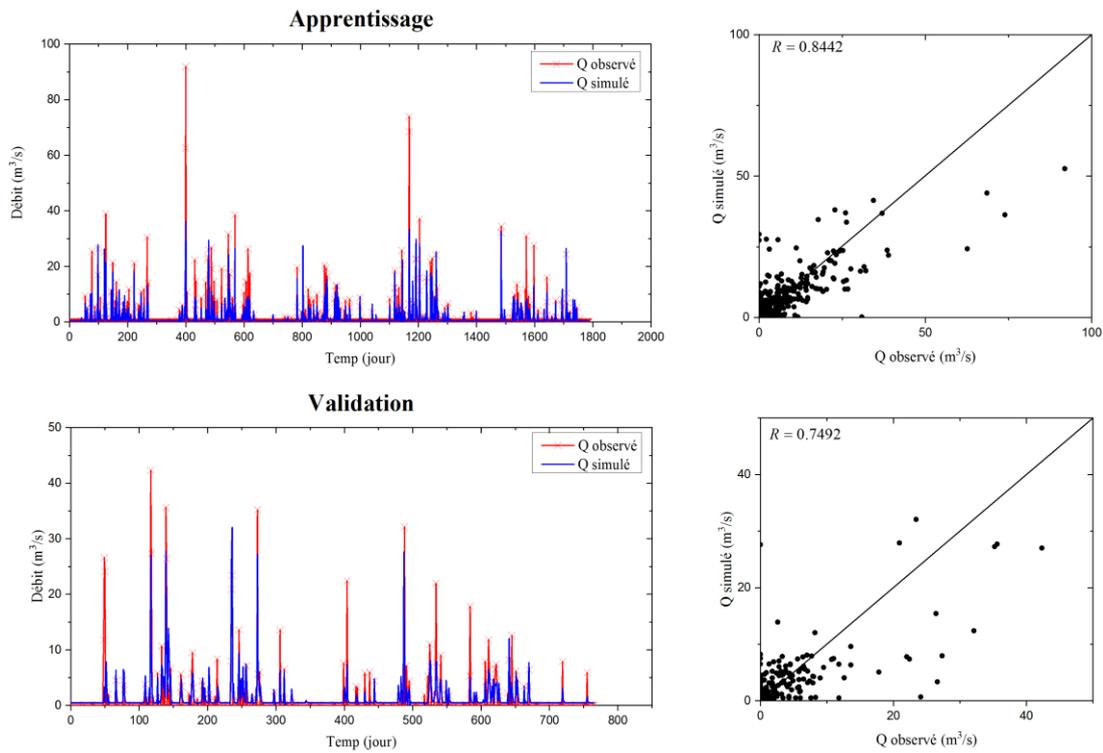


Figure.IV.19 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 3 dans les phases d'apprentissage et validation.

Modèle 4

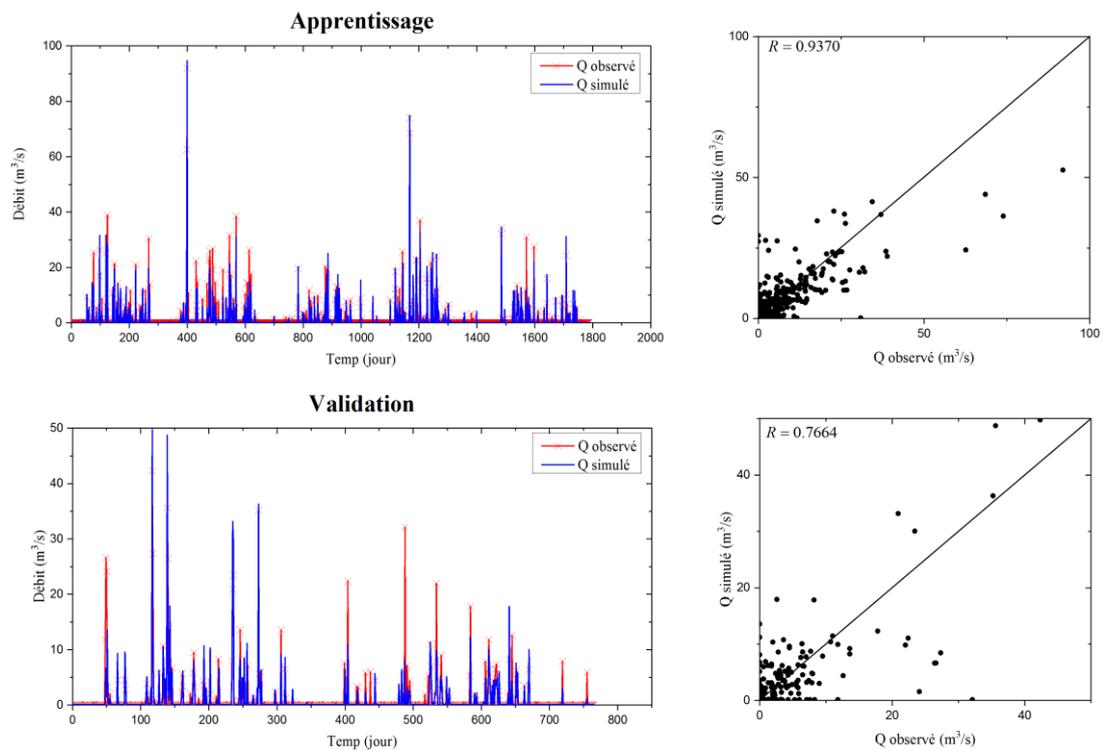


Figure IV.20 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 4 dans les phases d'apprentissage et validation.

Modèle 5

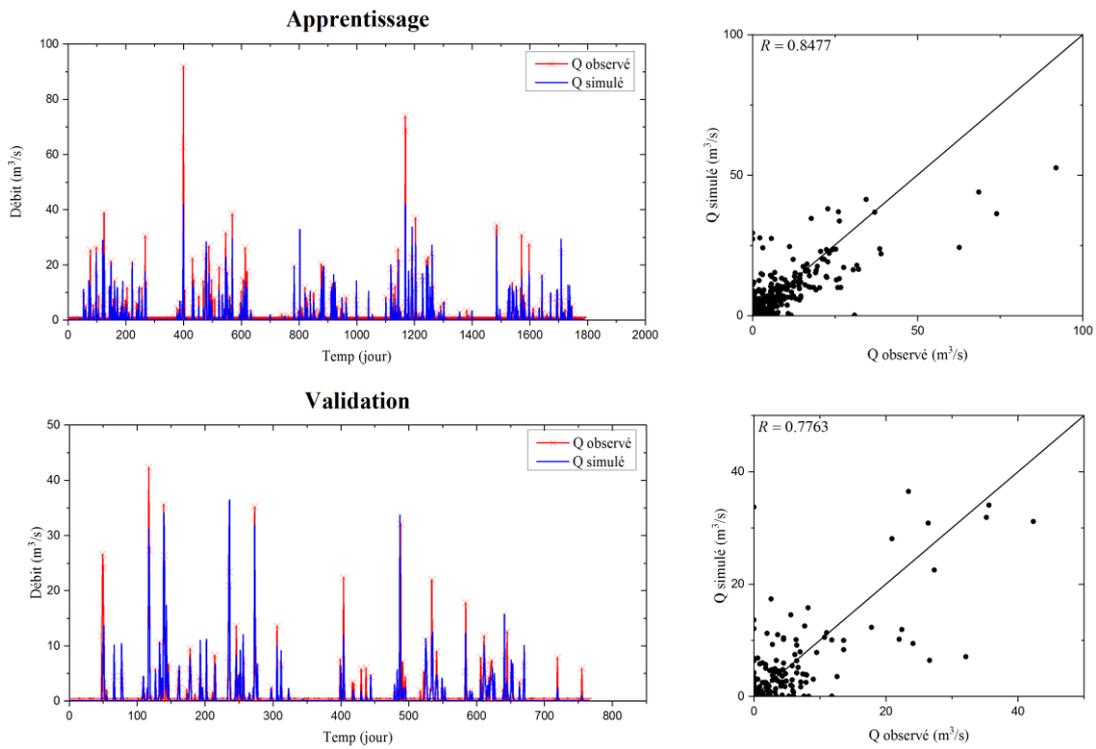


Figure IV.21. : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 5 dans les phases d'apprentissage et validation.

Modèle 6

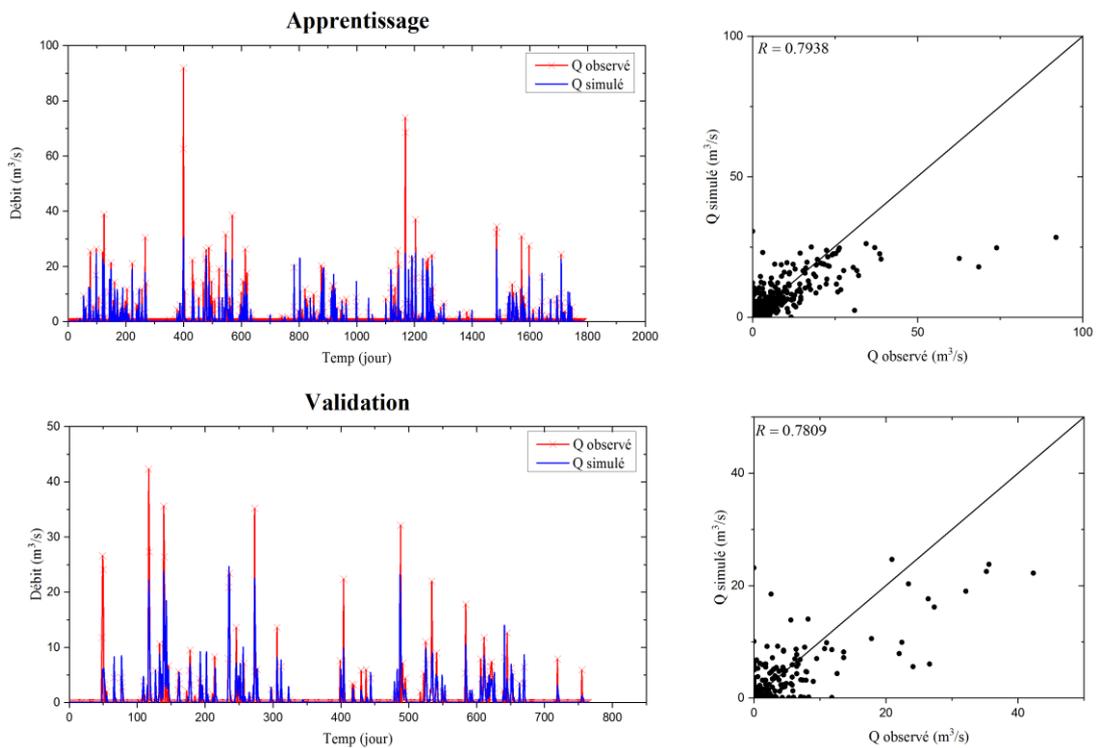


Figure IV.22 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 6 dans les phases d'apprentissage et validation.

Modèle 7

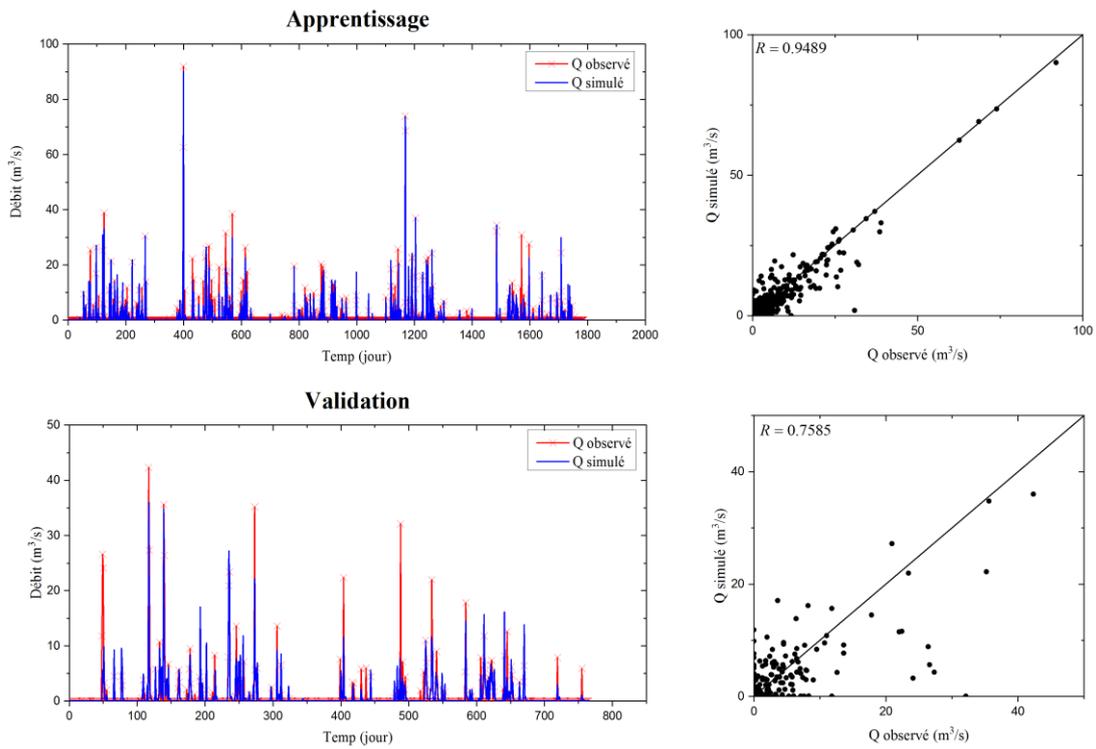


Figure IV.23 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 7 dans les phases d'apprentissage et validation.

Modèle 8

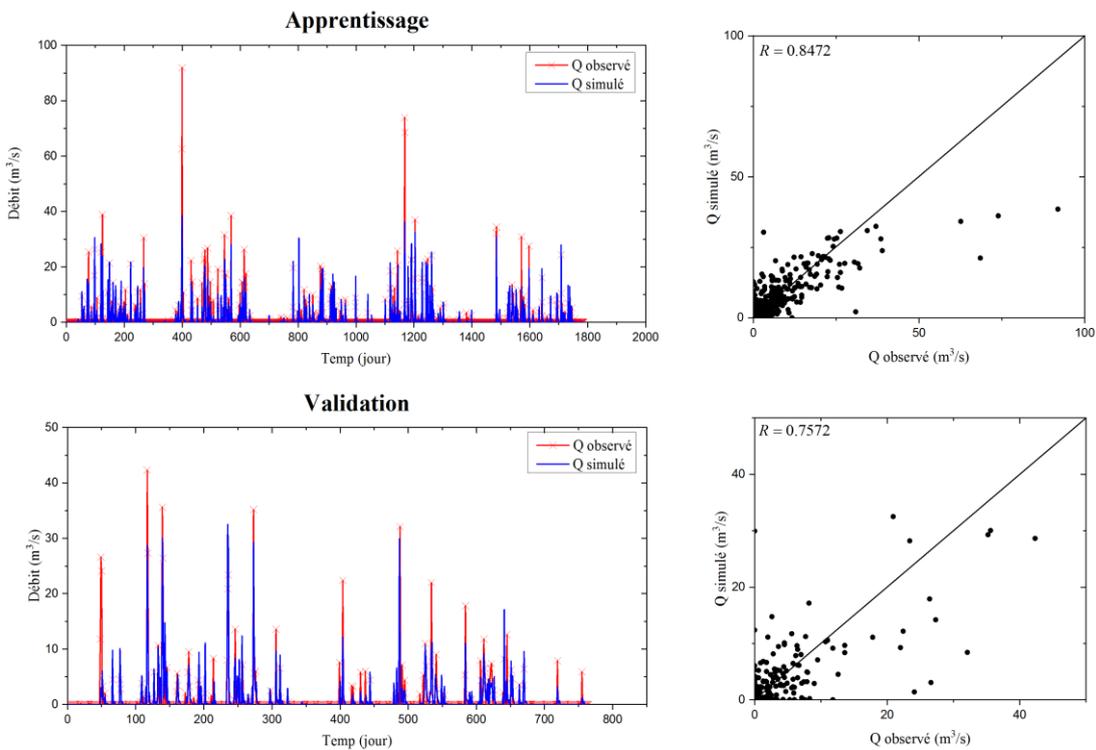


Figure IV.24 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 8 dans les phases d'apprentissage et validation.

Modèle 9

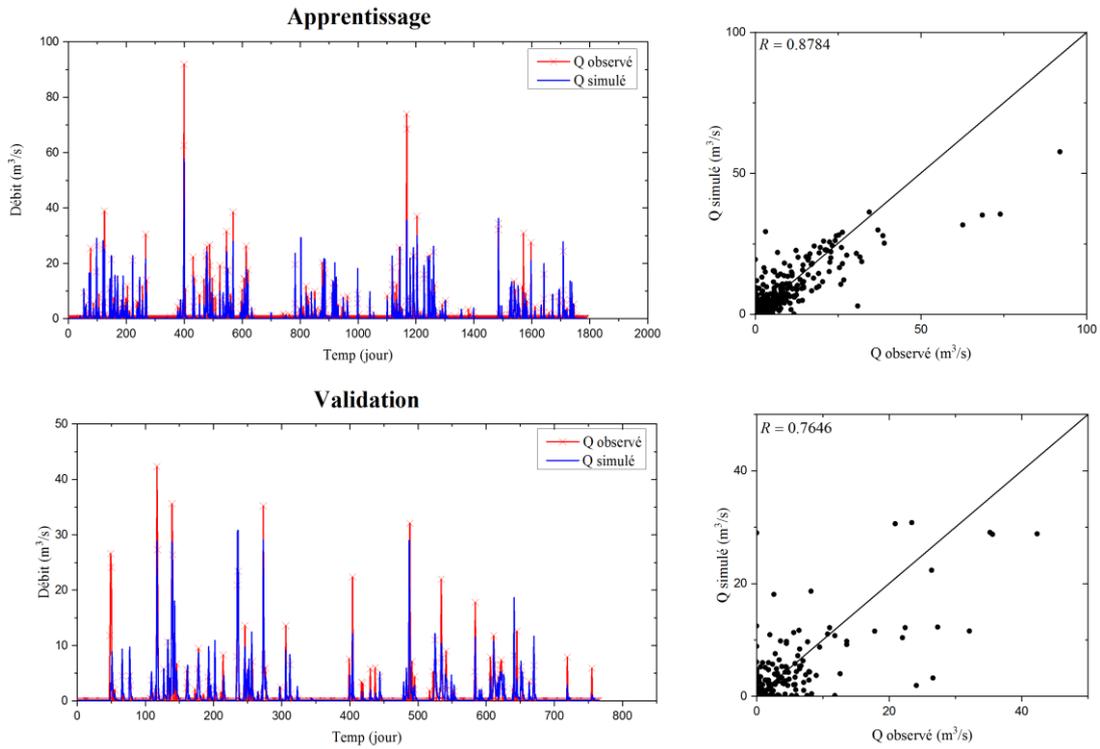


Figure IV.25 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 9 dans les phases d'apprentissage et validation.

Modèle 10

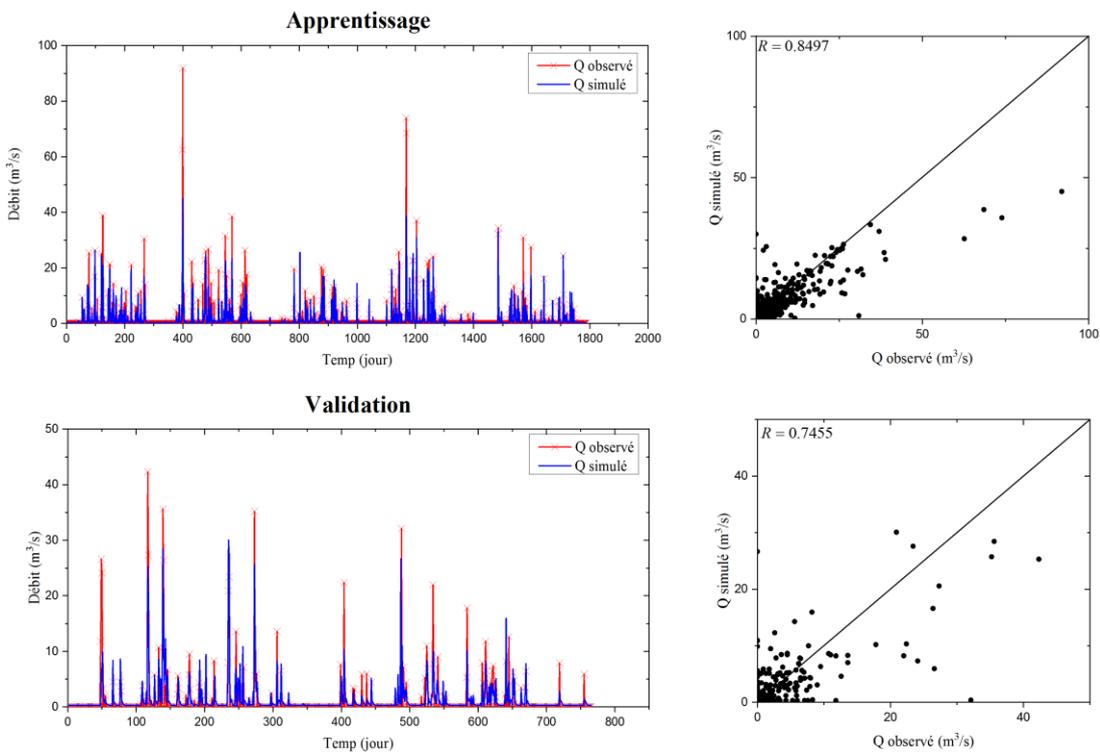


Figure IV.26 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 10 dans les phases d'apprentissage et validation.

Modèle 11

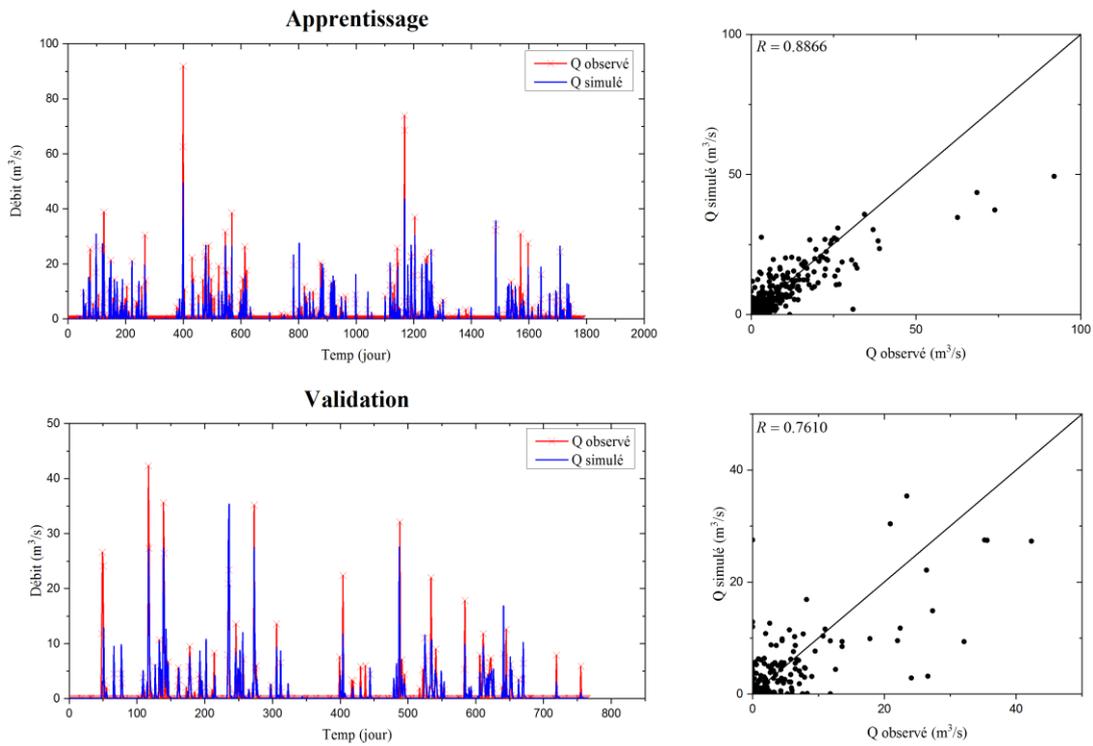


Figure IV.27 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 11 dans les phases d'apprentissage et validation.

Modèle 12

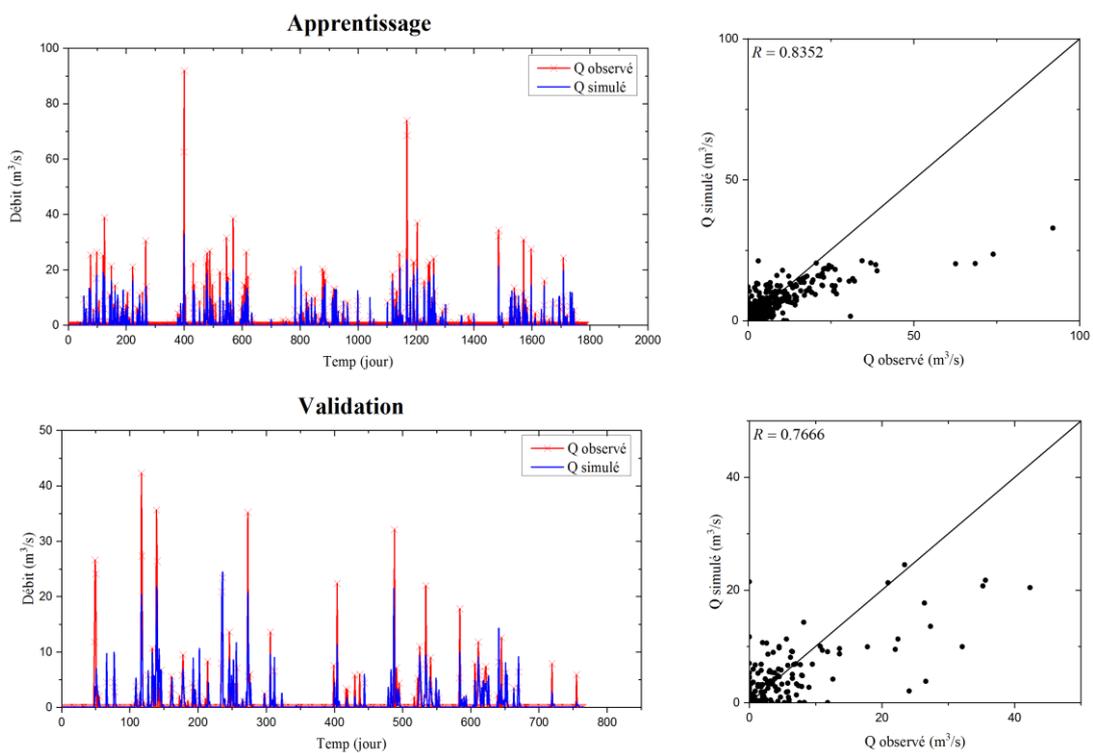


Figure IV.28 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 12 dans les phases d'apprentissage et validation.

Modèle 13

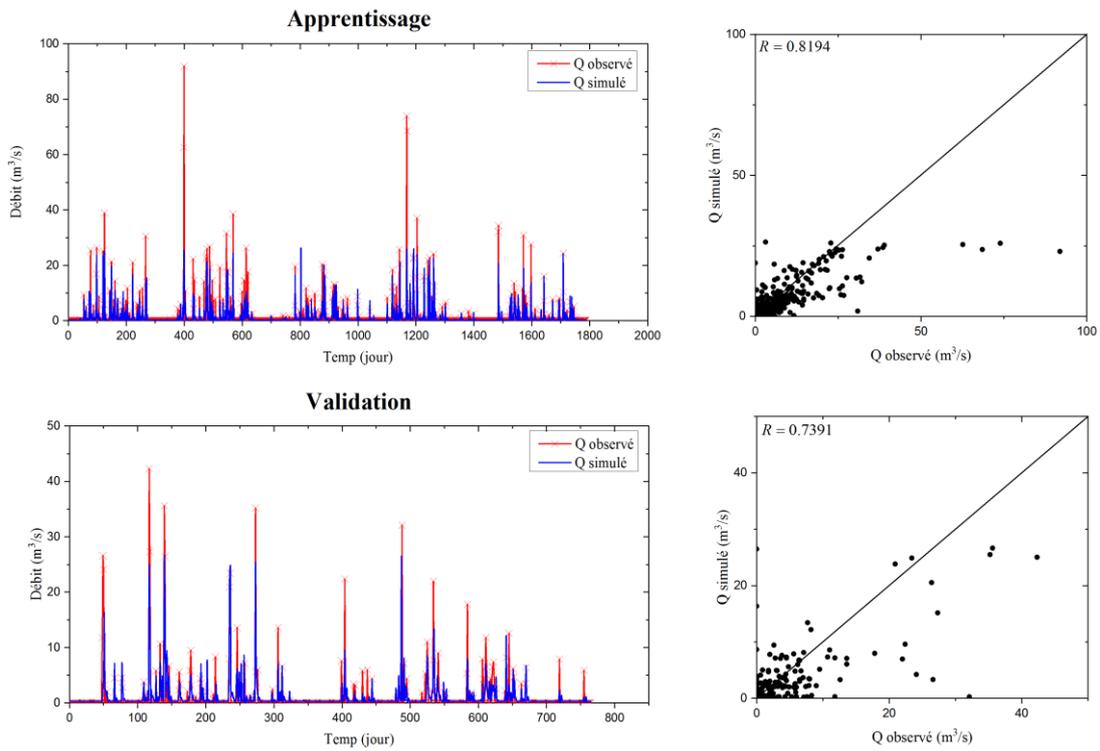


Figure IV.29 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 13 dans les phases d'apprentissage et validation.

Modèle 14

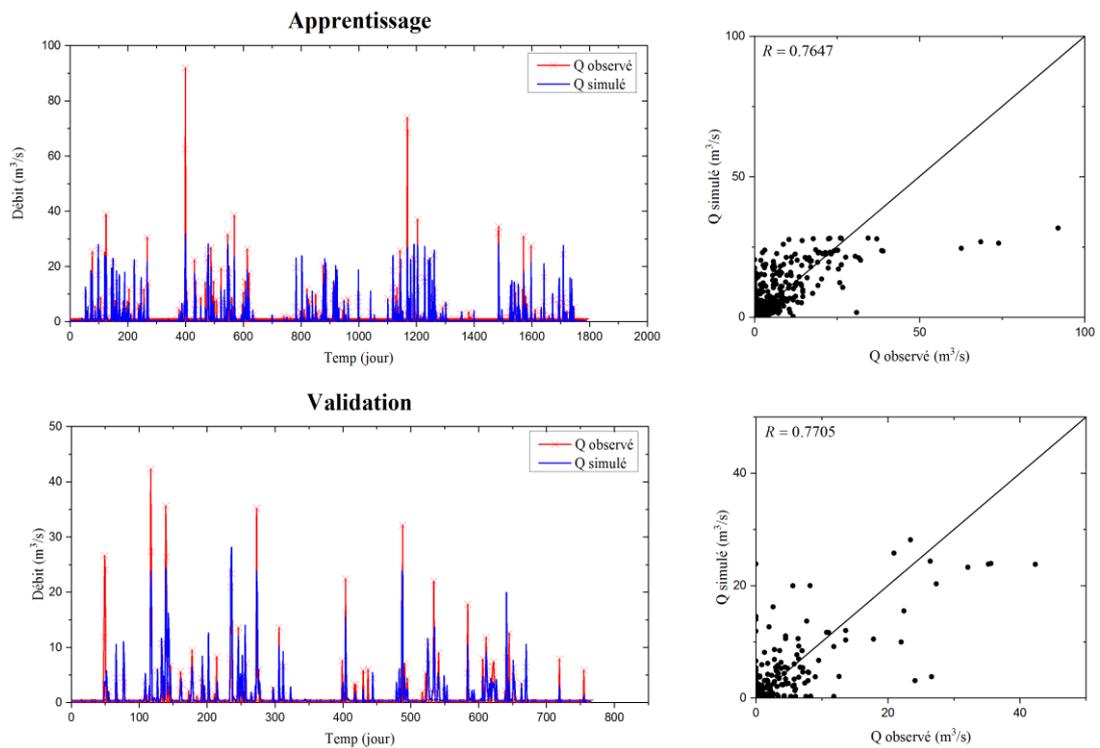


Figure IV.30 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 14 dans les phases d'apprentissage et validation.

Modèle 15

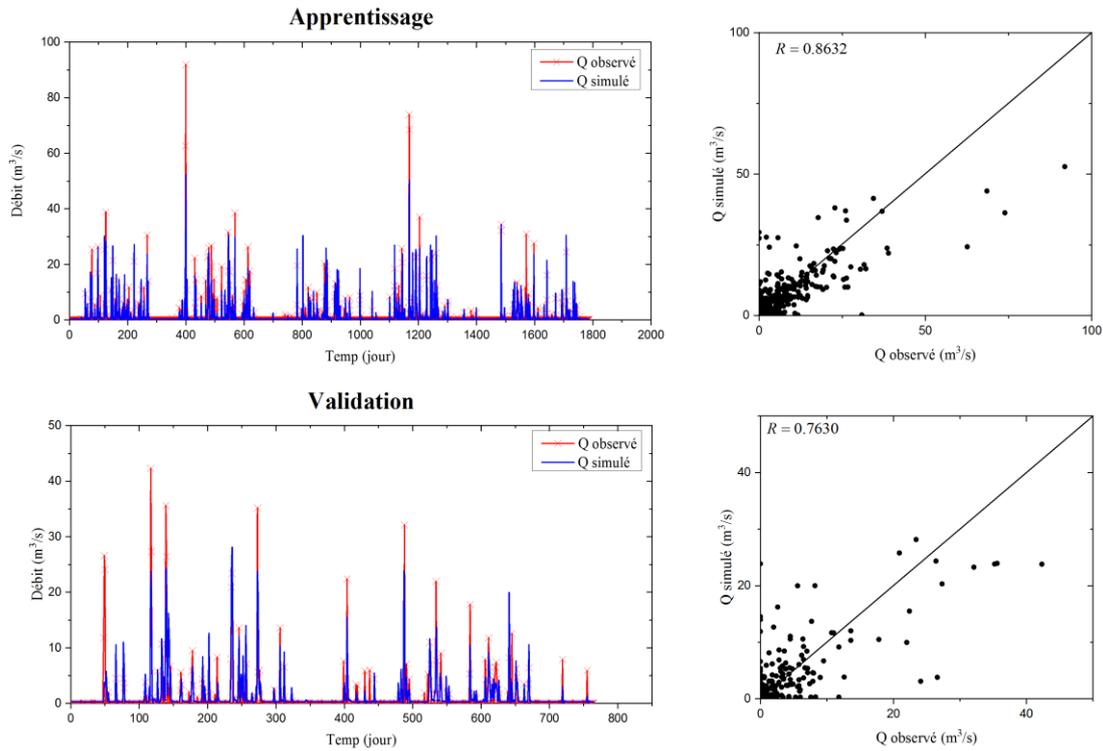


Figure IV.31 : Comparaison entre les débits observés et les débits simulés par RNA pour le modèle optimal des vecteurs 15 dans les phases d'apprentissage et validation.

Pour évaluer les performances de modèle RNA, une comparaison a été faite sur la phase de test avec le modèle classique de régression linéaire multiple (RLM). L'application de ce modèle a été faite sur le même ensemble des données d'entrée de RNA qui donne des meilleures performances (P_{t+1} , Q_t , Q_{t-1} et Q_{t-2}). Le Tableau IV.4 présente les résultats obtenus par ces modèles (RNA et RLM) dans la phase de test.

Tableau IV.4 Comparaison entre les résultats obtenus par RNA par rapport à RLM sur la phase de test.

Modèle	ASE	E	R(%)
<i>RNA</i>	4.1957	0.8395	91.6244
<i>RLM</i>	6.9706	0.7334	85.6360

La comparaison des performances des modèles indique que le modèle RNA avec la combinaison des vecteurs d'entrées 7 est un bon modèle pour modéliser la relation pluie-débit par rapport les autres combinaisons des vecteurs d'entrées.

Les résultats montrent que le modèle RNA est efficace que le modèle linéaire classique RLM dans la prévision des débits journalière. Cette performance reflète la force et la précision des sorties de modèle de RNA grâce à l'algorithme d'apprentissage qui lui permet de donner les bonnes décisions pour calculer les sorties.

Conclusion

Ce projet consiste à réaliser une analyse comparative de 15 structures de RNA différentes pour prédire les débits journaliers du bassin de l'Oued Hachem, situé dans la région de Tipaza, au nord de l'Algérie. Cette étude se base sur l'utilisation de données d'observation des précipitations et des débits des jours précédents.

Les résultats obtenus dans cette étude démontrent l'efficacité des systèmes d'intelligence artificielle basés sur les RNA par rapport aux modèles classiques traditionnels basés sur les RLM pour la modélisation de la relation pluie-débit et la prévision des écoulements. Les modèles de prévision ont été développés en utilisant des données historiques fournies, et leurs performances ont été évaluées en utilisant des métriques telles qu'ASE, E et R. Les résultats indiquent une meilleure performance des RNA par rapport aux RLM, en se basant sur les mesures d'ASE entre les débits simulés et observés.

Une analyse comparative des résultats révèle que la technique de RNA utilisant le modèle des vecteurs 7 offre des prévisions plus efficaces que les autres modèles. En d'autres termes, les performances de prévision hydrologique du RNA avec le modèle des vecteurs 7 surpassent celles des autres modèles. Cette étude confirme que le système intelligent basé sur les RNA est l'une des meilleures techniques pour modéliser la relation non linéaire entre les entrées et les sorties. Il peut être utilisé pour une gestion efficace des risques et la prévision des débits afin de réduire les risques d'inondations dans les bassins hydrologiques.

Ces résultats prometteurs ouvrent de nombreuses perspectives, notamment l'exploration de modèles hybrides intelligents qui combinent les réseaux de neurones artificiels avec les systèmes flous. Cette approche pourrait être très intéressante et permettrait d'exploiter les avantages des deux techniques pour des prévisions encore plus précises et fiables.

Référence

[¹] Rajurkar, M. P., Kothiyari, U. C., and Chaube, U. C., 2002. Artificial neural networks for daily rainfall—runoff modelling, *Hydrological Sciences Journal*, 47:6, 865-877.

[²] Abda, Z., Chettih, M., & Zerouali, B. (2021). Assessment of neuro-fuzzy approach based different wavelet families for daily flow rates forecasting. *Modeling Earth Systems and Environment*, 7(3), 1523-1538.

[³] Abda, Z., Zerouali, B., Chettih, M., Guimaraes Santos, C. A., de Farias, C. A. S., & Elbeltagi, A. (2022). Assessing machine learning models for streamflow estimation: a case study in Oued Sebaou watershed (Northern Algeria). *Hydrological Sciences Journal*, 67(9), 1328-1341.

[⁴] El-Shafie, A., Taha, M. R., and Noureldin, A., 2007. A neuro- fuzzy model for inflow forecasting of the Nile river at Aswan high dam, *Water Resour Manage*, 21:533–556.

[⁵] Pramanik, N. and Panda, R. K., 2009. Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction, *Hydrological Sciences Journal*, 54:2, 247-260.

[⁶] El-Shafie, A., Jaafer, O., and Seyed, A., 2011. Adaptive neuro- fuzzy inference system based model for rainfall forecasting in Klang River, Malaysia, *International Journal of the Physical Sciences*, Vol. 6(12), 2875-2888.

[⁷] Emiroglu, M. E. and Kisi, O., 2013. Prediction of Discharge Coefficient for Trapezoidal Labyrinth Side Weir Using a Neuro-Fuzzy Approach, *Water Resour Manage*, 27:1473 – 1488.

[⁸] AHMAIDI ABIR, 2022 , PREVISION DES PLUIES MENSUELLES A L'AIDE DES TECHNIQUES D'APPRENTISSAGE AUTOMATIQUE ET LES INDICES DE CIRCULATION A GRANDE ECHELLE: CAS DU BASSIN VERSANT DE LA SEBAOU (NORD CENTRAL DE L'ALGERIE) , MEMOIRE FIN D'ETUDE , Université Hassiba Benbouali de Chlef.

[⁹] <http://eduterre.ens-lyon.fr/thematiques/hydro/cycleau/modeliser>

[¹⁰] Musy A. et Higy C., 2004. *Compte rendu d'Hydrologie (1. Une science de la nature)*, Presses polytechniques et universitaires romandes, (21), 314 p.

- [¹¹] <https://epaga-aulne.bzh/739-2/>
- [¹²] Gilbert Castany. (1998). Hydrogéologie : principes et méthodes. 1 vol. (XVIII-236 p.) : ill. ; 24 cm
- [¹³] (<http://www4.agr.gc.ca/AAFC-AAC/display-afficher.do?id=1267805731369&lang=fra>).
- [¹⁴] hugolescargot.journaldesfemmes.fr
- [¹⁵] Bendaoud hadjer 2018 modélisation pluie-débit par le modèle conceptuel GR2M : cas des bassins versant de L'OUED ZEDDINE Projet de Fin d'Études Blida Dahleb Saad Université
- [¹⁶] 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.
- [¹⁷] www.gerbeaud.com Le 1er mars 2018 par Clémentine Desfemmes
- [¹⁸] Djellouli et Daget (1993)
- [¹⁹] Kettab, A., Mouhoub, A., Ouarda, T., & Bobbee, B (2002). Contribution à l'étude du phénomène de la sécheresse sur les régions littorales de l'Algérie.
- [²⁰] Khoualdia W (2009). Etude statistique du régime pluviométrique Cas de la ville Souk-Ahras. Thèse de Magister en Ressources Hydriques. Centre Universitaire de Souk-Ahras
- [²¹] Youcef Djeriri 2017 Les Réseaux de Neurones Artificiels University of Sidi-Bel-Abbes
- [²²] 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).
- [²³] Zhang, X., Mohanty, S. N., Parida, A. K., Pani, S. K., Dong, B., & Cheng, X. (2020). Annual and non-monsoon rainfall prediction modelling using SVR-MLP: an empirical study from Odisha. *IEEE Access*, 8, 30223-30233.
- [²⁴] Vuyyuru, V. A., Rao, G. A., & Murthy, Y. V. (2021). A novel weather prediction model using a hybrid mechanism based on MLP and VAE with fire-fly optimization algorithm. *Evolutionary Intelligence*, 14(2), 1173-1185.

- [²⁵] Vivekanandan, N. (2021). Comparison of MLP and RBF Networks for Prediction of Rainfall for Pune and Mahabaleshwar Regions. *i-Manager's Journal on Future Engineering and Technology*, 16(3), 8
- [²⁶] Appiah-Badu, N. K., Missah, Y. M., Amekudzi, L. K., Ussiph, N., Frimpong, T., & Ahene, E. (2021). Rainfall Prediction Using Machine Learning Algorithms for the Various Ecological Zones of Ghana. *IEEE Access*.
- [²⁷] Hastie, T. J., & Tibshirani, R. J. (2017). *Generalized additive models*. Routledge.
- [²⁸] Nayak, D. R., Mahapatra, A., & Mishra, P. (2013). A survey on rainfall prediction using artificial neural network. *International Journal of Computer Applications*, 72(16).
- [²⁹] Mishra, N., Soni, H. K., Sharma, S., & Upadhyay, A. K. (2018). Development and Analysis of Artificial Neural Network Models for Rainfall Prediction by Using Time-Series Data. *International Journal of Intelligent Systems & Applications*, 10(1).
- [³⁰] Abhishek, K., Kumar, A., Ranjan, R., & Kumar, S. (2012, July). A rainfall prediction model using artificial neural network. In *2012 IEEE Control and System Graduate Research Colloquium* (pp. 82-87). IEEE.
- [³¹] Gomes, E. P., & Blanco, C. J. C. (2021). Daily rainfall estimates considering seasonality from a MODWT-ANN hybrid model. *Journal of Hydrology and Hydromechanics*, 69(1), 13-28.
- [³²] Ghamariadyan, M., & Imteaz, M. A. (2021). A wavelet artificial neural network method for medium-term rainfall prediction in Queensland (Australia) and the comparisons with conventional methods. *International Journal of Climatology*, 41, E1396-E1416.
- [³³] Astutik, S., Pramoedyo, H., Rahmi, N. S., Irsandy, D., & Damayanti, R. H. P. Y. (2021, November). Rainfall Data Modeling with Artificial Neural Networks Approach. In *Journal of Physics: Conference Series* (Vol. 2123, No. 1, p. 012029). IOP Publishing.
- [³⁴] Kohonen, T. (1984): *Self-Organization and Associative Memory*, Berlin: Springer- Verlag.

[³⁵] 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

[³⁶] Lippmann, R, P, (1987): An Introduction to Computing with Neural Nets. IEEE ASSP Magazine, April 1987, 4 (2), pp.4-22.

[³⁷] Najjar, Y. ; Zhang, X, (2000): Characterizing the 3D Stress-Strain Behavior of sandy Soils: A Neuro-Mechanistic Approach. ASCE Geotechnical Special Publication No. 96, Filz, G. and Griffiths, D. (Editors) : pp. 43-57.

[³⁸] Najjar, Y. ; Ali, H, (1998a): On the Use of BPNN in Liquefaction Potential Assessment Tasks. Artificial Intelligence and Mathematical Methods in Pavement and Geomechanical Systems, Attoh- Okine (Editor): pp. 55-63.

[³⁹] Najjar, Y. ; Ali, H, (1998b): CPT-Based Liquefaction Potential Assessment: A Neuronet Approach. ASCE Geotechnical Special Publication No.75, Dakoulas, P. et. Al. (Editors), (1): pp. 542- 553.

[⁴⁰] Riad, S. ; Mania, J. ; Bouchaou , L. ; Najjar, Y, (2004): Predicting Catchment Flow In A Semi-Arid Region Via An Artificial Neural Network Technique. Hydrological processes hydrol. process. 18, pp. 2387–2393.

[⁴¹] Dawson, C, W. ; Wilby, R, L, (1998): An artificial neural network approach to rainfall-runoff modelling. Hydrological Sciences Journal, 43 (1), pp. 47-66.

[⁴²] Yonaba, Harouna, (2009) : Modélisation Hydrologique Hybride Réseau De Neurones - Modèle Conceptuel. Thèse Doctor (Ph.D) université laval québec. 97p

[⁴³] M. Belmadani Djalel etM. 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

[⁴⁴] Tadrict N., Debauche O., Remini B. et al 2016. Le diagramme des textures américain montre une20(4), 453-467

[⁴⁵] HALLOUCHE W. (2007). Studying Sediment. Revue International Water Power et Dam construction. Octobre, 42-45.

[⁴⁶] Agence Nationale des Ressources Hydrauliques (anrh)

[⁴⁷] Satin M , Régis R , Selm B (2006) Guide technique de l'assainissement

[⁴⁸] HUFTY, A., (2001) Introduction à la climatologie. De Boeck université. Laval. Canada. 542p.

[⁴⁹] Abda Zaki (2018). Modélisation de la relation pluie-débit à l'aide des systèmes hybrides intelligents pour la prévision des crues en Algérie. Thèse Doctorat, Université Amar Téliidji Laghouat 2019