

Remerciement

Je débute avant tout mes remerciements à DIEU sans qui je ne serai ce que je suis.

Je remercie le professeur Lahbassi OUERDACHI, directeur du Laboratoire d'Hydraulique et de Constructions Hydrauliques de l'université de Annaba, mon directeur de thèse, pour son soutien et son aide tout au long de mon parcours universitaire

Je remercie aussi les examinateurs: Pr. Djamel BOUTOUTAOU, Pr. Yacine DJEBAR, Dr. Aziez ZEDDOURI et également Abd El Ouahed KRIKER d'avoir accepté de présider le jury de soutenance.

Un grand merci aux professeurs qui m'ont soutenu, aidé et encouragé afin d'accomplir ce travail de thèse, tout particulièrement le Dr. Hamouda BOUTAGHANE pour sa disponibilité indéfectible tout au long de mon cursus, ainsi que le Pr. Charles PERRIN et ses orientations judicieuses sur la modélisation hydrologique.

Je remercie chaleureusement mes collègues pour leurs soutiens techniques et moraux, sans être exhaustif je citerai : Ala Eddine TIFRANI, Mohamed Amine HEBBACH, Hichem CHERRAD, Mehdi KEBLOUTI, Sabri BERHAIL.

Je tiens à remercier le collectif de l'université Kasdi Merbah Ouargla pour leurs collaborations et leurs accueil.

Mes remerciements vont aussi pour mes amis, Khairo, Ramzi, Ahmed, Issam, Khaled A. et Yassine, sans oublier Khaled B., Ali, Kacem qui ont été à mes côtés dans les moments les plus difficiles.

Ce travail est dédié :

A la mémoire de ma défunte mère

A mon père et mes sœurs Sara et Amel

A mon épouse Besma et mon petit ange Célia

Résumé : Contribution dans la modélisation de la relation pluie-débits

Le but de cet étude est de modéliser le phénomène de la relation pluie-débit, pour y arriver, trois approches différentes sont testées : modélisation conceptuelle, modélisation avec deux des méthodes issus de l'intelligence artificiel (un réseau de neurones artificiel et un système d'inférence à base de réseau adaptatif) et enfin une combinaison des modèles conceptuel et neuronal. Les résultats obtenus ont démontré que cette dernière approche est la plus robuste par rapport aux autres approches testées et c'est celle qui est préconisé, que ce soit en termes de prévision des crues ou de gestion de la ressource en eau.

Môts-clés : Pluie-débit, GR4j, Réseau de Neurone Artificiel, RNA, Système d'inférence flou à base de réseau adaptatif, ANFIS, mise à jour de modèle hydrologique, Oued Rassoul.

Abstract: Contribution in modeling rainfall-runoff relationship

The aim of this study is to model the rainfall runoff relationship phenomenon, in reach this objective, three different approaches were tested: conceptual modeling, modeling with two artificial intelligence model (artificial neural network and an adaptive-network-based fuzzy inference system) and finally, a combination of the conceptual and neuronal models. Obtained results showed that this last approach is the most robust compared with other approaches and is the one which recommend, whether in terms of flood forecasting or management of water resource.

Keywords: Rainfall-runoff, GR4j, Artificial Neural Network, ANN, daptive-Network-based Fuzzy Inference System, ANFIS, hydrological model updating, Oued Rassoul.

ملخص : المساهمة في نمذجة العلاقة بين الأمطار والجريان السطحي

الهدف من هذه الدراسة هو نمذجة هذه ظاهرة علاقة تساقط - تدفق, للوصول الى ذلك, تم اختبار ثلاثة نهج مختلفة: النمذجة التصورية، والنمذجة باستعمال نموذجين من الذكاء الاصطناعي (الشبكة العصبية الاصطناعية و منطق الاستدلال الضبابي القائم على شبكة التكيف) وأخيرا مزيج من النموذجين التصوري و الشبكي العصبي. النتائج المتحصل عليها بينت ان هذا النهج الاخير يعتبر الاكثر قوة من بين النماذج الاخرى و هو النهج الذي ينصح استعماله سواء كانت في الوقاية من الفيضانات او تسيير الموارد المائية.

الكلمات الجوهرية : تساقط - تدفق, الشبكة العصبية الاصطناعية, منطق الاستدلال الضبابي القائم على شبكة التكيف, تحديث نموذج هيدرولوجي, واد غسول.

Table des matières

Résumé	03
Abstract.....	03
ملخص.....	03
Table des matières.....	04
Liste des tableaux.....	12
Liste des figures.....	13
Liste des notations.....	16
INTRODUCTION.....	17
CHAPITRE 1 : Site d'étude et base de données	17
1.1. Introduction	18
1.2. Situation géographique	18
1.3. Caractéristique du sous bassin	19
1.4. L'urbanisation dans le sous bassin	22
1.5. Aménagement agricole	23
1.6. Géologie du sous bassin	25
1.7. Station hydrométrique de Oued Rassoul	26
1.8. Caractéristique de la station de jaugeage.....	27
1.9. Base de donnée	29
1.9.1. La pluie.....	31
1.9.2. L'évapotranspiration potentielle.....	34
CHAPITRE 2 Modélisation conceptuel de la relation pluie débit	37
2.1. Introduction	38
2.2. Les différents modèles conceptuels	38
2.3. Choix d'un modèle conceptuel	42
2.4. Le modèle GR4J	43

2.4.1.	Description du modèle	44
2.5.	Calage des modèles conceptuel	45
2.5.1.	La fonction objective.....	47
2.5.2.	Les algorithmes d'optimisation.....	48
2.6.	Les données de calibration et de test	53
2.7.	Les paramètres initiaux.....	54
2.8.	Résultats et discussion	54
2.9.	Conclusion.....	61
CHAPITRE 3 Modèles d'intelligence artificielle et relation pluie-débit.....		63
3.1.	Introduction	64
3.2.	Les réseaux de neurones artificiels	64
3.2.1.	Historique des RNA	64
3.2.2.	Neurone biologique	65
3.2.3.	Neurone formel	66
3.2.4.	Classification topologique des réseaux de neurones	70
3.2.5.	Apprentissage des RNA	73
3.2.6.	Réseau de neurone et relation pluie débit.....	75
3.3.	Les modèles neuro flous	78
3.3.1.	Historique des modèles neuro flou.....	78
3.3.2.	Les ensembles flous	79
3.3.3.	Opérateurs logiques flous.....	81
3.3.4.	Règles floues	82
3.3.5.	Principe de fonctionnement de ANFIS	86
3.3.6.	ANFIS et relation pluie-débit.....	90
3.4.	Type d'utilisation des modèles RNA et ANFIS	91
CHAPITRE 4 Application du modèles RNA et ANFIS dans la relation pluie-débit.....		93
4.1.	Introduction	94

4.2.	Réseau de neurone artificiel	94
4.2.1.	Architecture	94
4.2.2.	Apprentissage	95
4.2.3.	Normalisation des données.....	98
4.3.	Modèle neuro-flou	98
4.3.1.	Architecture	98
4.3.2.	Apprentissage	99
4.3.3.	Transformation des données.....	99
4.4.	Division des données	100
4.5.	Détermination des entrées pour les RNA et ANFIS.....	101
4.6.	Evaluation du modèle	102
4.7.	Résultats et discussion	102
4.7.1.	Application du RNA.....	102
4.7.2.	Application du ANFIS	108
4.8.	Conclusion	116
CHAPITRE 5 Mise à jour du modèle conceptuel avec les réseaux neuronaux		118
5.1.	Introduction	119
5.2.	Le réseau de neurone	120
5.3.	Division des données	120
5.4.	Calage de GR4j et apprentissage du RNA.....	121
5.5.	Sélection des données d'entrées du réseau de neurone	121
5.6.	Résultats et discussion	122
5.7.	Conclusion	126
CHAPITRE 6 Etude comparative des approches appliquées.....		128
6.1.	Introduction	129
6.2.	Comparaison par rapport aux performances.....	129
6.3.	Comparaison par rapport aux entrées de pluie	131

6.4.	Comparaison par rapport aux pics de débit	133
6.5.	Comparaison par rapport aux apports.....	135
CONCLUSION.....		151
BIBLIOGRAPHIE.....		156
ANNEXE.....		163

Liste des tableaux

- Tableau 1.** Répartition des surfaces en fonction des altitudes
- Tableau 2.** Récapitulatif des caractéristiques du sous bassin de Oued Rassoul
- Tableau 3.** Surfaces et périmètres des communes appartiennent au bassin versant
- Tableau 4.** Description des retenues collinaires existantes dans Medjez Ressoul.
- Tableau 5.** Model Conceptuel en continue (tirée de Singh 2002)
- Tableau 6.** Valeurs médiane des paramètres du modèle ainsi que leurs approximations dans un intervalle de confiance de 80 %
- Tableau 7.** Résultats du modèles GR4j utilisant les différentes entrées de pluie
- Tableau 8.** Simulation du modèle GR4j utilisant les différentes entrées de pluie et différents paramètres initiaux
- Tableau 9.** Résultats des simulations du modèle RNA utilisant différentes entrées de pluies
- Tableau 10.** Résultats des simulations de modèle ANFIS utilisant différentes entrées de pluies
- Tableau 11.** Résultats de la simulation du modèle NUCM
- Tableau 12.** Performances de tous les modèles utilisés dans l'étude
- Tableau 13.** Performances des modèles GR4j, RNA, ANFIS et NUCM en fonction des entrée des pluies P5, P6, Par et Pth
- Tableau 14.** Pics du débit utilisés dans la comparaison des modèles
- Tableau 15.** Simulation des pics de débit pendant la phase test pour les modèles GR4j, ANN, ANFIS, NUCM
- Tableau 16.** Apports annuelles observés et simulés par les modèles GR4j, RNA, ANFIS et NUCM

Liste des figures

- Figure 1.** Vue en plan du raccordement d'oued Ressoul avec l'Oued de la Seybouse.
- Figure 2.** Localisation du sous bassin de oued Rassoul dans le bassin de la Seybous
- Figure 3.** Courbe hypsométrique du sous bassin versant de Oued Rassoul
- Figure 4.** Relief et talwegs du sous bassin de Oued Rassoul
- Figure 5.** Carte des pentes du sous bassin de Oued Rassoul
- Figure 6.** Emplacement des centres urbains dans le sous bassin de Oued Rassoul
- Figure 7.** Les différents bassins des retenues collinaires du bassin de Medjez Ressoul Ain Berda.
- Figure 8.** Carte géologique de la ville d'Annaba tirée de (Djabri et al. 2003)
- Figure 9.** Vue en plan de la station hydrométrique Ain Berda
- Figure 10.** Plan de situation d'oued Ressoul Ain Berda (Jacon, 1986)
- Figure 11.** Photo d'un seuil-jaugeur Parshall
- Figure 12.** Observation journalière du débit utilisé dans l'étude
- Figure 13.** Pluies journalières moyennes annuelles mesurées sur les stations 140605 et 140606
- Figure 14.** Histogramme des nombre de jour dont la pluie est au-dessus de la pluie moyenne
- Figure 15.** Division des surfaces du sous bassin de Oued Rassoul par rapport aux polygones de Thiessen
- Figure 16.** Les différentes pluies utilisées dans le modèle avec les débits observées en fonction du temps
- Figure 17.** Evapotranspiration potentielle estimé par le modèle Oudin (2005)
- Figure 18.** Structure de SWM dans la version 4
- Figure 19.** Structure du modèle conceptuel « ESMA » de Dawdy and O'Donnell (1965)
- Figure 20.** Structure du modèle GR4J, version de Perrin et al (2003)
- Figure 21.** Stratégie de calibration des modèles (θ représente le jeu de paramètre à calibrer)
- Figure 22.** Le triangle BGW, le milieu M et le point réfléchi R de la méthode Nelder-Mead
- Figure 23.** Le triangle BGW, le point R et le point prolongé E de la méthode Nelder-Mead
- Figure 24.** Le point de contraction C1 ou C2 de la méthode Nelder-Mead

Figure 25. Rétrécissement du triangle vers B de la méthode Nelder-Mead

Figure 26. Simulation du modèle GR4j utilisant les différentes entrées de pluie (a) P5 (b) P6 (c) Par et (d) pour Pth

Figure 27. Performances du modèle GR4j en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth

Figure 28. Les MSE atteint (en phase test) après calage par le modèle GR4j pour différents paramètres initiaux

Figure 29. Dessin explicatif d'un neurone biologique

Figure 30. Schéma du fonctionnement d'un neurone formel

Figure 31. Les différents type de fonction de transfert dans les RNA(a) fonction binaire, (b) fonction linéaire par morceaux (c), fonction linéaire (d) fonction sigmoïde, (e) fonction gaussienne

Figure 32. Schéma descriptif du perceptron monocouche

Figure 33. Schéma descriptif du perceptron multicouches

Figure 34. Réseau récurrent sans "feedback" en soit et pas de couche cachée

Figure 35. Réseau récurrent avec une couche cachée

Figure 36. Schéma descriptif d'un apprentissage supervisé

Figure 37. (a) fonction caractéristique et (b) fonction d'appartenance

Figure 38. Fonction d'appartenance dans la logique floue, variable et terme linguistique.

Figure 39. Fonctions d'appartenance linéaires par morceaux

Figure 40. Les étapes fonctionnelles des règles floues

Figure 41. Mécanisme d'inférence de Mamdani : (a) Fuzzification, (b) Activation, (c) Implication

Figure 42. Agrégation des règles dans le système d'inférence Mamdani

Figure 43. Défuzzification par centre de gravité

Figure 44. (a) Schéma d'un système d'inférence logique. (b) Architecture ANFIS équivalente

Figure 45. Processus de recherché de la méthode du gradient descendant avec des constants d'apprentissages différentes [tirée de (Yu et Wilamowski, 2011)]

Figure 46. Courbes des simulations du débit avec le modèle RNA en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test

- Figure 47.** Nuages de points montrant les simulations du débit avec le modèle RNA en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test
- Figure 48.** Performances des modèle RNA en fonction des combinaisons des entrées et de type de pluie au niveau des critères (a) MSE, (b) NSE et (c) VE
- Figure 49.** Courbes des simulations du débit avec le modèle ANFIS en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test
- Figure 50.** Nuages de points montrant les simulations du débit avec le modèle ANFIS en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test
- Figure 51.** Performance du modèle ANFIS au niveau du critère MSE
- Figure 52.** Performance du modèle ANFIS au niveau du critère NSE
- Figure 53.** Performance du modèle ANFIS au niveau du critère VE
- Figure 54.** Schéma descriptif du modèle de la combinaison de GR4j et le RNA utilisé
- Figure 55.** Courbes des simulations du débit avec le modèle NUCM en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test
- Figure 56.** Nuages de points montrant les simulations du débit avec le modèle NUCM en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test
- Figure 57.** Performances des modèles GR4j et NUCM en fonction des différentes entrées de pluie
- Figure 58.** Performance des modèles GR4j, RNA, ANFIS et NUCM par rapport aux critères (a) MSE et (b) NSE et VE
- Figure 59.** Performances des modèles GR4j, RNA, ANFIS et NUCM en fonction des entrée des pluies P5, P6, Par et Pth selon les critères (a) MSE, (b) NSE et (c) VE
- Figure 60.** (a) Simulation des pics de débit ainsi que (b) leurs erreurs relatives, pendant la phase test pour les modèles GR4j, ANN, ANFIS, NUCM
- Figure 61.** Performances des modèles GR4j, ANN, ANFIS et NUCM au niveau de l'apport mensuel

Liste des notations

- ANFIS** « Adaptive-Network-based Fuzzy Inference System
- ANRH** l'Agence Nationale des Ressource Hydrique
- ASCE** American Society of Civil Engineers
- ASTER** Advanced Spacebone Thermal Emission and Reflection Radiometer
- ARMAX** « autoregressive moving average model with external inputs »
- ETP** Evapotranspiration potentielle
- ETR** Evapotranspiration réelle
- GDEM** Global Digital Elevation Model
- GR2M** Modèle du Génie rural à 2 paramètres, mensuel.
- GR4j** Modèle du Génie rural à 4 paramètres, journalier.
- GRNN** Generalized Regression Neural Network
- IRSTEA** Institut national de recherche en sciences et technologies pour l'environnement et l'agriculture
- LSE** Least Squares Estimate
- MF** fonction d'appartenance
- MITI** Ministère de la recherche japonais
- MNE** Modèle Numérique d'Elévation
- MNT** Modèle Numérique Terrain
- MSE** « mean square error » (Erreur quadratique)
- NSE** « Nash-Sutcliff efficiency » (Critère de Nash-Sutcliff)
- NUCM** "Neuro-Updating conceptual model
- P5** Pluie mesurée dans la station 140605
- P6** Pluie mesurée dans la station 140606
- Par** Pluie issue de la moyenne arithmétique de P5 et P6
- PMC** Perceptron multicouches
- Pth** Pluie issue de la méthode des polygones de Thiessen
- RBF** « Radial basis function »
- RNA** Réseau de neurones artificiels
- SIG** Système d'information géographique
- SRTM** Shuttle Radar Topography Mission
- VE** « Volumetric efficiency » (critère volumétrique).

INTRODUCTION GENERALE

L'eau est définie comme un corps liquide à la température et à la pression ordinaires, incolore, inodore, insipide, dont les molécules sont composées d'un atome d'oxygène et de deux atomes d'hydrogène (H₂O). Cette substance est d'une importance capitale pour tous les organismes vivants sur terre, elle est aussi le milieu de vie de la plupart des êtres vivants. Grâce à sa force, elle a taillé les forêts et sculpter les paysages qui forment aujourd'hui notre habitat. Devant l'accroissement alarmant de la population, le changement climatique et la pollution qui touche notre planète, les besoins en eau dépasse largement ce que la nature peut nous offrir. D'après l'OMS (organisation mondiale de la santé), plus d'un milliard de personnes n'ont pas accès à l'eau salubre, ce qui oriente notre focalisation à une bonne gestion de cette eau. L'eau est source de vie mais peut aussi être source de destruction, les inondations affectent plusieurs pays dans le monde, causant des pertes humaines et matérielles. Surtout que depuis longtemps, les humains construisent leurs habits près des cours d'eau, du fait de la ressource très importante qu'ils y trouvent. Mais cet emplacement est considéré comme une zone de risque d'inondation, qui est un phénomène naturel dont on doit se protégé. Hoyt et Langbein écrivent : « les inondations font tout autant partie du paysage que les collines et les vallées. Ce sont des éléments naturels avec lesquels il faut coexister, des événements qui demandent une certaine adaptation de notre part».

Que ce soit en termes de ressource en eau ou de prévention contre les inondations, l'eau est devenue un enjeu majeur pour le développement des états. Elle est le pilier principal pour l'avancé de l'agriculture, de l'industrie et de l'économie. De plus, certains pays souffrent de l'aridité du climat connu pour les faibles précipitations et une évaporation excessive, qui provoque un déséquilibre dans le maintien de leurs cultures. Tout ça place les scientifiques en front pour une meilleure connaissance des quantités d'eau passant par les cours d'eau et ayant été confronté à la complexité du phénomène de la génération du débit dans un bassin versant, les chercheurs tentent depuis longtemps de créer le modèle parfait qui sera en mesure de simuler le débit en fonction de quelques mesures (principalement la pluie) faites sur la région.

On définit un modèle comme une abstraction qui simplifie le système réel étudié (Coquillard et Hill, 1997). Il est utilisé comme outil de gestion (ex. l'aide à la décision) ou pour des raisons scientifiques (ex. tester des théories, comprendre le fonctionnement d'un système...etc.). Malgré le bon nombre de modèles existants, on n'arrive pas à faire une simulation exacte du débit à l'exutoire du bassin. Cette modélisation a connu une véritable prolifération avec la disponibilité croissante de données hydrométéorologiques, en plus de l'avènement de l'informatique qui a boosté son rendement et ses performances.

Trois différents types de modèle ont été développés par les modélisateurs en hydrologie, à savoir les modèles à base physique, les modèles empiriques ainsi que les modèles conceptuels appelés aussi modèles à réservoirs. Les premiers modèles cités sont fondés sur des lois physiques, résolvants explicitement, dans les trois dimensions de l'espace, les équations de Richards pour les écoulements souterrains, les équations hydrodynamiques d'écoulement à surface libre pour les écoulements en rivière et le ruissellement lorsqu'il est susceptible de se produire et qui soit apte à reproduire l'action de la végétation et de l'évaporation sur le bilan hydrique des sols. Les modèles de ce type ont besoin d'énormément de mesures sur terrain et trouvent rapidement leurs limites lorsque la superficie des bassins et la complexité des phénomènes augmentent. Ceci nous mène à s'intéresser qu'aux modèles empiriques et conceptuels appelés aussi les modèles mathématiques.

Les modèles mathématiques sont schématisés de la même manière : une entrée du modèle, composé d'une à plusieurs variables indépendantes (essentiellement des mesures de pluie) ; une sortie du modèle ou variables dépendantes (le débit dans notre cas) ; les variables d'état, ce sont eux qui caractérisent le système modélisé et peuvent évoluer en fonction du temps ; les paramètres du modèle, qui peuvent être liés à des variables mesurables ou pas, ces paramètres doivent être calés selon une fonction, appelée fonction objectif ou fonction de coût.

Ce travail de thèse a pour objective d'illustrer à travers une étude comparative entre différentes approches de modélisation mathématique de la relation pluie-débit, la meilleure procédure à suivre pour une bonne simulation des débits à l'exutoire d'un bassin versant. En plus des différentes approches de modélisation, plusieurs types de représentativité de la variable de la pluie ont été testés en entrée des modèles.

Le premier chapitre de la thèse concerne la présentation du sous bassin versant « Oued Rassoul » qui est situé au Nord Est Algérien et qui a servie comme bassin expérimental de la modélisation avec les trois approches citées au-dessus. Les caractéristiques du sous bassin, du climat, de la pluie et ainsi que la géologie de la région, ainsi que la base de données utilisée pour le développement des modèle font partie de ce chapitre.

Le chapitre suivant comportera la modélisation utilisant un modèle conceptuel (à réservoir) appelé GR4j (Perrin et al. 2003) qui a été appliquée sur le sous bassin de « Oued Rassoul » utilisant comme entrées les séries journalières de pluie et de l'évapotranspiration potentielle.

Dans le troisième chapitre, deux modèles d'intelligence artificielle à savoir les réseaux de neurones artificiels (RNA) et le système d'inférence logique à base de réseau adaptif (ANFIS), sont présentés. Cette présentation concerne les notions utilisées dans ces modèles, leurs principes de fonctionnement et leurs liaisons avec la modélisation de la relation pluie-débit.

Après la présentation des modèles RNA et ANFIS, dans ce chapitre est présentée l'application de ces modèles sur le sous bassin Oued Rassoul en mettant en avant les procédures de développement de ces modèles et les algorithmes utilisés pour les phases d'apprentissage.

Une combinaison de deux modèles (RNA et Conceptuel) est présentée dans ce cinquième chapitre. Ce mode d'hybridation est appelé mise à jour des modèles conceptuels avec les réseaux de neurones [Neuro-Updating Conceptual Model (NUCM)]. Dans cette approche, le rôle du réseau de neurones n'est plus la résolution de la relation pluie débit, mais la correction des erreurs du modèle conceptuel (GR4j).

Le sixième chapitre est consacré à l'analyse et la comparaison de tous les modèles en fonction des résultats de leurs performances a simulé le débit à l'exutoire du sous bassin.

Enfin dans la dernière section, nous présentons une conclusion de l'ensemble du travail de la thèse qui comporte différentes approches de la modélisation de la

relation pluie-débit en se basant sur leurs performances, ainsi que des perspectives aux futures études qui seront consacrés à cette thématique.

CHAPITRE 1

Site d'étude et base de données

1.1. Introduction

Afin de tester les approches de modélisation de la relation pluie-débit, des données réelles (pluie, débit...etc.) mesurées sur un sous bassin versant ont été utilisées. Ce sous bassin porte le nom de Oued Rassoul qui est codé 140606 par l'Agence Nationale des Ressource Hydrique (ANRH), et qui fait partie du grand bassin de Seybous (l'un des dix-sept bassins versant de l'Algérie).

Dans ce présent chapitre, le sous bassin de Oued Rassoul qui a servis comme bassin expérimental, est décrit en termes de situation géographique, climatologique, géologique...etc. La base de données utilisée pour le développement des modèles fait aussi partie de cette partie de la thèse.

1.2. Situation géographique

Le sous bassin versant de Oued Rassoul est situé au Nord Est Algérien (entre les Latitude $36^{\circ}70'$, $36^{\circ}50'$ et Longitude $7^{\circ}60'$, $7^{\circ}45'$). Ce sous bassin s'allonge sur trois commune (Ain Berda, Selmoun Alhachemi et Nechmaya) et faisant partie des surfaces de deux Wilaya (Annaba et Guelma). Oued Rassoul est un petit affluent de rive gauche d'oued Seybouse, important fleuve côtier de l'est Algérien (Figure 1).

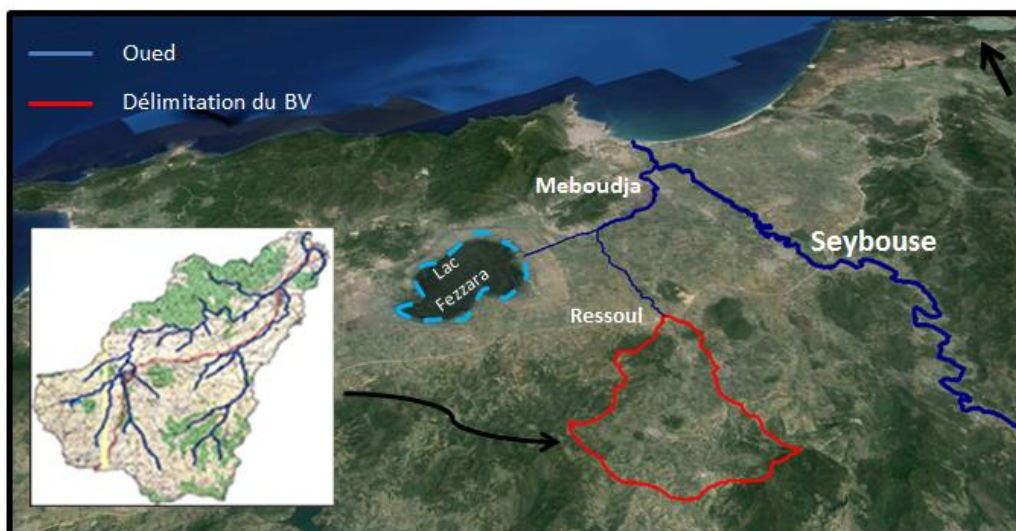


Figure 1. Vue en plan du raccordement d'oued Ressoul avec l'Oued de la Seybouse.

1.3. Caractéristique du sous bassin

Dans le but d'extraire les caractéristiques morphométrique du sous bassin versant de Oued Rassoul, un GDEM (Global Digital Elevation Model) qui est un Modèle Numérique d'Élévation (MNE), a été utilisé dans un logiciel de SIG (Système d'information géographique). Ces MNE, résultat du programme ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer), couvrant le monde entier (entre 83° Nord et 83° Sud), sont produit par le MITI (ministère de la recherche japonais) et la NASA. Ils ont une résolution de 1 seconde d'arc soit environ 30 mètres à l'équateur. Ils ont donc une résolution 3 fois plus fine que celle du SRTM (Shuttle Radar Topography Mission).

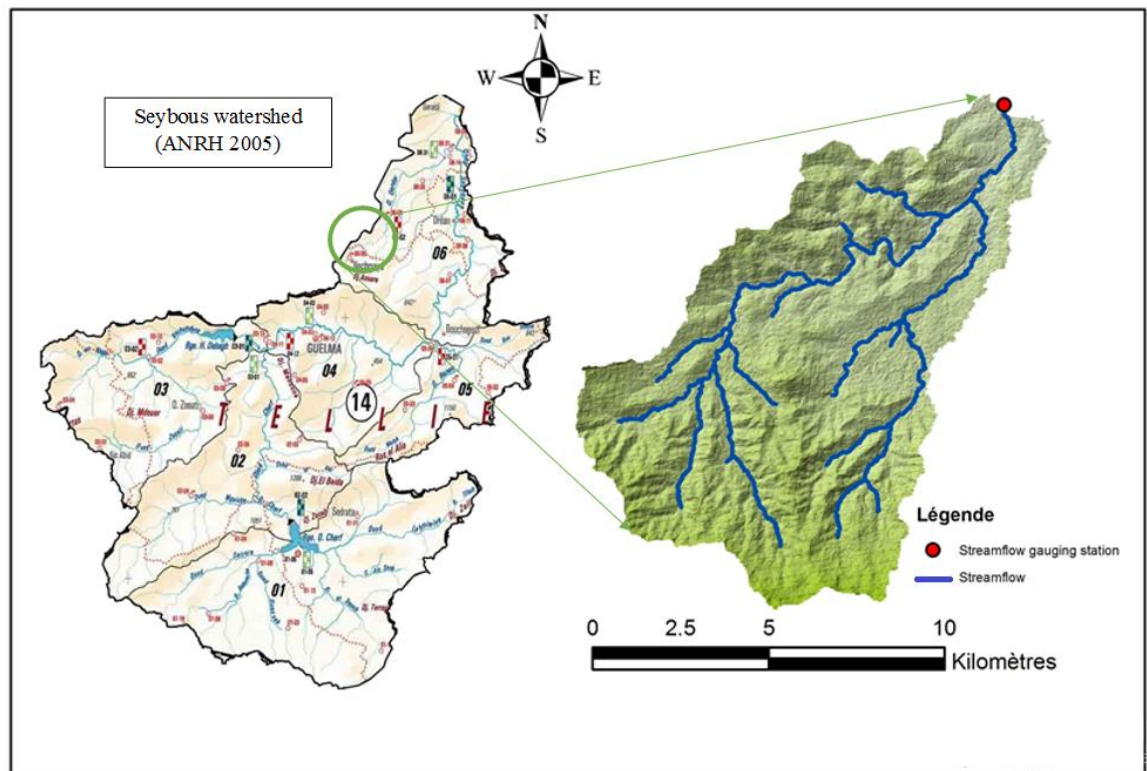


Figure 2. Localisation du sous bassin de oued Rassoul dans le bassin de la Seybous

Le sous bassin de Oued Rassoul draine une superficie de 103 km² (Figure 2) dont l'élévation varie entre 55 m et 927 m, avec une longueur du talweg principal mesuré à 23.27 km. La répartition des surfaces en fonction des altitudes sont montrées dans le (Tableau 1). A partir de cette répartition, la courbe hypsométrique a pu être tracée

(Figure 3). Aussi une carte montrant le relief du sous bassin de Oued Rassoul est montré dans la (Figure 4).

Tableau 1. Répartition des surfaces en fonction des altitudes

Elévation	Surfaces Partielles	Surfaces Cumulées	surfaces partielles	surfaces cumulées
[m]	(km ²)	(km ²)	(%)	(%)
[800 - 909]	0	0	0	0
[800 - 700]	3.58	3.58	3.46	3.46
[700 - 600]	23.11	26.7	22.35	25.82
[600 - 500]	30.25	56.95	29.26	55.08
[500 - 400]	22.07	79.02	21.34	76.42
[400 - 300]	13.58	92.59	13.13	89.55
[300 - 200]	6.66	99.25	6.44	95.99
[200 - 100]	2.06	101.31	2.39	97.97
[100 - 72]	1.69	103	1.63	100




Figure 3. Courbe hypsométrique du sous bassin versant de Oued Rassoul

Les caractéristiques morphométriques du sous bassin de Oued Rassoul calculé à partir de l'utilisation d'un logiciel de SIG sont montrées dans le (Tableau 2).

Tableau 2. Récapitulatif des caractéristiques du sous bassin de Oued Rassoul

Bassin versant	Surface	Périmètre	Indice de compacité	Longueur du rectangle équivalent	Largeur du rectangle équivalent	Altitude moyenne	Altitude médiane	Dénivelé	Indice de pente de roche	Indice de pente global
	[km ²]	[km]	[-]	[km]	[km]	[m]	[m]	[m]	[%]	[%]
Oued Rassoul	103,4	52,77	1,45	21,6	4,79	307,6	620	400	3,41	21,58

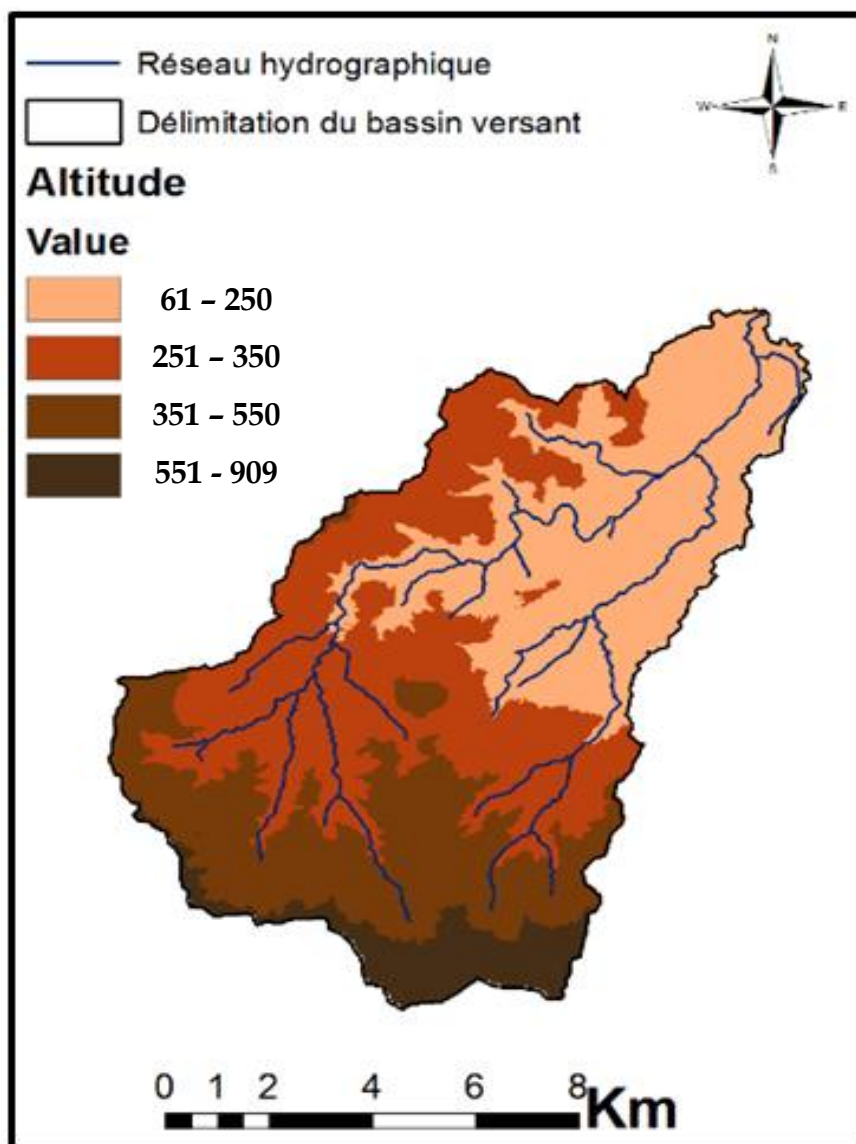


Figure 4. Relief et talwegs du sous bassin de Oued Rassoul

A partir d'un Modèle Numérique Terrain (MNT), une carte des pentes du sous bassin de Oued Rassoul a pu être extraite et est montrée dans la (Figure 5).

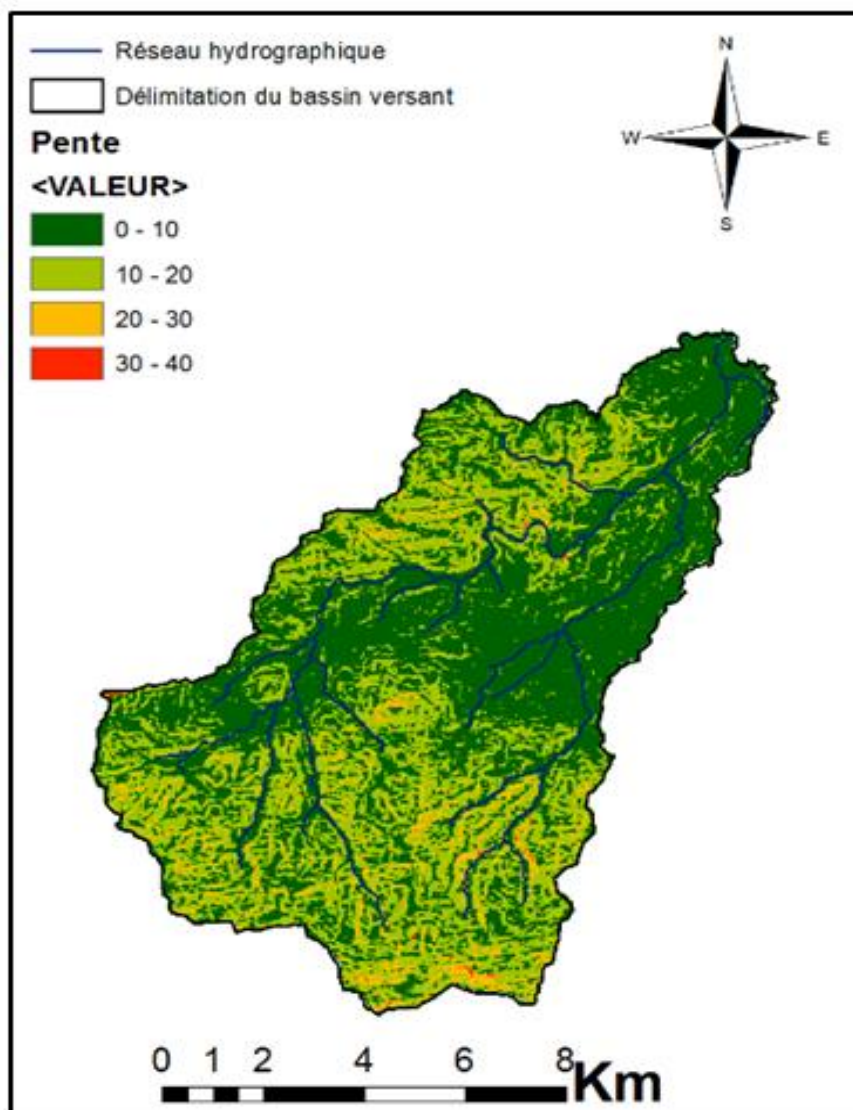


Figure 5. Carte des pentes du sous bassin de Oued Rassoul

1.4. L'urbanisation dans le sous bassin

Le bassin d'oued Ressoul est constitué de trois communes: Ain Berda, Selmoune Alhachemi et Nechmaya dont les surfaces et périmètres sont résumé dans le (Tableau 3), et qui sont montré dans la (Figure 6).

Tableau 3. Surfaces et périmètres des communes appartenant au bassin versant

Commune	Surface (km ²)	Périmètre (km)
Ain Berda	1,391	7,062
Selmoune Alhachemi	0,183	2,864
Nechmaya	0,927	5,122

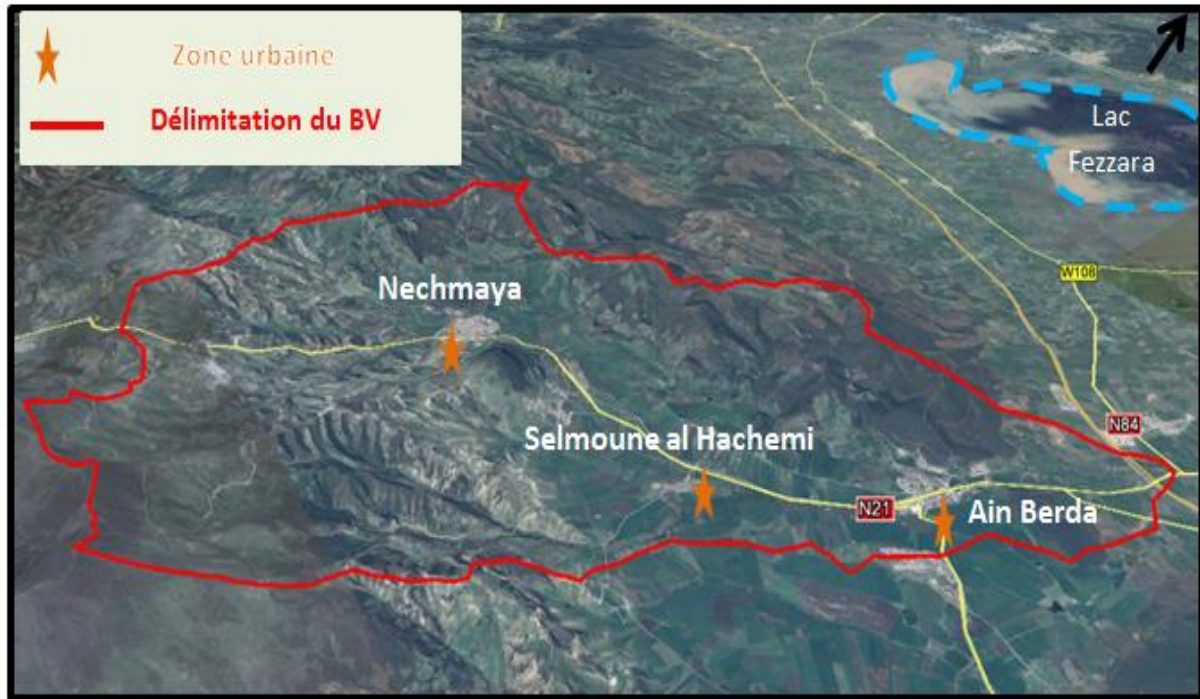


Figure 6. Emplacement des centres urbains dans le sous bassin de Oued Rassoul

1.5. Aménagement agricole

Sept retenues collinaires sont aménagées dans le sous bassin de Oued Rassoul. L'emplacement et la délimitation des sous bassins de ces retenues sont montrés dans la (Figure 7). Les caractéristiques des sous bassins sont décrit dans le (Tableau 4).

Tableau 4. Description des retenues collinaires existantes dans Medjez Ressoul.

Bassin versant du Retenue	Surface (km ²)	Périmètre (km)	H _{max} (m)	H _{min} (m)
Toumi Ahmed	1,324	9,749	171	69
Toumi laakrim 1	0,363	3,642	218	110
Toumi laakrim 2	0,740	4,707	238	161
Toumi laakrim 3	1,435	6,668	275	169
Selmoune alhechmi	2,304	9,301	323	158
Nekla	3,161	10,702	558	240
Hdjar guefta	5,001	13,055	579	297

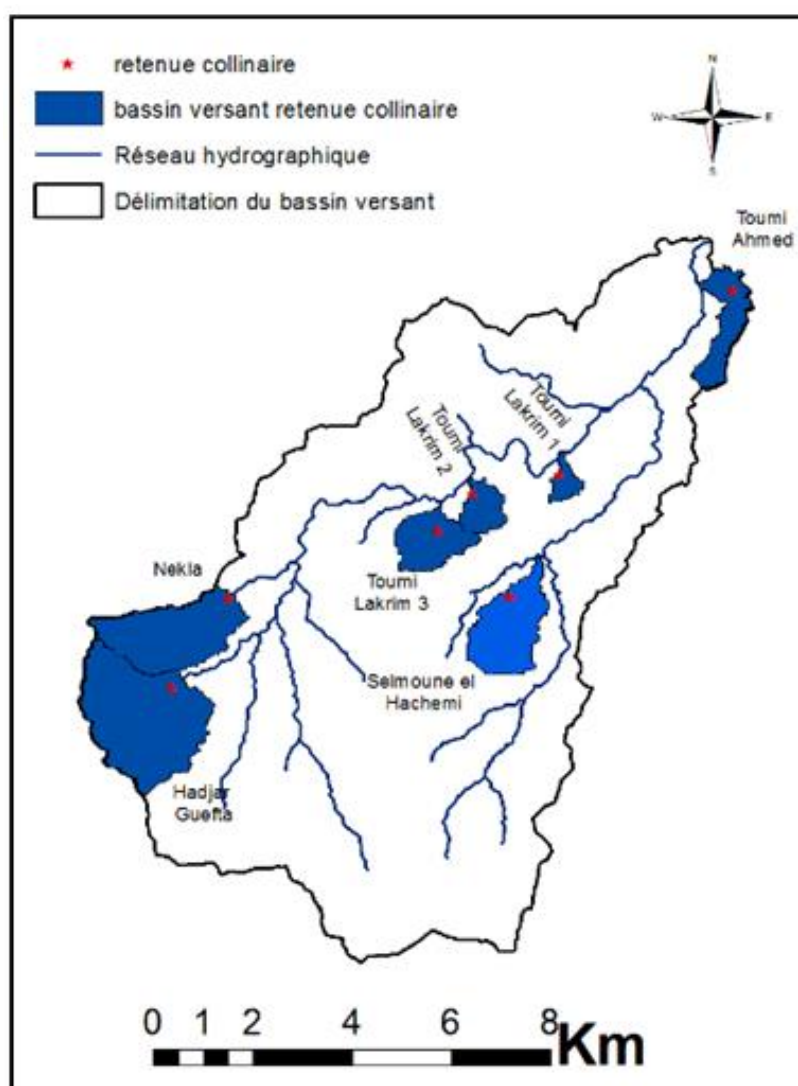


Figure 7. Les différents bassins des retenues collinaires du bassin de Medjez Ressoul Ain Berda.

1.6. Géologie du sous bassin

Le cadre géologique d'un bassin versant conditionne les écoulements des eaux souterraines et des eaux superficielles. La géologie de la région d'Ain Berda (Figure 8) est caractérisée par :

De flysch Mauritanienne : de formation de Cénomaniens à l'âge Oligocène, constitué de différentes lithologies : brèche, marnes, schistes, le calcaire et micacé grès ;

- les Flyschs Massylian du Crétacé constitué de grès, schiste et marnes
- les Flyschs Nummidian composées d'Oligo – Miocène grès.

La majeure partie de ces roches sédimentaires sont recouvert par un Miocène et du Pliocène à la couverture du Quaternaire de sable, gravier et alluvions. Ces formations sont d'origine continentale, elles incluent des horizons graveleux et des niveaux de travertins qui constituent le réservoir de la nappe des graviers.

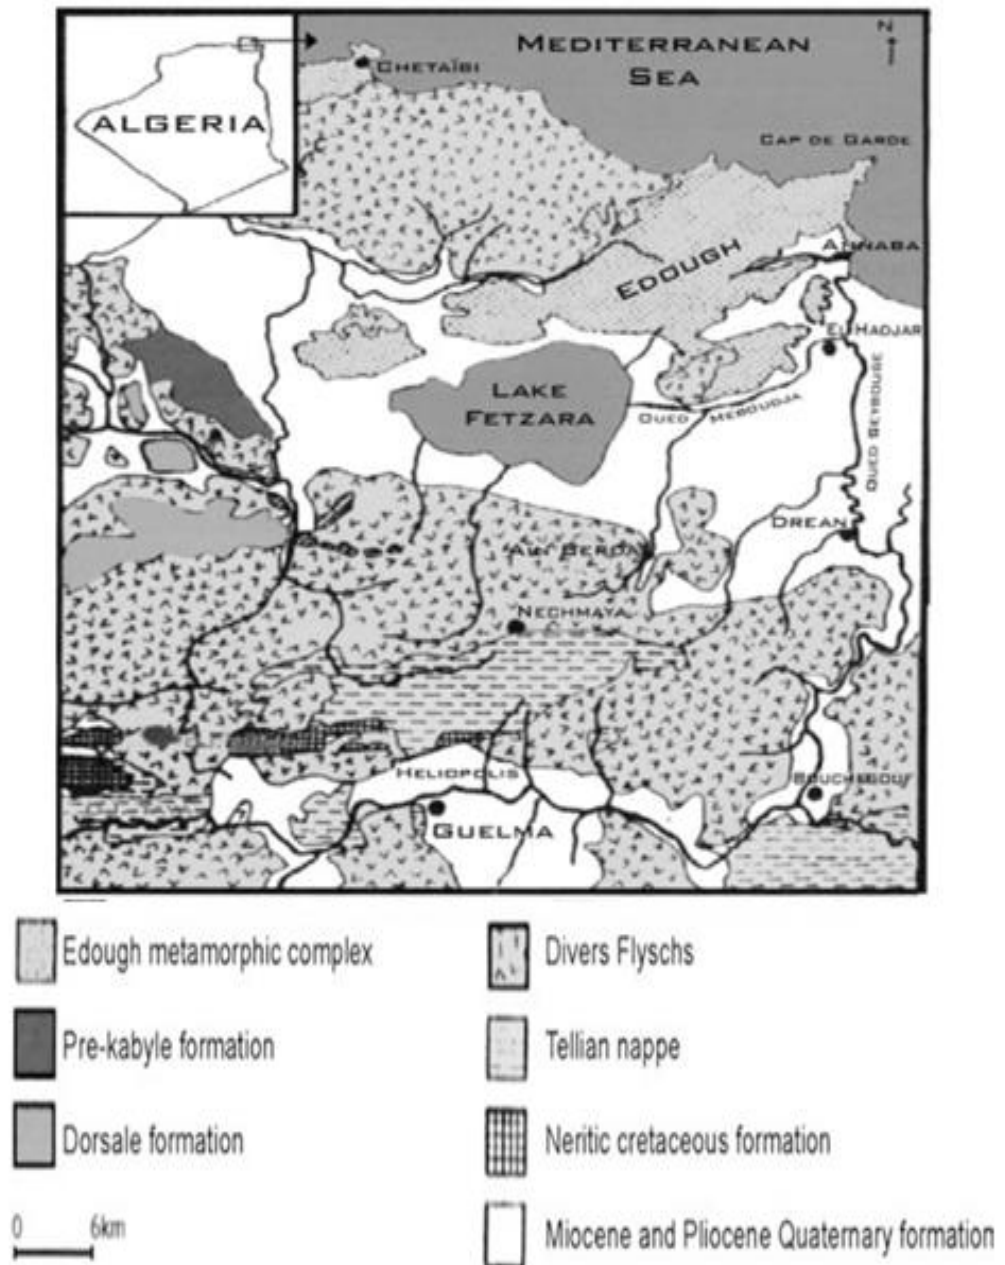


Figure 8. Carte géologique de la ville d'Annaba tirée de (Djabri et al. 2003)

1.7. Station hydrométrique de Oued Rassoul

Comme montré dans la (Figure 9) la station de jaugeage est située juste au sud de la RN84 qui mène vers Labidi Mouhamed et qui fait confluence avec Oued Rassoul. Ses coordonnées géographiques sont 36.683 Latitude et 7.605 Longitude.




Figure 9. Vue en plan de la station hydrométrique Ain Berda

1.8. Caractéristique de la station de jaugeage

La station a été équipée d'un seuil-jaugeur en béton de type parshall de 90 cm pour connaître la précision des débits les plus faibles.

L'équipement limnimétrique comprend : une échelle composée de quatre éléments verticaux, le premier de hauteur de 88 cm, est fixé sur la paroi du convergent, le second a une hauteur de 112 cm, et les deux autres éléments sont métriques et un limnigraphe pneumatique Telimnip avec réduction 1/5. La section de l'échelle et la prise de pression du limnigraphe sont situés au premier tiers du convergent.

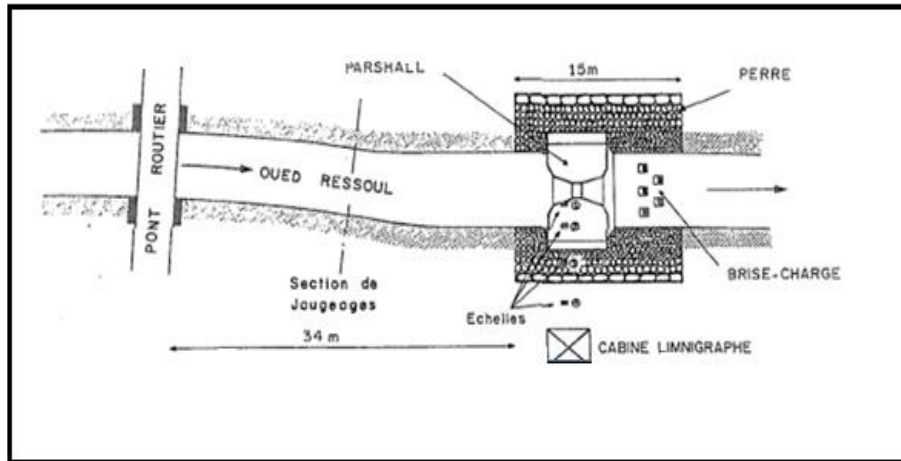


Figure 10. Plan de situation d'oued Ressoul Ain Berda

Le profil en travers de la section de l'échelle est parfaitement stable, grâce au seuil et au perré qui protège les berges (Figure 10).

Le profil en long est assez régulier avec une pente relativement forte de 9,2 m/km.

Les jaugeages sont faits soit à gué, à 15 m à l'amont du seuil, soit avec une potence depuis le pont routier, situé à 34 m à l'amont de l'échelle.

La seuil-jaugeur Parshall montré dans la (Figure 11) modifie le régime d'écoulement par le rétrécissement de la section transversale et par un brusque changement de la pente.



Figure 11. Photo d'un seuil-jaugeur Parshall

1.9. Base de donnée

Les séries de la pluie, le débit et l'évapotranspiration potentielle ont été utilisé pour modéliser le processus de la transformation pluie-débit avec une période de 8 ans. Cette période (1988 – 1996) a été choisie dans l'intervalle de [1973-1997] en se basant sur la qualité, l'homogénéité des données pluie-débit, la période la proche du présent et l'absence de lacune.

Ces séries sont appelées les données déterminantes ou simplement les entrées du modèle, c'est les données qui doivent être fournies pour que le modèle fonctionne. Dans les modèles conceptuels, il s'agit généralement de la pluie et l'évapotranspiration potentielle ainsi que la neige pour les modèles qui prennent en considération le module « neige ». Dans notre cas d'étude, ce phénomène n'est pas pris en considération dans le développement des modèles.




Figure 12. Observation journalière du débit utilisé dans l'étude

Dans les (Figure 13 et 14), on peut voir deux caractéristiques lié aux pluies mesurées sur les deux stations 140605 et 140606, et qui sont les pluies moyennes annuelles ainsi que le nombre de jour dont la pluie est au-dessus de la moyenne.

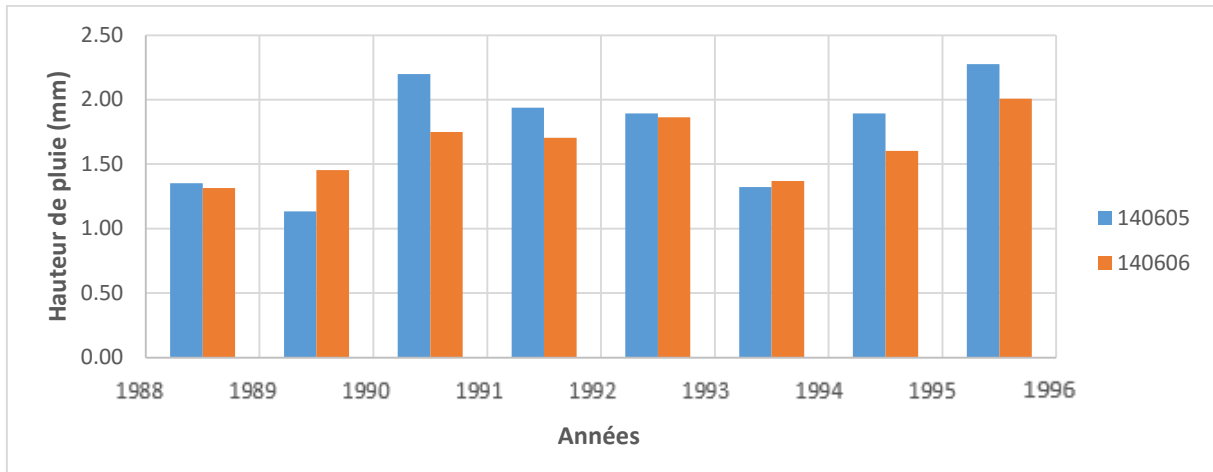


Figure 13. Pluies journalières moyennes annuelles mesurées sur les stations 140605 et 140606




Figure 14. Histogramme des nombre de jour dont la pluie est au-dessus de la pluie moyenne

En analysant la (Figure 13), on remarque que les pluies annuelles mesurées dans la station 140605 sont toujours supérieures à celle de la station 140606, sauf pour les années 1989 et 1993. Le minimum de pluie journalière moyenne enregistré dans la première station est celui de l'année 1993 avec 1.13 mm et son maximum dans l'année 1995 avec 2.28 mm. Alors que le minimum dans la station 140606 se trouve dans l'année 1988 avec 1.32 mm et son maximum est de 2.02 mm dans la dernière année (1995).

Dans la (Figure 14), on peut voir que le nombre de jour dont la pluie est au-dessus de la moyenne pour les deux stations varie d'une année à une autre et que ça a

augmenté considérablement la dernière année (1995) pour la station 140605 jusqu'à atteindre 83 jours au-dessus de la moyenne et pour la station 140606, 69 jours au-dessus de la moyenne.

1.9.1. La pluie

La variable de la pluie est la plus importante donnée d'entrée pour les modèles hydrologiques et sa variabilité spatiale fait qu'il est difficile de la représenter à l'échelle d'un bassin versant. Cette variabilité affecte la réponse du bassin (Shah et al., 1996a ; Shah et al., 1996b), le timing du pic de débit (Singh, 1997), l'estimation des paramètres du modèle (Chaubey et al., 1999) et les sortie des modèles hydrologiques (Bell et al., 2000 ; Segond et al., 2007). Sachant que les modèles conceptuels globaux nécessitent une seule entrée de pluie, le modélisateur doit choisir entre l'utilisation d'une pluie mesurée sur un point données et qui représente la totalité du bassin versant ou utiliser une pluie surfacique « Areal precipitation » résultant de plusieurs points de mesure. Cette dernière peut être estimée par la moyenne arithmétique, la moyenne de surfaces issues des polygones de Thiessen ou à partir des isohyètes tracés avec des méthodes d'interpolation. La méthode d'estimation de la pluie surfacique utilisant les isohyètes nécessitent un réseau de station pluviométrique assez dense, or le sous bassin étudié n'a que deux stations de mesure, ce qui nous oriente vers l'abandon de cette méthode qui est certes plus efficace que les autres méthodes cités au-dessus.

Etant donné que le sous bassin étudié est doté que de deux stations pluviométriques et que les autres stations ont une distance d'au moins 7 km par rapport aux limites du sous bassin étudié, le choix se limite donc sur l'utilisation des pluies dont la mesure est ponctuelle (Stations 140605, 140606), la moyenne arithmétique ainsi que la moyenne de surfaces issues des polygones de Thiessen.

1.9.1.1. Moyenne arithmétique

La méthode la plus simple qui consiste à calculer la moyenne arithmétique des valeurs obtenues aux stations étudiées.

1.9.1.2. Polygone de Thiessen

C'est une méthode simple et direct, les valeurs de pluie observées sur un point sont affecté aux zones qui ne sont pas couvert par des stations de mesure (Thiessen 1911). La procédure consiste a divisé la zone d'étude en polygones, ce dernier a une seule mesure observée qui représente la totalité de l'air (A_i) qui la couvre. La précipitation moyenne pondérée P_{moy} pour le bassin, se calcule alors en effectuant la somme des précipitations P_i de chaque station, multipliées par leur facteur de pondération (aire A_i), le tout divisé par la surface totale A du bassin. La précipitation moyenne sur le bassin s'écrit comme dans (Equation 1) :

$$P_{moy} = \frac{\sum A_i \cdot P_i}{A} \quad (1)$$

Avec :

P_{moy} : précipitation moyenne sur le bassin

A : aire totale du bassin

P_i : précipitation enregistrée à la station i

A_i : superficie du polygone associée à la station i




Figure 15. Division des surfaces du sous bassin de Oued Rassoul par rapport aux polygones de Thiessen

La (Figure 15) montre les surfaces résultant des polygones de Thiessen et qui ont été tracé en utilisant les stations pluviométrique 140605 et 140606. Les autres stations aux alentours du sous bassin n'ont pas été présent en considération vu leurs éloignement par rapport à ce dernier. A partir de la délimitation résultant des polygones de Thiessen, 23% de la surface totale est associé à la station pluviométrique codée 140606 alors que la plus grande superficie (77%) est représentée par la station dont le code est 140605 qui est située à l'amont et dont l'altitude est supérieur à l'autre station. Cette dernière a donc plus de poids avec un ratio de plus de $\frac{3}{4}$ de la superficie du sous bassin versant.

En résumé, quatre différentes entrées de la pluie sont utilisées pour modéliser la simulation du modèle GR4j, à savoir la pluie de : la station 140605 (P5), la station 140606 (P6), utilisant la moyenne arithmétique (Par) et enfin celle utilisant les polygones de Thiessen (Pth). La (Figure 16). Montre les différentes pluies utilisées

dans le modèle avec les débits observées à l'exutoire du sous bassin étudié en fonction du temps.

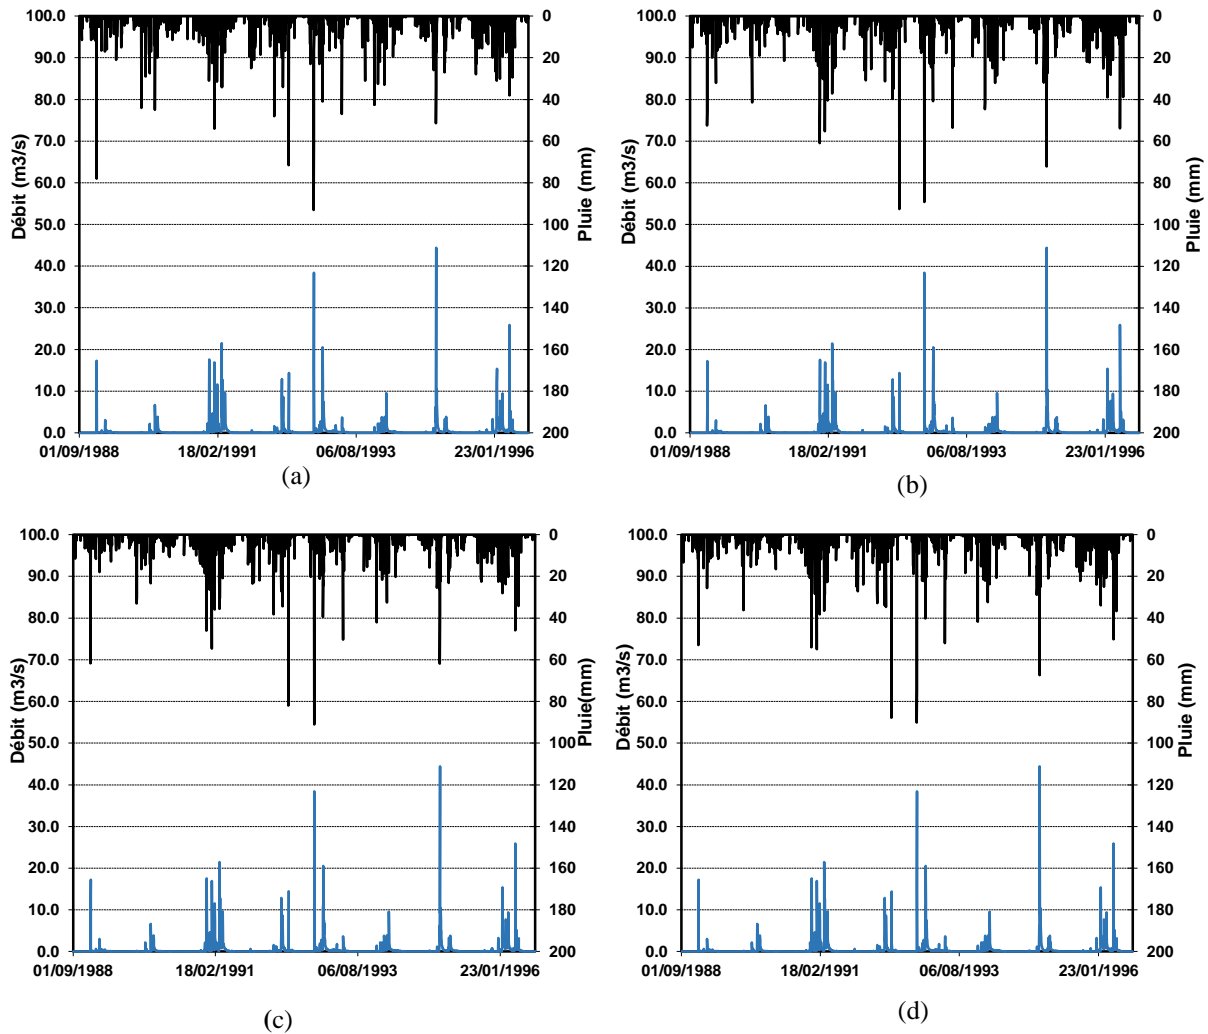


Figure 16. Les différentes pluies utilisées dans le modèle avec les débits observées en fonction du temps

1.9.2. L'évapotranspiration potentielle

L'évapotranspiration est un phénomène extrêmement complexe et le plus difficile à quantifier dans le cycle de l'eau. Dans les modèles pluie-débit, cette variable n'est pas directement mesurée et a été simplifiée par une autre variable appelée évapotranspiration potentielle (ETP). Contrairement à l'évapotranspiration réelle (ETR), cette variable ne nécessite que la connaissance de paramètres liés à l'atmosphère. Ce concept a été introduit par Thornthwaite, en 1948 en distinguant le volume d'eau qui est effectivement évapotranspiré et celui qui pourrait être évapotranspiré. Des travaux ont suivie, ceux de Penman (1948) qui ont permis

d'établir une formule de l'ETP combinant les principes physiques du bilan d'énergie et des ajustements empiriques issus de formules aérodynamiques appelé par la suite ETP de Penman, Plus tard, Penman (1956) indique qu'il considère l'ETP comme : « l'évaporation d'une pelouse rase suffisamment étendue, en bon état et convenablement alimentée en eau ». Si le terme « suffisamment étendue » signifie que les effets d'advection sont négligés, que le terme « pelouse rase » exclue les effets de résistance aérodynamique et enfin que le terme « convenablement alimenté en eau » signifie que le sol a un taux d'humidité proche de la capacité maximale du volume, l'ETP est alors clairement un paramètre climatique (Oudin 2004).

Xu et Singh (2001) ont dénombré cinq classes de méthodes d'estimation de l'évapotranspiration potentielle : bilan hydrique (bacs à évaporation, l'évaporomètre Piche...etc.), aérodynamique qui utilise le concept du mouvement de la vapeur d'eau de la surface évaporante vers l'atmosphère, combinatoires [Penman (1948) ; Monteith, (1965) ; Priestley-Taylor (1972) ; Kimberly-Penman by Wright (1982) ; Thom et Oliver (1977)] ; rayonnement [Makkink (1957) ; Turc (1955) ; Jensen-Haise (1963) ; McGuinness et Bordne (1972) ; Hargreaves (1975) ; Doorenbos et Pruitt (1977) ; Abtew (1996)], et température [Thornthwaite (1948; 1955) ; Blaney et Criddle (1950) ; Hamon (1961) ; Romanenko (1961) ; Linacre (1977)].

Les travaux de Oudin (2004) ont démontré une insensibilité des modèles pluie-débit à l'ETP et qu'une information extrêmement simple à obtenir (données interannuelles) peut suffire à estimer l'ETP conduisant à des simulations de débit aussi bonnes qu'une information datée difficile à obtenir. Cette étude de sensibilité a montré que des formules d'ETP de conceptions diverses conduisent à des performances en simulation de débit équivalentes. Dans ce contexte, l'utilisation de la formulation de Penman est critiquable, compte tenu du grand nombre d'observations de paramètres climatiques qu'elle exige (la température de l'air, de l'humidité relative, de la vitesse du vent et du rayonnement) tout en restant surclassée par des méthodes beaucoup plus sommaires.

Dans cette étude, un modèle développé par Oudin (2005) a été utilisé pour l'estimation de l'ETP ne nécessitant que la connaissance de la température moyenne journalière. Ce modèle s'est montré plus efficace que le modèle de Penman (Oudin,

2005). La (Figure 17) montre la variation de l'évapotranspiration potentielle estimée par le modèle de Oudin (2005).




Figure 17. Evapotranspiration potentielle estimé par le modèle Oudin (2005)

CHAPITRE 2

Modélisation conceptuel de la relation pluie débit

2.1. Introduction

Les modèles conceptuels sont fondés sur la similitude du fonctionnement d'un réservoir et un bassin versant avec son sol et son sous-sol. Ce fonctionnement est caractérisé par une équation de vidange qui relie le volume stocké dans le réservoir au temps t et le débit de vidange, et une équation de conservation entre l'entrée (pluie) et la sortie (débit et évapotranspiration)

Ils sont simple à utiliser et peuvent en général s'adapté sur une grande variété de bassin. On les différencie par le nombre de réservoir, le réseau de leurs connexions, la nature des fonctions de stockage et de vidange ainsi que le nombre des paramètres utilisés.

Dans ce présent chapitre, nous présentons l'historique de ces modèles, les principaux composants qui servent à leurs développements et enfin l'application sur le site d'étude exposé dans le chapitre 1.

2.2. Les différents modèles conceptuels

Ces modèles ont vu le jour en 1962 à l'université de Stanford avec l'apparition d'un modèle construit dans un langage informatique qui reproduit mathématiquement les liens entre la pluie, l'évapotranspiration potentielle et le débit à l'exutoire d'un bassin versant, c'était la première version et qui a été nommée SWM (Stanford Watershed Model) par Crowford et Linsley (1963) dont la nomination a changé à HSBF. C'était le début d'une nouvelle aire de modélisation mathématique dans le domaine de l'hydrologie. Les concepteurs du modèle SWM ont représenté le cycle hydrologique comme étant des compartiments ayant des échanges entre eux. Ces échanges reposent sur des lois simples de vidange de réservoirs et qui sont contrôlées par des paramètres déterminés avec un calage du modèle. Une version à huit compartiments et 14 paramètres (Figure 18) a été publié par la suite.

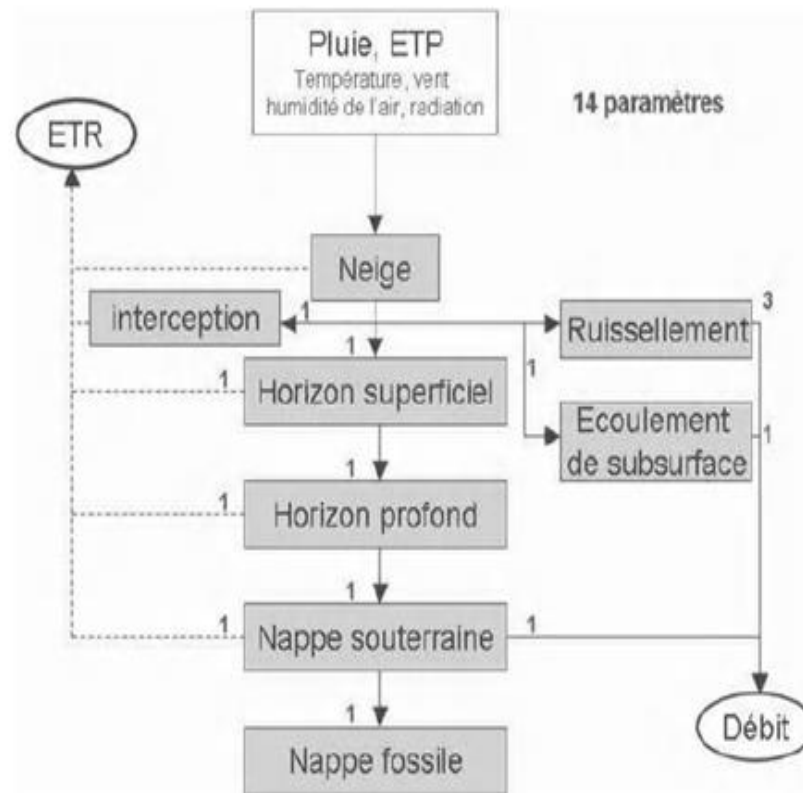


Figure 18. Structure de SWM dans la version 4

La plupart des modèles ont un nombre suffisant de paramètres et une flexibilité à produire une bonne simulation du débit en fonction de la pluie (et l'évapotranspiration potentielle) après une calibration du modèle. Dawdy et O'Donnell (1965) ont essayé de définir une simple structure du modèle avec peu de paramètres (Figure 19) baptisé du nom de « Explicit Soil Moisture Accounting » (ESMA). Dans les années qui suivent, un nombre de modèles semi distribués capable de prendre en considération la variabilité spatiale des processus hydrologique dans un bassin versant ont été développés, dont les modèles Tank développés dans l'institut de recherche national des sciences de la terre et de la prévention des désastres à Tokyo (Japon) par Sugawara (1967) et Sugawara et al. (1974). Y a aussi le modèle TOPMODEL (Beven et Kirkby 1979) dont le concept est de concilier les modèles hydrologiques et la théorie des surfaces contributives saturées, ils introduisent un indice topographique et supposent que les sols des zones de plus faible pente (fond de vallée) ont une plus grande propension à atteindre un état de saturation que les zones de forte pente et donc à générer des écoulements rapides lors d'événements pluvieux.




Figure 19. Structure du modèle conceptuel « ESMA » de Dawdy and O'Donnell (1965)

D'autres modèles qui sont encore utilisés jusqu'à ce jour incluant le modèle the Streamflow Synthesis and Reservoir Regulation (SSARR) qui est utilisé pour la prévision et la gestion de la rivière de Columbia et le modèle Hec Hms qui regroupe dans une interface graphique une multitude de méthodes pour la modélisation des processus dans un bassin. Ces deux modèles ont été développés par l'« US corps of engineers ». Il y a aussi les modèles Sacramento développés par le centre de prévision National Weather Service River Forecast Center in Sacramento, California des Etat Unis d'Amérique, le modèle HBV de la Suède, le modèle UBC de Canada et le modèle RORB de l'Australie. Une autre approche a été visée par le CEMAGREF de France pour construire les modèle GR (Génie Rural) (Michel, 1983), dont l'objectif été de minimisé au maximum les paramètres du modèle et ce qui a donné des résultats satisfaisant. Tous ces modèles varient en nombre d'élément de stockage, les fonctions contrôlant les échanges et donc du nombre et type de paramètres. Le (Tableau 5) montre un échantillon de modèles hydrologiques les plus populaires.

Nombreuse ont été les publications de comparaisons de ces types de modèles et pourtant, ça n'a pas été possible de conclure qu'un des modèle donne de meilleurs

performance par rapport aux autres après calibration (voir par exemple Franchini et Pacciani 1991 : Chiew et al. 1993 et Editjatno et al. 1999).

Tableau.5 Model Conceptuel en continue (tirée de Singh 2002)

Nom du modèle (acronyme)	Auteur(s) (Année)	Remarques
Stanford watershed Model (SWM)/ Hydrologic Simulation Package-Fortran IV (HSPF)	Crawford and Linsley. (1966), Bicknell et al. (1993)	Simulation en continue, évènementiel dynamique ou stationnaire des processus hydrologique, hydraulique et de la qualité
U.S. Geological Survey (USGS) Model	Dawdy et al. (1970, 1978)	Modèle de débit orienté processus, en continue et évènementiel.
Streamflow Synthesis and Reservoir regulation (SSARR) Model	Rockwood (1982), U.S. Army Corps of Engineers (1987) Speers (1995)	Modèle global de simulation des écoulements en continue
Tank Model	Sugawara et al. (1974), Sugawara (1995)	Modèle de simulation en continue global et semi distribué, orienté processus
Storm Water Management Model (SWMM)	Metcalf and Eddy et al. (1971), Huber and Dickinson (1988), Huber (1995)	Modèle des écoulements fluviaux en continue, semi distribué. Orienté processus
Xinanjiang Model	Zhao et al. (1980), Zhao and Liu (1995)	Modèle de simulation en continue global, orienté processus
Hydrological Simulation (HBV) Model	Bergstrom (1976, 1992, 1995)	Modèle de simulation des écoulements fluviaux en continue, global, orienté processus
Simulator for Water Resources in Rural Basins (SWRRB)	Williams et al. (1985), Williams (1995a,b)	Modèle de simulation des sédiments et de débit semi distribué, orienté processus
Physically Based Runoff Production	Beven and Kirkby (1976, 1979) Beven (1995)	Modèle de simulation hydrologique en continue, distribué, à base physique

Model (TOPMODEL)		
Generalized River Modeling Package—Systeme Hydrologue Europeen (MIKE-SHE)	Refsgaard and Storm (1995)	Modèle de simulation hydraulique et hydrologique en continue, distribué, à base physique
ARNO (Arno River) Model	Todini (1988a,b, 1996)	Modèle de simulation pluie-débit en continue, semi distribué
Topographic Kinematic Approximation and Integration (TOPIKAPI) Model	Todini (1995)	Modèle de simulation pluie-débit en continue, distribué, à base physique.
Hydrological (CEQUEAU) Model	Morin et al. (1995, 1998)	Modèle de simulation de débit en continue, distribué, orienté processus.
Systeme Hydrologique Europeen Transport (SHETRAN)	Ewen et al. (2000)	Modèle de simulation de la qualité et la quantité d'eau distribué, à base physique
Simplified Hydrology Model (SIMHYD)	Chiew et al. (2002)	Modèle conceptuel pluie-débit, global, journalier.
The Water and Snow Balance Modeling System (WASMOD)	Xu (1999)	Modèle conceptuel hydrologique en continue, global
Soil Water Assessment Tool (SWAT)	Arnold et al. (1998)	Modèle conceptuel de simulation en continue, distribué.
Génie Rural (GR)	Edijatno et Michel, (1989).	Modèle conceptuel de simulation continue, global

2.3. Choix d'un modèle conceptuel

Dans les années qui suivent l'expansion de l'informatique, chaque équipe d'hydrologue ayant accès à aux ordinateurs ont essayé de construire leurs propre modèle à un point où le nombre et la variété des modèles développés été si important qu'il y avait une difficulté dans le choix d'utilisation, discuté par Beven dans son livre « The primer » (Chapitre 10 P297) décrivant les critères qui doivent être pris en considération dans le choix du modèle, on cite :

- Est-ce que le modèle est disponible, ou pourrait-il être mis à la disposition si l'investissement dans le temps (et de l'argent) semble intéressant ?
- Est-ce que le modèle prédit les variables requises par les objectifs d'un projet particulier ?
- Est-ce que les hypothèses formulées par le modèle semblent être limitées en termes de ce que vous savez à propos de la réponse du bassin versant qui vous intéresse ?
- Est-ce que toutes les entrées requises par le modèle, peuvent pour la spécification du domaine d'écoulement, des conditions initiales et limites ainsi que les valeurs des paramètres être fournis dans les délais et les contraintes de coûts d'un projet ?

La puissance de l'informatique à mener les hydrologues à résoudre le problème de la relation pluie-débit en ajoutant des degrés de complexité dans leurs modèles, ce qui augmente au fur et à mesure le nombre de paramètres qui seront plus difficiles à calibrer. Ces structures peuvent aussi présenter des problèmes de sur-optimisation, qui sont connues pour les mauvais résultats de tests malgré un bon ajustement au calage. Ce problème nous oriente à l'utilisation du modèle GR4J (version évoluée du 1er GR) pour sa simple structure et le nombre minime de paramètres qui seront par la suite facile à optimiser en plus de sa disponibilité sur le site web de l'IRSTEA.

2.4. Le modèle GR4J

Les modèles du Génie Rural ont été développés en 1990 par l'IRSTEA (ex CEMAGREF), leurs premières apparitions ont été en 1983. Ils ont été testés sur plusieurs bassins à travers le monde, on cite la France, la Côte d'Ivoire (Servat et Dezetter 1993), la Grande Bretagne (Perrin, 1997) et en Australie (Pagano, Hapuarachchi et al. 2010). Dans cette étude, une version améliorée du GR4J (Figure 20) (Perrin et al. 2003) est utilisée. C'est un modèle conceptuel global à quatre paramètres, composé de deux réservoirs (production et routage), il utilise la pluie et l'évapotranspiration potentielle comme entrées du modèle.

2.4.1. Description du modèle

Le modèle du GR4J est composé de deux réservoirs (production et routage). Au début, la pluie brute (P) subit l'évapotranspiration potentielle (E) et est transformé en pluie nette (Pn), une partie de cette dernière (Ps) sert à alimenter le 1er réservoir.

Lorsque l'évapotranspiration potentielle (E) dépasse la pluie brute (P), le restant (En) servira à évaporer l'eau contenue dans le réservoir sol (production) avec un taux (Es).

Le réservoir de production va subir une percolation (Perc) qui va être additionnée avec le reste de la pluie nette (Pn) pour former la pluie efficace (Pr) et transiter vers l'exutoire.

La mise à jour du réservoir de production se fait par une entrée de (Ps) et deux sortie (Es et Perc).

La pluie obtenue et qui va transiter (Pr) est séparée en deux composante :

- 90% : Un écoulement routé par un hydrogramme unitaire et un réservoir de routage (UH1).
- 10% : Un écoulement pseudo-direct est routé par un hydrogramme symétrique (UH2) et transite directement vers l'exutoire (Qd).

L'hydrogramme unitaire simule le temps de montée de l'hydrogramme des deux écoulements et les retarde progressivement.

Les 90% de l'écoulement (Pr) qui a été retardé par l'hydrogramme unitaire (UH1) transitent par un réservoir de routage non linéaire et qui lui sert d'entrée (Q9). Le réservoir se vidange selon une loi qui est fonction d'une constante (K).

Une fonction d'échanges souterrains $F(X1)$ qui tient compte des infiltrations profondes et les échanges d'eau souterraine est soustraite à l'écoulement pseudo directe (Qp) et au niveau du réservoir de routage.

Le réservoir de routage est mise à jour avec l'entrée de la principale composante de la pluie efficace (Q_9), et les deux sorties qui sont la fonction d'échange $F(X_1)$ et le débit du réservoir (Q_r).

La somation des débits (Q_r) et (Q_d) va donner le débit total qui arrive à l'exutoire du bassin.




Figure 20. Structure du modèle GR4J, version de Perrin et al (2003)

2.5. Calage des modèles conceptuel

Le but du calage d'un modèle est d'estimer le jeu de paramètres optimal qui fera en sorte que le modèle puisse ajuster au maximum les valeurs simulées et observées (Figure 21). Deux types de calage existent :

- Le calage manuel : c'est un ajustement de paramètre par la méthode essai-erreur utilisant la visualisation entre l'hydrogramme simulé et observé comme moyen de jugement.
- Le calage automatique : dans ce type de calage, l'ajustement des paramètres se fait automatique selon un schéma de recherche spécifique appelé « algorithme d'optimisation », une mesure numérique appelée « fonction objective », des données utilisées pour le calage, des valeurs de paramètres initiales qui serviront de point de départ pour l'algorithme, et enfin un critère pour arrêter le processus de recherche appelé « critère d'arrêt », il peut s'agir par exemple de nombre d'itération de l'algorithme.

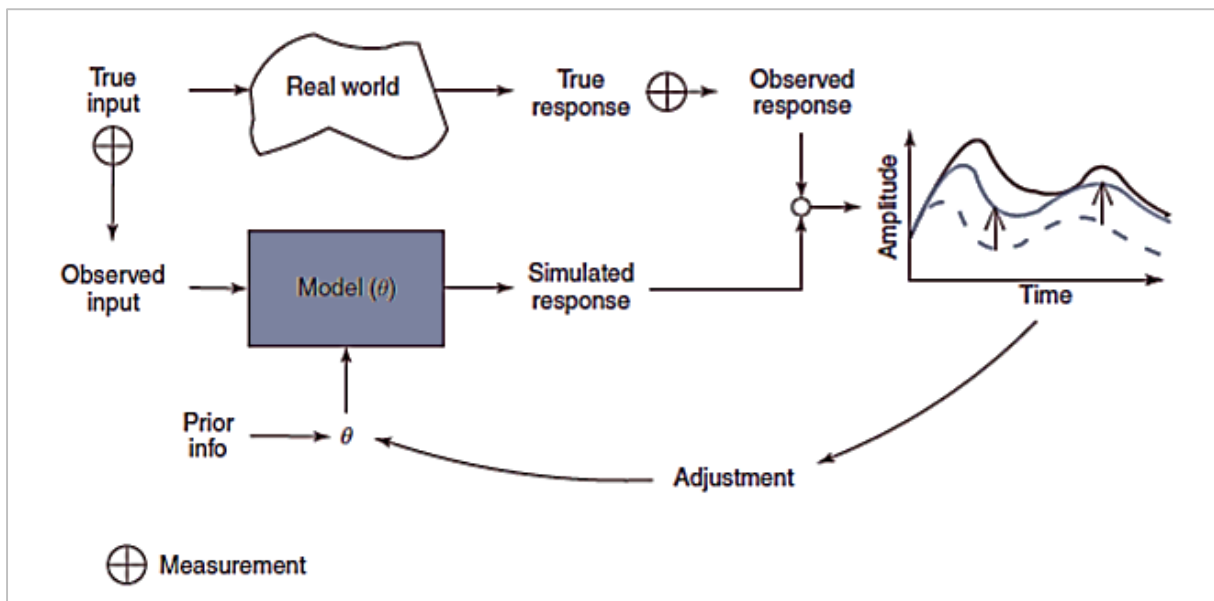


Figure 21. Stratégie de calibration des modèles (θ représente le jeu de paramètre à calibrer)

Pour un hydrologue expérimenté, il est possible d'obtenir un modèle hydrologiquement bon en utilisant la méthode de calibration manuel, ceci dit cette tâche reste très difficile et peut prendre énormément de temps et encore plus avec l'augmentation du nombre de paramètres, alors que le calage automatique nécessite beaucoup moins de temps. Dans cette étude, la méthode automatique est utilisée pour caler le modèle GR4j.

2.5.1. La fonction objective

Appelé aussi fonction de coût, c'est une équation qui doit être maximisée ou minimisée et sert comme critère de meilleure performance à l'algorithme d'optimisation. Cette fonction influence l'estimation des paramètres et la qualité des résultats du modèle. Rao et Han (1987) ont analysé plusieurs fonction objectives dans la calibration du modèle ILLUDAS et ont trouvé que le critère de l'erreur quadratique été le meilleur. Servat et Dezetter (1991) ont utilisé cinq fonctions objectives dans un modèle pluie-débit en Côte d'Ivoire et ont démontré que le critère Nash-Sutcliff (1971) donne aux résultats du modèle une meilleure qualité. Une autre étude a été faite par Muleta (2012) et qui consisté a testé trois groupe de fonction objective sur le modèle SWAT en utilisant la calibration automatique, le groupe 1 été basé sur la minimisation des déviations absolue, le deuxième sur la minimisation du carré des résidus et le groupe 3 sur l'utilisation du log des valeurs simulées et observées du débit. Ceci a montré qu'en ce qui concerne la capacité de décrire la qualité de simulations de modèle, les critères d'efficacité appartenant au groupe I montrent une robustesse supérieure aux deux autres groupes. Ces dernières années, l'utilisation des fonctions multi-objectives a connu une grande considération dans les applications de ressources en eau [Yapo et al (1998) ; Madsen (2000) ; Madsen & Khu (2002) ; Madsen (2003) ; Vrugt et al. (2003a) ; Cheng et al. (2005a) ; Fenicia et al. (2007a), Moussa & Chahinian (2009)] ça consiste à utiliser un vecteur de fonction objective au lieu d'un scalaire pour optimiser les paramètres du modèle et donc permet d'incorporer plusieurs critères dans la validation dans le but d'obtenir plusieurs jeux de paramètre alternative qui sont optimaux.

Le choix de fonction objective dépend généralement de l'objective du modélisateur. Dans cette étude, une comparaison entre plusieurs approches de modélisation est proposée. Pour que la comparaison soit équivalente entre les différentes approches, une seule fonction objective est utilisée, à savoir l'erreur quadratique (Equation 2) appelée en anglais « Mean Square Error » (MSE). L'algorithme d'optimisation à pour objective de minimiser cette fonction et s'approcher le plus possible du 0 (modèle parfait), plus il s'en éloigne, moins la prédiction est bonne.

$$MSE = \frac{1}{N} \sum_{i=1}^n (O_i - S_i)^2 \quad (2)$$

Avec :

O et S sont respectivement les valeurs observées et simulées

N est le nombre total d'observation

D'autres fonctions serviront comme critères de comparaison et qui sont :

Critère de Nash « Nash-Sutcliffe Efficiency » (Nash-sutcliffe 1971)

$$NSE = 1 - \frac{\sum_{i=1}^N (O_i - S_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (3)$$

Avec : \bar{O} et \bar{S} sont respectivement les valeurs moyennes observée et simulées

L'intervalle des valeurs du NSE (Equation 3) va de l'infini négative jusqu'à 1, où 1 montre un modèle parfait, et plus ou s'éloigne de cette valeur plus le modèle est mauvais en prédiction.

Critère volumétrique "Volumetric Efficiency" (Robert et William, 2008)

$$VE = 1 - \frac{\sum_{i=1}^N |O_i - S_i|}{\sum_{i=1}^N O_i} \quad (4)$$

Criss and Winston (2008) ont proposé un critère d'efficacité volumétrique (Equation 4) pour répondre aux limites du NSE. VE varie de 0 à 1 et représente la fraction de l'eau écoulee au moment approprié, son complément représente le décalage volumétrique fractionné. Contrairement au coefficient du NSE, le VE a une signification physique claire pour les hydrologues.

2.5.2. Les algorithmes d'optimisation

Deux catégories d'algorithmes existent : les algorithmes utilisant une méthode de recherche locale et d'autres globales.

- Méthodes locales : incluant les méthodes de recherche directe et du gradient, les deux méthodes consistent à partir d'un point de l'espace des paramètres et se déplacer dans une direction qui améliore la valeur de la fonction objective, mais pour ce qui est de la deuxième méthode, elle utilise en plus de la fonction

objective, le gradient pour décider de la stratégie d'évolution dans l'espace des paramètres. On cite la méthode de Rosenbrock (1960), la méthode du Pattern Search (Hooke et Jeeves, 1961) ou encore la méthode du Simplex (Nelder et Mead, 1965) qui est la plus utilisée dans les méthodes locales directe. Pour les méthodes du gradient, il y a l'algorithme de Davidon-Fletcher-Powell (Fletcher et Powell, 1963) et la méthode de Levenberg-Marquardt (Levenberg, 1944 ; Marquardt, 1963).

- Méthodes globales : Ces méthodes explorent une plus grande partie de l'espace des paramètres et adopte diverses stratégies d'exploration. Contrairement aux méthodes locales, qui peuvent bien souvent tomber dans les minimums locaux, les méthodes globales trouvent une multitude d'optima. On trouve les stratégies de recherche basées sur l'évolution naturelle des populations (Brazil and Krajewski, 1987; Brazil, 1988; Wang, 1991; Duan et al. 1992, 1993; Sorooshian et al. 1993), mais aussi la méthode Shuffled complex evolution (SCE-UA) qui a démontré son efficacité dans l'optimisation globale des modèle hydrologique (Duan et al. 1992, 1993 ; Sorooshian et al. 1993; Luce and Cundy 1994; Gan and Biftu 1996; Tanakamaru 1995; Tanakamaru and Burges 1996; Kuczera 1997). SCE-UA bénéficie de la force de différentes procédures incluant : la méthode de « downhill simplex », « Controlled Random Search » et « The Competitive Evolution » avec l'idée proposé du « Complex Shuffling »

Les deux méthodes ont des points faibles et forts, la première qui en partant d'un point de départ (jeu de paramètre initial), ne fait que descendre vers le minimum le plus proche et se trouve facilement piégé dans le minimum local de la fonction objective, ce qui fait de cette méthode, trop indépendante des conditions initiales (paramètres initiaux). Par contre, lorsqu'il s'agit de la précision du minimum, ce type de méthode est très efficace. Pour ce qui est de la méthode global, elle explore une plus grande partie de l'espace des paramètres et est donc plus apte à trouver un minimum global de la fonction objective. Reste que cette méthode ne permet pas

un réglage fin des paramètres pour approcher correctement le minimum par exemple les algorithmes génétiques présentent une perte d'efficacité quand on a besoin de résultats précis (Renders et Bersini, 1994).

Une autre approche qui consiste à utiliser les deux méthodes « locale » et « globale » a été étudiée par Wang (1991). Ce dernier a reporté que les algorithmes génétique, combiné avec une méthode de recherche local, été un moyen robuste et efficace pour la calibration de modèles pluie-débit.

Les modèles conceptuel de type « pluie-débit » peuvent avoir une multitude d'optima locaux dans la surface de la fonction objective (Duan et al. 1992), à partir de ce résonnement, le modélisateur s'oriente logiquement vers les méthodes globales, or le nombre réduit des paramètres du modèle GR4j fait qu'un simple algorithme d'optimisation est généralement capable d'identifier les valeurs de paramètres produisant des résultats satisfaisant. L'algorithme utilisé est celui de méthode de Nelder-Mead (Nelder et Mead, 1965) pour calibrer le modèle GR4j, ceci en se basant sur sa simplicité de mise en œuvre et sa rapidité de convergence (Duan et al., 1992; Gan et Biftu, 1996). Cette méthode qui fait partie des méthodes locales, utilise un nombre réduit de fonction d'évaluation par itération et est la plus largement utilisé comme méthode de recherche directe.

2.5.2.1. Algorithme de Nelder-Mead

La méthode simplex pour trouver le minimum local d'une fonction de plusieurs variables a été mise au point par Nelder et Mead. Pour deux variables, le simplex est un triangle, et la méthode est recherche direct qui compares les valeurs de la fonction dans les trois sommets du triangle. Le plus mauvais sommet, où $f(x, y)$ est plus large, est rejeté et remplacé par un nouveau sommet. Un nouveau triangle est formé et la recherche continue. Le processus génère une séquence de triangles (qui peuvent être de différentes formes), pour laquelle les valeurs de la fonction dans les sommets diminuent de plus en plus. La dimension des triangles est réduite et les coordonnées du point minimum sont trouvées.

2.5.2.1.1. Principe de fonction

Triangle initial BGW : Soit $f(x, y)$ une fonction qui doit être minimisée. Pour commencer, on donne trois sommets d'un triangle : $V_k = (x_k, y_k)$, $k = 1, 2, 3$. La fonction $f(x, y)$ est alors évalué pour chacun de ces trois points : $z_k = f(x_k, y_k)$ pour $k = 1, 2, 3$. Les indices sont alors réorganisé pour $z_1 \leq z_2 \leq z_3$. On utilise la notation :

$$B = (x_1, y_1), \quad G = (x_2, y_2), \quad \text{et } W = (x_3, y_3)$$

pour aider à se mémorisé que B est le meilleur sommet, G est le meilleur après B, et W est le plus mauvais des sommet.

Milieu du bon côté : Le processus de construction utilise le milieu de segment d'une ligne qui lie B et G. il est trouvé par la moyenne des coordonnées (Equation 5)

$$M = \frac{B+G}{2} = \left(\frac{x_1+x_2}{2}, \left(\frac{y_1+y_2}{2} \right) \right) \quad (5)$$

La réflexion utilisant le point R : La fonction diminue quand on se déplace le long du côté du triangle W jusqu'au B, et elle diminue quand on se déplace le long du coté de W jusqu'au G. Cependant, il est possible que $f(x, y)$ prend des valeurs plus petites aux points éloigné de W dans la direction opposé de la ligne entre B et G. On choisit point test R qui est obtenue par « réflexion » du triangle à travers le côté BG. Pour déterminé R, on trouve d'abord le milieu de M du côté BG. On dessine ensuite un segment de ligne de W jusqu'à M et on appelle cette longueur d. Ce dernier segment est prolongé à une distance d à travers M pour localisé le point R (Figure 22). La formule du vecteur pour R (Equation 6) est :

$$R = m + (M - W) = 2M - W \quad (6)$$

Expansion utilisant le point E : Si la valeur de la fonction en R est plus petite que la valeur de la fonction en W, c'est que le déplacement s'est fait dans la bonne direction vers le minimum. Il est possible que le minimum soit juste peu éloigné que le point R. Alors on prolonge le segment de la ligne à travers M et R vers le point E. Ceci forme un triangle étendu BGE. Le point E est trouvé par en déplaçant une distance additionnel d le long de la ligne joignant M et R (Figure 23). Si la

valeur de la fonction à E est plus petite que celle de la fonction en R, alors on a trouvé un meilleur sommet que R. La formule du vecteur pour E (Equation 7) est :

$$E = R + (R - M) = 2R - M \quad (7)$$




Figure 22. Le triangle BGW, le milieu M et le point réfléchi R de la méthode Nelder-Mead




Figure 23. Le triangle BGW, le point R et le point prolongé E de la méthode Nelder-Mead

Contraction utilisant le point C : Si la valeur de la fonction en R et W sont les mêmes, un autre point doit être testé. Peut-être que la fonction est plus petite en M, mais on ne peut remplacer W avec M parce qu'on doit avoir un triangle. On considère les deux milieux C_1 et C_2 des segments de lignes WM et MR, respectivement (Figure 24). Le point avec la valeur de fonction la plus petite est appelé C, et le nouveau triangle est BGC.




Figure 24. Le point de contraction C_1 ou C_2 de la méthode Nelder-Mead

Rétrécissement vers B : Si la valeur de la fonction en C n'est pas plus petite que la valeur en W, les points G et W doivent être rétréci vers B (Figure 25). Le point G est remplacé par M, et W est remplacé par S, qui sont les milieux respectifs des segments joignant G avec B et W avec B.




Figure 25. Rétrécissement du triangle vers B de la méthode Nelder-Mead

2.6. Les données de calibration et de test

C'est les données qui vont être utilisées pour l'estimation des paramètres, ils doivent être d'une bonne qualité et avec le maximum d'information. Dans cette étude, le nombre total d'année disponible est de 8 ans [1988-1996]. La première année [1988-1989] a été utilisée pour la mise en route du modèle, cette technique a été utilisée par Chiew et McMahon (1994) et Edijatno et al. (1999) dans le but d'éviter une mauvaise initialisation des états du modèle, à savoir le niveau des

réservoirs de production et de routage). Les cinq années qui suivent [1989-1994] seront utilisées pour calibrer le modèle GR4j et les deux derniers [1994-1996] pour tester le modèle

2.7. Les paramètres initiaux

La plupart des algorithmes d'optimisation nécessite une connaissance des paramètres initiaux pour une bonne calibration. L'analyse de l'hydrogramme est la méthode directe pour l'estimation des paramètres initiaux, mais peut comme même prendre du temps. Une autre approche consiste à utiliser les résultats d'autres bassins versants comme il a été fait dans les travaux de Perrin et al. (2003), où l'estimation des paramètres initiaux s'est faite en utilisant les valeurs médianes et les intervalles de confiance de 80% des quatre paramètres du GR4j et qui ont été tirées à partir de 0.1 et 0.9 centile de la distribution des paramètres du modèle appliqué sur une large variété de bassin versant (Tableau 6).

Tableau 6. Valeurs médiane des paramètres du modèle ainsi que leurs approximations dans un intervalle de confiance de 80 %

	Valeurs médianes	Intervalle de confiance 80%
X1 (mm)	350	100 - 2000
X2 (mm)	0	- 5 à 3
X3 (mm)	90	20 – 300
X4 (jours)	1.7	1.1 – 2.9

Pour assurer une bonne performance de calibrage et ne pas tomber dans le piège du minimum local, l'algorithme de Nelder- Mead a été appliqué dix fois en variant les paramètres initiaux aléatoirement, tout en restant dans l'intervalle reporté dans le (Tableau 6) par Perrin et al. (2003).

2.8. Résultats et discussion

Une simulation de la relation pluie-débit a été modélisée en utilisant le modèle GR4j sur le sous bassin de Oued Rassoul. Différentes entrées de pluie ont été suggérée afin de déterminer laquelle des méthodes, ponctuelles (mesure dans chaque station) et surfaciques (estimée par la moyenne arithmétique et la méthode de Thiessen) effectuent la meilleure performance. Les résultats de la simulation du débit avec le modèle GR4j sont reportés dans le (Tableau 7).

Tableau 7. Résultats du modèles GR4j utilisant les différentes entrées de pluie

Entrée de pluie	MSE (mm ²)		NSE		VE	
	Calibration	Test	Calibration	Test	Calibration	Test
P5	0.66	1.27	0.70	0.68	0.57	0.55
P6	0.61	1.26	0.72	0.68	0.60	0.58
Par	0.46	1.17	0.79	0.70	0.48	0.46
Pth	0.54	1.22	0.75	0.69	0.47	0.47

L'analyse du (Tableau 7) montre une différence entre les performances du modèle simulant le débit en fonction des quatre entrées de pluie. Au niveau du MSE, critère qui somme les erreurs au carré et qui est utilisé comme fonction objective, le modèle utilisant Par donne la meilleure performance avec un MSE dans la phase test de 1.17 mm² devant celui qui utilise Pth (1.22). Utilisant les autres entrées (P5 et P6), ce critère augmente jusqu'aux valeurs respectives 1.27 et 1.26. Le même constat peut être aperçu pour le critère NSE, sauf que la différence est assez légère entre les quatre pluies, allant de 0.01 pour Pth et 0.02 pour Par. Les deux critères cités au-dessus montrent une supériorité dans l'utilisation des pluies surfaciques par rapport au pluie ponctuelle, or les modèles utilisant ces dernières sont plus aptes à simuler le débit en gardant une meilleur performance au niveau volumétrique, ceci est mis en évidence par le critère VE résultant des modèles utilisant les pluies ponctuelles P5 et P6 dont les critères VE respectives sont 0.55 et 0.58 alors que ceux des pluies Par et Pth sont respectivement de 0.46 et 0.47. Le modèle utilisant P6 est celui qui effectue la meilleure performance en termes de critère volumétrique

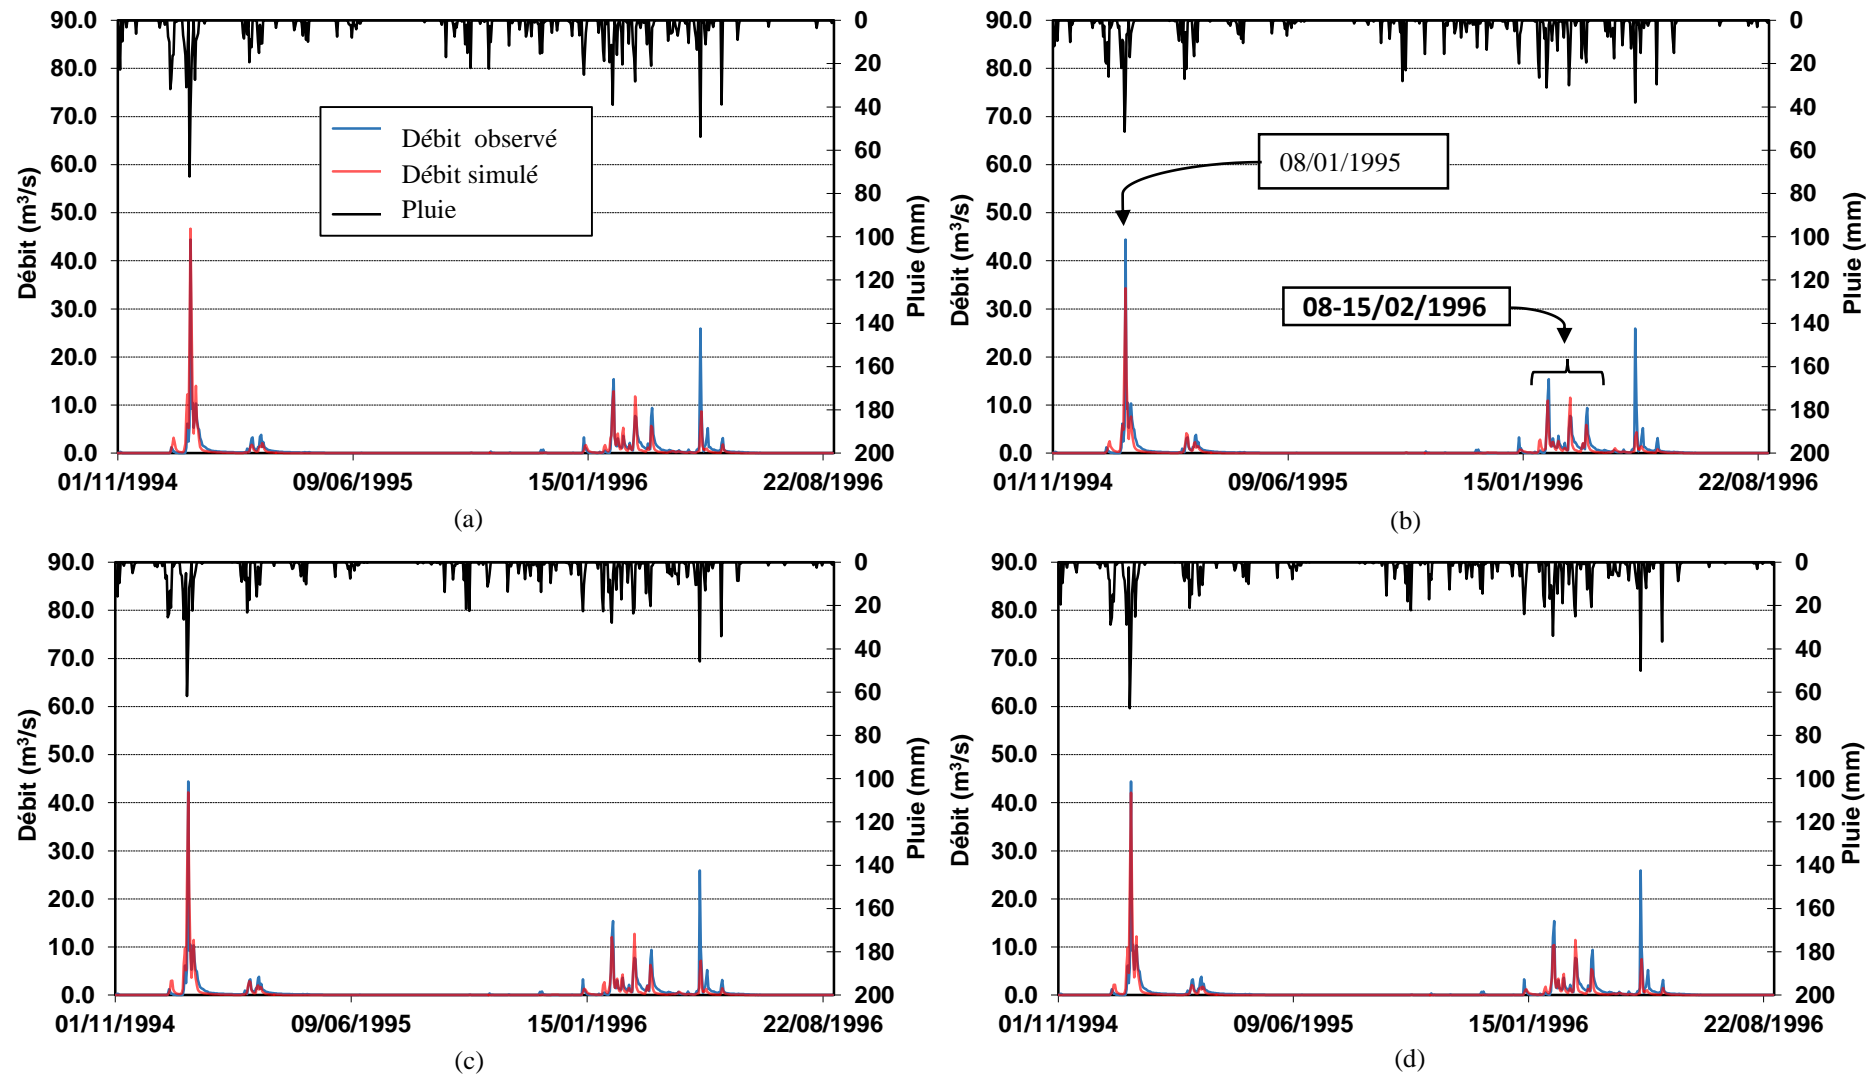

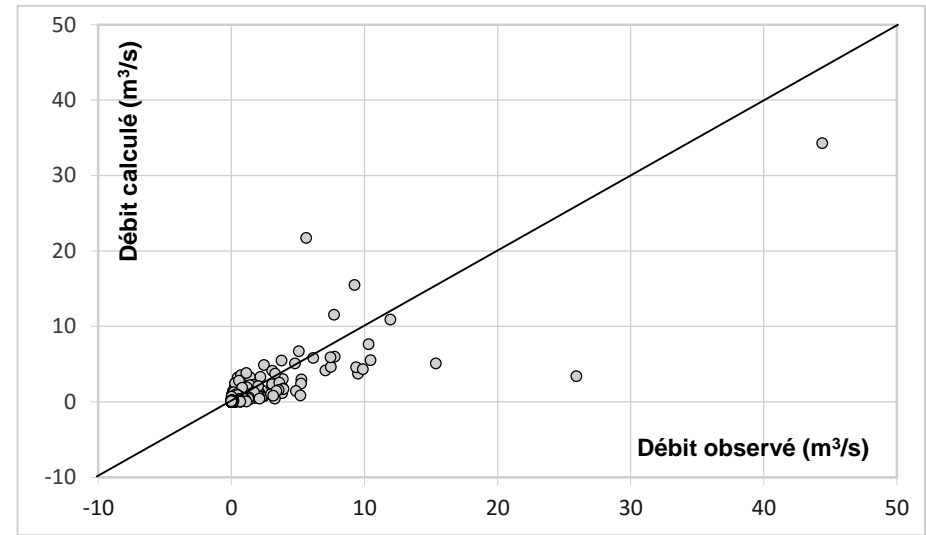


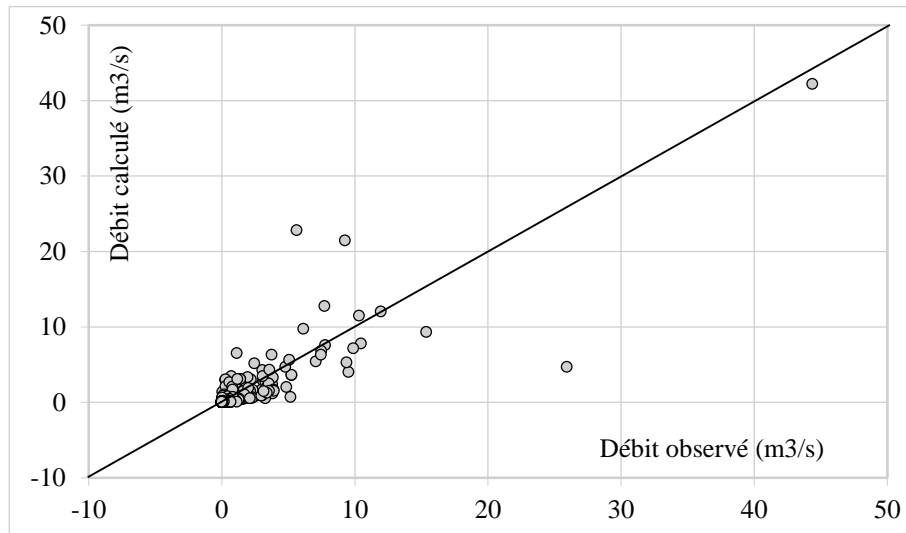
Figure 26. Simulation du modèle GR4j utilisant les différentes entrées de pluie (a) P5 (b) P6 (c) Par et (d) Pth



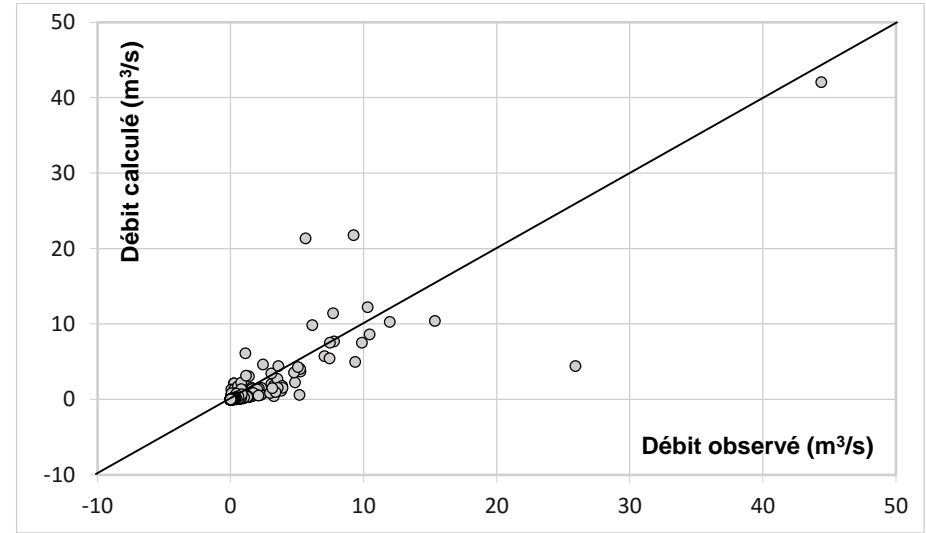
(a)



(b)



(c)



(d)

Figure 27. Performances du modèle GR4j en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth

Les graphes de la simulation du débit en fonction des différentes séries de pluie lors de la phase teste illustrées dans les (Figures 26 et 27) montrent un bon suivie de la dynamique du débit observé en utilisant les quatre variantes de pluie, sauf dans le cas du dernier évènement de l'année 1996 qui résulte d'une montée assez rapide du débit. Le 1^{er} pic du débit du 08/01/1995, mesuré à $44.39 \text{ m}^3/\text{s}$ a été bien simulé lors de l'utilisation de P5, Par et Pth avec une surestimation de $2.29 \text{ m}^3/\text{s}$ pour la 1^{ère} et des sous-estimations respectives des deux autres 2.23 et $2.33 \text{ m}^3/\text{s}$, l'erreur relatives lors de ce pic de débit est de $\pm 5\%$. Alors que pour le modèle qui utilise comme entrée P6 une sous-estimation de $10.1 \text{ m}^3/\text{s}$ est observée (équivalent à une erreur relative de -22.75%). Ceci peut s'expliquer du fait que la station mesurant la pluie P6 et qui a enregistré une hauteur journalière de 51.5 mm , est située à proximité de la station de jaugeage, emplacement où l'altitude est la plus basse (71 m) par rapport au reste du sous bassin et aussi par rapport à la station qui mesure la pluie P5 (286 m d'altitude) et qui a enregistré une hauteur de 72.2 mm . Cette différence a fait que le modèle utilisant P6 sous-estime le pic du débit survenue le 08/01/1995. Les évènements du 08 au 15/02/1996 ont été mal simulés avec tous les modèles avec des degrés d'erreurs différents, le premier pic mesuré à $15.37 \text{ m}^3/\text{s}$ a été simulés par les modèles P5, P6, Par et Pth respectivement à 12.88 , 5.08 , 9.32 et $10.41 \text{ m}^3/\text{s}$, traduites par les erreurs relatives respectives -16.2 , 66.95 , 39.36 et 32.27% . Le deuxième pic a été surestimé par tous les modèles avec des erreurs allant de $+48$ à 65% alors que le troisième a contrairement été sous-estimé avec des erreurs allant de -51.06 à -43% par rapport au mesures observées. Pour ce qui est du dernier évènement de l'année 1996, une sous-estimation est observée pour tous les modèles avec une erreur allant jusqu'à -86.92% .

Tableau 8. Simulation du modèle GR4j utilisant les différentes entrées de pluie et différents paramètres initiaux

Entrée de pluie	Paramètres initiaux				Paramètre après calage				MSEc	MSEv
	x1	x2	x3	x4	x1	x2	x3	x4		
Pluie mesurée sur la station 140605	220.01	-4.67	146.78	2.65	163.24	-3.67	20.17	1.34	0.66	1.27
	1035.78	0.94	64.6	2.44	163.25	-3.67	20.17	1.34	0.66	1.27
	304.29	1.05	39.81	2.27	163.24	-3.67	20.17	1.34	0.66	1.27
	983.75	0.99	127.51	2.05	107.28	-3.37	111.38	0.84	0.94	2.59
	813.17	-3.65	136.13	1.91	163.24	-3.67	20.17	1.34	0.66	1.27
	191.09	0.71	87.98	1.54	163.24	-3.67	20.17	1.34	0.66	1.27
	781.51	-1.54	278.76	2.8	163.25	-3.67	20.17	1.34	0.66	1.27
	616.12	-3.23	38.48	2.67	163.24	-3.67	20.17	1.34	0.66	1.27
	574.29	-0.76	296.67	2.29	163.24	-3.67	20.17	1.34	0.66	1.27
	1021.6	-3.35	212.86	1.95	163.24	-3.67	20.17	1.34	0.66	1.27
Pluie mesurée sur la station 140606	453.39	-3.06	91.92	2.19	138.85	-2.02	16.49	1.28	0.61	1.27
	478.97	1.63	102.31	2.84	137.9	-2.12	16.37	1.29	0.61	1.26
	895.38	2.63	272.8	1.42	90.52	-4.9	68.15	0.49	0.82	1.86
	435.69	0.46	33.94	2.84	138.85	-2.02	16.49	1.28	0.61	1.27
	717.38	-0.05	85.66	1.47	138.85	-2.02	16.49	1.28	0.61	1.27
	994.44	-0.92	175.24	1.74	90.5	-4.9	68.12	-4.86	0.82	1.86
	419.7	-3.04	222.71	1.68	138.84	-2.02	16.49	1.28	0.61	1.27
	479.39	1.7	266.68	2	45.79	1.76	405.61	1	1.34	2.08
	144.28	0.28	136.13	2.5	137.9	-2.12	16.37	1.29	0.61	1.26
	373.61	0.96	158.33	1.64	137.91	-2.12	16.37	1.29	0.61	1.26
Pluie issus de la moyenne arithmétique	1017.79	-1.82	226.37	1.72	143.12	-2.51	17.04	1.33	0.46	1.17
	441.86	-2.99	173.85	2.75	143.13	-2.51	17.04	1.33	0.46	1.17
	948.13	-4.31	257.33	1.41	143.12	-2.51	17.04	1.33	0.46	1.17
	607.82	-4.97	278.11	2.1	143.12	-2.51	17.04	1.33	0.46	1.17
	1082.68	-4.7	298.7	1.51	143.12	-2.51	17.04	1.33	0.46	1.17
	300.97	-3.95	276.36	2.18	143.12	-2.51	17.04	1.33	0.46	1.17
	914.14	-3.4	179.2	1.26	143.12	-2.51	17.04	1.33	0.46	1.17
	999.97	0.89	259.25	2.66	133.34	1.87	92.34	1	1.05	2.23
	243.78	-1.64	146.04	2.64	143.13	-2.51	17.04	1.33	0.46	1.17
	261.67	-1.98	201.73	1.98	143.12	-2.51	17.04	1.33	0.46	1.17
Pluie issus des polygones de Thiessen	504.40	2.22	222.02	1.92	148.77	-3.20	19.34	1.34	0.54	1.22
	146.74	-4.72	255.87	1.15	148.76	-3.20	19.34	1.34	0.54	1.22
	147.12	-0.88	75.92	2.64	148.76	-3.20	19.34	1.34	0.54	1.22
	736.06	-4.33	78.18	1.17	148.76	-3.20	19.34	1.34	0.54	1.22
	478.69	2.71	62.24	1.22	148.76	-3.20	19.34	1.34	0.54	1.22
	453.39	-3.06	91.92	2.19	148.76	-3.20	19.34	1.34	0.54	1.22
	478.97	1.63	102.31	2.84	148.76	-3.20	19.33	1.34	0.54	1.22
	895.38	2.63	272.80	1.42	94.94	-6.21	90.61	-0.15	0.81	2.44
	435.69	0.46	33.94	2.84	148.77	-3.20	19.34	1.34	0.54	1.22
	717.38	-0.05	85.66	1.47	148.76	-3.20	19.34	1.34	0.54	1.22

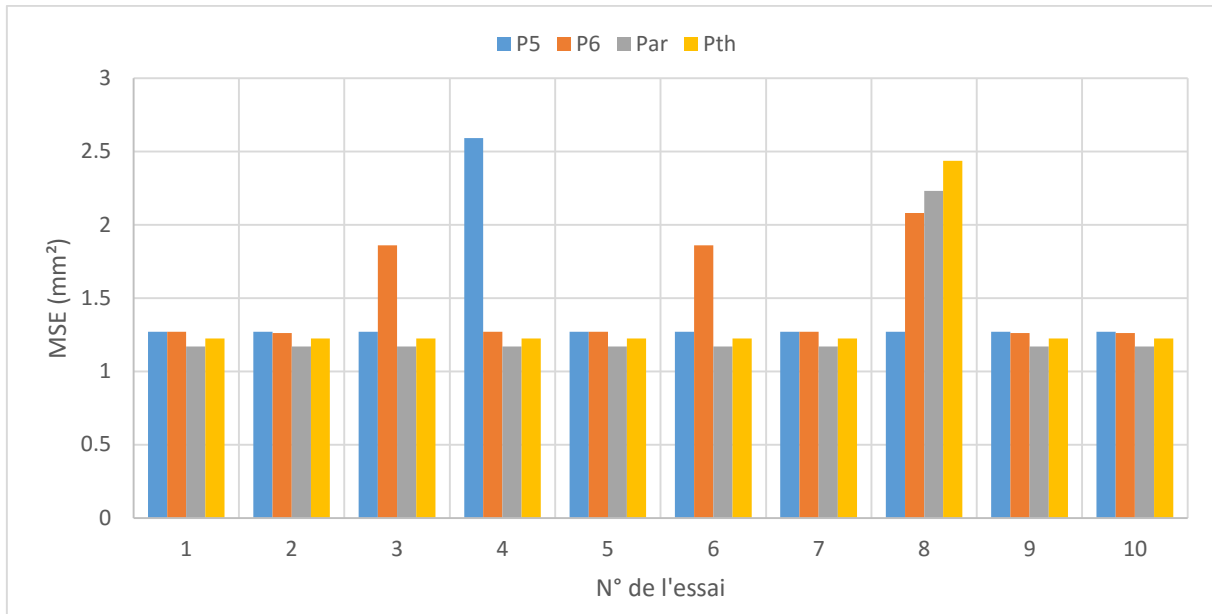


Figure 28. Les MSE atteint (en phase test) après calage par le modèle GR4j pour différents paramètres initiaux

Les mauvais résultats de la simulation du débit pendant l'année de 1996 peuvent être dus à :

- une mauvaise représentation de la pluie
- l'algorithme d'optimisation se fait piéger dans le minimum local
- les données de calibration ne contiennent pas assez d'informations pour développer le modèle correctement.
- une mauvaise qualité des données pluviométriques ou hydrométrique.
- le modèle GR4j n'est pas très bien ajuster pour le régime hydrologique de la région.

Pour le premier cas, il ne peut être justifiable étant donné qu'on a utilisé quatre méthodes de représentativité de la pluie, en plus du fait que la superficie du bassin versant n'est pas si grande pour que le phénomène spatio-temporelle affecte grandement les résultats, d'ailleurs les résultats des différentes simulations (variation de la pluie) sont plus ou moins similaires.

Les paramètres initiaux ont été varié aléatoirement dans l'intervalle mis par Perrin et al., (2003) dans le (Tableau 6) avant chaque démarrage de l'algorithme d'optimisation. En analysant le (Tableau 8 et la Figure 28) qui montrent les résultats (MSE en phase test) atteints par les différents modèles, on remarque que dans la

plupart des cas, on arrive aux mêmes résultats. Pour les modèles utilisant P5, P6 et P7, rien qu'une fois sur dix, on n'arrive pas au minimum global de la fonction, et que trois essais sur dix, le modèle utilisant P6 n'atteint ce minimum. De ces faits, on écarte le problème dû au calage.

Reste les dernières suppositions qui peuvent être à l'origine des mauvais résultats obtenus dans cette année 1996. La troisième peut être à l'origine de ces résultats vu que dans l'année 1996 il a été remarqué que les pluies journalières moyennes annuelles enregistrées dans les stations en plus du nombre de jour dont la pluie est au-dessus de la pluie moyenne ont considérablement augmentés (Figures 13 et 14). La quatrième et la cinquième dont la vérification nécessite une application sur d'autre bassin versant de la région pour pouvoir tirer des conclusions.

2.9. Conclusion

Un modèle de type conceptuel (GR4j) a été utilisé dans ce chapitre pour la simulation journalière du débit en fonction de deux entrées qui sont la pluie et l'évapotranspiration potentielle, en utilisant l'algorithme Nelder-Mead pour le calage. Les résultats montrent une meilleure performance en termes de critères MSE et NSE, en utilisant les pluies issues des méthodes surfaciques par rapport aux séries de pluie mesurée dans les stations pluviométrique (ponctuelle), alors que le contraire a été aperçu en termes de critère volumétrique.

Lors des grands pics du débit, le modèle utilisant les observations acquises de la station P5 dont la situation géographique est placée en haute altitude, réalise une meilleure simulation par rapport au modèle utilisant P6 (basse altitude). Quant au niveau du volume, ce dernier modèle est considéré comme plus efficace.

Les résultats globaux obtenus par le modèle GR4j ne sont pas satisfaisants car une année sur deux a été plus ou moins bien simulée. Après la mise au point de certaines hypothèses concernant ces mauvais résultats, il a été conclu qu'il peut s'agir soit d'un mauvais choix des données utilisées pour le calage du modèle, soit d'une mauvaise qualité des données pluviométriques ou hydrométriques, soit de la structure du modèle GR4j en elle-même. A partir de ces suppositions, une étude plus pointue sur l'application de ce modèle dans la région du Nord Est Algérien

doit être conduite pour éclaircir ces parties sombres qui restent inexploré, et augmenter les performances de ce modèle parcimonieux.

CHAPITRE 3

Modèles d'intelligence artificielle et relation pluie-débit

3.1. Introduction

Une autre option de modélisation hydrologique consiste à choisir une fonction mathématique reliant la pluie et le débit dans une famille de fonctions prédéterminée sans rentrer dans l'analyse et la tentative de représentation des processus. On renonce alors à donner tout sens physique aux paramètres du modèle. Le calage est une étape indispensable de mise en œuvre de ce dernier. Dans ce genre de modèle on trouve les modèle linéaire dit aussi modèles ARMAX (autoregressive moving average model with external inputs) (Box et Jenkins, 1976) qui sont parmi les plus utilisés, en particulier par les services d'annonce de crues, on trouve aussi les réseaux de neurones et les systèmes d'inférence logique à base de réseau adaptatif, ce sont d'autres types de fonctions qui peuvent être utilisés et qui ont connu un certain succès dans la communauté hydrologique ces dernières années.

Ces modèles nous intéressent dans la mesure où ils peuvent être utilisés comme un simple modèle de simulation pluie-débit ou être utilisé comme complément d'un autre modèle.

3.2. Les réseaux de neurones artificiels

Avant d'entamer l'état de l'art des réseaux de neurone dans la relation pluie-débit, il est important de connaître comment fonctionne les réseaux de neurones et connaître les notions de base de cette technique. Plusieurs notions ont été tirées et traduit à partir du livre de Haykin (2009)

3.2.1. Historique des RNA

La notion basic des réseaux de neurones artificiels (RNA), comme on l'a connaît aujourd'hui a été formalisé par McCulloch et Pitts (1943) dans leur modèle d'un neurone artificiel. Depuis ce temps, les réseaux de neurones ont évolué en trois phases distinctes (Schalkoff, 1997). La première ère implique les travaux préliminaire du développement d'un neurone artificiel jusqu'à Minsky et Papert (1969) qui ont identifié plusieurs facteurs limitant. La seconde ère a commencé avec la redécouverte et la popularisation de l'algorithme de rétropropagation (Rumelhart et McClelland, 1986). Avant ce travail fondateur, il était très difficile de former des réseaux de neurones de n'importe qu'elle taille pratique. La troisième

époque est caractérisée par des évaluations plus rigoureuses de limitations du réseau et les généralisations, la fusion avec d'autres technologies (comme les algorithmes génétiques et la logique floue) et la mise en œuvre des RNA utilisant du matériel dédié. Il a été prouvé que les RNA peuvent fournir de meilleures solutions lorsqu'ils sont appliqués à (1) des systèmes complexes qui peuvent être mal compris ou décrits; (2) qui traitent de problèmes de bruit ou qui impliquent la reconnaissance des formes, le diagnostic, l'abstraction et la généralisation; et (3) des situations où l'entrée est incomplète ou ambiguë par la nature (Tokar et Marcus, 2000).

3.2.2. Neurone biologique

Le neurone biologique (Figure 29) est une cellule constituant l'élément fondamental du tissu nerveux. Son noyau est bloqué en «interphase », ce qui l'empêche de se diviser. Ce sont les neurones qui constituent l'unité fonctionnelle du système nerveux. Le relais qui assure la transmission de l'influx nerveux est la synapse. Il existe deux sortes de synapse: les synapses électriques (minoritaires) et les synapses chimiques (majoritaires). La synapse est constituée d'un élément pré synaptique, d'une fente synaptique et d'un élément postsynaptique.

Du point de vue fonctionnel, il faut considérer le neurone comme une entité polarisée, c'est-à-dire que l'information ne se transmet que dans un seul sens : des dendrites vers l'axone




Figure 29. Dessin explicatif d'un neurone biologique

3.2.3. Neurone formel

Un "neurone formel" (ou simplement "neurone") (Figure 30) est une fonction algébrique non linéaire et bornée, dont la valeur dépend de paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées "entrées" du neurone, et la valeur de la fonction est appelée sa "sortie".

ça donne les (Equation 8 et 9):

$$y = f(P) \quad (8)$$

où :

y : Sortie du modèle

f : Fonction de transfert

P : somme pondérée

$$P = \sum_{i=1}^n x_i w_i \quad (9)$$

x : Entrées du modèle

w : Poids

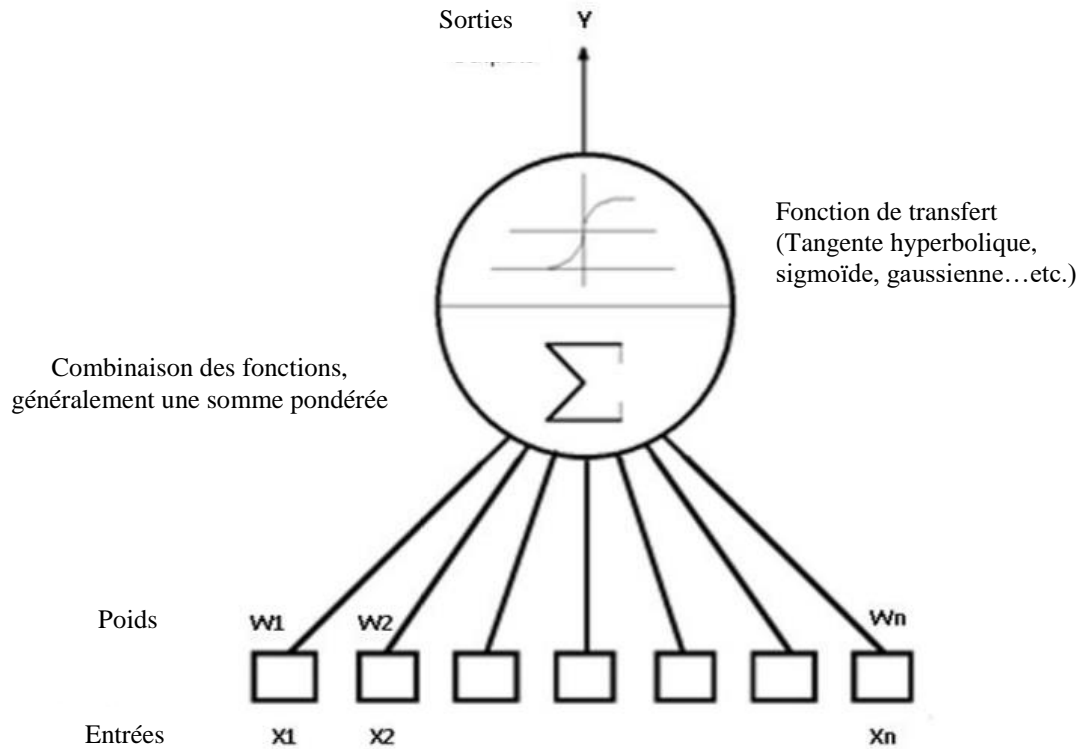


Figure 30. Schéma du fonctionnement d'un neurone formel

3.2.3.1. Les différents types de fonction de transfert

3.2.3.1.1. Fonction binaire

Les premiers modèles de neurones étaient caractérisés par une fonction d'activation à seuil simple (binaire: 0=inactif, 1=actif). Le déclenchement de l'activité intervient si la somme des excitations dépasse un certain seuil propre au neurone.

Si $P > 0 \implies$ Excitatrice

$y = 1$ Si $P < 0 \implies$ Inhibitrice

$y = -1$ Si $P = 0 \implies$ Non Connectée

La fonction binaire confère une certaine efficacité aux réseaux et correspond à un modèle proche de la réalité.

3.2.3.1.2. Fonction linéaire par morceaux

Dans l'intervalle $[-1, 1]$ (Equation 10):

$$f(x) = A \cdot x \quad (10)$$

Alors qu'en dehors de l'intervalle (Equation 11) :

$$f(x) = -1 \text{ ou } +1 \quad (11)$$

Ce modèle est plus réaliste en faisant apparaître des phénomènes de saturation.

3.2.3.1.3. Fonction linéaire

$$f(x) = A \cdot x \quad (12)$$

Lorsque la fonction d'activation est dérivable, il est possible d'utiliser des algorithmes d'apprentissage performants.

3.2.3.1.4. Fonction sigmoïde

$$f(x) = \frac{1}{1+e^{-x}} \quad (13)$$

Ce type de fonction (Equation 13) combine l'avantage de l'effet de seuil et de la dérivabilité. Les fonctions sigmoïdes sont donc très utilisées.

3.2.3.1.5. Fonction gaussienne

$$f(x) = \exp\left(-\frac{x^2}{2 \cdot \text{sigma}^2}\right) \quad (14)$$

Fonction non monotone : effet inhibiteur d'une trop grande sollicitation. Utilisée dans les réseaux de type «RBF» (Radial Basis Functions).




Figure 31. Les différents type de fonction de transfert dans les RNA(a) fonction binaire, (b) fonction linéaire par morceaux (c), fonction linéaire (d) fonction sigmoïde, (e) fonction gaussienne

3.2.4. Classification topologique des réseaux de neurones

3.2.4.1. Les réseaux feed-forward (Non bouclés)

Appelés aussi «réseaux de type Perceptron», ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière possible.

3.2.4.1.1. Le perceptron monocouche

Dans un réseau de neurone constitué de couches, les neurones sont organisés en fonction de ces derniers. Dans la forme la plus simple du réseau, on a une couche d'entrées des neurones sources qui projette directement sur une couche de sortie (neurones calculateurs), mais pas au sens inverse. En d'autres mots, ce réseau est strictement un type feedforward. Comme illustré dans la (Figure 32) pour le cas de quatre neurones dans les deux couches (entrée et sortie). Un tel réseau est appelé réseau monocouche désignant la seule couche de sortie qui comporte les neurones de calcul. On ne prend pas en considération la couche d'entrée vu qu'il n'y a pas de calcul dans cette couche.




Figure 32. Schéma descriptif du perceptron monocouche

3.2.4.1.2. Le perceptron multicouches (PMC)

La seconde classe des réseaux de neurones feedforward, se distingue par la présence d'une ou plusieurs couches cachées, dont ses neurones de calcul sont appelés des neurones cachés ou unité cachée. Ce terme « caché » se réfère dans le fait que cette partie du réseau de neurone n'est pas directement visible ni par les entrées ni par les sorties du réseau. La fonction des neurones de la couche cachée est d'intervenir entre les entrées extérieures et les sorties du réseau d'une certaine manière utile. En ajoutant une ou plusieurs couches cachées, le réseau est capable d'extraire des statistiques d'ordre élevé à partir des entrées. Les neurones sources dans la couche d'entrée du réseau constituent les signaux d'entrée appliqués sur les neurones de la seconde couche (ex : première couche cachée). Les signaux de sortie de la deuxième couche sont utilisés comme entrée pour la troisième couche, et ça continue jusqu'à la fin du réseau. Typiquement, les neurones dans chaque couche du réseau ont comme entrée que les signaux de sortie de la couche précédente. L'ensemble des signaux de sorties des neurones dans la couche de final du réseau constitue la réponse globale de ce dernier par rapport aux neurones sources de la couche d'entrée. Un schéma de la structure d'un PMC est montré dans la (Figure 33).




Figure 33. Schéma descriptif du perceptron multicouches

3.2.4.1.3. Les réseaux à fonction radiale (RBF)

Les réseaux à fonction radiale (RBF) qui possèdent deux couches forment une classe particulière de réseaux multicouches. Chaque cellule de la couche cachée utilise une fonction d'activation Gaussienne.

3.2.4.2. Les réseaux feed-back (Récurrents)

Un réseau récurrent se distingue du réseau de type feedforward dans le fait qu'il a au moins un seul « feedback » (retour d'information). Dans un cas de réseau récurrent constitué d'une seule couche de neurones, où chaque neurone effectue un « feedback » de ses signaux de sortie vers les entrées de tous les autres neurones, comme illustré dans la (Figure 34). Dans cette structure, un neurone n'effectue pas de « feedback » vers lui-même. Ce réseau récurrent ne comporte pas de couche cachée.

Une autre classe de réseau récurrent avec une couche cachée existe (Figure 35). La connexion du « feedback » est produite par des neurones cachés tout comme les sorties des neurones.

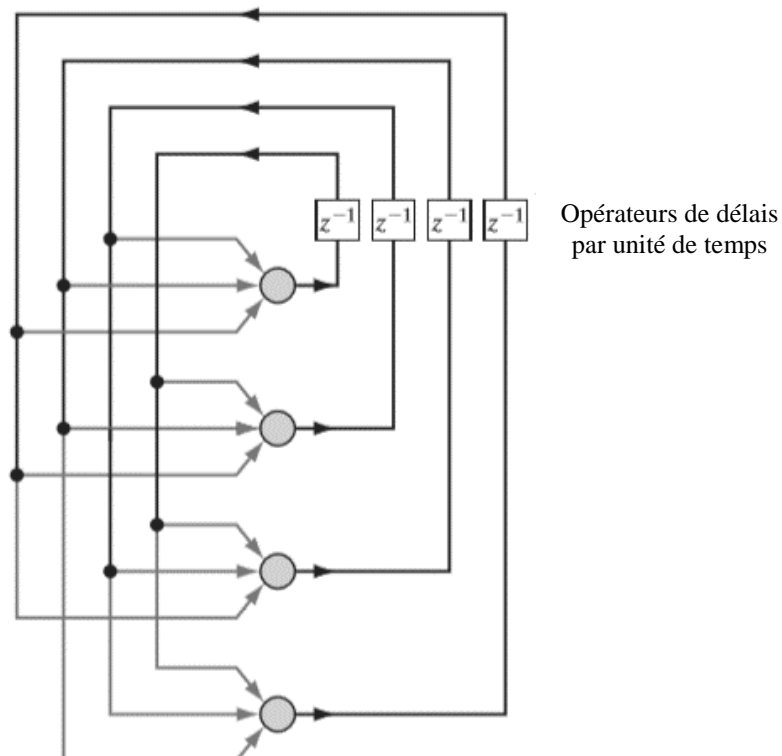


Figure 34. Réseau récurrent sans "feedback" en soit et pas de couche cachée




Figure 35. Réseau récurrent avec e couche cachée

Le choix entre la première et la deuxième structure a un profond impact sur l'habilité d'apprentissage du réseau et sa performance

3.2.5. Apprentissage des RNA

De même qu'il y a différentes manière que nous avons pour apprendre à partir de l'environnement qui nous entoure, les réseaux de neurone le font. Dans un large sens, on peut classer les processus d'apprentissage qu'ont les réseaux de neurone pour fonctionner en : apprentissage supervisé, un apprentissage non supervisé et un apprentissage par renforcement. Ces différentes formes d'apprentissage comme effectué par le réseau de neurone sont parallèles à celle d'apprentissage de l'humain. Etant donné que dans cette étude, on s'intéresse qu'à l'apprentissage supervisé, on ne détaillera que ce type-là.

3.2.5.1. Apprentissage supervise

La (Figure 36) montre un schéma qui illustre cette forme d'apprentissage. Sur le plan conceptuel, on peut représenter cette supervision par un enseignant ayant une connaissance de l'environnement, cette connaissance est présentée par un jeu d'exemples d'entrée et de sortie. L'environnement n'est cependant inconnu pour le

réseau de neurone. Supposant maintenant que l'enseignant et le réseau de neurone sont exposés à un vecteur d'apprentissage tiré du même environnement. Ayant les connaissances nécessaires, l'enseignant est capable de fournir au réseau de neurone les réponses souhaitées pour un vecteur d'apprentissage. En effet, ces réponses représentent l'action « optimale » que doit effectuer le réseau de neurone. Les paramètres du réseau sont ajustés en fonction du vecteur d'apprentissage et la fonction d'erreur (comme celle des modèles conceptuels). Cet ajustement est effectué d'une manière itérative étape par étape dans le but d'obtenir un réseau de neurone qui émule l'enseignant, cette émulation est présumé optimale dans un certain sens statistique. De cette façon, la connaissance de l'environnement à la disposition de l'enseignant est transférée au réseau de neurone à partir de l'apprentissage et stocké sous forme de poids synaptiques « fixé » représentant la mémoire à long terme. Quand cette condition est atteinte, on peut alors se dispenser de l'enseignant et laisser le réseau de neurone traité avec l'environnement complètement seul.

La forme d'apprentissage supervisé décrite juste au-dessus est basée sur l'apprentissage de correction d'erreur. Cette erreur peut être de type MSE appliqué à l'échantillon de donnée d'apprentissage, définie comme fonction de paramètres libres (poids) du système. Cette fonction peut être visualisée comme étant une surface d'erreur. Chaque opération faite sur le réseau (changement des poids) représente un point sur la surface d'erreur, pour que le système améliore ses performances, ce point doit descendre vers le minimum de cette surface. Faut savoir aussi que ce minimum peut être local ou global.

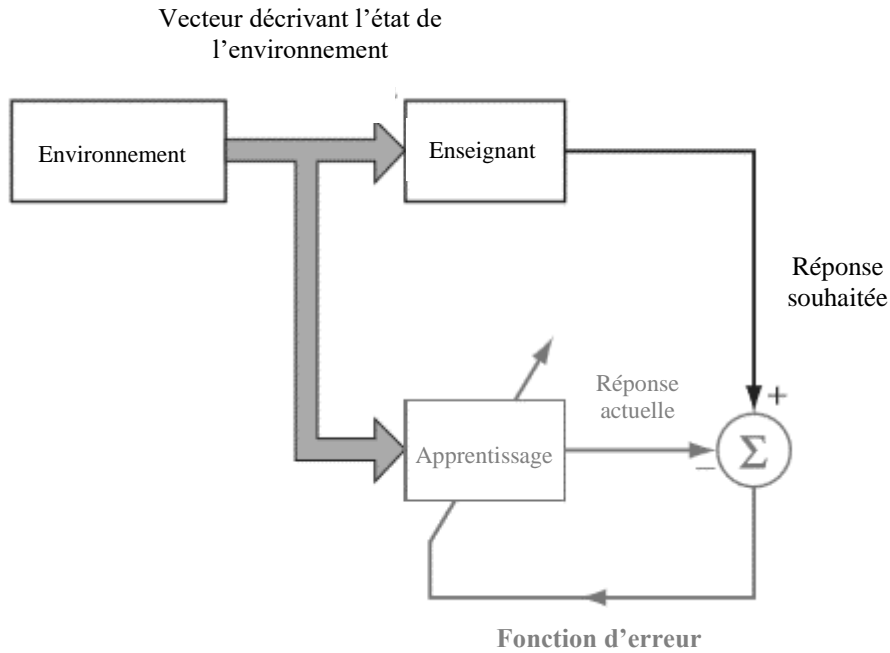


Figure 36. Schéma descriptif d'un apprentissage supervisé

3.2.5.2. Non Supervisé

Dans l'apprentissage non supervisé, le réseau de neurone fait des hypothèses, les teste, les évalue selon certains critères, il est sans enseignant. Le réseau va se modifier en fonction des régularités statistiques de l'entrée et établir des catégories, en attribuant et en optimisant une valeur de qualité, aux catégories reconnues.

3.2.5.2.1. Le renforcement

Dans l'apprentissage par renforcement, le réseau de neurone reçoit un feedback de son environnement, il n'y a pas de présence d'enseignant. Le système étant capable ici, de savoir si la réponse qu'il fournit est correcte ou non, mais il ne connaît pas la bonne réponse.

3.2.6. Réseau de neurone et relation pluie débit

Les RNA sont maintenant largement utilisés dans une multitude de domaines ce qui a inspiré les chercheurs à les utiliser sur des applications des ressources en eau et des systèmes environnementaux (Halff et al. 1993; Hsu et al. 1995; Lorrain and Sechi 1995; Minns and Hall 1996; Dawson and Wilby 1998; Tokar and Johnson 1999; Rajurkar et al. 2002, 2004; Dechemi et al., 2003; Benkaci et Dechemi, 2004; Riad

et al., 2003 ; Agarwal et Singh 2004 ; Cigizoglu et Alp, 2004 ; Giustolisi et Laucelli 2005; Srinivasulu et Jain 2006, Lin et Chen 2008 ; Zounemat-kermani et al. 2013). Des revues de l'application des RNA en hydrologie peuvent être trouvées dans ASCE Task Committee (2000a, b) et aussi dans Maier et Dandy (2000).

A cause de leurs capacités récursives d'apprendre des données, les RNA sont devenues très utiles pour les applications complexes et processus non linéaires comme c'est le cas pour la relation pluie-débit. Halff et al. (1993) ont fait une prédiction de l'hydrogramme utilisant un RNA avec une architecture « feed-forward » à trois couches. Cette architecture consiste à la propagation de l'information de couche en couche sans retour en arrière possible. Hsu et al., 1995 ont présenté une étude très approfondie dans le développement et l'application des RNA sur la relation pluie-débit. Ces chercheurs ont développé un nouvel algorithme de RNA appelé « Linear least squares simplex » pour identifier la structure et paramètres du réseau de neurone « feedforward » à trois couches. En comparant cet algorithme avec un modèle de type ARMAX (linear autoregressive moving average with exogenous input), ils ont trouvé que le réseau de neurone donné une meilleure représentation du système. Minns et Hall (1996) ont démontré l'importance de la standardisation des données dans un RNA, les résultats ont aussi montré une faiblesse en termes d'extrapolation en dehors de la plage d'interpolation. Dawson et Wilby (1998) ont comparé les performances des RNA et celle de système conventionnel de prévision de crue sur deux bassins versant inondable dans la Grande Bretagne, les résultats obtenus ont été de qualités comparables. Tokar et Johnson (1999) ont enquêté sur la sensibilité de la précision du RNA dans la prévision du débit journalier par rapport aux contenus et longueur des données d'apprentissage et les ont comparés aux modèles de régression statistiques et conceptuels. Ils ont prouvé que le RNA réduit la longueur des données et raccourcit le temps passé dans la calibration des modèles tout en améliorant la précision de prévision et la flexibilité par rapport aux modèles comparés. Rajurkar et al. (2002; 2004) ont travaillé sur la modélisation journalière de débit sur de grands bassins versants en Inde où la variation spatiale de la pluie était importante, ils ont réussi à améliorer la précision du modèle en couplant les RNA avec des modèles linéaires (auxiliaires) dont l'entrée était les pluies courantes et précédentes. Agarwal et Singh (2004) ont développé un RNA avec la rétropropagation comme algorithme

d'apprentissage pour simuler le processus pluie-débit sur deux sous bassins de la rivière Narmada (Inde) avec trois différents pas de temps, à savoir l'hebdomadaire, dix jour et mensuelle et avec des ensembles de données incertaines. Comparé à fonction de transfert linéaire, le réseau de neurone s'est callé en moins de d'itération et généralisé mieux que l'autre modèle. Kumar et al., (2004) ont comparé les performances des réseaux de neurones de types MLP (perceptron multicouche) et RBF (Radial basis function) en les appliquant sur la modélisation pluie-débit d'un bassin en Inde. Les résultats ont montrés que le réseau PMC donne une meilleure généralisation que le réseau RBF, mais que le premier nécessite une procédure de « essai-erreur » pour fixer le nombre de neurone dans la couche cachée, ce qui peut prendre du temps, alors que la structure du réseau RBF prend moins de temps avec un algorithme d'apprentissage approprié. Dans le même genre de comparaison, Cigizoglu et Alp (2004) ont employé trois types de réseau, le PMC, le RBF et GRNN (Generalized Regression Neural Network) sur des données en Turquie et ont déduit que seul le dernier réseau ne donné pas de valeurs négatives dans l'estimation des débits. Giustolisi et Laucelli (2005) ont souligné l'importance des techniques qui évitent le sur-apprentissage « overfitting » pour une bonne généralisation des RNA, ils ont présenté huit techniques et l'ont appliqué sur la modélisation de la relation pluie-débit. Srinivasulu et Jain (2006) ont comparé trois méthodes d'apprentissage des réseaux de neurones, la retropropagation, l'algorithme génétique ainsi que les cartes auto adaptatives. Cette dernière classifie en premier lieu l'espace des entrées-sorties en différentes catégories, et développé après un PMC utilisant la retropropagation pour chacune d'elles. Cette approche s'est montré meilleur en performance que de développé un seul RNA qui utilise l'algorithme de la retropropagation en apprentissage. Cette étude a aussi montré que le réseau de neurone utilisant l'algorithme génétique améliore l'efficacité de la prévision des faibles débits. Lin et Chen (2008) ont proposé une approche systématique pour la détermination des entrées du réseau de neurone, cette approche qui consiste à supprimer les entrées impertinentes et construire un réseau qu'avec des entrées adéquates s'est montré efficace en réduisant le temps d'apprentissage et en augmentant les performances du modèle. Depuis longtemps les RNA ont été traité comme étant des boites noires qui ne prennent pas en considération l'aspect physique du problème, cependant quelques chercheurs ont récemment reporté que c'était possible de détecter des processus physique dans

l'apprentissage des modèle RNA appliqués à l'hydrologie (Wilby et al., 2003; Sudheer et Jain, 2004), ce thème est détaillé dans le livre « Practical hydroinformatics », chapitre 7 par See et al. (2008).

Malgré la popularité des RNA dans la relation pluie-débit, on trouve peu d'étude (par rapport à la visibilité sur internet) qui les applique sur les bassins versant de l'Algérie, il y a l'étude de Dechemi et al. (2003) qui ont utilisé l'algorithme Levenberg-Marquardt pour l'apprentissage du RNA dans le but de modéliser la relation pluie-débit avec un pas de temps mensuelle (bassin versant du barrage Chaffia). Mrad et al. (2014) ont étudié la relation pluie-débit à un pas de temps mensuel par le modèle RNA et GR2M. Les modèles ont été appliqués sur un bassin versant situé à Souk Ahras et les résultats ont montré une nette performance du modèle RNA par rapport au modèle conceptuel. Dans la même thématique, Aichouri et al. (2015) ont démontré les performances que peut atteindre les RNA, en les comparants aux modèles à base de régression linéaire multiple. On remarque comme même qu'il y a un intérêt qui se développe ces dernières années sur l'utilisation des RNA dans la modélisation hydrologique en Algérie.

3.3. Les modèles neuro flous

Tout comme les réseaux de neurones artificiel, ces méthodes essayent d'émuler les opérations du cerveau humain. Elles sont utilisées pour identifier les caractéristiques de la prise de décision à travers un ensemble de règles logiques.

Dans cette section, les modèles neuro flou sont présentés de la même manière qu'ont été présentés les réseaux de neurone dans la section au-dessus, à savoir leurs historiques, leurs principes de fonctionnement et leurs rapports avec la relation pluie-débit.

3.3.1. Historique des modèles neuro flou

Les systèmes à base de logique flous (Zadeh, 1965) sont apparus pour la première fois en 1965 par le professeur Lotfi A. Zadeh de l'université de Berkeley aux USA, avec l'article « Ensembles flous » (Fuzzy sets). Il a dit que ces ensembles flous aller trouver leurs applications principales dans le domaine des systèmes humaniste (économique, linguistique, psychologique,...etc.). Au fur et à mesure qu'il réalisé

de nombreuses avancées majeures dans ce domaine avec les chercheurs qu'ils l'accompagné, d'autres chercheurs ont appliqués le principe de la logique floue sur des problèmes réputé difficile. A Londres en 1975, le professeur Mamdani développe une stratégie pour le contrôle des procédés et a obtenu de très bons résultats sur la conduite d'un moteur à vapeur. C'est en 1978 qu'a été réalisée par la société danoise F.L.Smith, la première application industrielle utilisant la logique floue sur le contrôle d'un four à ciment. Dans les années quatre-vingt, les japonais ont exploité au maximum ce concept, que ce soit sur des produits grand public (machines à laver, appareils photographiques...etc.), en industrie (traitement des eaux, grues portuaires, métros...etc.) mais aussi dans la finance et le diagnostic médical. Les autres pays se sont mis en plus grand nombre sur l'utilisation de la logique floue qui s'est généralisée sur la majorité des domaines d'application. Par la suite, l'exploration de la modélisation utilisant les ensembles flous s'est faite par Takagi et Sugeno (1985) et qui a été développé par Jang (1993) pour donner naissance à la nouvelle architecture appelé « Système d'inférence logique à base de réseau adaptif » [Adaptive-Network-based Fuzzy Inference System (ANFIS)].

3.3.2. Les ensembles flous

Dans la théorie des ensembles, un élément appartient ou n'appartient pas à un ensemble. La notion d'ensemble est à l'origine de nombreuses théories mathématiques. Cette notion essentielle ne permet cependant pas de rendre compte de situations pourtant simples et rencontrées fréquemment.

C'est pour prendre en compte de telles situations qu'a été créée la notion d'ensemble flou. La théorie des ensembles flous repose sur la notion d'appartenance partielle : chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis.

3.3.2.1. Fonctions d'appartenance

Un ensemble flou est défini par sa « fonction d'appartenance », qui correspond à la notion de « fonction caractéristique » en logique classique.

Supposons que nous voulions définir l'ensemble des personnes de « taille moyenne ». En logique classique, nous conviendrons par exemple que les personnes de taille

moyenne sont celles dont la taille est comprise entre 1,60 m et 1,80 m. La fonction caractéristique de l'ensemble (Figure 37.a) donne « 0 » pour les tailles hors de l'intervalle [1,60 m ; 1,80 m] et « 1 » dans cet intervalle. L'ensemble flou des personnes de « taille moyenne » sera défini par une « fonction d'appartenance » qui diffère d'une fonction caractéristique par le fait qu'elle peut prendre n'importe quelle valeur dans l'intervalle [0, 1]. A chaque taille possible correspondra un « degré d'appartenance » à l'ensemble flou des « tailles moyennes » (Figure 37.b), compris entre 0 et 1.




Figure 37. (a) fonction caractéristique et (b) fonction d'appartenance

Plusieurs ensembles flous peuvent être définis sur la même variable, par exemple les ensembles « taille petite », « taille moyenne » et « taille grande », notions explicitées chacune par une fonction d'appartenance (Mfs) (Figure 38).




Figure 38. Fonction d'appartenance dans la logique floue, variable et terme linguistique.

Les fonctions d'appartenance peuvent théoriquement prendre n'importe quelle forme. Toutefois, elles sont souvent définies par des segments de droites, et dites « linéaires par morceaux » (Figure 39).

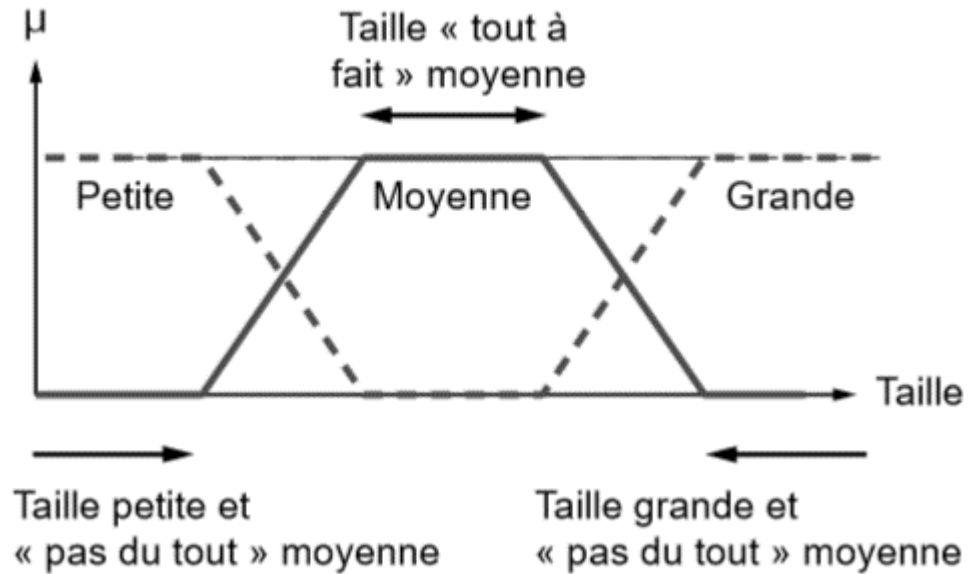


Figure 39. Fonctions d'appartenance linéaires par morceaux

Les fonctions d'appartenance « linéaires par morceaux » sont très utilisées car : c elles sont simples, c elles comportent des points permettant de définir les zones où la notion est vraie, les zones où elle est fausse, ce qui simplifie le recueil d'expertise.

Dans certains cas, les fonctions d'appartenance peuvent être égales à 1 pour une seule valeur de la variable et égales à 0 ailleurs.

3.3.2.2. Fuzzification – Degré d'appartenance

L'opération de fuzzification permet de passer du domaine réel au domaine du flou.

Elle consiste à déterminer le degré d'appartenance d'une valeur (mesurée par exemple) à un ensemble flou.

3.3.3. Opérateurs logiques flous

Ces opérateurs permettent d'écrire des combinaisons logiques entre notions floues, c'est-à-dire de faire des calculs sur des degrés d'appartenance. Comme pour la logique classique, on peut définir des opérateurs ET, OU, négation.

Exemple : Appartement Intéressant = Loyer Raisonnable ET Surface Suffisante

Il existe de nombreuses variantes dans ces opérateurs. Cependant, les plus répandus sont ceux dits « de Zadeh » décrits ci-dessous.

Dans ce qui suit, le degré d'appartenance d'une proposition A sera noté $\mu(A)$.

3.3.3.1. Intersection

L'opérateur logique correspondant à l'intersection d'ensembles est le ET. Le degré de vérité de la proposition « A ET B » est le minimum des degrés d'appartenance de A et de B (Equation 15) :

$$\mu(A \text{ ET } B) = \text{MIN}(\mu(A), \mu(B)) \quad (15)$$

3.3.3.2. Union

L'opérateur logique correspondant à l'union d'ensembles est le OU. Le degré de vérité de la proposition « A OU B » est le maximum des degrés de vérité de A et de B (Equation 16) :

$$\mu(A \text{ OU } B) = \text{MAX}(\mu(A), \mu(B)) \quad (16)$$

3.3.3.3. Complément

L'opérateur logique correspondant au complément d'un ensemble est la négation (Equation 17) :

$$\mu(\text{NON } A) = 1 - \mu(A) \quad (17)$$

3.3.4. Règles floues

La logique floue a pour objectif de formaliser et de mettre en œuvre la façon de raisonner d'un être humain. En cela, elle peut être classée dans le domaine de l'intelligence artificielle. L'outil le plus utilisé dans les applications de logique floue est la base de règles floues. Une base de règles floues est composée de règles qui sont généralement utilisées en parallèle, mais peuvent également être enchaînées dans certaines applications.

Une règle est du type : SI « prédicat » ALORS « conclusion ».

Une règle floue comporte trois étapes fonctionnelles résumées dans la (Figure 40).




Figure 40. Les étapes fonctionnelles des règles floues

3.3.4.1. Inférence

Le mécanisme d'inférence le plus couramment utilisé est celui dit « de Mamdani ». Il représente une simplification du mécanisme plus général basé sur « l'implication floue ».

La conclusion d'une règle floue est une combinaison de propositions liées par des opérateurs ET.

On n'utilise pas de clauses « OU » dans les conclusions, car elles introduiraient une incertitude dans la connaissance (l'expertise ne permettrait pas de déterminer quelle décision prendre). Cette incertitude n'est pas prise en compte par le mécanisme d'inférence de Mamdani, qui ne permet de gérer que des imprécisions.

De même, la négation est a priori interdite dans les conclusions pour des règles de Mamdani. En effet, si une règle avait par exemple la conclusion « Alors ventilation non moyenne », il serait impossible de dire si cela signifie « ventilation faible » ou « ventilation forte ». Ce serait encore un cas d'incertitude.

3.3.4.1.1. Mécanisme d'inférence de Mamdani

Une base de règles floues de Mamdani comprend donc des règles linguistiques faisant appel à des fonctions d'appartenance pour décrire les concepts utilisés.

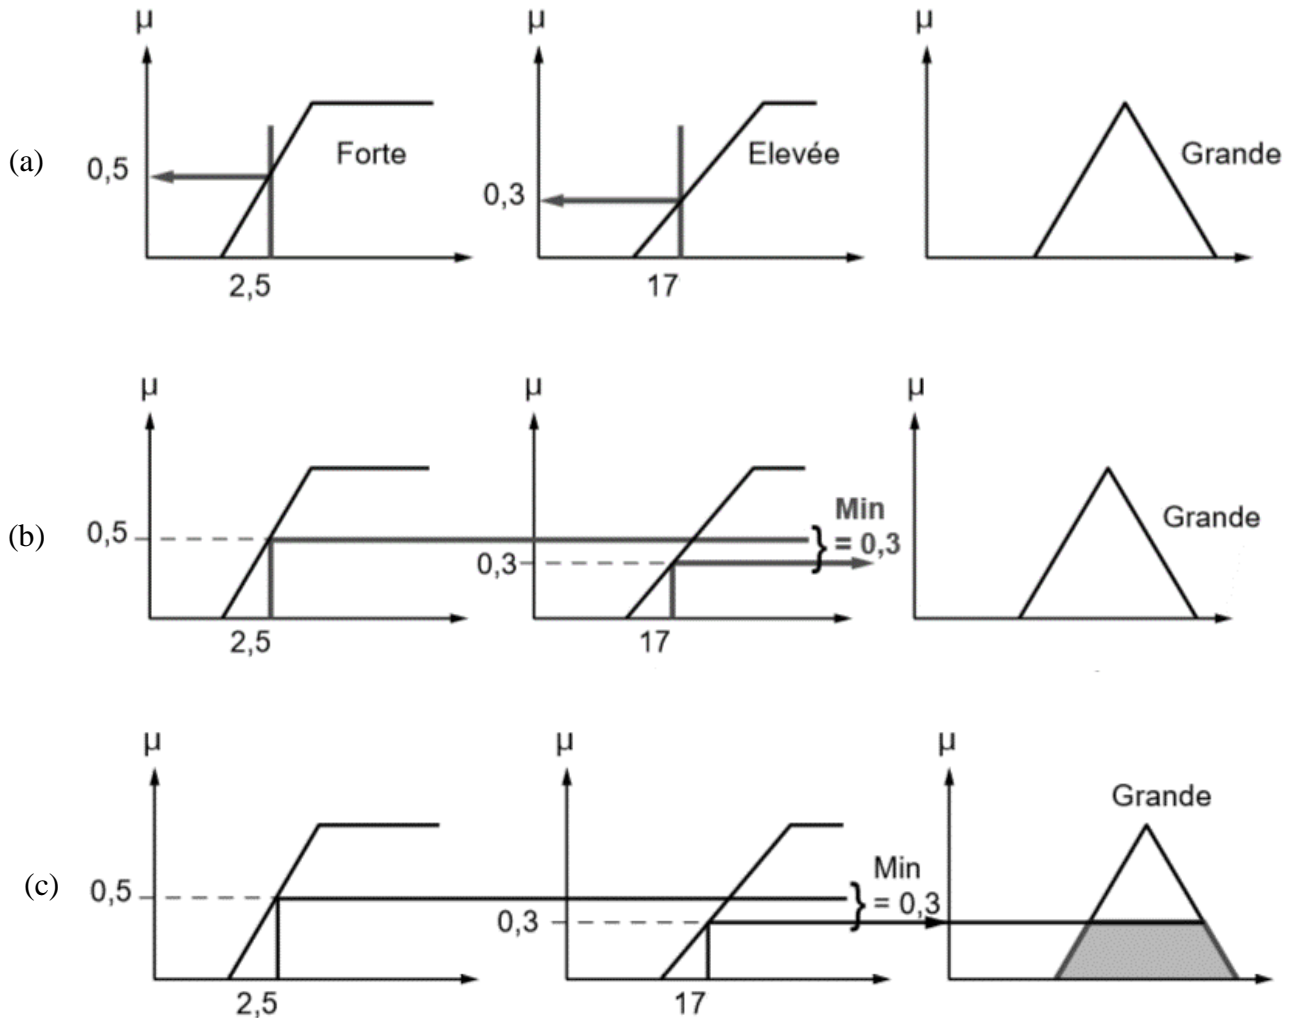


Figure 41. Mécanisme d'inférence de Mamdani : (a) Fuzzification, (b) Activation, (c) Implication

Le mécanisme d'inférence de Mamdani (Figure 41) comprend les étapes suivantes :

- 1) Fuzzification : La fuzzification consiste à évaluer les fonctions d'appartenance utilisées dans les prédicats des règles.
- 2) Degré d'activation : Le degré d'activation d'une règle est l'évaluation du prédicat de chaque règle par combinaison logique des propositions du prédicat. Le « ET » est réalisé en effectuant le minimum entre les degrés de vérité des propositions.

- 3) Implication : Le degré d'activation de la règle permet de déterminer la conclusion de la règle, c'est l'implication. Il existe plusieurs opérateurs d'implication mais le plus utilisé est le « minimum ». L'ensemble flou de conclusion est construit en réalisant le minimum entre le degré d'activation et la fonction d'appartenance, sorte d' « écrêtage » de la fonction d'appartenance de conclusion.
- 4) Agrégation : L'ensemble flou global de sortie est construit par agrégation des ensembles flous obtenus par chacune des règles concernant cette sortie. On considère que les règles sont liées par un « OU » logique, et on calcule donc le maximum entre les fonctions d'appartenance résultantes pour chaque règle (Figure 42).

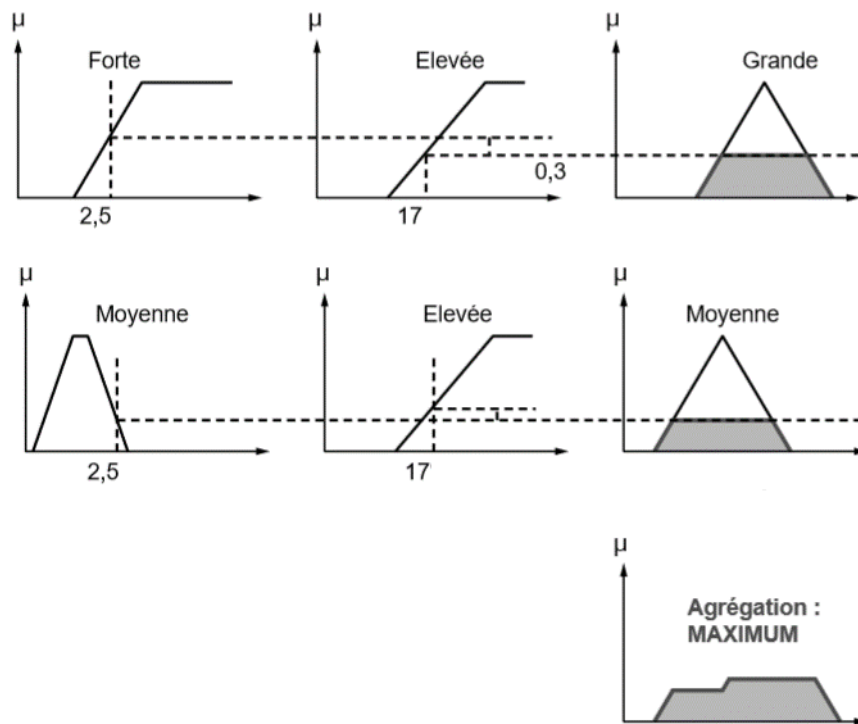


Figure 42. Agrégation des règles dans le système d'inférence Mamdani

- 5) Défuzzification : A la fin de l'inférence, l'ensemble flou de sortie est déterminé mais il n'est pas directement utilisable pour donner une information précise à l'opérateur ou commander un actionneur.

Il est nécessaire de passer du « monde flou » au « monde réel »,
c'est la défuzzification.

Il existe plusieurs méthodes, la plus souvent rencontrée étant le calcul du « centre de gravité » de l'ensemble flou (Figure 43)




Figure 43. Défuzzification par centre de gravité

3.3.5. Principe de fonctionnement de ANFIS

Le ANFIS est une intégration de l'architecture des réseaux de neurones avec un système de logique floue dans la même topologie. Ces derniers sont des modèles entrés-sortie non linéaire utilisant un ensemble de règles (contenant des règles logiques si-alors), qui implique des ensembles de variable d'entrées, présentés par des ensembles de logique avec des fonctions d'appartenance (MFs) et des ensembles logiques de conséquence. L'espace d'entrée doit être partitionné en un ensemble de fonctions d'appartenance sachant qu'un nombre réduit de MFs mène à des performances de modèle médiocre et un nombre trop élevé augmente le nombre des règles si-alors, ce qui rend le modèle non parcimonieux et difficile à calibrer. Différentes méthodes de partitionnement sont proposées dans la littérature et peuvent être partagées en des méthodes de classification (k-mean, subtractive methods [Chiu, 1994], ...etc.) et le partitionnement par pixel. Cette dernière consiste à diviser l'espace d'entrée en pixel rectangulaire et les règles logiques sont confinées dans les coins des pixels (Brown and Harris, 1994). La dimension des pixels dépend du nombre des MFs qui sont déterminés avec la procédure essai-erreur. MFs peuvent être des fonctions de formes triangulaire, trapézoïdale, gaussienne ou de forme Bell.

D'après la littérature, on peut trouver plusieurs structures de système à base floue (ex. Mamdani et Assilian, 1975 ; Tsukamoto, 1979 ; Takagi et Sugeno, 1985) qui sont caractérisés par leurs paramètres de conséquence.

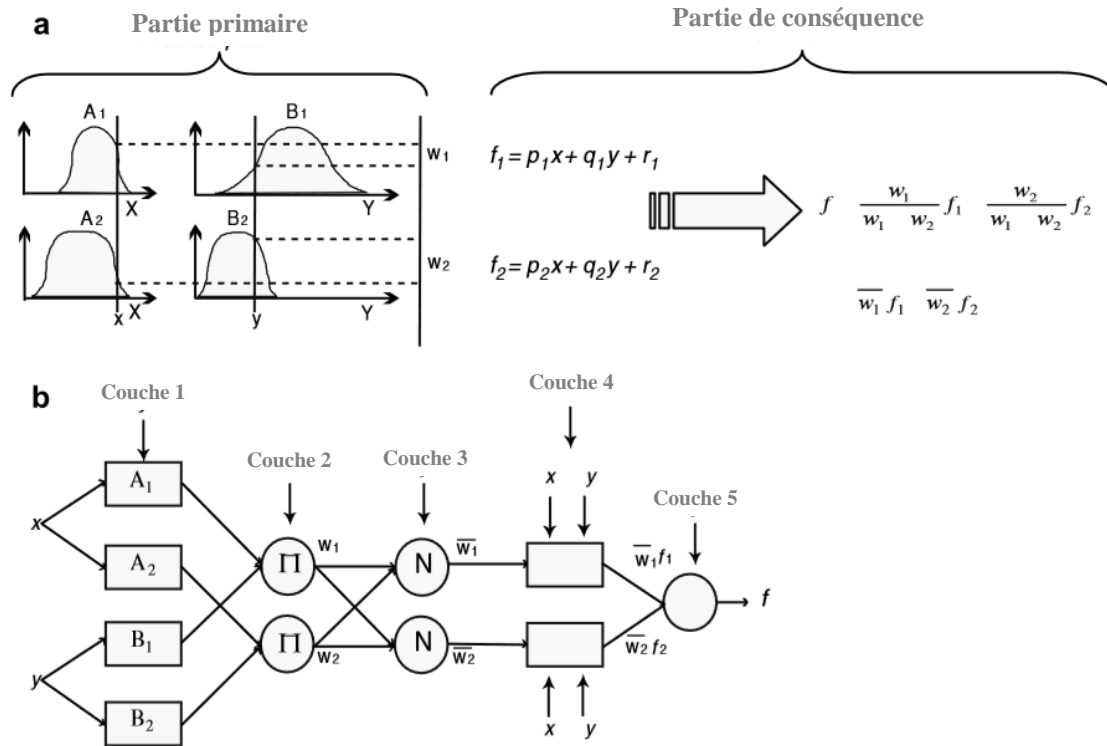


Figure 44. (a) Schéma d'un système d'inférence logique. (b) Architecture ANFIS équivalente

L'architecture des ANFIS est représenté comme un réseau de type multi couche non bouclé. Ça consiste en un ensemble de nœud (unité exécutante) rongé dans des couches et connecté à travers une liaison directionnelle mais contrairement à la structure du réseau de neurone, aucun poids n'est associé à ces liaisons. Chaque nœud exécute une fonction statique sur ces entrés pour générer une sortie. Les variables de chaque fonction d'appartenance et les coefficients des fonctions linéaires de Takagi-Sugeno sont les paramètres du réseau.

Le procédé dans un modèle ANFIS décrit par Jang (1993) est comme ce qui suit :

Considérons un système d'inférence logique ayant deux entrées, x et y et une seule sortie z . On suppose que la base de règle contient deux règles flous SI-ALORS de type Takagi et Sugeno :

- Règle 1 : Si x est A_1 ET y est B_1 , ALORS $f_1 = p_1x + q_1y + r_1$,
- Règle 2 : Si x est A_2 ET y est B_2 , ALORS $f_2 = p_2x + q_2y + r_2$,

On trouve dans la (Figure 44) le raisonnement flou ainsi que l'architecture ANFIS équivalente.

Couche 1

Pour deux entrées (x, y) avec deux MFs, chaque nœud exécute une fonction (Equation 18 et 19):

$$O_i^1 = \mu_{A_i}(x) \quad \text{pour } i = 1, 2 \quad (18)$$

$$O_i^1 = \mu_{B_i}(y) \quad \text{pour } i = 3, 4 \quad (19)$$

Où O_i^j est la sortie du i^{eme} nœud, x (ou y) est l'entrée du nœud i et μ est la fonction d'appartenance de A_i (ou B_i) caractérisé par la forme Bell dans ce cas, dans un intervalle de $[0, 1]$ comme dans l'(Equation 20):

$$\mu_{A_j}(x) = \frac{1}{1 + \left[\frac{x - c_i}{a_i} \right]^{b_i}} \quad (20)$$

Où $\{a_i, b_i, c_i\}$ est l'ensemble de paramètre primaire qui varie la fonction Bell

Couche 2

Dans cette couche, chaque nœud exécute une multiplication des signales entrants, les sorties se calculent avec l'(Equation 21) :

$$O_i^2 = w_i = \mu_{A_j}(x) \mu_{B_i}(y) \quad \text{pour } i = 1, 2 \quad (21)$$

Couche 3

Les sorties de cette couche se calculent avec l' (Equation 22):

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad \text{pour } i = 1, 2 \quad (22)$$

Couche 4

La fonction des nœuds dans cette couche (Equation 23) ont une forme de :

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad \text{pour } i = 1, 2 \quad (23)$$

où \bar{w}_i est la sortie de la troisième couche, et $\{p_i, q_i, r_i\}$ est considéré comme des paramètres de conséquence.

Couche 5

Le dernier nœud calcul la sortie totale de tous les signaux entrés (Equation 24):

$$O_1^5 = \sum_i^2 \overline{w}_i f_i = \frac{\sum_i^2 \overline{w}_i f_i}{\sum_i^2 w_i} \quad \text{for } i = 1, 2 \quad (24)$$

Les paramètres primaires $\{a_i, b_i, c_i\}$ décrivant la forme des MFs et les paramètres de conséquence $\{p_i, q_i, r_i\}$ qui décrivent la sortie du système, sont les paramètres du réseau qui doivent être estimés.

3.3.5.1. Apprentissage du modèle ANFIS

Les paramètres à optimiser dans un ANFIS sont les paramètres primaires $\{a_i, b_i, c_i\}$, qui décrivent la forme des MFs, et les paramètres de conséquence $\{p_i, q_i, r_i\}$, qui décrivent la sortie totale du système. L'apprentissage basique d'un réseau adaptatif est l'algorithme de retropropagation (Rumelhart et al., 1986), cet algorithme est basé sur le gradient descendant et peut être appliqué avec succès pour estimer ces paramètres. Cependant, Jang (1991) explique que la méthode du gradient descendant est généralement lente et peut probablement être piégé dans le minimum local. Jang a proposé un algorithme d'apprentissage rapide, qui combine la méthode du gradient descendant avec l'estimation des moindres carrés [Least Squares Estimate (LSE)] pour identifier les paramètres du système ANFIS.

A partir de la (Figure 44) montrant l'architecture ANFIS, on peut observer que dans le cas où les valeurs des paramètres primaires sont fixes, la sortie du système peut être exprimée comme une combinaison linéaire, ce qui mène à l'expression de (Equation 25):

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \overline{w}_1 f_1 + \overline{w}_2 f_2 \\ &= (\overline{w}_1 x) p_1 + (\overline{w}_1 y) q_1 + (\overline{w}_1 z) r_1 + (\overline{w}_2 x) p_2 + (\overline{w}_2 y) q_2 + (\overline{w}_2 z) r_2 \quad (25) \end{aligned}$$

Cette fonction est linéaire dans les paramètres de conséquence $p_1, q_1, r_1, p_2, q_2, r_2$. Ce qui explique la possibilité d'appliquer le modèle hybride cité au-dessus.

Dans le passage en avant de cette algorithm, les sorties de chaque nœud vont jusqu'à la 4ème couche, et les paramètres de conséquence sont estimés par la méthode des moindres carrés. Dans le passage en arrière, le taux d'erreur est propagé en arrière et les paramètres primaires sont mis à jour par le gradient descendant.

3.3.6. ANFIS et relation pluie-débit

Les approches de modélisation à base de logique flou a récemment reçu une attention dans la modélisation hydrologique et au fonctionnement de réservoir (Shrestha et al., 1996 ; Fontane et al., 1997 ; See et Openshaw, 2000 ; Xiong et al., 2001 ; Gautam et Holz, 2001 ; Yu et al., 2000 ; Chang et Chen, 2001 ; Nayak et al. 2004, 2005, 2007 ; El-Shafie et al., 2006 ; Lohani et al., 2006, 2007a,b ; Chen et al., 2006 ; Aqil et al., 2007 ; Firat et Güngör, 2007 ; -Pramanik et Panda, 2009 ; Mukerji et al., 2009 ; Talei et al., 2010 ; Lohani et al., 2012 ; Sanikhani et Kisi, 2012 ; He et al., 2014). On constate que l'utilisation de cette technique s'est beaucoup répondu dans les applications hydrologiques et que ça continue jusqu'à nos jours toute en ayant des résultats encourageants. Gautam et Holz (2001) ont appliqué le modèle ANFIS sur la modélisation de la relation pluie-débit et ont démontré l'efficacité de cette méthode pour la simulation, même s'ils ont remarqué une surestimation du volume total. Les résultats de Nayak et al., (2004) montre une préservation des propriétés statistiques des séries de débit en utilisant le modèle ANFIS lors de la prévision, et que ce dernier surpasse les RNA en termes de rapidité de calcul, d'erreur de prévision, d'efficacité et dans l'estimation des pics de débits. Chen et al. (2006) ont prouvé que le modèle ANFIS, fourni en général une grande précision et performance stable pour la prévision des crues. Aqil et al., (2007) ont démontré que ce modèle a de grande capacité de généralisation et d'adaptabilité pour une modélisation complexe de la relation pluie-débit. He et al., (2014) ont appliqué les trois modèles, RNA, ANFIS et Support Vector Machine (SVM) pour la prévision du débit d'une rivière située dans une région montagneuse et dont le climat et de type semi-aride (nord-ouest de la Chine), et ont eu des résultats

satisfaisants pour les trois modèles malgré la complication de la topographie du bassin versant étudié.

Des chercheurs Algériens se sont aussi intéressés à l'application de cette technique dans les applications hydrologiques, on trouve l'étude de Benkaci et Dechemi, (2004) qui ont comparé quatre modèles pluie-débit dans la région de Nord Est Algérien, avec un pas de temps journalier et ont trouvé que le système neuro-flou est celui qui a permis une meilleure reproduction des débits max par rapport aux deux modèles conceptuels (GR3j et CREC) et le modèle ARMAX. Il y a aussi l'étude de Zakhroufa et al. (2014) qui l'ont appliqué sur deux bassins côtiers de l'Algérie, leurs résultats montrent une meilleure performance par rapport au RNA et aux modèles classiques de régression linéaire multiples.

3.4. Type d'utilisation des modèles RNA et ANFIS

Les RNA et les ANFIS peuvent être décrits comme une solution générique, la tâche consacrée aux hydrologues et de découvrir comment utiliser ces outils. Trois différentes méthodes d'implémentation peuvent être envisagées :

- Option de remplacement : un remplacement direct est l'utilisation du modèle neuronal ou système neuro flou adaptatif, pour exécuter une opération identique que peuvent exécuter les solutions traditionnelles. L'alternative de ces modèles peut par exemple être développée à simuler la réponse du bassin versant à partir des entrées environnementales associées à de simples modèles conceptuels. Le remplacement de ces modèles peut aussi faciliter l'introduction de données additionnelles sans tenir compte de notre compréhension sur leurs rôles hydrologiquement relatifs. Ceci offre un potentiel considérable d'explorer des relations qui n'ont pas été utilisées dans la modélisation conventionnelle. Dans les situations où la compréhension théorique est limitée, où les équations sont difficiles à coder, ou les données sont non stationnaires (Minns, 1996), la « neurocomputation » est considérée comme une alternative à explorer.

- Option de clonage : Le clonage est un processus d'utilisation de ces modèles pour imiter une équation d'une solution incluant des imperfections. Ces clones peuvent aussi être utilisés pour réduire le temps de calibration modèles.
- Option d'amélioration : l'amélioration est un processus de construction d'un mécanisme hybride qui contient un lot intégral de solutions traditionnelles et modèle neuronal. L'amélioration peut s'agir de connecter deux ou plus de modèle existant, comme un simple filtre qui corrige les données d'entrée ou de sortie, ou pour combiner la simulation de multiple modèle (Xiong et al., 2001 ; Abrahart & See, 2002 ; Shamseldin et al., 2002 ; Yu et Chen, 2005).

CHAPITRE 4

Application du modèles RNA et ANFIS dans la relation pluie-débit

4.1. Introduction

Dans ce présent chapitre, une modélisation de type empirique est développée sur la relation pluie débit. Cette modélisation repose sur l'utilisation des réseaux de neurone artificiel (RNA) et du système d'inférence logique à base de réseau adaptif (ANFIS), et qui font partie des modèles d'intelligence artificielle. Ce chapitre englobe les principaux choix à prendre lors du développement de ce genre de modèle en se reposant sur ce qu'il y a dans la littérature (études similaires précédentes), ainsi que les résultats de leurs applications sur notre problème qui est la simulation de la relation pluie-débit.

4.2. Réseau de neurone artificiel

4.2.1. Architecture

Les architectures du réseau de neurones artificiels les plus utilisés dans la modélisation du processus pluie-débit sont les perceptrons MultiCouche (PMC) et les réseaux à fonction radial (RBF) (Dawson et Wilby 2001). L'architecture PMC peut, avec une seule couche cachée contenant suffisamment de nombre de neurone, approximer n'importe quelle fonction relationnelle avec quelconque degré de précision (Funahashi, 1989 ; Hornik et al. 1989). A cet effet, cette architecture a été adoptée dans cette étude.

Comme il a été expliqué dans le premier chapitre dans la section des réseaux de neurones, les neurones de la couche cachée ont comme fonction ce qu'on appelle une fonction de transfert (ou d'activation). Dans la littérature, la plupart des études réalisées utilise comme fonctions de transfert, le type sigmoïde dans la couche cachée et une fonction linéaire dans la couche de sortie. Cette structure a comme avantage l'extrapolation en dehors des données d'apprentissage (Hsu et al, 1995; Maier et Dandy, 2000; Zealand et al., 1999; Calvoa et Portelab 2007).

Abrahart et al. (2008) dans le livre « Practical hydroinformatique », chapitre 3 ont représenté les solutions neuronal comme un art noir vu qu'il n'existe pas de règle fixe ou de règlement dans le développement de ce genre de modèle, et que l'intuition et l'expérience personnelle sont des facteurs importants dans le processus de construction. L'hydrologue travaillant sur les réseaux de neurones doit spécifier

non seulement le nombre de couche cachée mais aussi le nombre de neurones dans cette couche. Si le nombre de neurone dans cette couche n'est pas suffisant, le réseau ne pourra pas décrire la fonction étudiée à cause du nombre insuffisant de paramètres qui permet l'exploration de tous les points des données d'apprentissage, ceci peut être représenté par un manque de degré de liberté du réseau. Dans le cas contraire, s'il y a beaucoup de neurone, le réseau aura beaucoup de paramètres libres ce qui peut mener à ce qu'on appelle le sur-apprentissage « overfitting », dont le résultat est la perte de la capacité de généralisation du réseau. De plus, le nombre excessif des neurones dans la couche cachée peut retarder énormément le processus d'apprentissage. Pour éviter ce genre de cas, on a préféré lancer à chaque fois la procédure « essai-erreur », en commençant par deux neurones et en ajoutant un autre jusqu'à arriver au nombre 20 de neurones dans la couche cachée. A chaque essai, l'apprentissage est lancé 50 fois de sorte à varier à chaque fois les conditions initiales (valeurs initiales des poids) dans le but d'éviter de tomber dans le minimum local. Dans les 50 essais, seul le résultat de la meilleure performance de généralisation (MSE) est retenu.

4.2.2. Apprentissage

Le but de l'apprentissage étant d'ajuster les poids du réseau de façon à ce que les sorties du réseau approchent le plus possible les données réelles, ceci en utilisant une fonction appelée fonction objective (ou fonction de coût) et une série de données appelée données d'apprentissage. Cette tâche s'effectue avec un algorithme d'apprentissage dont le plus célèbre est celui de la rétropropagation du gradient. Cet algorithme qui s'est développé dans les années soixante n'a connu un succès qu'après l'avoir appliqué sur les réseaux de neurones (Rumelhart et al., 1986a ; 1986b ; Werbos, 1994). Des améliorations ont été faites sur cet algorithme (Wilamowski et Torvik, 1993 ; Andersen et Wilamowski, 1995 ; Wilamowski, 1996 ; Wilamowski et al., 1999). Cet algorithme reste jusqu'à ce jour le plus utilisé, cependant il est connu comme un algorithme non efficace vu qu'il est long à converger. Il y a deux raisons principales pour cette lenteur, la première raison est que la taille du pas doit être adéquate aux gradients (Figure 45). Logiquement, un pas de petite taille doit être pris quand le gradient est raide pour ne pas rater le minimum requis. Si la taille du pas est constante, elle doit être petite, or dans les places où le gradient est plat, le processus d'apprentissage sera très long. La seconde

raison est que la courbure de la surface d'erreur ne peut être la même dans toutes les directions, comme dans la fonction Rosenbrock, le problème classique « erreur de vallée » (Osborne, 1992) peut exister et peut résulter dans la convergence lente.

La lenteur de convergence de la méthode du gradient peut être grandement améliorée par l'algorithme Gauss-Newton (Osborne, 1992). Utilisant les dérivées de second ordre dans la fonction d'erreur pour évaluer « manuellement » la courbure de la surface d'erreur, l'algorithme de Gauss-Newton peut trouver une taille de pas adéquate pour chaque direction et converger très rapidement, particulièrement si la fonction d'erreur a une surface quadratique, il peut converger directement à la première itération. Mais ce développement arrive seulement quand l'approximation quadratique de la fonction d'erreur est raisonnable. Dans le cas contraire, l'algorithme Gauss-Newton sera surtout divergent.




Figure 45. Processus de recherché de la méthode du gradient descendant avec des constants d'apprentissages différentes [tirée de (Yu et Wilamowski, 2011)]

Pour pallier à ces problèmes, Levenberg et Marquard (Levenberg, 1944, Marquardt, 1963) ont développé un algorithme appelé l'algorithme de Levenberg-Marquard, qui est rapide et qui a une bonne stabilité de convergence. Cet algorithme allie la méthode du gradient descendant et celle de l'algorithme Gauss-Newton. Il hérite de l'avantage de vitesse de l'algorithme Gauss-Newton et la stabilité de la méthode du Gradient descendant. Il est plus robuste que l'algorithme de Gauss-Newton, car dans de nombreux cas il peut converger même si la surface d'erreur est beaucoup plus complexe que la situation quadratique, même s'il perd un peu de vitesse de convergence par rapport à cet algorithme (dans certaines situations), il est comme même beaucoup plus rapide que l'algorithme du Gradient descendant.

L'idée basique de l'algorithme Levenberg-Marquardt est qu'il effectue un processus d'apprentissage combiné : autour de la surface à courbure complexe, l'algorithme de Levenberg-Marquardt switch vers l'algorithme du Gradient descendant jusqu'à ce que la courbure locale soit appropriée pour faire une approximation quadratique, il devient alors l'algorithme de Gauss-Newton, ce qui peut accélérer la convergence de manière significative.

Les itérations faites par l'algorithme de Levenberg-Marquardt suivent (Equation 26) :

$$x_{i+1} = x_i - (H + \mu I)^{-1} \nabla f \quad (26)$$

où f est une fonction quadratique et H la matrice Hessienne évalué en x_i . Sachant que le calcul de la Hessienne est complexe, elle est remplacée par la matrice Jacobienne J (Equation 27):

$$H = J^T J \quad (27)$$

Le gradient peut être calculé par (Equation 28)

$$\nabla f = J^T e \quad (28)$$

où e est le vecteur d'erreur, alors on obtient l' (Equation 29):

$$x_{i+1} = x_i - (J^T J + \mu I)^{-1} J^T e \quad (29)$$

Si le scalaire μ est égale à 0, la méthode deviant une méthode Gauss Newton qui est assez rapide et précis près d'un minimum local, mais avec un μ plus grand, l'algorithme tend vers la méthode du gradient descendant. Si la fonction de l'erreur de la fonction diminue, μ diminue aussi (par un facteur de 10) pour réduire l'influence du gradient descendant mais si l'erreur augmente, le test n'est pas accepté et μ est augmenté (Ranganathan, 2004).

4.2.3. Normalisation des données

La normalisation est une transformation de mise à l'échelle. Au sein des données, il y a souvent des différences assez large entre le maximum et le minimum des valeurs (ex. 0.01 et 1000). Quand la normalisation est effectuée, l'ordre de grandeur des valeurs est réduit.

La normalisation des données est importante pour deux raisons : la première, c'est que les données d'entrées doivent avoir le même poids. Si les entrées de deux neurones se situent dans différents intervalles, alors le neurone avec la plus grande échelle absolue sera plus favorable durant l'apprentissage. Deuxièmement, parce que la fonction sigmoïde est utilisée et par conséquent, elle ne peut être exécuté que sur un intervalle limité de valeurs (Azadeh et al., 2010). Dans cette étude, les séries de données du réseau ont été normalisé suivant le type « normalisation min-max ». Cette dernière effectue une transformation linéaire des valeurs de données originaux (Equation 30)

$$v' = \frac{v - \min_x}{\max_x - \min_x} \cdot (\text{new_max}_x - \text{new_min}_x) + \text{new_min}_x \quad (30)$$

Où v est l'ancienne données et v' la donnée normalisée

4.3. Modèle neuro-flou

4.3.1. Architecture

Dans cette étude, la méthode de partitionnement en grille a été utilisée. Cette méthode partage l'espace des entrées en sous-espace rectangulaire utilisant un nombre de régions locales floues par un partitionnement d'axe en parallèles, ceci en se basant sur un nombre prédéfini de MFs et leurs types dans chaque dimension. En augmentant le nombre des variables d'entrée, le nombre des règles floues est exponentiellement augmenté. Dans le cas de n variables d'entrées et m MFs pour chaque variable d'entrée, le nombre total des règles floues est égale à n^m .

Cette méthode est illustrée en détail par Abonyi et al. (1999) et Kennedy et al. (2003). La forme choisie pour les MFS est de type gaussienne sachant que le type des fonctions MFs utilisé n'a pas de considération critique pour les performances

du ANFIS (Nayak et al. 2004). Le nombre des Mfs testées dans la procédure de l'essai-erreur est de 2 à 5 MFs.

4.3.2. Apprentissage

Le modèle Sugeno (Takagi et Sugeno, 1985 ; Sugeno et Kang, 1988) a été choisis pour pouvoir calculer l'équation linéaire des paramètres de conséquence en utilisant la méthode des moindres carrés. Durant la construction des règles floues, les paramètres de conséquence dans la sortie linéaire sont mis à zéro. Le nombre d'epochs définie avant l'arrêt de l'algorithme hybride (Retropropagation et méthode des moindres carrés) a été fixé à 20 epochs.

4.3.3. Transformation des données

De même que les réseaux de neurone artificiel, l'effet positif de la transformation des données sur la performance des modèles ANFIS a été prouvé (Aqil et al. 2007). Dans cette étude on a testé quatre méthodes de transformation de donnée :

- T1 : Transformation avec la fonction log avec (Equation 31) :

$$z_x = a \cdot \log_{10}(x + b) \quad (31)$$

où

z_x sont les valeurs transformées de x , a est une constante arbitraire, et b qui est fixé à 1 pour de mettre un zéro dans la fonction log.

- T2 : La mise à l'échelle [0 – 1] (Equation 32) qui consiste à ce que les variables aient les mêmes intervalles. Cette transformation se fait avec l'équation :

$$z_x = \frac{[x - \min(x)]}{[\max(x) - \min(x)]} \quad (32)$$

- T3 : Transformation en variables centrée réduite (Equation 33), ça consiste à modifié les valeurs de la variable afin de fixer sa moyenne à 0 et sa variance à 1, suivant l'équation

$$z_x = \frac{x - \text{moy}(x)}{\sigma} \quad (33)$$

Où σ est l'écart type de la variable x

- T4 : Diviser chaque valeur de la variable sur l'écart type afin d'obtenir des données dont la variance égale à 1 mais avec différents intervalles et moyennes.

4.4. Division des données

Afin de modéliser la relation pluie-débit avec les RNA et ANFIS, les données doivent être partagées en deux parties comme c'est le cas pour le modèle conceptuel utilisé dans le chapitre 3. Cependant, ces modèles sont connues pour leur problème du sur-apprentissage (overfitting). Ce problème se caractérise par une erreur dans l'ensemble de données d'apprentissage, mais quand de nouvelles données sont présentées aux réseaux, on trouve une erreur assez importante. Ceci peut s'expliquer du fait que le modèle à mémoriser les exemples de données de calibration, mais il n'a pas appris à généraliser les nouvelles situations. Pour améliorer la généralisation de ces modèles et éviter le sur-apprentissage il faut utiliser un nombre de paramètres qui est juste assez large pour fournir une approximation adéquate. Plus le modèle contient un nombre important de paramètres, plus complexes les fonctions sont créées. Dans le cas contraire, si le modèle est de petite taille, il ne sera même pas capable d'approximer la fonction souhaitée. Malheureusement, il est difficile de connaître a priori la taille que devrait avoir le modèle pour une application spécifique. Donc dans ce cas, on est orienté vers l'utilisation de l'une des techniques qui évite le sur-apprentissage et celle qui est très utilisée vu sa simplicité, est l'arrêt anticipé « early stopping ». Cette technique consiste à diviser la période en trois parties au lieu de deux. La première est utilisée pour l'apprentissage du réseau dans le but d'ajuster les poids et biais (pour le RNA) ou paramètres primaires et de conséquence des MF (pour le ANFIS), selon une fonction objective (l'erreur « MSE » est utilisée dans cette étude), la deuxième (validation) est celle qui concerne le sur-apprentissage, elle est utilisée pour mesurer l'erreur de la généralisation du réseau et arrêter le processus d'apprentissage quand cette dernière ne s'améliore plus. La troisième partie des données et qui n'ont aucun effet sur le processus d'apprentissage est utilisée pour voir les performances de notre réseau.

La période totale utilisée pour les modèles RNA et ANFIS a été divisée comme suit :

- Apprentissage : 4 ans [1989-1993]
- Validation : 1 an [1993-1994]
- Test : 2 ans [1994-1996]

4.5. Détermination des entrées pour les RNA et ANFIS

La sélection des données est une tâche très importante dans la modélisation dirigée par les données (data-driven modelling), un choix optimal des entrées évite la perte d'information et menant à de bonnes performances des modèles. L'analyse de la cross-corrélation utilisée par Nayak et al. (2005a, b, 2007) est considérée comme étant la technique analytique la plus populaire pour la sélection des entrées (Bowden et al., 2005) malgré ses limites étant donnée qu'elle ne capture que les dépendances linéaires entre les variables. Néanmoins, Shoaib et al. (2014) ont montré que la sélection des entrées pour le modèle de type « data driven » (Système d'inférence neuroflou), basé sur la procédure « essai-erreur » est plus efficace qu'utiliser l'analyse cross-corrélation. Même si cette procédure nécessite beaucoup de temps, vu l'importance des enjeux, elle a été adoptée dans cette étude pour l'apprentissage du réseau de neurone.

La sélection des entrées avec la procédure « essai-erreur » consiste à commencer par utiliser un seul pas de temps et en rajouter un autre jusqu'à atteindre un délai spécifique mis par le modélisateur. Dans cette étude, un maximum de trois jours de délais a été adopté. Cette procédure est répétée pour chaque variable seule ou combinée avec d'autres variables.

Sachant que le réseau de neurone peut contenir plusieurs entrées et que la pluie est un phénomène spatiotemporel, les deux stations des pluies (P5 et P6) qui sont introduites séparément comme entrée du réseau de neurones, sont aussi introduites ensemble dans l'entrée du modèle pour tenter d'exploiter les informations des deux mesures et prendre en considération l'effet de phénomène spatiotemporel.

L'information de la pluie seule n'est pas suffisante pour la modélisation de la relation pluie-débit, ceci est dû à l'importance de l'état d'humidité du sol dans la production du bassin versant. Cette information peut être incorporée dans le débit observé dans un passé récent (Minns et Hall, 1996 ; Campolo et al., 1999). Pour cette raison, la variable du débit observée dans un passé récent a été introduite dans le vecteur d'entrée pour évaluer son importance.

Les variables et combinaisons de variables utilisées dans le réseau de neurone sont :

- 1) $P5(t-i)$; $P6(t-i)$; $Par(t-i)$; $Pth(t-i)$
- 2) $P(t-i)$; $Q(t-k)$

où

i et j sont les indices de délais qui concernent la pluie, ils vont de 0 jusqu'à 2

k est l'indice de délais du débit observé, il va de 1 jusqu'à 3

Dans (1) chaque pluie est utilisée seule comme entrée

Dans (2) les différentes pluies ($P5$, $P6$, Par et Pth) sont combinées séparément avec la variable du débit observé.

Les abréviations données aux modèles qui sont fonction de l'entrée (1) et (2) sont :

- M1** : $P(t)$
- M2** : $P(t-1)$
- M3** : $P(t-2)$
- M4** : $P(t)$ & $Q(t-1)$
- M5** : $P(t)$ & $Q(t-1)$ & $Q(t-2)$
- M6** : $P(t)$ & $Q(t-1)$ & $Q(t-2)$ & $Q(t-3)$
- M7** : $P(t)$ & $P(t-1)$ & $Q(t-1)$
- M8** : $P(t)$ & $P(t-1)$ & $Q(t-1)$ & $Q(t-2)$
- M9** : $P(t)$ & $P(t-1)$ & $Q(t-1)$ & $Q(t-2)$ & $Q(t-3)$
- M10** : $P(t)$ & $P(t-1)$ & $P(t-2)$ & $Q(t-1)$
- M11** : $P(t)$ & $P(t-1)$ & $P(t-2)$ & $Q(t-1)$ & $Q(t-2)$
- M12** : $P(t)$ & $P(t-1)$ & $P(t-2)$ & $Q(t-1)$ & $Q(t-2)$ & $Q(t-3)$

4.6. Evaluation du modèle

Trois critères d'efficacité ont été utilisés pour évaluer les performances de la généralisation du modèle, ces critères sont les mêmes utilisés dans le modèle conceptuel GR4j, à savoir le MSE, NSE et VE montrés respectivement dans les (Equation 2, 3 et 4).

4.7. Résultats et discussion

4.7.1. Application du RNA

Un modèle neuronal a été appliqué pour la simulation du débit. L'architecture choisie pour cette simulation est celle du PMC à trois couches avec la fonction sigmoïde pour les neurones de la couche cachée et une fonction linéaire pour le



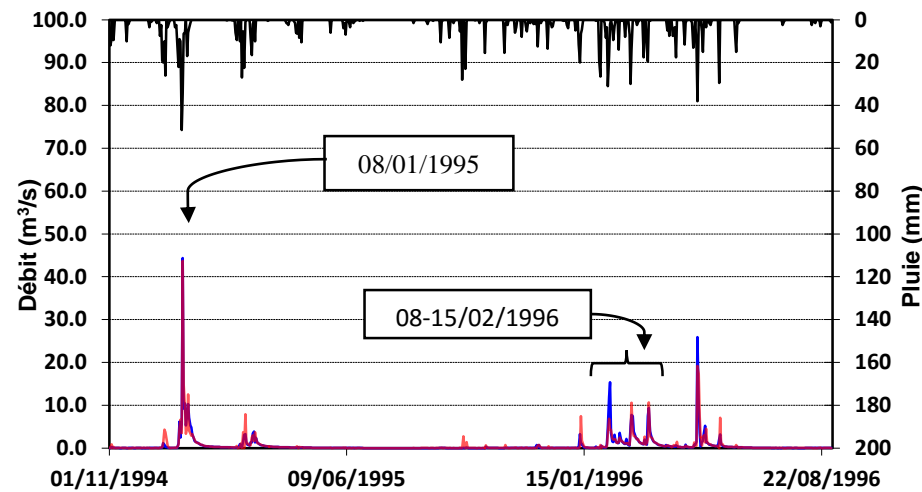

neurone de sortie. L'apprentissage du réseau s'est fait en utilisant l'algorithme de Levenberg-Marquardt sur plusieurs combinaisons d'entrées dans le but de définir le vecteur le plus approprié pour une meilleure performance. Le (Tableau 9) résume les résultats obtenues des modèles RNA utilisant les différents types de pluie (P5, P6, Par, Pth) en fonction des trois critères de performances (MSE, NSE et VE)


Tableau 9. Résultats des simulations du modèle RNA utilisant différentes entrées de pluies

Entrée de pluie	Nombre de neurone dans la couche cachée	MSE		NSE		VE	
		Apr	Test	Apr	Test	Apr	Test
P5	4	0.414	0.511	0.841	0.870	0.554	0.563
P6	19	0.155	0.598	0.941	0.848	0.766	0.585
Par	17	0.349	0.546	0.866	0.862	0.586	0.599
Pth	8	0.333	0.419	0.872	0.894	0.540	0.568


A première vue sur le (Tableau 9), les résultats obtenues avec les différentes entrées de pluies (P5, P6, Par et Pth) sont généralement proches les uns aux autres. La même chose peut être observée entre les performances lors des phases d'apprentissage et de test, sauf pour le modèle développé avec la pluie P6, où la différence entre les performances lors des deux phases est considérable (MSE = 0.155 en apprentissage et 0.598 en période test). Cet écart peut être dû à un sur-apprentissage malgré le fait qu'il y a la procédure d'arrêt anticipé mise au point dans l'algorithme d'apprentissage pour éviter ce problème.

Toujours d'après le (Tableau 9), la meilleure performance se trouve dans le modèle développé par l'utilisation de la pluie Pth avec un MSE dans la phase de généralisation de 0.419 devant les modèles utilisant P5, Par et P6 qui ont respectivement un MSE de 0.511 et 0.546 et 0.598. Dans le même ordre, la même chose peut être aperçue à travers le critère NSE entre le modèle développé avec l'entrée Pth et celui développé avec P5 qui est de 0.092 pour le MSE et 0.024 pour le MSE. Ce n'est pas le même constat qu'on trouve dans la performance au niveau du critère VE, car à l'opposé des critères cités en premiers, c'est les modèles Par et P6 qui effectuent de meilleures performances avec respectivement 0.599 et 0.585 alors que pour les modèles développés avec Pth et P5, ils ont des VE respectives de 0.568 et 0.563.







(a)



(b)



(c)



(d)

D'après les (Figures 46 et 47) montrant les performances de chaque modèles (entrée de pluie différente), on s'aperçoit que ces modèles suivent plus ou moins bien la dynamique du débit. On peut voir qu'au niveau de la simulation du plus grand pic du débit (08/01/1995), les modèles utilisant P5 et Pth sous-estime le débit avec des valeurs respectives de (- 3.9 m³/s) et (- 4.51 m³/s) traduites par des erreurs relatives équivalentes respectivement de (- 8.79 %) et (- 10.16 %) alors que les modèles utilisant les pluies P6 et Par simulent bien ce pic avec une précision de - 0.72 m³/s et + 0.81 m³/s (les erreurs relatives équivalentes respectives sont de - 1.62 % et + 0.81 %).

En analysant la (Figure 47), on s'aperçoit que les débits moyens (allant de 8 à 15.5 m³/s) sont simulés de façon satisfaisante avec les modèles utilisant P5, Par et Pth alors que modèle utilisant P6 effectue des simulations assez médiocre pour cette tranche de débit.

Le dernier pic de la série de données qui a été mesuré à 25.92 m³/s a été grandement sous-estimé avec les quatre modèles. La meilleure performance de ce pic a été effectuée par le modèle utilisant P6 avec une erreur relative de -33.21 % et la plus mauvaise avec le modèle Par avec une erreur relative de - 66.32 %.




Figure 48. Performances des modèle RNA en fonction des combinaisons des entrées et de type de pluie au niveau des critères (a) MSE, (b) NSE et (c) VE

On peut voir à partir de la (Figure 48) qui illustre les performances atteintes par le modèle RNA utilisant différentes entrées et différentes pluie, que le modèle M1 qui utilise seulement la pluie au temps t qui donne les plus mauvais résultats. Ces résultats s'améliorent au fur et à mesure qu'on rajoute des variables en entrée. L'ajout d'un délai de pluie en plus fait qu'il y ait une amélioration considérable au niveau de la simulation par rapport à l'ajout des délais de la variable du débit. En termes de MSE et NSE, on peut partager les résultats en 3 niveaux de performances [M1 ; M2, M3, M6 ; M7, M8 M12] alors qu'en terme du critère VE, on trouve quatre niveaux de performances [M1 ; M2, M3 ; M4, M5 M6 ; M7, M8 M12]. Le modèle M11 est celui qui donne de meilleurs résultats si on se base sur les critères de MSE et NSE alors que le modèle M8 effectue une meilleure performance par rapport au critère VE (0.615).

4.7.2. Application du ANFIS


Un système d'inférence flou à base de neurone adaptif (ANFIS) a été appliqué pour la simulation du débit en fonction de la pluie. On rappelle que le modèle choisit est de type Sugeno avec la méthode de partitionnement en grille comme méthode de partage de l'espace des entrées en fonctions d'appartenance dont la forme est de type gaussienne. L'apprentissage de ce système s'est fait avec la méthode hybride (Retropropagation et méthode des moindres carrés).

Le (Tableau 10) résume les résultats obtenues des modèles ANFIS utilisant les différents types de pluie (P5, P6, Par, Pth) en fonction des trois critères de performances (MSE, NSE et VE).


Tableau 10. Résultats des simulations de modèle ANFIS utilisant différentes entrées de pluies

Entrée de pluie	Nombre de règle	MSE (mm ²)		NSE		VE	
		Apr	Test	Apr	Test	Apr	Test
P5	27	0.807	0.808	0.691	0.795	0.587	0.621
P6	64	0.631	0.701	0.758	0.822	0.632	0.606
Par	36	0.356	0.789	0.864	0.800	0.608	0.581
Pth	9	0.815	0.769	0.688	0.805	0.583	0.621


A partir du (Tableau 10), on s'aperçoit que les performances du modèle ANFIS sont plutôt satisfaisantes avec des MSE allant de 0.701 jusqu'à 0.808, mais le sont encore plus au niveau du critère VE allant de 0.581 jusqu'à 0.621. Le modèle utilisant la pluie P6 effectue les meilleures performances au niveau des critères MSE, NSE en période test, et qui sont respectivement de 0.808 et 0.795. Cependant, en termes de critère VE, c'est les modèles utilisant P5 et Pth qui donnent de meilleurs résultats avec des VE = 0.621. Les plus mauvais résultats ont été obtenus avec le modèle utilisant la pluie Par, même si les résultats de ce dernier ne s'éloignent pas beaucoup des résultats des autres modèles. Les (Figures 49 et 50) montrent les performances de chaque modèle ANFIS en variant les entrées de pluie. Les simulations des quatre modèles suivent assez bien la dynamique de la variation du débit en fonction du temps. Si on analyse les pics, on s'aperçoit que celui de l'évènement du 08/01/1995 a été approché plus ou moins satisfaisamment par les modèles utilisant P5, P6, Par et Pth avec des erreurs relatives respectives de +18.95, -9.19, -30.39, +12.86 %. On remarque que les modèles utilisant P5 et Pth surestiment ce pic, sachant que la pluie Pth est calculée avec un poids multiplié par P5 supérieur à celui du poids de P6. Alors que les modèles utilisant P6 et Par sous-estime cette valeur mais avec des précisions différentes, le modèle P6 s'en approche le plus alors que Par effectue la plus mauvaise performance dans la simulation de ce pic.




(a)




(b)




(c)




(d)




(a)



(b)



(c)



(d)

Les débits moyens qui sont montrés dans la (Figure 50) sont mieux simulés par les modèles utilisant P5, Par et Pth que le modèle utilisant P6 dont les points sont éparpillés.

Pour ce qui est du dernier pic de la série de données, les modèles ANFIS (différentes entrées de pluies) sous-estime d'une façon similaire ce pic avec des erreurs relatives allant de 46 % jusqu'à 67 %.



Figure 51. Performance du modèle ANFIS au niveau du critère MSE



Figure 52. Performance du modèle ANFIS au niveau du critère NSE




Figure 53. Performance du modèle ANFIS au niveau du critère VE

Les trois (Figures 51, 52 et 53) montrent les performances du modèle ANFIS en variant l'entrée de pluie et le type de transformation effectuée sur les données. Pour ce qui est des performances suivant le critère MSE, on trouve le meilleur résultat dans le modèle M7 utilisant la pluie P5 et la transformation T1 avec un MSE égale à 0.808. Alors qu'au niveau des performances par rapport au critère NSE, le modèle M10 utilisant P6 et la transformation T1 qui effectue la meilleure performance avec un NSE égale à 0.822. Quant au critère VE, la meilleure performance est observée dans le modèle M9 utilisant Pth et la transformation T4 avec un VE égale à 0.644 alors qu'en utilisant le même modèle (M9) et la même pluie (Pth) avec la transformation T1 on obtient un VE égale à 0.621. On constate que la transformation T1 utilisant la fonction log est celle qui globalement donne des résultats satisfaisants.

On remarque dans la (Figure 53) que les modèles M2 et M3 ayant comme seule entrée la variable de la pluie affecte énormément les performances au niveau du critère VE par rapport aux critères MSE et NSE (Figure 51 et 52). En ajoutant la variable du débit à différent délais, une amélioration est observée par rapport à tous les critères utilisés.

4.8. Conclusion

Deux modèles de type empirique ont été utilisées dans la résolution de la relation pluie-débit. Un réseau de neurone de type perceptron multicouches avec une seule couche caché et un système d'inférence flou à base de neurone adaptif avec le partitionnement en grille comme méthode de partage des espaces d'entrées. Pour le premier, l'algorithme de Levenberg-Marquard a été utilisé pour son apprentissage, alors que pour le deuxième on a utilisé un algorithme hybride qui fonctionne avec la méthode de la retropropagation et la méthode des moindres carrés. Quatre types d'entrée de pluie ont été utilisés dans ces deux modèles, à savoir les deux pluies ponctuelles P5 et P6 ainsi que les deux pluies surfaciques issus de la moyenne arithmétique et de la méthode de polygone de Thiessen.

En appliquant le RNA, de bons résultats ont été obtenues en utilisant les différentes entrées de pluie. En termes de critères MSE et NSE, c'est le modèle utilisant P5 et Pth qui effectuent les meilleures performances alors qu'en termes de critère VE

c'est les modèle P6 et Par. On peut déduire que c'est les modèles utilisant en entrée les pluies influencé par la station P5 (situé à haute altitude) qui donnent de meilleurs résultats par rapport aux modèles utilisant les pluies P6 et Par. En variant les entrées du modèle RNA (différentes combinaisons), les performances changent en ajoutant ou en retirant une variable ou un délai. D'après les résultats obtenus et selon le critère d'efficacité visé, deux modèles peuvent être choisis, dans notre application, le modèle M11 pour les critères MSE et NSE et le modèle M8 pour le critère VE.

Pour ce qui est de l'application ANFIS, les résultats sont moins bons que ceux du RNA en terme de critères MSE et NSE mais meilleurs si on se réfère au critère VE. Le modèle utilisant Par effectue la meilleure performance par rapport aux critères MSE et NSE alors que c'est dans les modèles utilisant P5 et Pth qu'on trouve de meilleures résultats au niveau du critère VE. Dans ce modèle, la différence de performance entre l'utilisation des pluies ponctuelles ou pluies surfaciques n'a pas été mise en évidence.

En expérimentant différents types de transformation sur les données utilisées dans le modèle ANFIS, il a été constaté que la transformation T1 qui utilise la fonction log, donne globalement les résultats les plus satisfaisants.

L'application des deux modèles empiriques (RNA et ANFIS) dans la simulation de la relation pluie-débit a permis de montrer la puissance de ces outils qui malgré le fait qu'ils ne nécessitent pas une grande connaissance dans les phénomènes et processus qui rentre en considération dans la génération du débit dans un bassin versant, donnent de bons résultats et peuvent être exploiter en pratique que ce soit dans la gestion de la ressource en eau ou la prévention contre les crues.

CHAPITRE 5

Mise à jour du modèle conceptuel avec les réseaux neuronaux

5.1. Introduction

Les modèles présentés dans le chapitre 3, peuvent aussi remplacer un composant interne, ou peuvent être entraînés à corriger l'erreur d'un modèle existant (Shamseldin & O'Connor, 2001). Anctil et al. (2003) ont prouvé que la mise à jour des sorties de modèle avec les RNA effectuée la meilleure performance qu'une mise à jour avec paramètres ou un simple schéma de mise à jour des sorties, qui reproduit toujours la dernière erreur de prévision observée. Abebe et Price (2004) ont utilisé cette approche pour corriger les erreurs du modèle de routage de la rivière Wye au Royaume Uni avec un RNA. D'autres chercheurs comme Kayastha et al., (2013) ont exploré l'idée qu'un modèle hydrologique seul ne peut capturer les détails d'une relation aussi complexe que la relation pluie-débit et ont donc combiné plusieurs modèles calés avec des régimes hydrologiques différents avec un modèle à base de logique floue.

Dans cette étude, la combinaison consiste à une modélisation de la relation pluie-débit avec le modèle GR4j et utiliser les sorties de ce dernier comme entrées du réseau de neurone (Figure 54) afin d'améliorer la simulation en corrigeant les erreurs de ce modèle. Cette combinaison est appelée « Neuro Updating Conceptual Model (NUCM) ».

Pour ce qui est de la préparation des données et l'évaluation du modèle, on retient le même type de normalisation de données pour le réseau de neurone [décrit dans (Equation 30)] et les mêmes critères d'évaluation (Equation 2, 3 et 4).

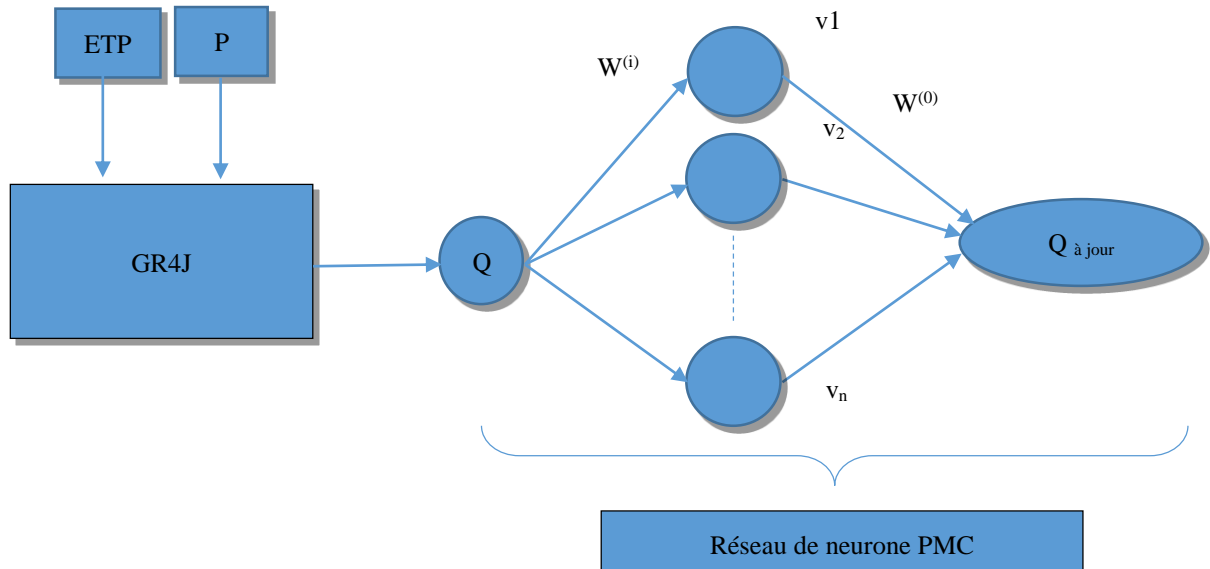


Figure 54. Schéma descriptif du modèle de la combinaison de GR4j et le RNA utilisé

5.2. Le réseau de neurone

Le réseau de neurone utilisé dans cette approche est le même utilisé dans le quatrième chapitre et qui consiste en un perceptron multicouches à trois couches. Les fonctions utilisées aussi sont les mêmes, à savoir la fonction sigmoïde pour les neurones de la couche cachée et la fonction linéaire pour le neurone de sortie.

5.3. Division des données

Dans cette approche, les données introduites au modèle conceptuel (GR4j) sont divisées de la même manière qu'au chapitre 2. On rappelle qu'une année a été utilisée pour la mise en marche du modèle, cinq ans pour le calage et deux ans pour tester le modèle. Dans le réseau de neurone, la première année est supprimée puisqu'elle ne fait pas partie du calage du premier modèle, et donc son introduction dans l'apprentissage compromettrait la comparaison des approches. Les cinq années qui suivent et qui sont utilisées pour le calage ont elles-mêmes été divisées pour garder une année de validation (1993-1994) qui a servi à éviter le sur-apprentissage du réseau de neurone. Les deux dernières années ont été laissées comme pour les deux autres approches afin de tester le modèle.

5.4. Calage de GR4j et apprentissage du RNA

Le modèle combiné (GR4j et RNA) n'a pas été calibré en totalité avec un seul algorithme, mais par partie. Une fois le modèle GR4j a été calibré en utilisant l'algorithme de Nelder-Mead pour ajuster ses quatre paramètres, l'apprentissage du RNA est lancé avec les données de sorties du premier modèle, avec Levenberg-Marquardt comme algorithme d'apprentissage.

5.5. Sélection des données d'entrées du réseau de neurone

Dans le but de mettre à jour les sorties du modèle GR4j, plusieurs scénarios ou combinaisons peuvent être mis en œuvre, ceci en choisissant des variables qui peuvent beaucoup influencer la sortie du modèle. Parmi les variables qui peuvent être combinés avec le débit simulé par le modèle GR4j, les données de la pluie, le débit observée a un passé récent et aussi les dernières erreurs effectuées par le modèle conceptuel. On trouve cette dernière dans le travail de Anctil et al., (2003) et qui a montré de bons résultats.

Ayant comme objectif final de comparer les trois approches (Modèle conceptuel, RNA et modèle hybride), seul le modèle dont les performances sont meilleures (voir chapitre 2), a été combiné avec le réseau de neurone.

Les entrées du modèle neuronal qui ont été testé sont :

- 1) $\hat{Q}(t-i)$ & $e(t-j)$
- 2) $\hat{Q}(t-i)$ & $P(t-k)$
- 3) $\hat{Q}(t-i)$ & $e(t-j)$ & $P(t-k)$

où

\hat{Q} est le débit simulé par le modèle GR4j

P est la pluie utilisée dans le modèle GR4j (P=Par)

e est l'erreur de sortie du modèle GR4j

i et k sont des indices de délais, allant de 0 jusqu'à 3

j est l'indice de délais lié à l'erreur e, allant de 1 jusqu'à 3

5.6. Résultats et discussion

Une approche de combinaison de modèles a été appliquée pour la modélisation de la relation pluie-débit. Le modèle GR4j qui a été développé en utilisant les quatre types de pluie (P5, P6, Par, Pth), est mis à jour avec un réseau de neurone PCM. Les résultats de cette approche sont montrés dans le (Tableau 11)

4. Tableau 11. Résultats de la simulation du modèle NUCM

Pluie	Entrée	Nombre de neurone caché	MSE		NSE		VE	
			Apr	Test	Apr	Test	Apr	Test
P5	$\hat{Q}(t) \& \hat{Q}(t-1) \& e(t-1) \& e(t-2) \& P(t) \& P(t-1) \& P(t-2) \& P(t-3)$	18	0.090	0.482	0.965	0.878	0.801	0.655
P6	$\hat{Q}(t) \& \hat{Q}(t-1) \& \hat{Q}(t-2) \& e(t-1) \& e(t-2) \& P(t) \& P(t-1)$	17	0.283	0.619	0.891	0.843	0.644	0.613
Par	$\hat{Q}(t) \& e(t) \& P(t) \& P(t-1) \& P(t-2) \& P(t-3)$	12	0.243	0.501	0.907	0.873	0.398	0.441
Pth	$\hat{Q}(t) \& e(t) \& P(t) \& P(t-1) \& P(t-2)$	17	0.177	0.481	0.932	0.878	0.577	0.537

D'après le (Tableau 11) le modèle utilisant la pluie P5 effectue la meilleure performance avec un MSE de 0.482 dans la période teste. Ce résultat est très proche des performances du modèle utilisant Pth et Par au niveau des critères MSE et NSE, alors qu'au niveau du critère volumétrique (VE), l'écart est plus large avec un VE de 0.655 pour le premier, 0.537 pour le deuxième et 0.441 pour le troisième. Le modèle utilisant la pluie P6 se situe en dernière place au classement des performances en termes de MSE et NSE tandis qu'il se situe en deuxième place par rapport au critère VE. En fonction de ce dernier critère, les modèles utilisant les pluies ponctuelles (P5 et P6) donnent de meilleurs résultats que les modèles utilisant les pluies surfaciques (Par et Pth).

En analysant les (Figure 55 et 56), montrant les performances du modèle NUCM en variant les entrées de pluie, on remarque que les simulations des quatre modèles suivent correctement la variation du débit mesuré. Au niveau du pic de l'évènement du 08/01/1995, les meilleures performances des modèles (suivant l'entrée de pluie) dans l'ordre décroissant sont : P5, P6, Par et Pth, avec des écarts respectives entre la simulation et l'observation de - 0.79, - 2.39, - 3.44 et - 3.77 m³/s équivalent à des erreurs relatives de - 1.78, - 5.38, 7.75, 8.49 %. On peut remarquer que tous les

modèles sous-estiment ce pic avec des degrés de précision différents, le modèle utilisant P5 effectue la meilleure performance et celui qui utilise Pth la plus mauvaise. Pour l'évènement du 08/02/1996, la simulation qui s'en approche le plus est celle du modèle utilisant P5 avec un écart de $-0.51 \text{ m}^3/\text{s}$ (erreur relative équivalente égale à 3.32 %), les autres modèles utilisant P6, Par et Pth, effectuent des simulations avec des erreurs relatives de 40.20, 24.72 et 17.17 %. Pour le dernier évènement du 29/04/1996, tous les modèles sous-estiment ce pic avec une meilleure performance du modèle utilisant P5 (erreur relative = 32.79 %) et la plus mauvaise celle du modèle utilisant P6 (erreur relative = 70.68 %). En se basant sur ces trois évènements, on peut affirmer que le modèle utilisant la pluie P5 est celui qui effectue la meilleure simulation au niveau des pics de débit.

En ce qui concerne les débits moyens illustrés dans la (Figure 56) les simulations des quatre modèles sont plus ou moins bonnes avec des performances similaires.

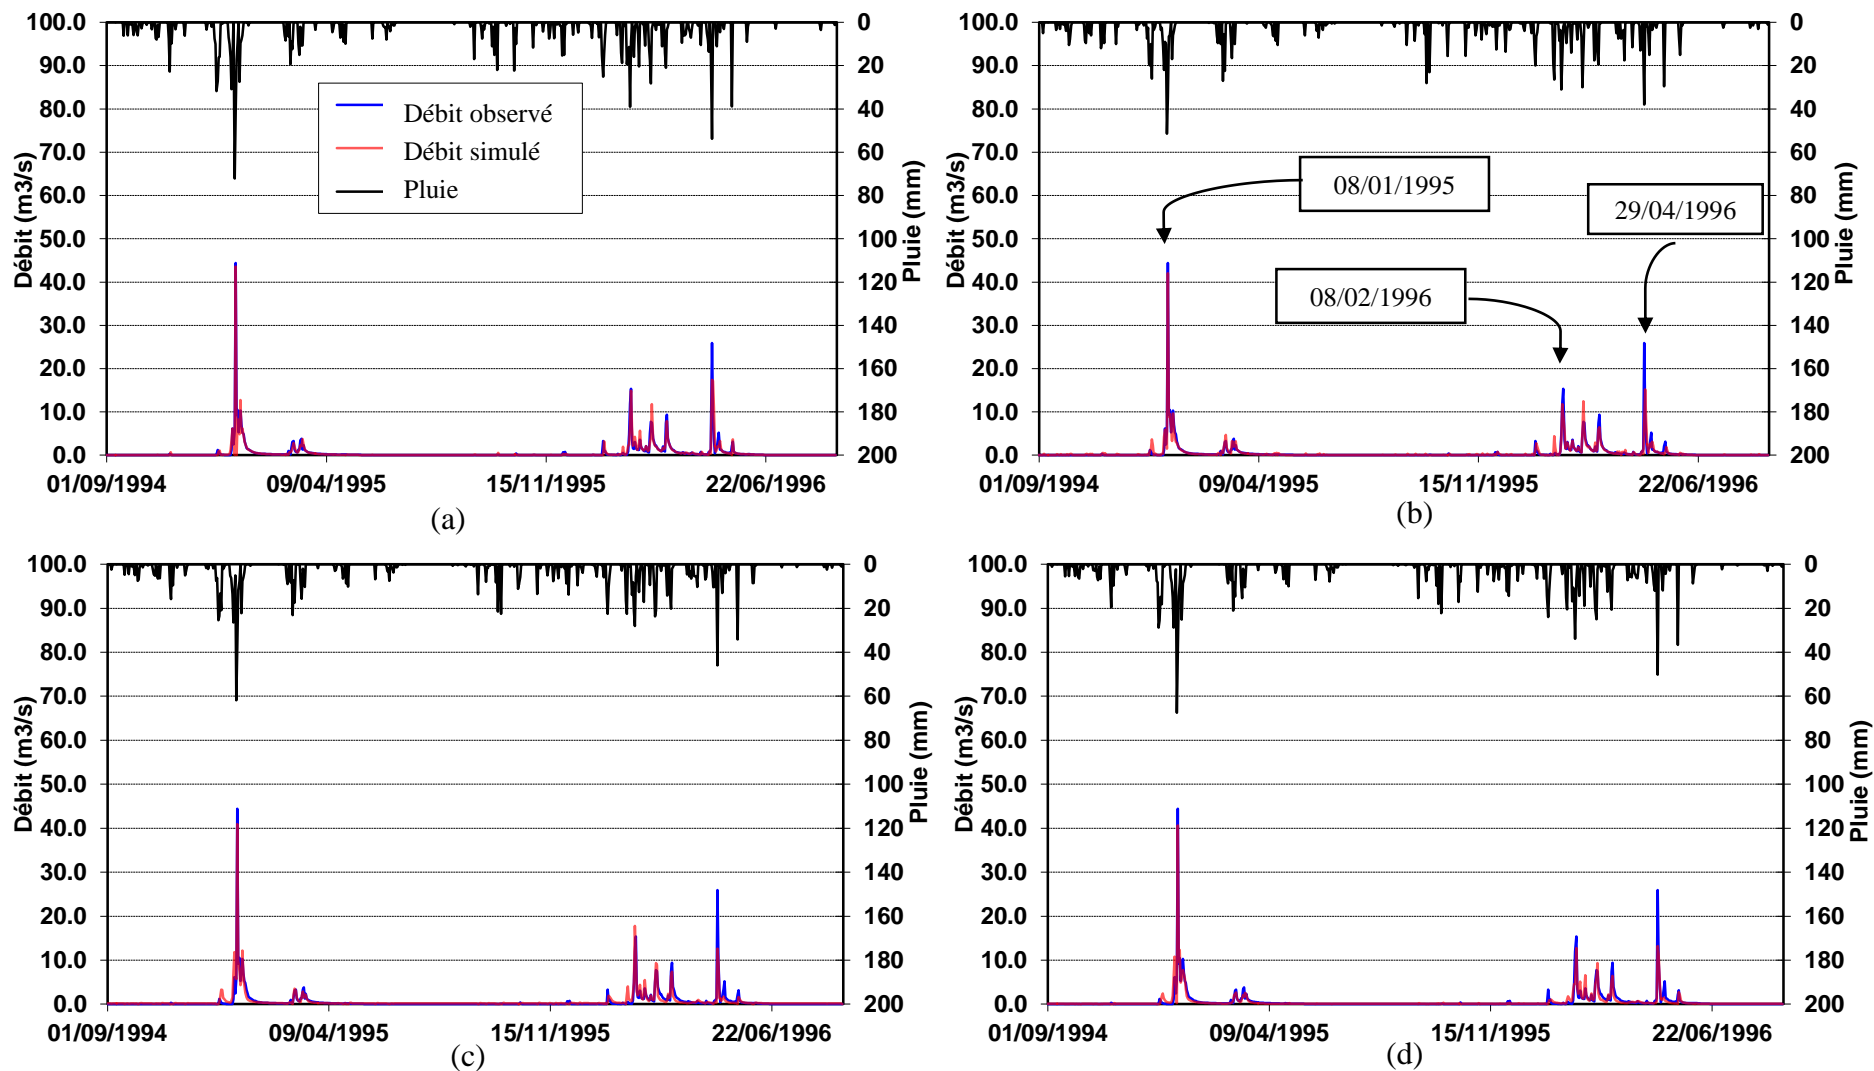





Figure 55. Courbes des simulations du débit avec le modèle NUCM en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie P7 et (d) la pluie Pth durant la période test




(a)



(b)



(c)



(d)

Figure 56. Nuages de points montrant les simulations du débit avec le modèle NUCM en utilisant (a) la pluie P5, (b) la pluie P6, (c) la pluie Par et (d) la pluie Pth durant la période test

On peut visualiser dans la (Figure 57) l'effet des RNA dans la mise à jour du modèle conceptuel GR4j. On constate que l'amélioration des performances est assez considérable avec le passage des MSE pour les modèles utilisant P5, P6, Par et Pth de 1.27, 1.26, 1.17 et 1.22 jusqu'à respectivement 0.482, 0.619, 0.501 et 0.481, ainsi que celui des critères NSE qui passent respectivement de 0.68, 0.68, 0.7, 0.69 à 0.84, 0.843, 0.873 et 0.878. Cependant, en se basant sur le critère VE, seuls les modèles utilisant P5, P6 et Pth ont connus une amélioration alors que le modèle utilisant Par, l'effet a été inverse, une dégradation par rapport au critère VE a été observée en passant de 0.463 pour le modèle GR4j à 0.441 pour le modèle mis à jour.

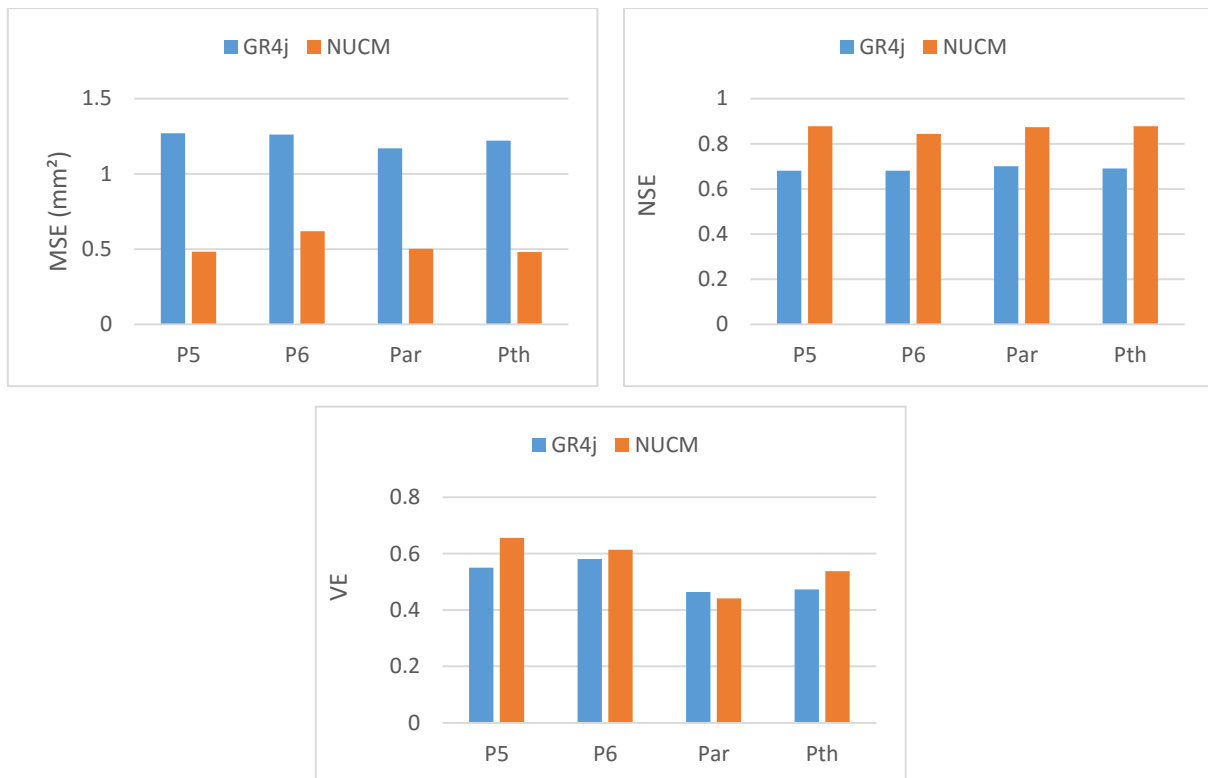


Figure 57. Performances des modèles GR4j et NUCM en fonction des différentes entrées de pluie

5.7. Conclusion

Une mise à jour d'un modèle conceptuel (GR4j) avec les réseaux de neurones artificiels a été appliquée pour une meilleure simulation des débits. Quatre modèles GR4j ont été développés en variant l'entrée de pluie, deux pluies ponctuelles (P5 et P6) et deux pluies surfaciques (Par et Pth). Les sorties de ces modèles ont été

injectées dans des RNA de type PCM pour les mettre à jour selon les observations réelles du débit.

En comparant les modèles NUCM utilisant différentes entrée de pluie, celui qui utilise la pluie ponctuelle P5 a effectué la meilleure performance au niveau de tous les critères MSE, NSE et VE. Ce modèle est aussi celui qui dont l'amélioration a été la plus significative par rapport à tous les autres modèles, et celui dont la simulation des pics de débit a été la plus proche par rapport aux mesures dans la station de jaugeage.

En comparant entre les modèles utilisant les pluies ponctuelles et les pluies surfaciques, on a constaté qu'en termes de critères MSE et NSE, il n y a pas de différence entre l'utilisation de ces deux types de pluie, alors qu'en termes de critère VE, critère qui représente la fraction de l'eau écoulée au moment approprié, les modèles utilisant les pluies ponctuelle effectuer une meilleure performance.

Malgré le fait que les simulations de GR4j étaient de mauvaise qualité, ses performances ont été considérablement améliorées en les mettant à jour avec les RNA, pour atteindre un très bon résultat. A partir de ce constat, on peut mettre en hypothèse que l'amélioration de la simulation du modèle conceptuel peut affecter positivement les résultats après mise à jour pour atteindre des performances très élevés.

CHAPITRE 6

Etude comparative des approches appliquées

6.1. Introduction

Après avoir modélisé le phénomène de la relation pluie-débit avec le modèle conceptuel GR4j, les réseaux de neurone et en combinant ces deux derniers, on a consacré cette partie de la thèse pour comparer ces approches en se reposant principalement sur leurs performances à simuler le débit. On rappelle que plusieurs types de représentations de la pluie ont été testés à savoir les pluies ponctuelles utilisant à chaque fois la mesure d'une station pluviométrique, les pluies surfaciques issus de la méthode arithmétique et les polygones de Thiessen et en plus les mesures des deux stations en même temps pour les RNA.

6.2. Comparaison par rapport aux performances

Dans cette section, les modèles utilisés dans la simulation des débits sont comparés selon leurs performances en termes de critères d'efficacité. Le (Tableau 12) et la (Figure 58) montrent les meilleures performances obtenues par les modèles GR4j, RNA, ANFIS et NUCM en ne tenant pas en considération le type de pluie injecté en entrée.

Tableau 12. Performances de tous les modèles utilisés dans l'étude

Modèles	MSE		NSE		VE	
	Cal	Test	Cal	Test	Cal	Test
GR4j	0.46	1.17	0.79	0.70	0.60	0.58
RNA	0.333	0.419	0.872	0.894	0.586	0.599
ANFIS	0.631	0.701	0.758	0.822	0.587	0.621
NUCM	0.090	0.482	0.965	0.878	0.801	0.655

Suivant le (Tableau 12) et la (Figure 58), on observe qu'en termes de critères MSE et NSE, c'est le modèle RNA qui effectue la meilleure performance avec des valeurs de 0.419 en MSE et 0.894 en NSE, suivie en ordre décroissant par les modèles NUCM, ANFIS et enfin GR4j. Alors qu'en termes de VE, c'est le modèle NUCM qui a le meilleur résultat (0.655), suivie par les modèles ANFIS, RNA et GR4j.




Figure 58. Performance des modèles GR4j, RNA, ANFIS et NUCM par rapport aux critères (a) MSE et (b) NSE et VE

Si on met en considération les performances en période de calibration en plus des écarts entre les performances des modèles, on peut mettre le modèle NUCM comme étant le plus robuste. Ceci peut être expliqué par les performances de ce modèle selon les critères MSE et NSE en période de calibration qui sont bien meilleures que ceux du modèle RNA, et ceux de la période test sont assez proches de ceux de ce dernier modèle. Enfin, le critère VE obtenu du modèle NUCM dépasse ceux de tous les autres modèles.

6.3. Comparaison par rapport aux entrées de pluie

On rappelle que dans le développement des modèles, plusieurs types de pluie ont été utilisés en entrée des modèles GR4j, RNA, ANFIS et NUCM. Ces pluies sont de type ponctuel issus des mesures prises dans les stations 140605 et 140606 dont la nomination a été respectivement P5 et P6, ainsi que des pluies de type surfacique, l'une utilisant la moyenne arithmétique (Par) et une autre issues de la méthode des polygones de Thiessen (Pth).

Tableau 13. Performances des modèles GR4j, RNA, ANFIS et NUCM en fonction des entrées des pluies P5, P6, Par et Pth

		MSE		NSE		VE	
		Cal	Test	Cal	Test	Cal	Test
P5	GR4j	0.66	1.27	0.7	0.68	0.57	0.55
	RNA	0.414	0.511	0.841	0.87	0.554	0.563
	ANFIS	0.807	0.808	0.691	0.795	0.587	0.621
	NUCM	0.09	0.482	0.965	0.878	0.801	0.655
P6	GR4j	0.61	1.26	0.72	0.68	0.6	0.58
	RNA	0.155	0.598	0.941	0.848	0.766	0.585
	ANFIS	0.631	0.701	0.758	0.822	0.632	0.606
	NUCM	0.283	0.619	0.891	0.843	0.644	0.613
Par	GR4j	0.46	1.17	0.79	0.70	0.48	0.46
	RNA	0.349	0.546	0.866	0.862	0.586	0.599
	ANFIS	0.356	0.789	0.864	0.8	0.608	0.581
	NUCM	0.243	0.501	0.907	0.873	0.398	0.441
Pth	GR4j	0.54	1.22	0.75	0.69	0.47	0.47
	RNA	0.333	0.419	0.872	0.894	0.54	0.568
	ANFIS	0.815	0.769	0.688	0.805	0.583	0.621
	NUCM	0.177	0.481	0.932	0.878	0.577	0.537




Figure 59. Performances des modèles GR4j, RNA, ANFIS et NUCM en fonction des entrée des pluies P5, P6, Par et Pth selon les critères (a) MSE, (b) NSE et (c) VE

En analysant le (Tableau 13) et la (Figure 59), on peut s'apercevoir qu'en termes de critères MSE et NSE, les modèles RNA et NUCM utilisant la pluie P5 ou Pth effectuent de meilleures performances que ceux des modèles utilisant P6 ou Par, alors que pour le modèle GR4j et le modèle ANFIS, c'est l'utilisation de Par pour le premier et P6 pour le deuxième qui donnent de meilleurs résultats.

Etant donné que les deux modèles GR4j et NUCM sont liés vu que le deuxième à un module en plus par rapport au premier, les modèles utilisant les pluies ponctuelles (P5 et P6) sont ceux qui effectuent de meilleures performances selon le critère VE par rapport à l'utilisation des pluies surfaciques (Par et Pth). Dans le cas des modèles RNA et ANFIS, l'utilisation de P6 et Par en entrée pour le premier et P5 et Pth en deuxième sont ceux qui effectuent donnent de meilleurs résultats.

En essayant de trouver une relation claire sur l'utilisation des pluies et les modèles utilisés dans cette étude, il est impossible de sortir une règle unique à appliquer pour tous les modèles. La représentation de la pluie comme entrée, qu'elle soit ponctuelle ou surfacique, reste au cas par cas selon le modèle utilisé.

6.4. Comparaison par rapport aux pics de débit

La simulation des pics de débit est une tâche très importante en termes de protection contre les inondations. Une bonne estimation de ces valeurs aide à une meilleure estimation du risque et donc de bonnes prises de décision.

Les pics du débit qui ont été prise dans la série de test pour comparer les simulations sont celle des évènements montrés dans le (Tableau 14).

Tableau 14. Pics du débit utilisés dans la comparaison des modèles

Noms	Dates	Débits [m ³ /s]
EV1	08/01/1995	44.39
EV2	08/02/1996	15.37
EV3	29/02/1996	7.48
EV4	15/03/1996	9.38
EV5	29/04/1996	25.92

Tableau 15. Simulation des pics de débit pendant la phase test pour les modèles GR4j, ANN, ANFIS, NUCM

Pics observés [m ³ /s]	GR4j		ANN		ANFIS		NUCM	
	[m ³ /s]	Erreur (%)	[m ³ /s]	Erreur (%)	[m ³ /s]	Erreur (%)	[m ³ /s]	Erreur (%)
44.39	42.07	-5.226	40.49	-8.786	40.31	-9.191	43.6	-1.780
15.37	10.41	-32.271	13.55	11.84	17.33	12.752	14.86	-3.318
7.71	11.44	48.379	8.25	7.004	13.18	70.947	11.78	52.789
9.38	4.99	-46.802	5.51	41.25	4.22	-55.011	3.78	-59.701
25.92	7.5	-71.065	14.1	45.60	10.08	-61.111	17.17	-33.758

Selon le (Tableau 15) et la (Figure 60), les meilleures performances en termes de simulations des pics de débit sont partagés entre le modèle RNA et le modèle NUCM. EV1, EV2 et EV5 ont été mieux simulés par NUCM avec des erreurs relatives -1.78, -3.318 et -33.758 %, alors que pour EV3 et EV4 c'est le modèle RNA qui effectue les meilleures simulations avec des erreurs relatives de 7.004 et -41.258 %. En effectuant une meilleure performance dans trois sur cinq des évènements, le modèle NUCM est considéré comme étant le modèle le plus apte à simuler les pics de débit.

En comparant les modèles GR4j et ANFIS, on trouve que le premier estime mieux les pics des évènements EV1, EV3 et EV4 avec des erreurs relatives respectives de -5.226, 48.379 et -46.802 %, alors que les estimations du deuxième modèle sont meilleures pour EV2 et EV5 (erreurs relatives respectives de 12.752 et -61.111 %).




Figure 60. (a) Simulation des pics de débit ainsi que (b) leurs erreurs relatives, pendant la phase test pour les modèles GR4j, ANN, ANFIS, NUCM

Si on veut classer les modèles utilisés dans cette étude selon les meilleures simulations des pics de débit, du meilleure au plus mauvais, ça donne : NUCM, RNA, GR4j et enfin ANFIS.

6.5. Comparaison par rapport aux apports

Une bonne simulation du débit est aussi une bonne estimation des apports d'eau passant par l'exutoire d'un bassin versant. Cette connaissance permet de mieux gérer cette ressource inestimable et peut être très utile dans la gestion des barrages.

Dans le but d'évaluer les performances de simulation des apports des modèles utilisés dans cette étude (GR4j, RNA, ANFIS et NUCM), une comparaison entre les apports annuelles (Tableau 16) et mensuelles (Figure 61) simulés et observés a été effectué.

Tableau 16. Apports annuelles observés et simulés par les modèles GR4j, RNA, ANFIS et NUCM

Année	Observation	GR4j	RNA	ANFIS	NUCM
	[millions de m ³]				
Sep. 1994 - Aout. 1995	16.47	14.43	14.86	15.75	15.27
Sep. 1995 - Aout. 1996	20.95	12.56	16.80	17.90	17.50

D'après le (Tableau 16), on constate que les meilleures estimations des apports annuelles pour la première et deuxième année sont ceux du modèle ANFIS avec un écart entre la simulation et l'observation de - 0.72 millions de m³ pour la première année et de -3.05 millions de m³ (erreurs équivalentes respectives égales à 4.37 et 14.56 %), suivi par les modèles NUCM, RNA et GR4j dont les écarts sont respectivement de -1.2, -1.61 et -2.04 million de m³ pour la première année et - 3.45, -4.15 et -8.39 million de m³ pour la deuxième année, soit des erreurs équivalentes respectives de de -7.29, -9.78, -12.39 et -16.47, -19.81 et -40.04 %. On remarque que tous les modèles sous-estiment les apports annuels avec des degrés de précision différents.

En comparant les modèles GR4j, RNA, ANFIS et NUCM dans la simulation des apports mensuels (Figure 61), on remarque que c'est les approches simulé par le modèle ANFIS qui approchent le plus aux apports mensuels observés avec une meilleure simulation dans 12 mois sur 24 par rapport aux autres modèles GR4j, NUCM et RNA qui ont effectué respectivement 5, 4 et 2 mois sur les 24 mois de la période test. Dans le mois de juillet 1995, aucune valeur de débit n'a été enregistrée dans la station de jaugeage. Même si les modèles NUCM et RNA ont effectué de meilleures performances que 4 et 2 mois sur 24, leurs simulations des apports mensuels restent assez proche de celle du modèle ANFIS et peuvent être considéré comme satisfaisantes.

On remarque que le modèle GR4j a effectué une meilleure performance et des simulations qui approchent à celles des autres modèles pendant la période de septembre 1995 jusqu'à janvier 1996. La période qui a suivi (février jusqu'au mai

1996), la qualité de simulation des apports mensuelle du modèle GR4j a été considérablement dégradée avec des sous-estimations allant de 23 jusqu'à 65 % des apports observés.




Figure 61. Performances des modèles GR4j, ANN, ANFIS et NUCM au niveau de l'apport mensuel

Conclusion générale et perspectives

La résolution de la relation pluie-débit avec de la modélisation fait partie des tâches les plus importantes en hydrologie. Ces modèles peuvent être utilisés dans la gestion des ressources en eau (ex : gestion d'un barrage) mais aussi dans la protection contre les inondations (ex : comme outil de prévention des crues).

Ce travail dont l'intitulé « Contribution à la modélisation de la relation pluie-débit » a pour but d'illustrer à travers un cas d'étude, différentes approches de modélisation de cette relation. Le cas utilisé dans cette étude est celui du sous bassin de oued Rassoul, un des affluents de Oued Seybous (Nord Est d'Algérie). Alors que les approches testées reposent sur l'utilisation d'un modèle conceptuel (GR4j), deux modèles d'intelligence artificiel (RNA et ANFIS) enfin un modèle hybride.

Etant données que la variable de la pluie est une donnée déterminante dans la génération du débit, ses valeurs doivent être le plus représentatives possible afin d'obtenir de bonnes performances dans les modèles. Pour cela, on a exploité plusieurs méthodes de la représentativité de la pluie, à savoir les méthodes ponctuelle (un seul point de mesure) et surfacique (méthode arithmétique et polygone de Thiessen), pour toutes les approches étudiés.

Dans la première approche, la modélisation de relation pluie-débit consiste à l'utilisation du modèle conceptuel GR4j ayant comme entrées la pluie et l'évapotranspiration potentielle, deux réservoirs (production et routage) ainsi que quatre (04) paramètres ajustables. L'estimation de l'évapotranspiration potentielle journalière a été faite avec le modèle de Oudin (2005), qui nécessite que la température comme entrée du modèle. Après calage avec l'algorithme de Nelder-Mead sur plusieurs variantes (variation de la pluie), les résultats ont montrés une meilleure performance en termes de simulation des pics, pour les modèles utilisant des pluies influencées par la station qui se trouve à haute altitude (140605) et qui sont : la pluie ponctuelle de la station et la pluie issue de la méthode de Thiessen, cette dernière étant calculée avec un poids favorisant cette station. Alors qu'en

termes de volume, c'est le modèle utilisant la pluie de la station qui se trouve près de l'exutoire et qui est situé à basse altitude qui donne de meilleurs résultats.

Dans la deuxième approche, un modèle de réseau de neurones artificiel et un système d'inférence floue à base de neurone adaptif ont été testés sur la résolution de la relation étudiée. Le premier consiste en un perceptron à trois couches avec fonction sigmoïdale dans la couche cachée et le deuxième utilisant le partitionnement en grille comme méthode de partage des espaces d'entrées et la forme gaussienne pour les fonctions d'appartenance. L'apprentissage du premier a été effectué en utilisant l'algorithme de Levenberg-Marquard alors que le deuxième avec un algorithme hybride qui fonctionne avec la méthode de la retropropagation et la méthode des moindres carrés. La procédure de essai-erreur a été utilisé sur plusieurs entrée afin d'arriver aux meilleures performances. Avant l'apprentissage des deux modèles, es transformations de donnée a été effectuées, une transformation de type mise à l'échelle pour le modèle RNA et ANFIS, et trois autres en plus pour ce dernier modèle, et qui sont : transformation avec la fonction log, transformation en variables centrée réduite et enfin une division des valeurs de variables sur l'écart-type.

Les résultats de l'application des RNA et ANFIS ont montré qu'en termes de critères MSE et NSE, c'est le premier modèle qui effectue les meilleures performances alors qu'en termes du critère VE, c'est le deuxième modèle dont les résultats sont supérieurs.

Par rapport aux entrées de pluie, le modèle RNA effectue une meilleure performance au niveau des critères MSE et NSE en utilisant les pluies influencées par la station qui se trouve à haute altitude (140605) alors qu'au niveau du critère VE, c'est en utilisant les pluies mesurées dans la station (140606) et issue de la moyenne arithmétique qui donnent de meilleurs résultats. Cependant, aucune conclusion ne peut être tirée sur les entrées des pluies dans le modèle ANFIS.

Pour ce qui est de la transformation des données avant l'apprentissage du modèle ANFIS, il a été constaté que la transformation T1 qui utilise la fonction log, donne globalement les résultats les plus satisfaisants.

Pour la troisième et dernière approche, une combinaison du modèle conceptuel GR4j et un réseau de neurone artificiel de type perceptron multicouches a été testé. Le premier a servi à modéliser la relation pluie débit et le deuxième à mettre à jour les sorties du premier.

Les résultats de cette troisième approche ont montré une grande efficacité dans la mise à jour du modèle GR4j développé avec la pluie ponctuelle P5. Ce résultat a été illustré par la supériorité au niveau de toutes les performances (MSE, NSE et VE) et par les simulations très précises des pics de débit en période test.

Selon le critère VE, les modèles NUCM développés par l'utilisation des pluies ponctuelles et mis à jour par le réseau de neurone sont ceux qui effectuent une meilleure performance.

Dans la dernière partie de cette thèse, une comparaison entre tous les modèles utilisés dans cette étude a été réalisée. Cette comparaison a été basée sur les performances des modèles par rapport aux critères d'efficacité, au type de pluie en entrée, aux pics du débit et enfin par rapport aux apports annuels et mensuels.

L'évaluation des modèles suivant les critères de performance a mis en première position le modèle NUCM comme étant le plus robuste, suivi en ordre par les modèles RNA, ANFIS et GR4j si on se réfère aux critères MSE et NSE ou aux modèles ANFIS, RNA et GR4j si on se base sur le critère VE.

Quant à la représentation de la pluie comme entrée des modèles, il n'est pas évident de mettre en place une règle concernant tous les modèles vu que les performances diffèrent d'un modèle à un autre, cette entrée dépend donc du modèle utilisé.

Dans la simulation des pics du débit, quatre événements ont été extraits de la série des débits en période test. Les résultats ont montré que le modèle NUCM a été le plus apte à simuler les pics de débit, suivie en ordre par les modèles RNA, GR4j et enfin ANFIS.

Enfin, suivant les apports annuels et mensuels observés, l'évaluation de simulations obtenues par les modèles a montré que le modèle ANFIS surpasse tous les autres

modèles, suivi en ordre par le modèle NUCM, RNA et GR4j. Les performances de ce dernier ont été bonnes que pour la première année de test et mauvaises pour la deuxième année, ceci peut être dû à la rigidité du modèle conceptuel face aux nouveaux évènements climatiques.

Dans cette étude, le modèle NUCM s'est montré très efficace dans presque toutes les évaluations appliquées sur les modèles. Toutefois, cette approche doit être généralisée sur un plus grand échantillon de bassin versant pour confirmer son efficacité. Aussi, il est possible que ces performances puissent encore être améliorées si les performances du modèle conceptuel sont augmentées. A partir de cette hypothèse, d'autres modèles conceptuels à part GR4j peuvent être testés sur les bassins versants Algériens pour trouver celui qui soit plus adéquat et dont la mise à jour avec les RNA surpasse les performances obtenues avec le modèle GR4j. On met comme même comme supposition que le modèle ne doit pas être trop souple (beaucoup de paramètres) afin que le RNA soit en mesure capter la fonction d'erreur de ce modèle. Mieux encore, ça serai plus intéressant de créer un modèle conceptuel dont les fondements sont développés à partir du régime hydrologique spécifique à l'Algérie.

Sachant que la plupart des données pluviométriques et hydrométriques en Algérie ne sont pas de bonne qualité, ça sera très intéressant de travailler sur le prétraitement des données avant injection dans un modèle de type « Data-driven » comme les RNA ou les ANFIS. On donne comme exemple l'utilisation de la transformation en ondelette. Cette méthode a connu dernièrement un grand intérêt par la communauté hydrologique travaillant sur la relation pluie-débit avec les méthodes d'intelligence artificiel, son application à montrer de forte amélioration en termes de performance des modèles.

BIBLIOGRAPHIE

1. Abonyi, J., Nagy, L., Szeifert, F. (1999) 'Adaptive fuzzy inference system and its application in modelling and model based control' *Chemical Engineering Research and Design*, Vol. 77 No. 4, pp. 281-290.
2. Abrahart, R. J., See, L. M., & Solomatine, D. P. (2008). 'Practical hydroinformatics: computational intelligence and technological developments in water applications' Vol. 68 Springer Science & Business Media.
3. Abrahart, R.J. and See, L. (2002) 'Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two contrasting catchments', *Hydrology and Earth System Sciences*, Vol. 6 No. 4, pp. 655 – 670
4. Abrahart, R.J. Kneale. P.E. See, L.M (2005) 'Neural network for hydrological modelling', *Taylor & Francis e-Library*.
5. Abtew, W., (1996) 'Evapotranspiration measurements and modeling for three wetland systems in south Florida', *Water Resources Bulletin*, Vol. 32 No.3, pp. 465-473
6. Adamowski, J. and Karapataki, C. (2010) 'Comparison of Multivariate Regression and Artificial Neural Networks for Peak Urban Water-Demand Forecasting: Evaluation of Different ANN Learning Algorithms', *Journal of Hydrologic Engineering*, Vol. 15 No. 10, pp. 729-743
7. Aichouri, I., A. Hani, et al. (2015) 'River Flow Model Using Artificial Neural Networks', *Energy Procedia*, Vol. 74, pp. 1007-1014
8. Alfred H. Thiessen, (1911) 'Precipitation averages for large areas', *Mon. Wea. Rev.*, Vol. 39, pp. 1082–1089
9. Anctil, F. Perrin, C. Andreassian, V. (2003) 'ANN Output Updating of Lumped Conceptual Rainfall/Runoff Forecasting Models', *JAWRA Journal of the American Water Resources Association*, Vol. 39 No. 5, pp. 1269-1279
10. Andersen, T. J., & Wilamowski, B. M. (1995) 'Modified Regression Algorithm for Fast One Layer Neural Network Training', In *World Congress of Neural Networks*, Vol. 1, pp. 687-690

11. Aqil, M., I. Kita, et al. (2007). 'A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff', *Journal of Hydrology*, Vol. 337 No 1–2, pp. 22-34
12. Arnold, J. G., Srinivasan, R., Muttiah, R. S., and Williams, J. R. (1998) 'Large area hydrologic modeling and assessment. Part I: Model development' *J. Am. Water Resour. Assoc.*, Vol. 34 No. 1, pp. 73–89.
13. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000). "Artificial Neural Networks in Hydrology. I: Preliminary Concepts." *J. Hydrol. Eng.*, Vol. 2 No. 115, pp. 115-123.
14. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000) 'Artificial Neural Networks in Hydrology. II: Hydrologic Applications' *J. Hydrol. Eng.*, Vol. 2 No. 124, pp. 124-137
15. Azadeh, A. Asadzadeh, S. M. Ghanbari, A. (2010) 'An adaptive network-based fuzzy inference system for short-term natural gas demand estimation: Uncertain and complex environments', *Energy Policy*, Vol. 38 No. 3, pp. 1529-1536
16. Azadeh, A. Saberi, M. Ghaderi, S. F. Gitiforouz, A. Ebrahimipour, V. (2008) 'Improved estimation of electricity demand function by integration of fuzzy system and data mining approach', *Energy Conversion and Management*, Vol. 49 No. 8, pp. 2165-2177
17. Babovic, V. Cañizares, R. Jensen, H. Klinting, A. (2001) 'Neural Networks as Routine for Error Updating of Numerical Models', *Journal of Hydraulic Engineering*, Vol. 127 No. 3, pp. 181-193
18. Gerald D. Bell, Michael S. Halpert, Russell C. Schnell, R. Wayne Higgins, Jay Lawrimore, Vernon E. Kousky, Richard Tinker, Wasila Thiaw, Muthuvel Chelliah, and Anthony Artusa (2000) 'Climate Assessment for 1999', *Bull. Amer. Meteor. Soc.*, Vol. 81, No. S1-S50
19. Benkaci A. T. et Dechemi N. (2004) 'Modélisation pluie-débit journalière par des modèles conceptuels et « boîte noire »; test d'un modèle neuroflou' *Hydrological Sciences Journal*, Vol. 49 No. 5, pp null-930.
20. Bergstrom, S. (1976) 'Development and application of a conceptual runoff model for Scandinavian countries' SMHI Rep. No. 7, Norrkoping, Sweden.

21. Bergstrom, S. (1992) 'The HBV model—its structure and applications' SMHI Rep. RH, No. 4, Norrkoping, Sweden.
22. Bergstrom, S. (1995) 'Chapter 13: The HBV model, Computer models of watershed hydrology', *Water Resources Publications*, Littleton.
23. Beven K. J. (2002), 'Rainfall-Runoff Modelling: The Primer', 2nd Edition, Wiley-Blackwell
24. Beven, K. J. (1995) 'Chapter 18: TOPMODEL, Computer models of watershed hydrology' *Water Resources Publications*, Littleton.
25. Beven, K. J., and Kirkby, M. J. (1976) 'Toward a simple physically based variable contributing area of catchment hydrology' Working Paper No. 154, School of Geography, Univ. Leeds, U.K.
26. Beven, K.J. et Kirkby, M.J. (1979) 'A physically based, variable contributing area model of basin hydrology' *Hydrological Sciences Bulletin*, Vol.24 No. 1, pp. 43-69.
27. Bicknell, B. R., Imhoff, J. L., Kittle, J. L., Donigian, A. S., and Johanson, R. C. (1993) 'Hydrologic simulation program—Fortran; User's manual for release 10' U.S. EPA Environmental Research Laboratory, Athens.
28. Bicknell, B.R., Imhoff, J.C., Kittle, J.L., Jr., Donigian, A.S., Jr., and Johanson, R.C., (1997), 'Hydrological Simulation Program--Fortran, User's manual for version 1' U.S. Environmental Protection Agency, National Exposure Research Laboratory, Athens, pp. 455
29. Blaney, H.F. et Criddle, W.D., (1950) 'Determining water requirements in irrigated areas from climatological and irrigation data' US Department of Agriculture, Soil Conservation Service, Washington D.C., pp. 48.
30. Bowden, G. J., Maier, H. R., & Dandy, G. C. (2005) 'Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river' *Journal of Hydrology*, Vol. 301 No. 1, pp. 93-107
31. Box G.E.P. et Jenkins G.M. (1976) 'Time Series Analysis: forecasting and Control' Holden-Day, San Francisco.
32. Brazil, L.E. (1988) 'Multilevel calibration strategy for complex hydrologic simulation models' PhD dissertation, Colorado State University, Fort Collins, Colorado, USA

33. Brazil, L.E. et Krajewski, W.F. (1987) 'Optimization of complex hydrologic models using random search methods' *Engineering Hydrology Proceedings*, Williamsburg, Virginia, USA, August 3-7, Hydraulics Division, ASCE, pp. 726-731
34. Brown, M & Harris, C. J. (1994) 'Neuro fuzzy adaptive modelling and control' Prentice Hall., Hemel Hempstead.
35. Calvoa I, Portelab M. (2007) 'Application of neural approaches to one-step daily flow forecasting in Portuguese watersheds' *J. Hydrol.* Vol. 332 No. 1-2, pp. 1-15.
36. Campolo, M., Andreussi, P., Soldati, A. (1999) 'River flood forecasting with a neural network model' *Water resources research*, Vol. 35 No. 4, pp. 1191-1197.
37. Chang, F. J., et Chen, Y. C. (2001) 'A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction' *Journal of hydrology*, Vol. 245 No. 1, pp 153-164.
38. Chaubey, I. Haan, C. T. Grunwald, S. Salisbury, J. M. (1999) 'Uncertainty in the model parameters due to spatial variability of rainfall' *Journal of Hydrology*. Vol. 120, No. 1-2, pp. 48-61.
39. Chen, S. Billings, S. A. Grant, P. M. (1990) 'Non-linear system identification using neural networks', *International Journal of Control*, Vol. 51 No 6, pp. 1191-1214
40. Chen, S.-H., Y.-H. Lin, et al. (2006) 'The strategy of building a flood forecast model by neuro-fuzzy network' *Hydrological Processes*, Vol. 20 No 7, pp. 1525-1540
41. Cheng, C.T., Wu, X. Y., Chau, K. W. (2005) 'Multiple criteria rainfall-runoff model calibration using a parallel genetic algorithm in a cluster of computers' *Hydrol. Sci. J.*, Vol. 50 No. 6, pp. 1069-1087
42. Chiew, F. and McMahon, T. (1994) 'Application of the daily rainfall-runoff model MODHYDROLOG to 28 Australian catchments', *Journal of Hydrology*, Vol. 153 No. 1-4, pp. 383-416.
43. Chiew, F. H. S., Peel, M. C., and Western, A. W. (2002) 'Application and testing of the simple rainfall-runoff model SIMHYD Mathematical models

- of small watershed hydrology and applications' Water Resources Publications, Littleton.
44. Chiew, F.H.S., Stewardson, M.J., McMahon, T.A. (1993) 'Comparison of six rainfall runoff modelling approaches' *Journal of Hydrology*, Vol. 147, No. 1-36.
 45. Chiu, S., (1994) 'Fuzzy model identification based on cluster estimation' *J. Intell. Fuzzy Syst.*, Vol. 2, pp. 267-278
 46. Cigizoglu HK. (2004) 'Estimation and forecasting of daily suspended sediment data by multi layer perceptrons' *Advances in Water Resources*. Vol. 27, pp. 185-195
 47. Cigizoglu, H. K. and M. Alp (2004) 'Rainfall-Runoff Modelling Using Three Neural Network Methods. Artificial Intelligence and Soft Computing' ICAISC 2004: 7th International Conference, Berlin, Heidelberg, Springer Berlin Heidelberg, pp. 166-171.
 48. Coquillard, P. & Hill. D. R. C. (1997) 'Modélisation et Simulation d'Ecosystèmes : des modèles déterministes aux simulations à événements discrets'. Collection « Recherche en Ecologie », 273 pages, Masson Ed., Paris
 49. Crawford, N. H., and Linsley, R. K. (1966) 'Digital simulation in hydrology: Stanford Watershed Model IV' Tech. Rep. No. 39, Stanford Univ., Palo Alto, Calif.
 50. Crawford, N.H. et Linsley, R.K. (1963) 'A conceptual model of the hydrologic cycle' IAHS Publication n° 63, pp. 573-587
 51. Criss, R. E., Winston, W. E. (2008) 'Do Nash values have value? Discussion and alternate proposals' *Hydrol. Processes* , Vol. 22 No. 14, pp. 2723 – 2725
 52. Dawdy, D. R., Litchy, R. W., and Bergmann, J. M. (1970) 'Rainfall runoff simulation model for estimation of flood peaks for small drainage basins' USGS Open File Rep., Washington, D.C.
 53. Dawdy, D. R., Schaake, J. C., and Alley, W. M. (1978) 'Users guide for distributed routing rainfall-runoff model' USGS Water Resources Invest. Rep. No. 78-90, Gulf Coast Hydrosience Center, NSTL, Miss

54. Dawdy, D.R. et O'Donnell, T. (1965). 'Mathematical models of catchment behavior' *American Society of Civil Engineers Proceedings*, Vol. 91 No. HY4, pp. 123-137
55. Dawson, C. W. and Wilby, R. (1998) 'An artificial neural network approach to rainfall-runoff modelling', *Hydrological Sciences Journal*, Vol. 43 No.1, pp. 47-66.
56. Dawson, C. W., & Wilby, R. L. (2001). Hydrological modelling using artificial neural networks. *Progress in physical Geography*, 25(1), 80-108.
57. Dechemi, N., Benkaci, T., Issolah, A. "Modélisation des débits mensuels par les modèles conceptuels et les systèmes neuro-flou." *Revue des sciences de l'eau*.
58. Djabri, L. Hani, A. Laouar, R. Mania, J. Mudry, J. Louhi, A. (2003) 'Potential pollution of groundwater in the valley of the Seybouse River, north-eastern Algeria' *Environmental Geology*, Vol. 44 No. 6, pp. 738-744
59. Doorenbos, J. et Pruitt, W.O., (1977) 'Crop water requirements' *Irrigation and Drainage Paper No. 24*. FAO, Rome, Italy.
60. Duan, Q., Gupta, V.K. et Sorooshian, S. (1993) 'Shuffled Complex Evolution approach for effective and efficient global minimization' *Journal of Optimization Theory and Applications*, Vol. 76 No. 3, pp. 163-168
61. Duan, Q., Sorooshian, S., Gupta, V.K. (1992) 'Effective and efficient global optimization for conceptual rainfall-runoff models' *Water Resources Research*, Vol. 28 No. 4, pp 1015-1031.
62. Edijatno et Michel, C., (1989) 'Un modèle pluie-débit journalier à trois paramètres' *La Houille Blanche* No. 2, pp. 113-121.
63. Edijatno, Nascimento, N.O., Yang, X., Makhlouf, Z. et Michel, C. (1999) 'GR3J: a daily watershed model with three free parameters' *Hydrological Sciences Journal*, Vol. 44 No. 2, pp. 263-277
64. El-Shafie, A., M. R. Taha, et al. (2006) 'A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam' *Water Resources Management*, Vol. 21 No. 3, pp. 533-556
65. Ewen, J., Parkin, G., and O'Connell, P. E. (2000) 'SHETRAN: Distributed river basin flow and transport modeling system' *J. Hydrologic Eng.*, Vol. 5 No. 3, pp. 250-258

66. Fenicia, F., Savenije, H. H. G., Matgen, P. & Pfister, L. (2007a) A comparison of alternative multi objective calibration strategies for hydrological modeling. *Water Resour. Res.* 43, W03434
67. Firat, M. and M. Güngör (2007) 'River flow estimation using adaptive neuro fuzzy inference system' *Mathematics and Computers in Simulation, Vol. 75* No. 3-4, pp. 87-96
68. Fletcher, R. et Powell, M.J.D. (1963) 'A rapidly convergent descent method for minimization' *The Computer Journal*, No 6, pp. 163-168.
69. Fontane DG, Gates TK, Moncada E (1997) 'Planning reservoir operations with imprecise objectives' *J Water Res Plng Mgmt*, Vol. 123 No. 3, pp. 154-162
70. Franchini, M. and Pacciani, M. (1991) 'Comparative Analysis of Several Conceptual Rainfall-Runoff Models' *Journal of Hydrology*, No. 122, 161-219.
71. Gan, T.Y. et Biftu, G.F. (1996) 'Automatic calibration of conceptual rainfall-runoff models: optimization algorithms, catchment conditions, and model structure' *Water Resources Research*, Vol. 32 No. 12, pp. 3513-3524.
72. Gautam, D. K., & Holz, K. P. (2001) 'Rainfall-runoff modelling using adaptive neuro-fuzzy systems' *Journal of Hydroinformatics*, Vol. 3 No.1, pp. 3-10.
73. Giustolisi, O. & Laucelli, D. (2005) 'improving generalization of artificial neural networks in rainfall-runoff modelling' *Hydrological Sciences Journal*, Vol. 50 No. 3, pp. 457.
74. Markstrom, S.L., Niswonger, R.G., Regan, R.S., Prudic, D.E., and Barlow, P.M., (2008) GSFLOW—Coupled Ground-Water and Surface-Water Flow Model Based on the Integration of the Precipitation-Runoff Modeling System (PRMS) and the Modular Ground-Water Flow Model (MODFLOW-2005)
75. Hagan, M. T. and Menhaj, M. (1994) 'Training feedforward networks with the Marquardt algorithm', *IEEE Transaction on Neural Networks*, Vol. 5 No. 6, pp. 989-993.
76. Halff, A. H. Halff, H. M. Azmoodeh, M. (1993) 'Predicting runoff from rainfall using neural networks' in ASCE: *Proceedings of the Symposium*

- sponsored by the Hydraulics Division of ASCE, Engineering Hydrology, San Francisco, CA, USA, 760–765.*
77. Hamon, W.R., (1961) 'Estimating potential evaporation', *Proceedings of the American Society of Civil Engineers*, pp. 107-120.
78. Hao Yu and B. M. Wilamowski, (2011) 'Levenberg–Marquardt Trainin' *Industrial Electronics Handbook, vol. 5 – Intelligent Systems, 2nd Edition*, chapter 12, pp. 12-1 to 12-15, CRC Press.
79. Hargreaves, G.H. et Samani, Z.A., (1982) 'Estimating potential evapotranspiration'. *Technical Note Journal of Irrigation and Drainage Engineering*, Vol. 108 No. 3, pp. 225-230.
80. Haykin, S. (2009) 'Neural Networks and Learning Machines', 3rd ed., Prentice Hall.
81. He, Z., X. Wen, et al. (2014) 'A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region." *Journal of Hydrology*, No. 509, pp. 379-386.
82. Hooke, R. et Jeeves, T.A. (1961) Direct search solutions of numerical and statistical problems. *J. Ass. Comput. Mach.*, Vol. 8 No. 2, pp. 212-229.
83. Hornik, K. Stinchcombe, M. White, H. (1989) 'Multilayer feedforward networks are universal approximators', *Neural Networks*, Vol. 2 No. 5, pp. 359-366.
84. Hsu, K. Gupta, H. V. and Sorooshian, S. (1995) 'Artificial Neural Network Modeling of the Rainfall-Runoff Process' *Water Resour.Res*, Vol. 31 No. 10, pp. 2517-2530.
85. Huber, W. C. (1995) 'Chapter 22: EPA storm water management model SWMM Computer models of watershed hydrology', Water Resources Publications, Littleton.
86. Huber, W. C., and Dickinson, R. E. (1988) 'Storm water management model user's manual, version 4' Rep. No. EPA/600/3-88/001a, U.S. Environmental Protection Agency, Athens.
87. Jain, A. and Srinivasulu, S. (2006) 'Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques', *Journal of hydrology*, Vol. 317 No. 3-4, pp. 291-306.

88. Jang, J. S. R. (1993) 'ANFIS: adaptive-network-based fuzzy inference system' *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23 No. 3, pp. 665-685.
89. Jean-Michel Renders, Hugues Bersinin (1994) 'Hybridizing genetic algorithms with hill-climbing methods for global optimization: two possible ways' Conference: Evolutionary Computation. IEEE World Congress on Computational Intelligence., Proceedings of the First IEEE Conference on Pages 312-317 Publisher IEEE
90. Jensen, M.E. et Haise, H.R., (1963) 'Estimating evapotranspiration from solar radiation' *Journal of Irrigation and Drainage Division, ASCE*, Vol. 89 No. LR4, pp. 15-41.
91. Kuczera, G. (1997) 'Efficient subspace probabilistic parameter optimization for catchment models' *Water Resour. Res.*, Vol. 33 No. 1, pp. 177-185
92. Kumar, R., Chatterjee, C., Singh, R. D., Lohani, A. K. and Kumar, S. (2007), 'Runoff estimation for an ungauged catchment using geomorphological instantaneous unit hydrograph (GIUH) models' *Hydrol. Process.*, Vol. 21, pp. 1829-1840
93. Leontaritis, I. J. and Billings, S. A. (1985) 'Input-output parametric models for non-linear systems Part I: deterministic non-linear systems', *International Journal of Control*, Vol. 41 No. 2, pp. 303-328.
94. Levenberg, K. (1944) 'A Method for the Solution of Certain Non-linear Problems in Least Squares', *Quarterly of Applied Mathematics*, Vol. 2 No. 2, pp. 164-168.
95. Lin, G.-F. and Chen, G.-R. (2008), 'A systematic approach to the input determination for neural network rainfall-runoff models' *Hydrol. Process.*, No. 22, pp. 2524-2530
96. Linacre, E.T., (1977) 'A simple formula for estimating evaporation rates in various climate, using temperature data alone' *Agricultural Meteorology*, No. 18, pp. 409-424
97. Lohani, A. K., N. K. Goel, et al. (2006) 'Takagi-Sugeno fuzzy inference system for modeling stage-discharge relationship' *Journal of Hydrology* Vol. 331 No. 1-2, pp. 146-160

98. Lohani, A. K., N. K. Goel, et al. (2007) 'Deriving stage–discharge–sediment concentration relationships using fuzzy logic', *Hydrological Sciences Journal* Vol. 52 No. 4, pp. 793-807.
99. Lohani, A. K., R. Kumar, et al. (2012) 'Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques' *Journal of Hydrology* Vol. 442–443, pp. 23-35.
100. Lorrai, M. and Sechi, G.M. (1995) 'Neural nets for modelling rainfall-runoff transformations', *Wat. Res. Manage*, Vol. 9 No. 4, pp. 299-313.
101. Luce, C.H., Cundy, T.W., (1994) Parameter identification for a runoff model for forest roads' *Water Resources Research* Vol. 30 No. 4, pp. 1057-1069
102. Madsen, H. & Khu, S.-T. (2002) 'Parameter estimation in hydrological modelling using multi-objective optimization' In: Proc.Fifth Int. Conf. on Hydroinformatics, Cardiff, UK, vol. 2, 1160–1165. IAHR, IWA, IAHS.
103. Madsen, H. (2000) 'Automatic calibration of a conceptual rainfall–runoff model using multiple objectives' *Journal of Hydrology*, Vol. 235 No. 3-5, pp. 276–288
104. Madsen, H. (2003) 'Parameter estimation in distributed hydrological catchment modelling using automatic calibration with multiple objectives' *Adv. Water Resour.*, Vol. 26 No. 2, pp. 205–216
105. Maier, H. R. and Dandy, G. C., (2000) 'Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications' *Environmental Modelling & Software*, Vol. 15 No. 1, pp. 101-124
106. Makkink, G. F. (1957) 'Testing the Penman formula by lysimeter' *J. Int. Water Eng.*, Vol. 11 No. 3, pp. 277-288
107. Mamdani, E.H., Assilian, S., (1975) 'An experiment in linguistic synthesis with a fuzzy logic controller' *International Journal of Man-Machine Studies*, Vol. 7 No. 1, pp. 1 – 13.
108. Riad S., Mania J. Bouchaou L., Najjar Y. (2004) 'Rainfall-Runoff Model Using an Artificial Neural Network Approach' *Mathematical and Computer Modelling*, Vol. 40 No. 7-8, pp. 839–846

109. Segond M. L., Neokleous N., Makropoulos C., Onof C. & Maksimovic C. (2007) 'Simulation and spatio-temporal disaggregation of multi-site rainfall data for urban drainage applications' *Hydrological Sciences*, Vol. 52 No. 2, pp. 917-935
110. Marquardt, D. W. (1963). 'An Algorithm for least-squares estimation of nonlinear parameters', *J. Soc. Indust. Appl. Math*, Vol. 11 No. 2, pp. 431-441
111. McCulloch, W. and Pitts, W. (1943) 'A logical calculus of the ideas immanent in nervous activity' *Bulletin of Mathematical Biophysics*, Vol. 5 No. 4, pp. 115-133
112. McGuinness, J.L. et Bordne, E.F., (1972) 'A comparison of lysimeter-derived potential evapotranspiration with computed values' Technical Bulletin 1452, Agricultural Research Service, U.S. Department of Agriculture, Washington D.C., 71 pp.
113. Metcalf and Eddy (1971) 'Storm water management model, Vol. 1—Final report' Inc., Univ. of Florida, and Water Resources Engineers, Inc. EPA Rep. No. 11024DOC07/71 (NITS PB-203289), EPA, Washington, D.C
114. Michel, C. (1983) 'How to use single-parameter conceptual model in hydrology?', *La Houille Blanche*, No. 1, pp. 39-44
115. Minns, A. W. and Hall, M. J. (1996) 'Artificial neural networks as rainfall-runoff models', *Hydrological Sciences Journal*, Vol. 41 No. 3, pp. 399-417.
116. Minsky M., Papert S. (1969) 'Perceptrons' MIT Press, Cambridge, MA
117. Monteith, J.L., (1965) 'Evaporation and the environment, The state and movement of water in living organisms' XIXth symposium. Cambridge University Press, Swansea, pp. 205-234.
118. Morin, G., Paquet, P., et Sochanski, W. (1995) 'Le modèle de simulation de quantité de qualité CEQUEAU, Manuel de références' INRS Eau Rapport de Recherche, No. 433, Sainte-Foy.
119. Morin, G., Sochanski, W., and Paquet, P. (1998) 'Le modèle de simulation de quantité CEQUEAU-ONU, Manuel de références' Organisation des Nations-Unies et INRS Eau Rapport de Recherche' No. 519, Sainte-Foy.

120. Moussa, R. & Chahinian, N. (2009) 'Comparison of different multi-objective calibration criteria using a conceptual rainfall-runoff model of flood events' *Hydrol. Earth System Sci.* No. 13, 519–535.
121. Zakhrouf M., Chettih M., Mesbah M. (2014) 'Adaptive neural fuzzy inference systems for the daily flow forecast in Algerian coastal basins' *Desalination and Water Treatment*, Vol. 52 No. 10-12, pp. 2131-2138
122. Mrad D., Dairi S. et Djebbar Y., (2014) 'Rainfall- Rainoff Modeling Using Artificial Neural Network' *APCBEE Procedia* No. 10, pp. 251–256
123. Muleta, M. (2012) 'Model Performance Sensitivity to Objective Function during Automated Calibrations' *J. Hydrol. Eng.*, Vol. 17 No. 6, pp. 756-767.
124. Narendra, K. S. and Parthasarathy, K. (1990) 'Identification and control of dynamical systems using neural networks', *Neural Networks, IEEE Transactions*, Vol.1 No. 1, pp. 4-27
125. Nash, J. E. and Sutcliffe, J. V. (1970) 'River flow forecasting through conceptual models part I - A discussion of principles', *Journal of Hydrology*, Vol. 10 No. 3, pp. 282-290.
126. Nayak, P. C., K. P. Sudheer, et al. (2005) 'Fuzzy computing based rainfall-runoff model for real time flood forecasting' *Hydrological Processes*, Vol. 19 No. 4, pp. 955-968
127. Nayak, P. C., Sudheer, K. P., & Jain, S. K. (2007) 'Rainfall-runoff modeling through hybrid intelligent system' *Water resources research*, Vol. 43 No.7, W07415
128. Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2004) 'A neuro-fuzzy computing technique for modeling hydrological time series' *Journal of Hydrology*, Vol. 291 No.1, pp. 52-66
129. Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2005) 'Short-term flood forecasting with a neurofuzzy model' *Water Resources Research*, Vol. 41 No. 4, pp. W04004
130. Nelder, J.A. et Mead, R. (1965) 'A Simplex method for function minimisation' *The Computer Journal*, Vol. 7 No. 4, pp. 308-313
131. Pagano, T. Hapuarachchi, H. Wang, Q. J. (2010) 'Continuous rainfall-runoff model comparison and short-term daily streamflow forecast skill

- evaluation' CSIRO Water for a Healthy Country National Research Flagship, EP103545.
132. Penman, H. L. (1956) 'Estimating evaporation', *Eos Trans. AGU*, Vol. 37 No. 1, pp. 43–50
133. Penman, H.L. (1948) 'Natural evaporation from open water, bare soil and grass' *Proc. Roy. Soc. London A* (194), S. 120-145.
134. Perrin, C. (1997) 'Comparative assessment of two rainfall-runoff modelling approaches: *GR4J and IHACRES*'. DEA thesis. Institute of Hydrology, France.
135. Perrin, C. Michel, C. Andréassian, V. (2003) 'Improvement of a parsimonious model for streamflow simulation'. *Journal of Hydrology*, Vol. 279 No. 1–4, pp. 275-289.
136. Pramanik, N. et R. K. Panda (2009) 'Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction' *Hydrological Sciences Journal*, Vol. 54 No. 2, pp. 247-260
137. Priestley, C.H.B. et Taylor, R.J., (1972) 'On the assessment of surface heat fluxes and evaporation using large-scale parameters' *Monthly Weather Review*, No. 100, pp. 81-92
138. Raghuwanshi, A. M. C. C. a. N. S. (2009) 'Flood Forecasting Using ANN, Neuro-Fuzzy, and Neuro-GA Models' *Journal of Hydrologic Engineering* Vol. 14 No. 6, pp. 647-652
139. Rajurkar, M.P. Kothyari, U.C, Chaube, U.C. (2002) 'Artificial neural networks for daily rainfall-runoff modelling'. *Hydrol. Sci. J.* Vol. 47 No. 6, pp. 865-877.
140. Rajurkara, M.P., Kothyarib, U.C., Chaubec, U.C. (2004) 'Modeling of the daily rainfall-runoff relationship with artificial neural network' *Journal of Hydrology*', Vol. 285 No. 1–4 , pp. 96–113
141. Ranganathan, A. (2004) 'The levenberg-marquardt algorithm' *Tutorial on LM algorithm*, 1-5.
142. Refsgaard, J. C., and Storm, B. (1995) 'Chapter 23: MIKE SHE Computer models of watershed hydrology', Water Resources Publications, Littleton.
143. Rockwood, D. M. (1982) 'Theory and practice of the SSARR model as related to analyzing and forecasting the response of hydrologic systems'

- Applied modeling in catchment hydrology, Water Resources Publications, Littleton, Colo., 87–106.
144. Roger Jang, J.-S. (1991) 'Fuzzy modeling using generalized neural networks and Kalman filter algorithm' in Proc. Ninth Nat. Conj Artificial Intell. (AAAI-91), pp. 762-767
145. Romanenko, V. A. (1961) 'Computation of the autumn soil moisture using a universal relationship for a large area' *Proc. Ukrainian Hydrometeorological Research Institute*, No. 3, Kiev.
146. Rosenbrock, H.H. (1960) 'An automatic method for finding the greatest or least value of a function' *The Computer Journal*, No. 3, pp. 175-184
147. Rumelhart D E, Hinton G E, Williams R J (1986) 'Learning internal representations by error propagation' *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* . MIT Press, Cambridge, MA, Vol. 1, pp. 318-62
148. Rumelhart, D. E., Smolensky, P., McClelland, J. L., & Hinton, G. (1986). 'Sequential thought processes' in PDP models. Vol. 2, 3-57.
149. Sanikhani, H. and O. Kisi (2012) 'River Flow Estimation and Forecasting by Using Two Different Adaptive Neuro-Fuzzy Approaches' *Water Resources Management*, Vol. 26 No. 6, pp. 1715-1729
150. Schalkoff, R.J., *Artificial Neural Networks*, McGraw-Hill, (1997), ISBN 007-057118-X.
151. See, L., & Openshaw, S. (2000) 'A hybrid multi-model approach to river level forecasting' *Hydrological Sciences Journal*, Vol. 45 No.4, pp. 523-536
152. Servat, E. and Dezetter, A. (1993) 'Rainfall-runoff modelling and water resources assessment in northwestern Ivory Coast. Tentative extension to ungauged catchments', *Journal of Hydrology*, Vol. 148 No. 1–4, pp. 231-248.
153. Servat, E. et Dezetter, A. (1991) 'Selection of calibration objective functions in the context of rainfall-runoff modelling in a sudanese savannah area' *Hydrological Sciences Journal*, Vol. 36 No. 4, pp. 307-331.
154. Shah S.M.S., Connell P.E., and Hosking J.R.M., (1996) 'Modelling the effects of spatial variability in rainfall on catchment response.2.

- Experiments with distributed and lumped models' *Journal of Hydrology*, Vol. 175, pp. 89-111.
155. Shah S.M.S., P.E. Connell, and J.R.M. Hosking, (1996) 'Modelling the effects of spatial variability in rainfall on catchment response. 1. Formulation and calibration of a stochastic rainfall field model' *Journal of Hydrology*, Vol. 175 No. 67-88
156. Shamseldin, A. Y. and O'Connor, K. M. (1999) 'A real-time combination method for the outputs of different rainfall-runoff models', *Hydrological Sciences Journal*, Vol. 44 No. 6, pp. 895-912.
157. Shamseldin, A. Y. O'Connor, K. M. Liang, G. C. (1997) 'Methods for combining the outputs of different rainfall-runoff models'. *Journal of Hydrology*, Vol. 197 No. 1-4, pp. 203-229.
158. Shamseldin, A.Y. Ahmed, E.N., O'Connor, K.M. (2002) 'Comparison of different forms of the multi-layer feed-forward neural network method used for river flow forecast combination' *Hydrology and Earth System Sciences*, Vol. 6 No. 4, pp. 671-684.
159. Shamseldin, A.Y. and O'Connor, K. M. (2001) 'A non-linear neural network technique for updating of river flow forecasts', *Hydrol. and Earth System Sciences*, Vol. 5 No. 4, pp. 577-597.
160. Shoaib, M., Shamseldin, A. Y., Melville, B. W., & Khan, M. M. (2014) 'Hybrid Wavelet Neuro-Fuzzy Approach for Rainfall-Runoff Modeling' *Journal of Computing in Civil Engineering*, Vol. 30 No. 1, 04014125.
161. Shrestha, B. P., Duckstein, L.E., and Stokhin, Z. (1996) 'Fuzzy rule-based modeling of reservoir operation' *Journal of Water Resources Planning and Management*, Vol. 122 No. 4, pp. 262-269
162. Singh, V. P. (1997) 'Effect of spatial and temporal variability in rainfall and watershed characteristics on stream flow hydrograph' *Hydrol. Process.*, No. 11, pp. 1649-1669
163. Sorooshian, S., Duan, Q. et Gupta, V.K. (1993) 'Calibration of rainfall-runoff models: application of global optimization to the Sacramento soil moisture accounting model' *Water Resources Research*, Vol. 29 No. 3, pp. 1185-1194

164. Speers, D. D. (1995) 'Chapter 11: SSARR model. Computer models of watershed hydrology', Water Resources Publications, Littleton, Colo
165. Srinivasulu, S. and A. Jain (2006) 'A comparative analysis of training methods for artificial neural network rainfall-runoff models' *Applied Soft Computing* Vol. 6 No. 3, pp. 295-306
166. Sugawara, M. (1995) 'Chapter 6: Tank model Computer models of watershed hydrology', Water Resources Publications, Littleton, Colo.
167. Takagi, T. & Sugeno, M. (1985) 'Fuzzy identification of systems and its applications to modeling and control', *Proceedings of the IEEE Transactions on Systems, Man and Cybernetics*, Vol. 15, pp. 116-132
168. Takagi, T., Sugeno, M., (1985) 'Fuzzy identification of systems and its application to modeling and control' *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 15 No. 1, pp. 116 - 132
169. Talei, A., L. H. C. Chua, et al. (2010) 'A novel application of a neuro-fuzzy computational technique in event-based rainfall-runoff modeling' *Expert Systems with Applications* Vol. 37 No. 12, pp. 7456-7468
170. Tanakamaru, H. (1995) 'Parameter estimation for the Tank Model using global optimisation'. *Trans. JSIDRE*, Vol. 178, pp. 103-112
171. Tanakamaru, H., Burges, S.J. (1996) 'Application of global optimization to parameter estimation of the TANK model' *Proc. Int. Conf. on Water Resour. and Environ. Res.*, Kyoto, Japan, 2, pp. 39-46
172. Thom, A.S. et Oliver, H.R., (1977) 'On Penman's equation for estimating regional evaporation' *Quart. J. Roy. Met. Soc.*, Vol. 103, pp. 345-357
173. Thornthwaite, C.W. et Mather, J.R., (1955) 'The water balance'. *Publ. Climatol. Lab. Climatol. Drexel. Inst. Techol.*, Vol. 8 No. 1, pp. 1-104
174. Thornthwaite, C.W., (1948) 'An approach towards a rational classification of climate' *Geographical Review*, No. 38, pp. 55-94.
175. Todini, E. (1988a) 'II modello afflussi deflussi del fiume Arno. Relazione Generale dello studio per conto della Regione Toscana' *Tech. Rep.*, Univ. of Bologna, Bologna, en Italien
176. Todini, E. (1988b) 'Rainfall runoff modelling: Past, present and future' *J. Hydrol.*, Vol. 100, pp. 341-352

177. Todini, E. (1995) 'New trends in modeling soil processes from hillslopes to GCM scales' *The role of water and hydrological cycle in global change*, NATO Advanced Study Institute, Series 1: Global, Kluwer Academic, Dordrecht, The Netherlands.
178. Todini, E. (1996) 'The ARNO rainfall-runoff model' *J. Hydrol.*, Vol. 175, pp. 339–382
179. Tokar, A. S. & Markus, M. (2000) 'Precipitation runoff modeling using artificial neural networks and conceptual models' *J. Hydrol. Engng ASCE*, Vol. 5 No. 2, pp. 156-161
180. Tokar, A. and Johnson, P. (1999) 'Rainfall-Runoff Modeling Using Artificial Neural Networks' *Journal of Hydrologic Engineering*, Vol. 4 No. 3, pp. 232-239.
181. Tsukamoto, Y., (1979) 'An approach to fuzzy reasoning method' *Advances in Fuzzy Set Theory and Application*, North-Holland, Amsterdam, pp. 137 – 149
182. Tsungnan, L. Bill G. H. Tiño, P. Giles, C. L. (1996) 'Learning long-term dependencies in NARX recurrent neural networks'. *Neural Networks, IEEE Transactions*, Vol. 7 No. 6, pp. 1329-1338.
183. Turc, L., (1955) 'Le bilan d'eau des sols. Relations entre les précipitations, l'évaporation et l'écoulement' *Ann. Agr.*, Vol. 6, pp. 5-131
184. U.S. Army Corps of Engineers. (1987) SSARR user's manual, North Pacific Division, Portland, Ore.
185. Vrugt, J. A., Gupta, H. V., Bastidas, L. A., Bouten, W. & Sorooshian, S. (2003a) 'Effective and efficient algorithm for multiobjective optimization of hydrologic models' *Water Resour. Res.* Vol. 39 No. 8, pp. 1214
186. Wang, Q.J. (1991) 'The genetic algorithm and its application to calibrating conceptual rainfall runoff models'. *Water Resources Research*, Vol. 27 No. 9, pp. 2467-2471
187. Wen, He. Z., X. et al. (2014) 'A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region' *Journal of Hydrology*, Vol. 509, pp. 379-386

188. Werbos, P. J. (1994) 'Supervised learning: can it escape its local minimum?' In *Theoretical Advances in Neural Computation and Learning*, Springer US. pp. 449-461.
189. Wilamowski, B. M., & Torvik, L. (1993) 'Modification of gradient computation in the back-propagation algorithm'. ANNIE'93-Artificial Neural Networks in Engineering.
190. Wilamowski, B. M., Chen, Y., & Malinowski, A. (1999) 'Efficient algorithm for training neural networks with one hidden layer' In *IJCNN. Proc. 1999 International Joint Conference*, Vol. 3, pp. 1725-1728
191. Wilamowski, B. M., Jaeger, R. C., Padgett, M. L., & Myers, L. J. (1996) 'CMOS implementation of a pulse-coupled neuron cell' In *Neural Networks, 1996., IEEE International Conference on*, Vol. 2, pp. 986-990. IEEE.
192. Wilby, R.L. Abrahart, R.J. Dawson, C.W. (2003) 'Detection of conceptual model rainfall-runoff processes inside an artificial neural network', *Hydrol. Sci. J.* Vol.48 No. 2, pp. 163-181.
193. Williams, J. R. (1995a) 'Chapter 25: the EPIC model. Computer models of watershed hydrology', Water Resources Publications, Littleton, Colo.
194. Williams, J. R. (1995b) 'Chapter 24: SWRRB—A watershed scale model for soil and water resources management' Computer models of watershed hydrology, Water Resources Publications, Littleton, Colo.
195. Williams, J. R., Nicks, A. D., and Arnold, J. G. (1985) 'Simulator for water resources in rural basins' *J. Hydraul. Eng.*, Vol. 111 No. 6, pp. 970–986.
196. Wright, J. L. (1982) 'New evapotranspiration crop coefficients' *J. Irrig. and Drain. Engrg. Div., ASCE*, Vol. 108 No. 2, pp. 57-74
197. Xiong, L. Shamseldin, A.Y. O'Connor, K.M. (2001) 'A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi-Sugeno fuzzy system', *Journal of Hydrology*, Vol. 245 No. 1–4, pp. 196–217
198. Xiong, L., Shamseldin, A. Y., & O'connor, K. M. (2001) 'A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi–Sugeno fuzzy system'. *Journal of hydrology*, Vol. 245 No. 1, pp. 196-217.

199. Xu, C. Y. (1999) 'Operational testing of a water balance model for predicting climate change impacts' *Agric. Forest Meteorol.*, Vol. 98– 99 No. 1–4, pp. 295–304
200. Xu, C.-Y. et Singh, V.P., (2001) 'Evaluation and generalization of temperature-based methods for calculating evaporation' *Hydrological Processes*, Vol. 15 No. 2, pp. 305-319.
201. Yang, G. Meng Joo, E. (2005) 'NARMAX time series model prediction: feedforward and recurrent fuzzy neural network approaches', *Fuzzy Sets and Systems*, Vol. 150 No. 2, pp. 331-350.
202. Yapo, P. O., Gupta, H. V., Sorooshian, S. (1998) 'Multi-objective global optimization for hydrologic models' *J. Hydrol.* Vol. 204 No 1-4, pp. 83–97
203. Yu, P. S., & Chen, S. T. (2005) 'Updating Real-Time Flood Forecasting Using a Fuzzy Rule-Based Model' *Hydrological sciences journal*, Vol. 50 No. 2, pp. 278
204. Yu, P. S., & Yang, T. C. (2000) 'Fuzzy multi-objective function for rainfall-runoff model calibration' *Journal of hydrology*, Vol. 238 No. 1, pp. 1-14
205. Zadeh, L. A, (1965) 'Fuzzy sets. Information and Control' No. 8, pp. 338-353
206. Zealand, C. M., Burn, D. H., & Simonovic, S. P. (1999) 'Short term streamflow forecasting using artificial neural networks' *Journal of hydrology*, Vol. 214 No. 1, pp. 32-48.
207. Zhao, R. J., and Liu, X. R. (1995) 'Chapter 7: the Xinjiang model. Computer models of watershed hydrology' Water Resources Publications, Littleton, Colo.
208. Zhao, R. J., Zhuang, Y.-L., Fang, L. R., Liu, X. R., and Zhang, Q. S. (1980) 'The Xinanjiang model' Proc., Oxford Symposium on Hydrological Forecasting, IAHS Publication No. 129, International Association of Hydrological Sciences, Wallingford, U.K., pp. 351–356.
209. Zounemat-kermani, M. Kizi, O.Rajae, T (2013) 'Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff', *Applied Soft Computing*, Vol. 13 No. 12, pp. 4633-4644.

210. Zounemat-kermani, M., O. Kisi, et al. (2013). 'Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff' *Applied Soft Computing*, Vol. 13 No. 12, pp. 4633-4644