

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique



Département : Hydraulique

Laboratoire : Matériaux de génie civil et environnement

Mémoire de projet de fin d'études pour l'obtention du diplôme d'ingénieur d'état en
Hydraulique

Couplage Wavelet-ANN pour la modélisation pluie-débit

Bouchra Zineb KHEBRI

Présentée et soutenue publiquement le 21/06/2017

Composition du Jury :

Président	Mr E.H BENYOUSSEF,	Grade :Professeur	Université : ENP
Promoteurs	Mr A.BERMAD,	Grade : Professeur	Université : ENP
	Mr A.AMIRECHE	Grade : MAA	Université : OEB
Examineur	Mr A.LEFKIR	Grade : MCA	Université :ENSTP

ENP 2017

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique



Département : Hydraulique

Laboratoire : Matériaux de génie civil et environnement

Mémoire de projet de fin d'études pour l'obtention du diplôme d'ingénieur d'état en
Hydraulique

Couplage Wavelet-ANN pour la modélisation pluie-débit

Bouchra Zineb KHEBRI

Présentée et soutenue publiquement le 21/06/2017

Composition du Jury :

Président	Mr E.H BENYOUSSEF,	Grade :Professeur	Université : ENP
Promoteurs	Mr A.BERMAD,	Grade : Professeur	Université : ENP
	Mr A.AMIRECHE	Grade : MAA	Université : OEB
Examineur	Mr A.LEFKIR	Grade : MCA	Université :ENSTP

ENP 2017

DEDICACES

*À la plus douce des mamans et le meilleur des papa, merci pour
avoir toujours été à mes côtés.*

*À Faten, Amine, khadidja, Amira, tata Saida à toute
ma famille et mes amis.*

À toute la classe d'Hydraulique,

À tous ceux qui m'aiment,

Bouchra Zineb KHEBRI

Remerciements

Mes remerciements vont d'abord à Dieu pour m'avoir permis d'effectuer ce travail dans de bonnes conditions.

Mes remerciements sont aussi adressés à tous ceux qui ont contribué à l'élaboration de mon mémoire de fin d'études. Particulièrement, je remercie mon promoteur, M. A.BERMAD, d'avoir accepté de m'encadrer dans ce travail, de m'avoir appris autant de choses, pour ses encouragements et ses conseils pour l'élaboration de ce travail et pour sa disponibilité tout au long de cette période.

Mes vifs remerciements vont également au Pr. LEFKIR, professeur agrégée à l'École Nationale Supérieure des Travaux Publics. Pour son soutien, sa patience et de m'avoir fait bénéficier de ses compétences scientifiques et pratiques.

J'exprime ma profonde reconnaissance à tous les membres du Jury pour l'honneur qu'ils m'ont accordé en acceptant de lire et examiner mon travail.

Je tiens également à remercier tous ceux qui ont contribué à ma formation et tous ceux qui m'ont inspiré depuis l'enfance.

Je remercie également mes parents pour leurs précieux conseils et contributions à ce travail.

ملخص

النماذج الهيدرولوجية هي واحدة من الأدوات المستخدمة لإعادة الإعمار أو المحاكاة، وتوقعات تحسبا للتطورات المستقبلية في تدفق النهر، مما يتيح إدارة أفضل للموارد المائية في فترات الجفاف والترقب مخاطر الفيضانات خلال الفيضانات والتحديد المسبق لغرض تحليل تواتر الظواهر: التدفقات المرتبطة الفترة مقابل انخفاض تدفق أو الفيضانات (تصميم الجسور واقتنية والجسور، الخ) أو ترسيم مناطق الفيضانات (خطة الوقاية من مخاطر الفيضانات، وما إلى ذلك).

استخدام اقتران الموجات الخلايا العصبية الاصطناعية لنمذجة الأمطار والسيول ثلاثة مستجمعات المياه (منطقة Belle-Isle-sur-Terre - غرب فرنسا، Zardezas، شمال شرق الجزائر، Isser المركز الجزائري) يسمح لتحسين نماذج متعددة الطبقات الأداء وغير الخطية الانحدار شبكة بيرسيبترون مع المدخلات الخارجية، عندما لا يؤخذ بعين الاعتبار تدفق المدخلات من طراز ليست فعالة واقتران لا يحسن الأداء بشكل ملحوظ، بينما يحسن الأداء في نماذج NARX في حالة Isser

NARX كلمات البحث: الهيدرولوجيا، الموجات، النمذجة،

Abstract

Hydrological models are one of the tools used for reconstruction or simulation, the forecast for the anticipation of future flows of a river, which allows better management of water resources during low water periods and anticipation the risk of flooding during periods of flood and the predetermination for the purpose of frequency analysis of extremes: flows associated with a return period for a low or a flood (dimensioning of structures, floodwaters, bridges, Etc.) or delimitation of flood zones (Flood Prevention Plan, etc.).

The use of the Wavelet-ANN (Artificial Neuronal Network) coupling for rainfall-runoff modeling of three watersheds (Belle-Isle-sur-Terre region of France, Zardezas, Northeast of Algeria and Les Isser, Algerian Center) and nonlinear autoregressive network with exogenous inputs, when the flow is not taken into account in the inputs, the model (MLP) is not efficient and the coupling does not significantly improve performance, whereas in the case of NARX models it is important in the case of the Isser catchment.

Key words: Hydrology, Models, Wavelet, ANN, MLP

Résumé

Les modèles hydrologiques sont un des outils utilisés pour la reconstitution ou la simulation, la prévision pour l'anticipation des évolutions futures du débit d'une rivière, ce qui permet une meilleure gestion des ressources en eau en période d'étiage et l'anticipation des risques d'inondations en période de crue et la prédétermination dans un but d'analyse fréquentielle des extrêmes : débits associés à une période de retour pour un étiage ou une crue (dimensionnement d'ouvrages d'art, déversoirs de crue, ponts, etc.) ou la délimitation de zones inondables (Plan de Prévention de Risques d'Inondation, etc.).

L'utilisation du couplage Wavelet – ANN (Artificial Neuronal Network) pour la modélisation pluie-débit de trois bassins versants (région Belle-Isle-sur-Terre Ouest de la France, Zardezas, Nord-Est algérien et les Isser, Centre algérien) permet d'améliorer les performances des modèles Perceptrons multicouches (MLP) et nonlinear autoregressive network with exogenous inputs, lorsque le débit n'est pas pris en compte dans les inputs du modèle (MLP) n'est pas performant et le couplage n'améliore pas significativement les performances, alors que dans le cas des modèles NARX elle est importante dans le cas du bassin versant des Isser.

Mots clés : Hydrologie, Wavelets, Modélisation, ANN, MLP, performance.

Table de matières

Liste des figures

Liste des tableaux

Liste des abréviations

Introduction générale 14

Chapitre 1 : Modélisation hydrologique et modélisation pluie-débit

1.1	Introduction :	17
1.2	L'hydrologie : Définition et objet.....	17
1.3	Qu'est-ce qu'un modèle ?	17
1.4	Typologie des modèles hydrologiques:	18
1.4.1	Modèles statistiques	20
1.4.1.1	Stochastique	20
1.4.2	Modèles physiques et déterministes.....	20
1.4.2.1	Modèles empiriques/ boîte noir.....	20
1.4.2.2	Modèles conceptuel.....	20
1.5	Mise en œuvre des modèles	21
1.5.1	Calage des modèles	21
1.5.1.1	Le calage manuel.....	21
1.5.1.2	Le calage automatique.....	21
1.5.2	Validation des modèles	21
1.5.3	Exploitation des modèles	21
1.6	Applications des modèles hydrologiques.....	21
1.7	Critères d'évaluation et performance des modèles :	22
1.7.1	Evaluation graphique	23
1.7.2	Evaluation statistique	23
1.7.2.3	Les régressions standard.....	23
1.7.2.4	Coefficient de détermination	23
1.7.3	Les critères adimensionnels	23
1.7.3.1	Coefficient de NASH-SUTCLIEFFE.....	24
1.7.4	Les indices d'erreurs	24
1.7.4.1	MAE, MSE, RMSE.....	24
1.7.4.2	Percent Bias (PBIAS).....	25

1.7.4.3	RMSE-observations standard deviation ratio (RSR)	25
1.8	Conclusion :	25
Chapitre 2: Les réseaux neurones artificiels (ANN)		
2.1	Introduction.....	27
2.2	Définition et Historique des réseaux de neurones	27
2.2.1	Définition :	27
2.2.2	Bref historique de l'utilisation des réseaux neurones	27
2.3	Neurones Biologiques	28
2.4	Neurones artificiels (formels).....	28
2.5	Types de réseaux neurones artificiels.....	29
2.5.1	Réseaux « non bouclés ».....	29
2.5.1.1	Modèles perceptrons monocouches	30
2.5.1.2	Modèles perceptrons multicouches	30
2.5.1.3	Modèles à fonction radiale « Radial Basic Functions ».....	31
2.5.2	Réseaux « récurrents »	31
2.5.3	Réseaux de Hopfield	31
2.5.4	Réseaux à apprentissage par compétition ou « Adaptative Resonance Theory » (ART) 32	
2.6	Fonctions d'activation :	32
2.7	APPRENTISSAGE DES RÉSEAUX DE NEURONES	32
2.7.1	Différentes approches d'apprentissage.....	34
2.7.2	Règles d'apprentissage	34
2.7.2.1	Règle de correction d'erreurs.....	34
2.7.2.2	Règle de Boltzmann	34
2.7.2.3	Règle de Hebb	34
2.7.2.4	Règle par compétitions.....	34
2.8	Application du Réseau de neurones artificiels (Artificial Neural Network (ANN)) en Hydrologie	34
2.8.1	Modélisation Pluie-débit.....	34
2.8.2	Modélisation de l'écoulement fluvial	36
2.8.3	Modélisation des eaux souterraines	37
2.9	Propriétés des réseaux de neurones	38
2.9.1	Non-linéarité	38

2.9.2	Tolérance au manque d'information.....	39
2.9.3	Résistance aux entrées aberrantes	39
2.9.4	Non-unicité des modèles neuronaux par rapport aux paramètres	39
2.9.5	Adaptabilité.....	39
2.9.6	Utilisation des données dans leur état brut.....	39
2.10	Limites et précautions dans la modélisation avec les reseaux neurones formels	39
2.10.1	Problème des minimas locaux	39
2.10.2	Problème de généralisation	40
2.10.3	Arrêt prématuré	40
2.10.3.1	Régularisation	40
2.10.4	Limites conceptuelles pour la modélisation pluie-débit	40
2.11	Conclusion	41
Chapitre 3: la transformée en wavelet		
3.1	Introduction :.....	43
3.2	Qu'est-ce qu'une Wavelet <<Ondelette>> ?	43
3.3	Transformée en wavelet :.....	44
3.3.1	Transformée en wavelet continue (CWT) :.....	44
3.3.1.1	Définitions :.....	44
3.3.1.2	Les étapes pour la création d'une CWT:.....	45
3.3.2	Transformée en wavelets discrètes (DWT):.....	46
3.4	Les familles des wavelets:	48
3.4.1	Haar & Daubechies wavelets	48
3.4.2	Symlets.....	49
3.4.3	Coiflets.....	49
3.4.4	Meyer wavelet.....	50
3.4.5	Biorthogonal wavelets with compact support.....	50
3.5	Compression et débruitage d'un signal :.....	51
3.5.1	Principe de débruitage par wavelets.....	51
3.5.1.1	Débruitage : avant et après	52
3.5.1.2	L'algorithme de débruitage	52
3.5.2	Méthodes de débruitage :	52
3.5.2.1	Exact minimax.....	53
3.5.2.2	Universal thresholding	53

3.5.2.3	SURE.....	54
3.6	Application de la transformée en wavelet en hydrologie	54
3.7	Conclusion	58
Chapitre 4: Etude de cas		
4.1	Introduction.....	60
4.2	Données :	60
4.2.1	Le Léguer, Belle-Isle-en-Terre, France.....	60
4.2.2	Région de Zardezas, Skikda, Algérie.....	62
4.2.3	Région des Isser, Algérie	63
4.3	Méthodes	64
4.3.1	Les modèles proposés	64
4.3.1.1	Modèles basé sur les réseaux neurones artificiels	64
4.3.1.2	Modèle basé sur le couplage Wavelet-ANN (Réseaux neurones artificiels)	68
4.4	Outil informatique de mise en œuvre des modèles :	71
4.5	Critères de validation choisis.....	71
Chapitre 5: Analyse des résultats		
5.1	Le taux de performance d'un modèle :	73
5.2	Région de Belle-Isle-en-Terre, France :	73
5.3	Région de Zardezas, Algérie :	87
5.4	Région des Isser, Algérie :	93
Conclusion générale		99
Références bibliographie...		102
Annexe.....		107

Liste des figures

- Figure 1.1 : Fonctionnement d'un modèle hydrologique
- Figure 1.2: classification des modèles mathématiques (Nourani 2007)
- Figure 2.1: Neurone biologique Vs neurone formel
- Figure 2.2: Types de réseaux neurones artificiels
- Figure 2.3: Réseau neuronal perceptron monocouche
- Figure 2.4: réseau perceptron multicouche
- Figure 2.5: Apprentissage supervisé
- Figure 2.6: Apprentissage non supervisé
- Figure 2.7 : Poids W_{ij}
- Figure 3.1 : wavelet transform
- Figure 3.2 : génération des coefficients de wavelet
- Figure 3.3: l'arbre de décomposition des wavelets
- Figure 3.4: Schéma d'un exemple d'algorithme pyramidal à 9 niveaux
- Figure 3.5: Haar wavelet
- Figure 3.6 : La famille de Daubechies
- Figure 3.7 : La famille de symlets
- Figure 3.8 : la famille de Coiflets
- Figure 3.9 : Meyer wavelet
- Figure 3.10 : Biorthogonal wavelet family
- Figure 3.11: exemple d'un avant (a) et après débruitage (b)
- Figure 4.1: Positionnement de la région Belle-Isle-en-Terre en France
- Figure 4.2: Bassin versant le Léguer
- Figure 4.3 : Données de la pluie de la région de Belle-Isle-en-Terre
- Figure 4.4 : Données de Débit (en mm/j) de la région de Belle-Isle-en-Terre
- Figure 4.5: Positionnement de Zardezas et du bassin versant
- Figure 4.6: Pluie journalière du BV de Zardezas
- Figure 4.7: Débit en mm/j du BV de Zardesas
- Figure 4.8 : Carte des situations des stations hydro-climatologique du bassin versant de l'Isser
- Figure 4.9: Pluie du bassin versant Isser
- Figure 4.10 : Débit du bassin versant Isser
- Figure 4.12: Diagramme du modèle ANN (MLP)
- Figure 4.13 exemple d'un réseau avec une boucle fermé avec $n=5$
- Figure 4.14 : Détermination de $y(t+1)$, avec le NARX*
- Figure 4.15: Diagramme du modèle ANN (NARX)
- Figure 4.16: Diagramme du modèle Wavelet-ANN (MLP)
- Figure 5.1 Pluie journalière du BV du Léguer:

Figure 5.2: Débit observé et Débit simulé pour la partie validation selon le modèle MLP (non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer

Figure 5.3: Débit observé et Débit simulé pour la partie validation selon le modèle MLP (non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer

Figure 5.4: Débit observé et Débit simulé pour le test selon le modèle MLP non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer

Figure 5.5 : Avant et après le débruitage de la série de données de la pluie pour le BV du Léguer

Figure 5.6 : Avant et après le débruitage de la série de données du débit pour le BV du Léguer

Figure 5.7 Débit observé et Débit simulé pour le training (apprentissage) selon le modèle Wavelet-ANN pour la structure 10-14-1 pour le BV du Léguer

Figure 5.8 : Débit observé et Débit simulé pour la validation selon le modèle wavelet-ANN (MLP) pour la structure 10-14-1 pour le BV du Léguer

Figure 5.9 : Débit observé et Débit simulé pour le test selon le modèle wavelet-ANN (MLP) pour la structure 10-14-1 pour le BV du Léguer

Figure 10: Variation des graphes $Q_{\text{predicted}}=f(Q_{\text{observed}})$, dans le training, validation et test pour le BV du Léguer

Figure 5.11 Le débit simulé et le débit observé en fonction du temps (jours) de la partie training pour le BV du Léguer

Figure 5.12 Le débit simulé et le débit observé en fonction du temps (jours) de la partie validation pour le BV du Léguer

Figure 5.13 : Le débit simulé et le débit observé en fonction du temps (jours) de la partie testing pour le BV du Léguer

Figure 5.14: Pluie journalière du BV Léguer débruité en utilisant sym3

Figure 15 Débit en mm/j du BV Léguer débruité en utilisant sym3

Figure 5.16 : Le débit simulé et le débit observé en fonction du temps (jours) de la partie testing pour le BV du Léguer

Figure 5.17 : : Le débit simulé et le débit observé en fonction du temps (jours) de la partie training pour le BV du Léguer

Figure 5.18 : : Le débit simulé et le débit observé en fonction du temps (jours) de la partie validation pour le BV du Léguer

Figure 5.19 Pluie journalière du BV de Zardezas

Figure 5.20 Débruitage en utilisant coif1 pour la série de la pluie

Figure 5.21 Débruitage en utilisant coif1 pour la série du débit

Figure 22 Pluie du bassin versant Isser

Figure 5.23 : $Q_{\text{sim}}=f(Q_{\text{obs}})$ pour la phase testing (toute les données)

Figure 5.24 : $Q_{\text{sim}}=f(Q_{\text{obs}})$ pour la phase validation

Figure 5.25 : $Q_{\text{sim}}=f(Q_{\text{obs}})$ pour la phase training

Liste des tableaux

Tableau 1.1: Critère de classification des modèles hydrologiques

Tableau 1.2 Qualité des modèles en fonction des valeurs du critère de Nash

Tableau 2.1: fonctions d'activation des réseaux neurones

Tableau 5.1: Intervalles d'appréciation des critères de validation (Yetoui, 2012)

Tableau 5.2 : Performance du modèle ANN selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Tableau 5.3 : Performance du modèle Wavelet-ANN selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Tableau 5.4 Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Tableau 5.5 Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Tableau 5.6 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV de Zardezas

Tableau 5.7 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV de Zardezas

Tableau 5.8 : Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV de Zardezas

Tableau 5.9 Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV de Zardezas

Tableau 5.10 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV des Isser

Tableau 5.11 : Performance du modèle Wavelet-MLP selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV Isser

Tableau 5.12 : Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV Isser

Tableau 5.13: Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV Isser

Liste des abréviations

ANN : Réseaux neurones artificiels

CANN : conventionnel réseaux neurones artificiels

ARIMA: Autoregressive Integrated Moving Average

CRA : Analyse de régression conventionnelle

CWT : Transformée en wavelet continue

DWT : transformée en wavelet discrète

FFBP : Feedforward Backpropagation

MAE : Erreur moyenne absolue

MLP : Perceptrons multicouches

NARX: The nonlinear autoregressive network with exogenous inputs

MSE : Erreur quadratique moyenne

NSE : Coefficient de NASH-SUTCLIEFFE

PARMA: Periodic Autoregressive Moving Average

PTF : fonctions de transfert périodique

RBF : Radial Basic Functions

RMSE : Racine de l'erreur quadratique moyenne

TANN : Réseaux neurones artificiels à base de seuils

TPB-NN : rétro-propagation temporelle réseaux neurones artificiels

WT : Transformée en wavelet

Introduction générale

Introduction générale

L'eau est la source de la vie sur terre. Avec le réchauffement climatique, cette ressource tend à se raréfier dans beaucoup de régions du monde et provoque d'importants exodes de populations.

De même, le réchauffement climatique induit des catastrophes climatiques qui touchent de plus en plus de régions dans le monde (inondations, cyclones) induisant des dégâts humains et matériels considérables.

La compréhension des phénomènes liés à l'eau est devenue une préoccupation majeure de nos jours et beaucoup de recherches lui sont consacrées à travers l'hydrologie.

L'hydrologie est définie comme une science de la terre qui s'intéresse au cycle de l'eau. On peut dire aussi qu'elle est concernée par l'eau présente sur la terre, son apparition, sa distribution et sa circulation, ses propriétés physiques et chimiques, ses effets sur l'environnement et la vie de toutes ses formes.

L'hydrologie repose sur les études de précipitations et de ruissellement, c'est-à-dire aux problèmes liés à la conception et à la gestion des projets de ressources en eau tels que l'approvisionnement en eau, le contrôle des inondations ou l'utilisation récréative de l'eau.

Le cycle de l'eau est un processus très complexe. Les modèles hydrologiques sont un des outils dont disposent les hydrologues pour essayer de comprendre, simuler et prévoir le fonctionnement d'un bassin versant. Ils sont notamment utilisés pour :

- La reconstitution ou la simulation : pour combler les lacunes contenues dans une série chronologique de débit ou l'extension de séries de débit ;
- La prévision : le but du modèle est essentiellement l'anticipation des évolutions futures du débit d'une rivière, ce qui permet une meilleure gestion des ressources en eau en période d'étiage et l'anticipation des risques d'inondations en période de crue ;
- La prédétermination : le modèle est utilisé pour la simulation de séries chronologiques de débits, dans un but d'analyse fréquentielle des extrêmes : débits associés à une période de retour pour un étiage ou une crue (dimensionnement d'ouvrages d'art, déversoirs de crue, ponts, etc.) ou la délimitation de zones inondables (Plan de Prévention de Risques d'Inondation, etc.).

Les modèles hydrologiques sont utilisés pour répondre à deux problématiques principales : l'évaluation des risques hydrologiques et la gestion de la ressource en eau.

Dans ce mémoire de fin d'études, nous nous intéresserons aux modèles hydrologiques pluie-débit et plus particulièrement l'utilisation du couplage Wavelet – ANN (Artificial Neuronal Network) pour la modélisation pluie-débit de trois bassins versants (région Belle-Isle-sur-Terre Ouest de la France, Zardezas, Nord-Est algérien et les Issers, Centre algérien).

Dans ce mémoire, nous examinerons :

- Dans le Chapitre 1, nous présenterons les différents modèles, leurs typologies et les critères de mesures de la performance des modèles ;
- Le Chapitre 2 s'intéressera à la présentation d'un outil important, en l'occurrence donner une définition des neurones biologiques et artificiels, puis développer les différents types des réseaux neurones ainsi que leurs applications dans le domaine d'hydrologie ;
- Le chapitre 3 sert à définir la transformée en wavelets en mettant l'accent sur leur application aux problèmes hydrologiques. Il présente une brève description de la transformée en wavelet (WT), ses aspects mathématiques, et le rôle de la transformée enwavelet par rapport à d'autres approches en hydrologie. Les lignes directrices pour l'application de WT aux problèmes hydrologiques sont présentées ;
- Le Chapitre 4 présentera les régions qui seront étudiées dans ce mémoire, les données qui seront utilisées et les étapes à suivre pour appliquer les modèles choisis. Un programme informatique, composé de plusieurs sous-programme sera développé sur Matlab pour effectuer les prédictions et simulations nécessaires ;
- Dans le Chapitre 5 nous analyserons les résultats obtenus et des recommandations seront tirées.

Chapitre 1
Modélisation hydrologique
&
Modélisation pluie-débit

Chapitre 1

Modélisation hydrologique et modélisation pluie-débit

1.1 Introduction :

L'objet de ce chapitre est de définir l'hydrologie, les différents types de modèles ainsi que leurs classifications et leurs applications dans le modèle d'hydrologie. On va aborder aussi les critères d'évaluation et de performance de ces modèles.

1.2 L'hydrologie : Définition et objet

Le terme « hydrologie » peut être considéré comme un sujet important pour la vie humaine et leur environnement. Il traite l'eau de la terre, son apparition, sa circulation et sa distribution, ses propriétés chimiques et physiques et leur réaction avec l'environnement, y compris leur relation avec les êtres vivants (Ray 1975). Il traite également la relation entre l'eau et l'environnement à chaque phase du cycle hydrologique.

La définition de l'hydrologie varie d'un hydrologue à un autre. Généralement elle est définie comme une science de la terre qui s'intéresse au cycle de l'eau, c'est une science très vaste. On peut dire aussi qu'elle est concernée par l'eau présente sur la terre, son apparition, sa distribution et sa circulation, ses propriétés physiques et chimiques, ses effets sur l'environnement et la vie de toutes formes.

Cependant, l'hydrologie repose sur les études de précipitations et de ruissellement, c'est-à-dire aux problèmes liés à la conception et à la gestion des projets de ressources en eau, tels que l'approvisionnement en eau, le contrôle des inondations ou l'utilisation récréative de l'eau. En fait, les hydrologues devraient fournir les données de base sur lesquelles la conception et la gestion seront basées. Les méthodes d'optimisation et de gestion les plus sophistiquées sont toujours aussi bonnes que les données de base fournies par les hydrologues et une grande partie des données est très difficile à obtenir et à interpréter. [Raudkivi,1979]

1.3 Qu'est-ce qu'un modèle ?

Le cycle de l'eau est un processus complexe. Pour étudier ce processus, le modélisateur utilise des modèles. On peut définir un modèle comme un outil qui aide à donner une représentation simplifiée qui réduit la complexité naturelle de tout ou d'une partie de ce cycle. Le modélisateur procède à des choix de représentation du système en ne gardant que les aspects qui lui paraissent les plus concordants, pour tendre vers une solution la plus exacte.

Le développement du modèle s'appuie généralement sur trois éléments [Perrin,2000] :

- 1) Le système observé et sa discrétisation spatiale et temporelle, qui en définissent l'objet et ses limites. La connaissance du système est conditionnée par la mesure de ses caractéristiques et l'acquisition de données, les stocks et les transformations de phase.
- 2) L'objectif de modélisation, pour lequel le modèle est développé. Nous nous intéresserons plus dans ce projet de fin d'études à la représentation de la transformation de la pluie en débit.
- 3) Le choix d'une formulation de la réalité. Après la définition des deux points précédents, l'essentiel dans la modélisation est de trouver la formulation de la réalité la plus satisfaisante relativement aux objectifs fixés. Le modèle est la plupart du temps le résultat d'un compromis entre généralité, réalisme et précision (Kauark-Leite et Nascimento, 1993). La formulation d'un modèle est conditionnée par la connaissance antérieure des processus ou des systèmes considérés, par les idées et l'imagination du modélisateur et par les hypothèses qui sont formulées.

1.4 Typologie des modèles hydrologiques:

Un modèle hydrologique pluie-débit est généralement défini par [Mathevet,2005] :

- **Ses variables d'entrée (variables indépendantes)** : il s'agit des entrées du modèle, qui dans notre mémoire sont représentées par la pluie,
- **Ses variables de sortie (variables dépendantes)** : il s'agit des sorties du modèle, qui sont généralement les débits simulés.
- **Ses variables d'état** : il s'agit des variables internes au système, qui évoluent en fonction du temps et rendent compte de l'état du système à un moment donné. Typiquement, ces variables sont les niveaux de remplissage des différents réservoirs (neige / production),
- **Ses paramètres** : les paramètres des modèles hydrologiques, qu'ils aient une pseudo-signification physique ou qu'ils soient calés, servent à adapter la paramétrisation des lois régissant le fonctionnement du modèle, au bassin versant étudié,
- **Ses performances** : il s'agit d'estimer l'amplitude des erreurs de modélisation, calculées généralement sur la base d'une mesure de l'écart entre les valeurs simulées et les valeurs mesurées.

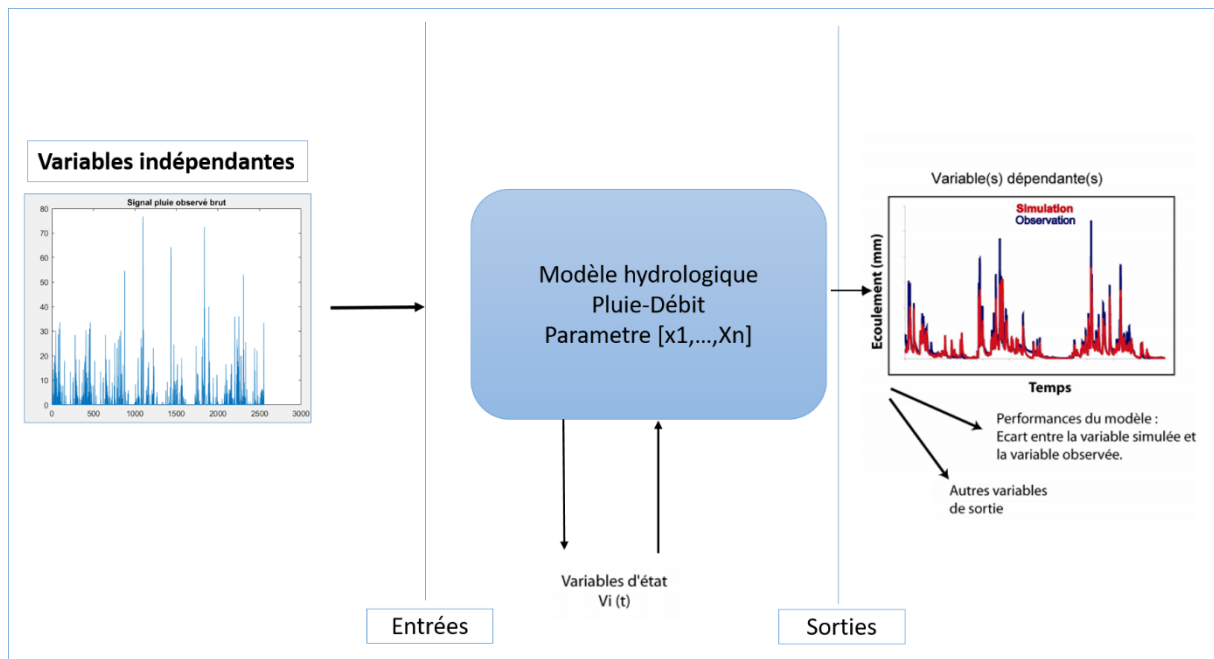


Figure 1.1 : Fonctionnement d'un modèle hydrologique

La typologie des modèles hydrologiques vise à classer les différents types de modèles disponibles selon quelques critères comme le montre le Tableau 1.1 suivant :

Tableau 1.1: Critère de classification des modèles hydrologiques

<u>Critère de classification</u>	<u>Type de modèle</u>
Fenêtre temporelle de simulation	Événementiel
	Continu
Pas de temps	Horaire
	<u>Journalier</u>
	Mensuel
	Annuel
	Pluriannuel
Fondement théorique	<u>Mathématique (Modèle boîte noire)</u>
	Conceptuel (Modèle à réservoirs ou boîte grise)
	Empirique (Modèle à réservoirs ou boîte grise)
	Théorique (Modèle fondé sur la physique)
Paramètres	Estimés par calage
	Mesurés sur le terrain

Ci-dessous une classification proposé par Nourani en 2007 dans un article :

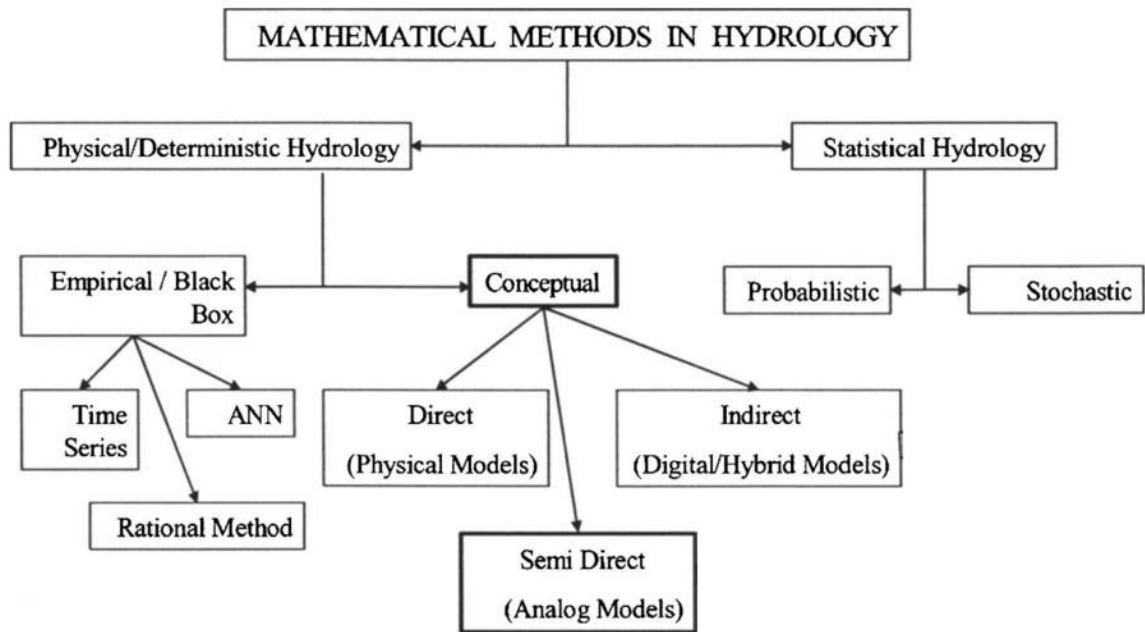


Figure 1.2: classification des modèles mathématiques (Nourani 2007)

1.4.1 Modèles statistiques

1.4.1.1 Stochastique

Il prend en compte les phénomènes à caractère aléatoires prédominant (pluie) ainsi que les incertitudes inhérentes à l'estimation des paramètres.

1.4.2 Modèles physiques et déterministes

Le modèle déterministe permet de simuler les phénomènes physiques identifiables.

1.4.2.1 Modèles empiriques/ boîte noir

Un modèle empirique utilise des relations mathématiques directes établies entre les entrées et les sorties observées sur le bassin versant choisi. Ce type de modèle ne cherche pas à connaître les processus impliqués dans la relation pluie-débit et est donc souvent caractérisé comme des modèles "boîtes noires".

1.4.2.2 Modèles conceptuel

Généralement constitué de réservoirs connectés entre eux, un modèle conceptuel essaye de représenter les principaux processus de la relation pluie-débit sans utiliser les lois physiques régissant les processus concernés.

1.5 Mise en œuvre des modèles

1.5.1 Calage des modèles

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

Calibrage : Processus de calage, consiste à déterminer les paramètres d'un modèle à partir d'un jeu de données observées [Sétra,2010].

1.5.1.1 Le calage manuel

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

1.5.1.2 Le calage automatique

En utilisant un programme informatique, les données simulées sont ajustées aux données observées. Malgré les avantages que cette méthode propose mais elle est influencée par certaines critères qui ont été proposés par (Benkaci., 2006), citées ci-dessous :

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

1.5.2 Validation des modèles

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

1.5.3 Exploitation des modèles

Après que le modèle soit calé et validé, ce modèle peut être utilisé pour différents usages.

1.6 Applications des modèles hydrologiques

Les modèles hydrologiques sont un des outils dont disposent les hydrologues pour essayer de comprendre, de simuler et de prévoir le fonctionnement d'un bassin versant. En fonction du pas de temps choisi. En se limitant aux applications quantitatives des modèles hydrologiques, leurs domaines d'applications sont vastes et concernent aussi bien la recherche que l'ingénierie. Ils sont notamment utilisés pour :

- **La reconstitution ou la simulation** : le but du modèle est le comblement des lacunes contenues dans une série chronologique de débit ou l'extension de séries de débit ;
- **La prévision** : le but du modèle est essentiellement l'anticipation des évolutions futures du débit d'une rivière, ce qui permet une meilleure gestion des ressources en eau en période d'étiage et l'anticipation des risques d'inondations en période de crue ;
- **La prédétermination** : le modèle est utilisé pour la simulation de séries chronologiques de débits, dans un but d'analyse fréquentielle des extrêmes : débits associés à une période de retour pour un étiage ou une crue [Lamb, 1999; Perrin et al., 2001] (dimensionnement d'ouvrages d'art, déversoirs de crue, ponts, etc.) ou la délimitation de zones inondables (Plan de Prévention de Risques d'Inondation, etc.). Pour étudier les événements particulièrement rares, les modèles pluie-débit peuvent être couplés à des générateurs (stochastiques) de pluie, capables de générer de longues chroniques de pluie.

Les modèles hydrologiques sont utilisés pour répondre à deux problématiques principales : l'évaluation des risques hydrologiques et la gestion de la ressource en eau. Ainsi, lors de l'utilisation d'un modèle hydrologique dans un cas concret, il est impératif de connaître le domaine d'application et les hypothèses conditionnant l'utilisation d'un modèle en particulier.

De nombreux auteurs ont étudié ces problèmes en utilisant des modèles pluie-débit. A titre d'exemple, nous citons :

- La prédétermination des crues, les travaux de Cameron *et al.* (1999) et Uhlenbrook *et al.* (1999)
- Le dimensionnement et la gestion de réservoirs ceux de Xu et Vandewiele (1995) et Yang *et al.* (1995)
- La prévision des débits ceux de Da Ros et Borga (1997) et Yang et Michel (2000)
- Détecter a posteriori les effets de tels changements, Lavabre *et al.*, 1993; Nascimento, 1995; Lørup *et al.*, 1998

1.7 Critères d'évaluation et performance des modèles :

Le modèle auquel on s'intéresse dans ce mémoire de fin d'études fait partie des modèles hydrologiques pluie-débit. Face à la diversité des bassins versants et des applications possibles des modèles hydrologiques, de nombreux auteurs comme Nash et Sutcliffe, 1970; Bergström et Forsman, 1973; Linsley, 1982 ont fait la liste des qualités attendues des modèles hydrologiques, ce sont principalement les suivantes [Mathevet, 2005]:

- Le modèle doit être basé sur des fondements scientifiques sains ;
- Les données nécessaires au bon fonctionnement du modèle doivent être en accord avec la disponibilité de celles-ci ;
- La complexité du modèle doit être aussi limitée que possible pour atteindre un objectif de performance donné ;
- Le modèle doit être correctement validé, général, transposable et robuste ;
- Le modèle doit être compréhensible par les utilisateurs.

De nombreux critères sont utilisés en hydrologie pour évaluer la sensibilité des modèles, ci-dessous quelques critères détaillés :

1.7.1 Evaluation graphique

Pour savoir si le modèle reproduit bien les événements, on utilise l'évaluation graphique qui permet d'avoir un aperçu sur les tendances des variables simulées et de trouver les anomalies non décelables par les critères numériques.

1.7.2 Evaluation statistique

Afin de juger l'efficacité des modèles, on fait une évaluation statistique. Les critères globaux d'appréciation des performances des modèles de simulation des débits diffèrent sur trois points essentiels : la forme analytique de l'erreur (quadratique, absolue, cumulée...), la forme de la variable cible (transformée ou non) et le choix d'un modèle de référence (pour avoir une mesure relative).

1.7.2.3 Les régressions standard

Évaluent la force de la relation linéaire existant entre les observations et les prédictions.

1.7.2.4 Coefficient de détermination

Le coefficient de détermination r^2 est défini comme étant le carré du coefficient de corrélation, d'après Bravais-Pearson :

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_{0i} - Q_{0.moy})(Q_{s.i} - Q_{s.moy})}{\sqrt{\sum_{i=1}^n (Q_{0.i} - Q_{0.moy})^2} \sqrt{\sum_{i=1}^n (Q_{s.i} - Q_{s.moy})^2}} \right]^2$$

Le r^2 estime la dispersion (distribution) entre les valeurs simulées et observées, en déterminant la proportion avec laquelle la dispersion estimée explique la dispersion observée. Il varie de 0 (pas de corrélation) à 1 (la distribution de la prédiction est égale à celle de l'observation). L'inconvénient majeur du r^2 est qu'il ne quantifie que la dispersion des variables, et de là, si le modèle sous-estime ou surestime toujours la prédiction, on aura toujours un r^2 proche de 1 même si les valeurs simulées sont fausses.

1.7.3 Les critères adimensionnels

Fournissent un modèle d'évaluation où les indices d'erreur quantifient l'écart dans les unités de données traitées.

1.7.3.1 Coefficient de NASH-SUTCLIEFFE

C'est un critère qui évalue le pouvoir prédictif des modèles hydrologiques. Il est défini comme suit :

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_0 - Q_s)^2}{\sum_{i=1}^n (Q_0 - Q_{0.moy})^2}$$

Le NASH varie entre "-∞" et "1.0". Un NASH de 1.0 représente une simulation parfaite. L'inconvénient du coefficient « NASH » est que les faibles erreurs sont négligées. Ce qui conduit à la surestimation de la performance du modèle lors des pics et sa sous-estimation lors des étiages. Le NASH accorde plus de poids aux débits moyens. Tout comme le R², le NASH n'indique pas les sous/surestimations des modèles.

En fonction de la valeur du critère de Nash-Sutcliffe, on peut définir des performances des modèles pluie-débit au pas de temps journalier [Rakem,1999] :

Tableau 1.2 Qualité des modèles en fonction des valeurs du critère de Nash

Nash (%)	Qualité
Nash < 70	Très insuffisant
70 ≤ Nash ≤ 80	Insuffisant
80 ≤ Nash ≤ 85	Médiocre
85 ≤ Nash ≤ 90	Correct
90 ≤ Nash ≤ 95	Bon
Nash > 95	Très bon

1.7.4 Les indices d'erreurs

1.7.4.1 MAE, MSE, RMSE

L'erreur moyenne absolue (MAE), l'erreur quadratique moyenne (MSE) et racine de l'erreur quadratique moyenne (RMSE) sont les indices d'erreurs les plus utilisés. Ils sont intéressants car ils indiquent l'erreur dans les unités des variables étudiées. Ils sont définies ci-dessous :

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{0.i} - Q_{s.i}|$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Q_{0.i} - Q_{s.i})^2$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{0.i} - Q_{s.i})^2}$$

Une valeur de « 0 » de ces indices indique que le modèle simule bien la variable étudiée. Une version standardisée du RMSE (RSR) est recommandée et est présentée par la suite.

1.7.4.2 Percent Bias (PBIAS)

Mesure la tendance moyenne des valeurs simulées par rapport aux valeurs observées (GUPTA et al., 1999), donc estime la sous/surestimation de la simulation. La méthode de calcul de cet indice est la suivante :

$$PBIAS = \frac{\sum_{i=1}^n (Q_{0,i} - Q_{s,i})}{\sum_{i=1}^n Q_{0,i}}$$

Sa valeur optimale est de «0». Des valeurs positives de ce critère indiquent qu'il y a sous-estimation du biais et des valeurs négatives indiquent qu'il y a surestimation du biais.

1.7.4.3 RMSE-observations standard deviation ratio (RSR)

Ce modèle est plus performant quand la valeur du RMSE est petite. Un modèle d'évaluation statistique a été développé par SINGH et al. (2004).

$$RSR = \frac{RMSE}{STDEV_{obs}} = \frac{\sqrt{\sum_{i=1}^n (Q_{0,i} - Q_{s,i})^2}}{\sqrt{\sum_{i=1}^n (Q_{0,i} - Q_{0,moy})^2}}$$

Le RSR incorpore les avantages d'un indice d'erreur statistique et d'un facteur de normalisation pour qu'il soit applicable aux différentes variables, en accordant le même poids à tous les débits. Il varie de la valeur optimale « 0 » qui indique une variation résiduelle nulle et donc un modèle de simulation parfait, à des valeurs positives très grandes.

1.8 Conclusion :

Aujourd'hui, divers modèles hydrologiques ont été développés à travers le monde pour découvrir l'impact du climat et des propriétés du sol sur l'hydrologie et les ressources en eau. Chaque modèle a ses propres caractéristiques. Dans notre mémoire nous allons nous focaliser, dans le chapitre 2, sur le modèle réseau neurone artificiel (ANN) de la famille des modèles empiriques (boîte noire).

Chapitre 2
Les réseaux de neurones artificiels
ANN

Chapitre 2

Les réseaux de neurones artificiels (ANN)

2.1 Introduction

Passionné par la complexité du cerveau qui est le siège de l'intelligence, la mémoire et la conscience, l'être humain commence à s'intéresser au fonctionnement de ce dernier et essayer de le copier.

Le cerveau humain est composé de plusieurs éléments différents, mais le constituant le plus important est le neurone. Le cerveau humain contient environ 10^{10} neurones reliés entre eux par environ 10^{13} connexions afin de créer un réseau neuronal considérable. Le cerveau fonctionne grâce aux impulsions envoyées entre les neurones par le biais des connexions et ces impulsions. Le réseau de neurones reçoit également des impulsions des cinq sens et envoie des impulsions aux muscles sous la forme de mouvements ou de paroles.

Dans ce chapitre on va donner une définition des neurones biologiques et artificiels, puis développer les différents types des réseaux neurones ainsi que leurs applications dans le domaine d'hydrologie.

2.2 Définition et Historique des réseaux de neurones

2.2.1 Définition :

Si on prend individuellement le neurone, on peut le considérer comme une sorte de machine d'entrées/sorties dans l'attente d'impulsions de la part des neurones voisins et lorsqu'elle reçoit suffisamment d'impulsions, elle envoie une impulsion aux autres.

2.2.2 Bref historique de l'utilisation des réseaux neurones

Les premières recherches remontent au début des années 1940 avec les travaux de Warren McCulloch et Walter Pitts (1943) qui ont créé les premiers neurones formels mimant les neurones biologiques capables de mémoriser les fonctions booléennes simples et qui ont montré qu'avec de tels réseaux on pouvait en principe calculer n'importe quelle fonction arithmétique ou logique. Vers la fin des années 1940, Donald Hebb a ensuite proposé une théorie fondamentale pour l'apprentissage.

Vers la fin des années 1950, et grâce à Rosenblatt la première réalisation concrète des réseaux neurones artificiels dénommé « perceptron » a vu le jour. Ils ont démontré que ce réseau pouvait

reconnaitre des formes, mais malheureusement par la suite ils ont démontré aussi que ce réseau perceptron monocouche autrement dit perceptron simple ne pouvait résoudre qu'une certaine classe de problèmes.

Au début des années 1960, inspiré de la structure et les capacités du perceptron, Bernard Widrow et Ted Hoff ont proposé un nouvel algorithme d'apprentissage pour entraîner un réseau adaptatif de neurones linéaires, intitulé Modèle ADALINE (ADaptative LINear Element).

Vers la fin des années 1960, la sortie du livre de M. Minsky et S. Papert qui démontre les limitations des réseaux développés par Rosenblatt et Widrow-Hoff. Ce livre a influencé beaucoup de chercheurs à abandonner les recherches, d'autant plus qu'ils ne disposaient pas à l'époque d'ordinateurs puissants pour effectuer des calculs complexes.

Au début des années 1980, J. J. Hopfield a proposé le modèle de Hopfield et Théorie du fonctionnement et des possibilités des réseaux de neurones et en 1983 Boltzman a créé la Machine Boltzman qui est le premier modèle apte à traiter les limitations recensées du perceptron. Mais l'utilisation pratique s'avère difficile, la convergence de l'algorithme extrêmement longue.

En 1985, Rumelhart et Y. Le Cun ont développé les Réseaux Rétro propagation du gradient, un algorithme d'apprentissage utilisé pour les multicouches.

2.3 Neurones Biologiques

Les neurones se distinguent des autres cellules par leurs fonctions, en effet, des signaux se propagent entre les neurones, chaque neurone intègre dans son soma les signaux qu'il reçoit des autres neurones par l'intermédiaire des dendrites, l'activité du neurone est définie comme une pondération des signaux reçus, si cette activité est suffisante, il engendre un signal qu'il transmet à son tour aux autres neurones par son axone.

2.4 Neurones artificiels (formels)

Les neurones sont dotés de connexions en entrée qui s'ajoutent entre eux afin de déterminer la force de leur sortie, c'est le résultat de la somme injectée dans une fonction d'activation. La résultante de cette fonction est ensuite passée comme entrée pour d'autres neurones à travers un nombre plus élevé de connexions, chacune d'entre elles étant pondérée. Ces poids déterminent le comportement du réseau.

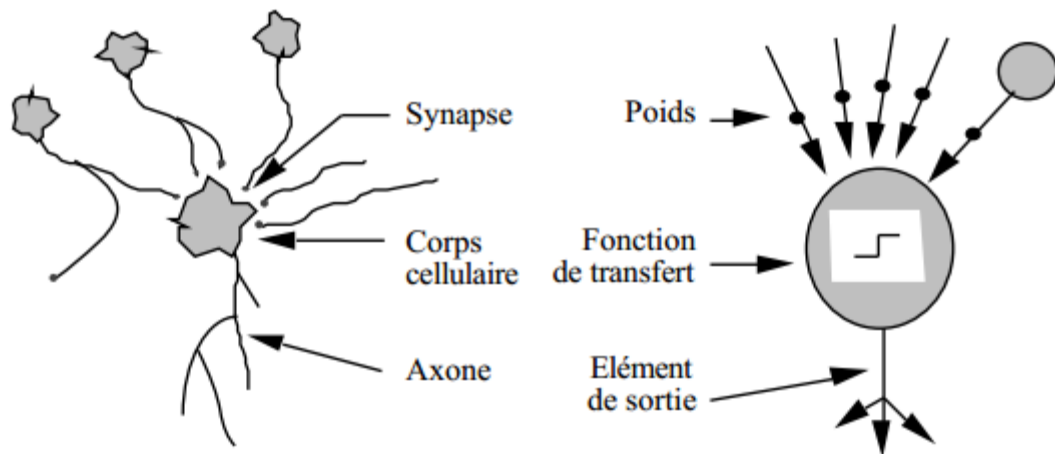


Figure 2.1: Neurone biologique Vs neurone formel

2.5 Types de réseaux neurones artificiels

Selon le chemin suivi par l'information dans le réseau on peut classer les réseaux de neurones en deux grandes catégories : les réseaux « non-bouclés » et les réseaux « bouclés » résumés dans ce schéma et détaillé ci-après :

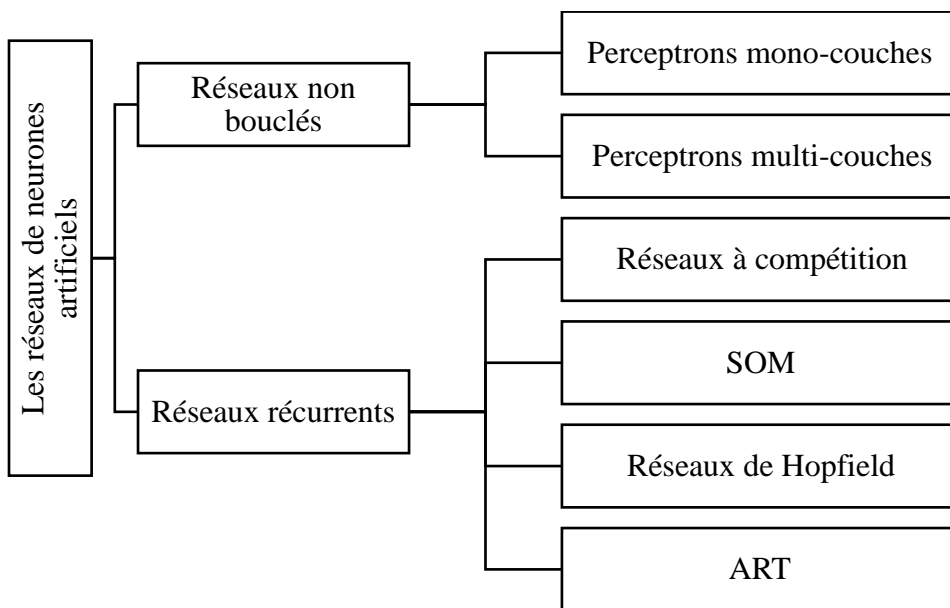


Figure 2.2: Types de réseaux neurones artificiels

2.5.1 Réseaux « non bouclés »

Les réseaux non bouclés sont constitués de neurones statiques, en d'autres termes le temps n'est pas pris en considération pour ce type de modélisation. Ces réseaux sont organisés en couches, chaque couche reçoit des entrées de la couche précédente et les neurones d'une même couche ne sont pas connectés les uns aux autres. Dans ces réseaux, la ou les variables qu'on essaye à simuler n'interviennent pas. Dans ces réseaux, l'information se propage de couche en couche,

sans retour possible en arrière. Nous pouvons citer parmi ces réseaux les Perceptrons et les réseaux à fonction radiale.

2.5.1.1 Modèles perceptrons monocouches

Le Perceptron Monocouche est un réseau simple car il se compose d'une couche d'entrée et d'une couche de sortie. Il a été conçu dans un but premier de reconnaissance des formes. Mais il peut aussi être utilisé pour faire de la classification et/ou pour résoudre des opérations logiques simples (« ET » ou « OU »). Il n'est pas utile pour résoudre la thématique pluie-débit car il ne résout que des problèmes linéairement séparables. Il suit généralement un apprentissage de type supervisé selon la règle de correction de l'erreur (ou selon la règle de Hebb (Parizeau, 2004)).




Figure 2.3: Réseau neuronal perceptron monocouche

2.5.1.2 Modèles perceptrons multicouches

Le Perceptron Multicouches est une extension du monocouche, avec une ou plusieurs couches cachées entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante.

Ce type de réseaux a été récemment classé comme outil de prévision et de simulation des débits (Fortin et al., 1997). Il peut résoudre des problèmes non-linéairement séparables et des problèmes logiques comme la relation pluie-débit. Il suit aussi un apprentissage supervisé selon la règle de correction de l'erreur et utilise la fonction d'activation sigmoïde.




Figure 2.4: réseau perceptron multicouche

2.5.1.3 Modèles à fonction radiale « Radial Basic Functions »

Dans les réseaux à fonction radiale (RBF), l'architecture est la même que pour les Perceptrons multicouches (MLP), cependant, les fonctions de base utilisées ici sont des fonctions Gaussiennes. Les RBF seront donc employés dans les mêmes types de problèmes que les MLP à savoir la classification et l'approximation de fonctions (Parizeau, 2004). L'apprentissage le plus utilisé pour les RBF est le mode hybride qui fait intervenir les modes supervisés et non supervisés définis dans les paragraphes suivants et les règles sont soit la règle de correction de l'erreur, soit la règle d'apprentissage par compétition.

2.5.2 Réseaux « récurrents »

Dans les réseaux bouclés, la sortie de certains neurones est renvoyée sur l'entrée de neurones de la même couche ou d'une couche inférieure. Ce bouclage donne un comportement dynamique au réseau, la sortie ne dépend plus seulement des entrées du réseau, mais également de sa sortie aux instants précédents.

- Les réseaux bouclés non dirigés réalisent un bouclage avec les débits calculés. Lors de la simulation ou la prévision d'un événement (après apprentissage), la connaissance de la sortie à un pas de temps ultérieur permet de recadrer la sortie prévue.
- Les Réseaux Bouclés Dirigés réalisent un bouclage, non plus sur la sortie calculée par le modèle à un temps $t-1$, mais par la sortie désirée à un temps $t-1$ sur les débits observés.

Ce bouclage permet au réseau de pouvoir se caler après son apprentissage sur les vraies valeurs.

2.5.3 Réseaux de Hopfield

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés (Johannet, 2006). Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune différenciation entre les neurones d'entrées et de sorties. Ils fonctionnent comme une mémoire associative non-linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. Le mode d'apprentissage utilisé ici est le mode non-supervisé.

2.5.4 Réseaux à apprentissage par compétition ou « Adaptive Resonance Theory » (ART)

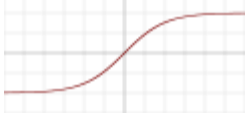


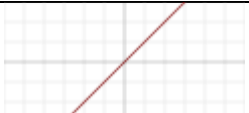
Les réseaux ART « Adaptive Resonance Theory » sont des modèles de réseau de neurones à architecture évolutive développé en 1987 par Carpenter et Grossberg. Ils suivent un apprentissage par compétition. Dans ce réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche, d'un prototype déjà connu par le réseau ; on parlera alors de résonance. A l'inverse, si l'entrée s'éloigne trop des prototypes existants, une nouvelle catégorie va alors se créer, avec pour prototype, l'entrée qui a engendrée sa création.

2.6 Fonctions d'activation :

Il s'agit d'une fonction qui permet de transformer le signal entrant dans une unité (neurone) en signal de sortie. Généralement, les fonctions d'activation ont un effet "d'aplatissement".

Les fonctions d'activation les plus courantes sont les fonctions tangentes hyperbolique, logistique sigmoïde, exponentielle et identité. Ci-dessous un tableau présentant les fonctions d'activations les plus courantes.

Tableau 2.1: fonctions d'activation des réseaux neurones

Nom	Graphe	Equation	Etendu
tangente hyperbolique		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$	$(-\infty, +\infty)$
logistique sigmoïde		$f(x) = \frac{1}{1 + e^{-x}}$	$(0,1)$
exponentielle		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{pour } x < 0 \\ x & \text{pour } x \geq 0 \end{cases}$	$(-\alpha, +\infty)$
identité		$f(x) = x$	$(-\infty, +\infty)$

2.7 APPRENTISSAGE DES RÉSEAUX DE NEURONES

Pour un modèle type réseau de neurones, l'apprentissage peut être considéré comme le problème de la mise à jour des poids des connexions au sein du réseau, afin de réussir la tâche qui lui est demandée. L'apprentissage étant la caractéristique principale des réseaux de neurones formels, il peut se faire de différentes manières et selon différentes règles.

2.7.1 Différentes approches d'apprentissage

Les quatre modes d'apprentissage pour les réseaux de neurones sont ici présentés :

i. **Mode supervisé :** Dans ce type d'apprentissage, le réseau s'adapte par comparaison entre le résultat qu'il a calculé, en fonction des entrées fournies, et la réponse attendue à la sortie. Ainsi, le réseau va se modifier jusqu'à ce qu'il trouve la bonne sortie, c'est-à-dire celle attendue, correspondant à une entrée donnée.

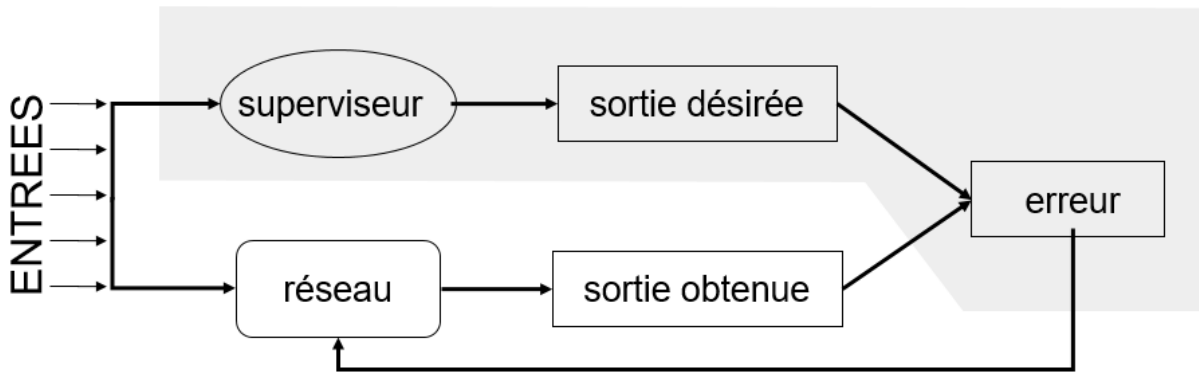


Figure 2.5: Apprentissage supervisé

ii. **Mode renforcé :** Le renforcement est en fait une sorte d'apprentissage supervisé et certains auteurs le classe d'ailleurs, dans la catégorie des modes supervisés. Dans cette approche, le réseau doit apprendre la corrélation entrée/sortie via une estimation de son erreur, c'est-à-dire du rapport échec/succès. Le réseau va donc tendre à maximiser un index de performance qui lui est fourni, appelé signal de renforcement.

iii. **Mode non-supervisé :** Dans ce cas, l'apprentissage est basé sur des probabilités. 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. En effet, le réseau doit détecter des points communs aux exemples présentés, et modifier les poids, afin de fournir la même sortie pour les entrées aux caractéristiques proches (Roussillon, 2004).




Figure 2.6: Apprentissage non supervisé

iv. **Mode hybride :** Le mode hybride comprend à la fois l'apprentissage supervisé et l'apprentissage non - supervisé.

2.7.2 Règles d'apprentissage

Les quatre règles précédemment énoncées sont ici successivement énoncées.

2.7.2.1 Règle de correction d'erreurs

Cette règle s'inscrit dans l'apprentissage supervisé, c'est-à-dire dans le cas où l'on fournit au réseau une entrée et la sortie correspondante. Si on considère la variable y comme étant la sortie calculée par le réseau, et la variable d la sortie désirée, le principe de cette règle est d'utiliser l'erreur ($d-y$), afin de modifier les connexions et de diminuer ainsi l'erreur globale du système. Le réseau va donc s'adapter jusqu'à ce que y soit égal à d ou très proche. Ce principe est notamment utilisé dans le modèle Perceptron.

2.7.2.2 Règle de Boltzmann

Les réseaux de Boltzmann sont des réseaux symétriques récurrents. Ils possèdent deux sous-groupes de cellules, le premier étant relié à l'environnement (cellules dites visibles) et le second ne l'étant pas (cellules dites cachées). Cette règle d'apprentissage est de type stochastique, relevant partiellement du hasard et consiste à ajuster les poids des connexions.

2.7.2.3 Règle de Hebb

Si deux unités connectées sont actives simultanément, le poids de leur connexion est augmenté ou diminué. R est une constante positive qui représente la force d'apprentissage. Il est à noter ici que l'apprentissage est localisé, c'est-à-dire que la modification d'un poids synaptique w_{ij} ne dépend que de l'activation d'un neurone i et d'un autre neurone j . $\Delta w_{ij} = R a_i a_j$




Figure 2.7 : Poids W_{ij}

2.7.2.4 Règle par compétitions

Le principe de cette règle est de regrouper les données en catégories en se basant sur les corrélations des données, et seront représentés par un seul neurone.

2.8 Application du Réseau de neurones artificiels (Artificial Neural Network (ANN)) en Hydrologie

2.8.1 Modélisation Pluie-débit

La complexité du phénomène hydrologique est due aux phases de transformation de la présence. L'eau pluviale à travers le ruissellement se dirige vers un bassin versant qui est distribué spatialement, variant dans le temps et non linéaire. Diverses plates-formes de simulation sont

utilisées pour la modélisation de ce phénomène complexe. Pour concevoir un modèle simple, il existe des modèles qui sont développés en établissant une relation linéaire entre l'entrée et la sortie en évitant les lois physiques complexes. Un tel processus d'écoulement linéaire des précipitations est bien illustré par l'hydrogramme unitaire. Mais ces modèles ne permettent pas de décrire la dynamique non linéaire de la transformation des précipitations et des eaux de ruissellement.

Un dernier développement de l'approche système-modélisation conceptuelle est l'application de la technique ANN dans la modélisation des précipitations. L'avantage de la technique ANN est qu'il n'exige pas la connaissance détaillée des caractéristiques du bassin versant. Il établit simplement une relation entre l'entrée (pluie) et la sortie (débit) sur la base de l'apprentissage grâce au processus de formation du réseau neuronal. Ainsi, les caractéristiques physiques, bien qu'elles ne soient pas évaluées séparément, sont une partie intégrante du modèle.

- En 1992, French et al ont appliqué pour la première fois l'ANN dans le domaine de l'Hydrologie ;
- En 1993, Halff et al ont utilisé une ANN pour la prédiction des hydrogrammes ;
- En 1995, Kothayari a proposé une ANN simple pour l'estimation du ruissellement mensuel moyen alors que Raman & Sunil Kumar proposait le même modèle ANN pour l'estimation des précipitations mensuelles ;
- En 1996, Mason et al. ont développé un système hydrologique virtuel à l'aide de ANN, ils ont montré que le réseau de fonctions à base de radial fournit une formation plus rapide par rapport à la technique régulière de rétro-propagation pour la modélisation pluviométrique avec ANN ;
- En 1999, Sajikumar & Thandaveswara, pour prédire la modélisation mensuelle des pluies-débits dans des conditions de données limitées, utilisaient la technique du réseau neuronal de rétro-propagation temporelle (TBP-NN) ;
- En 2000, Un comité de tâches de la Société américaine des ingénieurs civils (ASCE) a discuté de manière approfondie et a établi le rôle de ANN en hydrologie et l'a également comparé aux autres méthodes de modélisation ;
- En 2002, Rajurkar et al. fournissent une meilleure représentation de la relation pluie-débit pour les bassins versants de grande taille en couplant ANN avec le modèle à multiple entrées ;
- En 2008, Kalteh a développé un modèle de pluie-écoulement utilisant l'approche Artificial Neural Network (ANN) et décrit différentes approches, y compris le Diagramme d'interprétation neurale, l'algorithme de Garson pour comprendre la relation acquise par le modèle ANN. Les résultats montrent que les ANNs sont des outils prometteurs pour une modélisation précise des processus complexes.
- En 2010, Goyal et al. ont analysé les données mensuelles moyennes mensuelles sur les eaux de ruissellement des bassins versants indiens en utilisant des variables sans dimension par le réseau neuronal artificiel (ANN). Les résultats indiquent que le modèle ANN utilisant des variables sans dimension a permis de mieux représenter le processus de pluie-débit ;

- En 2013, Chen et al. ont utilisé l'approche du réseau neuronal artificiel (ANN) pour modéliser les pluie-débit dû au typhon. Les interprétations ont été faites en appliquant les modèles feed Forward Backpropagation (FFBP) et d'Analyse de régression conventionnelle (CRA).

2.8.2 Modélisation de l'écoulement fluvial

La prévision de flux est un élément important du système de ressources en eau et une tâche difficile pour les ingénieurs en ressources en eau. Elle contribue à améliorer le fonctionnement systématique des ressources en eau dans le cadre des priorités économiques, techniques et politiques. Un contrôle efficace et précis de la gestion des ressources en eau peut être obtenu par un système de prévision qui explique la variabilité spatiale et le temporel de tous les champs de flux. Une opération en temps réel du système de ressources en eau pendant un délai d'heures et de jours pourrait être facilement mise en œuvre avec des prévisions de flux. Les prévisions allant d'une semaine à l'autre sont utilisées pour analyser la gestion et la planification du système, à savoir l'analyse de la sécheresse, la planification et le développement de l'hydroélectricité, l'allocation de l'eau d'irrigation.

- En 1993, Kang et al. ont mis en place des modèles de moyenne mobile autorégressive et des ANN pour prédire les flux quotidiens et horaires dans le bassin de la rivière Pyung Chang en Corée. Différentes architectures ANN à trois couches ont été étudiées. Cette étude préliminaire a conclu que les ANN sont des outils utiles pour la prévision des flux.
- En 1994, Karunanithi et al. estiment la prédiction du débit de la rivière Huron en appliquant l'approche Artificial Neural Network en utilisant l'algorithme Cascade-Correlation. Les résultats montrent que les réseaux neuronaux artificiels (ANN) sont capables de modifier les correspondances dans l'historique des flux.
- En 1995, Markus et al. ont utilisé un algorithme de rétro-propagation pour prédire les flux mensuels à la station de jaugeage Del Norte dans le bassin de Rio Grande, dans le sud du Colorado. Les intrants utilisés étaient l'équivalent de l'eau de neige seule, ou l'équivalent d'eau de neige et la température. Comme une autre forme de prédiction, ils ont utilisé des fonctions de transfert périodique (PTF) pour prédire les flux en fonction d'entrées similaires. Pour la formation, les données mensuelles de 1948 à 1977 ont été utilisées et elles ont testé les performances du modèle sur les données mensuelles de 1978 à 1987. Les résultats indiquaient que les ANN et les PTF ont bien prévu les flux d'émissions et que la température a permis d'améliorer les performances du modèle.
- En 1996, Poff et al. ont utilisé les ANN pour évaluer les changements dans l'hydrogramme de flux à partir de scénarios spéculatifs sur le changement climatique basés sur les précipitations et les changements de température.
- En 1998, Karabörk et Kahya ont obtenu des expressions mathématiques de modèles de moyenne mobile autorégressive périodique multivariée (PAR) et périodique autorégressif pour les observations mensuelles (PARMA) de 12 stations situées dans le bassin de Sakarya.
- En 1999, Shrivastava et Jain ont utilisé des modèles ANN pour prédire les entrées de réservoir dans les réservoirs. Ils ont comparé le modèle ANN et Autorégressive

Integrated Moving Average (ARIMA), et ont conclu que l'ANN produisait un meilleur résultat.

- En 2002, Birikundavyi et. Al. ont utilisé des méthodes ANN en prévision du flux quotidien et ont étudié la performance de l'ANN. Les résultats montrent que ANN a donné de meilleurs résultats que les modèles ARMA.
- En 2004, Kumar et. Al. ont utilisé le modèle du Réseau de neurones récurrents (RNN) dans la prévision des flux.

Dans la même année Kişi a étudié l'application de réseaux neuronaux artificiels (ANN) dans la prévision du flux mensuel moyen et comparé aux modèles Auto Régressive (AR).

Et Huang et. Al. (2004) ont comparé les modèles ANN et ARIMA dans les prévisions de flux.

- En 2005, Wang et. Al. ont utilisé les modèles hybrides ANN pour la prévision du débit quotidien. On a utilisé trois formes différentes de réseaux neuronaux artificiels hybrides, à savoir l'ANN à base de seuil (TANN), l'ANN (CANN) et l'ANN périodique (PANN).

2.8.3 Modélisation des eaux souterraines

L'eau souterraine est une ressource d'approvisionnement précieuse pour les activités domestiques, agricoles et industrielles. La précision et la responsabilité sont les facteurs importants dans un modèle de niveau des eaux souterraines. Comme le niveau de l'eau change périodiquement, la durabilité ne peut être assurée que par un modèle de prévision parfait. La prévision du niveau des eaux souterraines dans un bassin hydrographique joue un rôle important dans la gestion des ressources en eaux souterraines, en particulier dans une zone semi-aride où les ressources en eau souterraine ont un énorme besoin afin de préparer les besoins en eau pour les affaires agricoles, municipales et industrielles. Il est difficile de séparer les eaux souterraines et la qualité de l'eau en différentes sections.

- En 1992, Aziz et Wong déterminent les valeurs des paramètres de l'aquifère à partir des données de prélèvement normalisées obtenues à partir des tests de pompage en utilisant le modèle ANN. Ceci est communément appelé le problème inverse de l'hydrologie des eaux souterraines.
- En 1993, Ranjithan et al. ont utilisé un réseau feedforward à trois couches pour examiner de telles réalisations critiques en identifiant d'abord les caractéristiques qui rendent une réalisation critique. Le réseau a prédit une sortie unique qui représentait la réalisation critique d'une normalisation. Les auteurs ont conclu que les atouts de reconnaissance de formes des RNA sont particulièrement utiles pour identifier les réalisations plus critiques
- En 1994, Rizzo et Dougherty ont introduit l'idée du krigeage neuronal pour la caractérisation des propriétés aquifères. Un réseau neuronal threelayer utilisant l'algorithme de contre-propagation a été combiné avec le krigeage pour estimer la

conductivité hydraulique. Les noeuds d'entrée représentaient les coordonnées des points d'observation. Les noeuds de sortie ont prédit la classe de conductivité hydraulique à différents endroits. Ils ont conclu que les RNA pourraient être des outils utiles en géohydrologie lorsqu'ils sont appliqués à des problèmes spécifiques de caractérisation de l'aquifère.

- En 1995, Johnson et Rogers, ils ont conclu que les ANNs, combinés à un algorithme génétique, donnent lieu à des outils robustes et flexibles qui peuvent être utilisés pour planifier des stratégies efficaces d'assainissement des eaux souterraines.
- En 1997, Yang et al. ont prédit les élévations de la nappe phréatique dans les terres cultivées drainées au sous-sol en utilisant le modèle ANN. Les intrants qu'ils utilisaient sont les précipitations quotidiennes, les anciennes stations de la nappe phréatique et l'évapotranspiration potentielle. La sortie était l'emplacement actuel de la nappe phréatique. Ils ont constaté qu'une ANN-alimentation à trois couches pourrait prédire les élévations de la nappe phréatique de manière satisfaisante après l'entraînement en utilisant les valeurs observées.
- En 2005, Nayak et. Al ont utilisé l'approche du Réseau de neurones artificiels (ANN) pour la prévision du niveau d'eau souterraine dans un aquifère peu profond. Cet article rapporte une étude de recherche qui étudie le potentiel de la technique du réseau nerveux artificiel dans la prévision des fluctuations du niveau des eaux souterraines dans un aquifère côtier non confiné en Inde. L'ensemble de variables d'entrée le plus approprié au modèle est sélectionné par une combinaison de connaissances de domaine et d'analyse statistique des séries de données disponibles. Les résultats suggèrent que les modèles ANN peuvent prévoir les niveaux d'eau jusqu'à 4 mois à l'avance raisonnablement bien.
- En 2012, Nourani et. Al. ont estimé le niveau des eaux souterraines (GWL) selon un modèle mathématique d'Ardabil situé au nord-ouest de l'Iran. Le réseau neuronal artificiel (ANN) à trois couches a été utilisé pour corréler le modèle via les enregistrements des eaux souterraines des puits représentatifs et des données hydrologiques pertinentes. Les résultats peuvent être utilisés pour encadrer les stratégies correspondantes pour réduire le coût de la surveillance et augmenter les coûts-avantages effectifs.

2.9 Propriétés des réseaux de neurones

Mangeas et Haykin dans leurs articles font la description de certaines propriétés telles que : la non linéarité, la tolérance au manque d'information, la résistance aux entrées aberrantes, la non-unicité du modèle par rapport aux paramètres, l'adaptabilité et l'utilisation des données dans leur état brut.

2.9.1 Non-linéarité

Etant donné que le neurone est un élément non linéaire et que les neurones sont parallèlement distribués dans le réseau, celui-ci peut s'adapter aux phénomènes physiques les plus complexes.

2.9.2 Tolérance au manque d'information

La distribution de l'information est parallèle, l'endommagement d'un neurone ou d'une connexion ou bien la perte de données, ne provoque pas un échec irrémédiable dans la performance du réseau, mais seulement une dégradation moins sérieuse dans les résultats. Ceci est seulement vrai si la couche cachée est munie de suffisamment de neurones. Le calcul de la sortie étant mené par plusieurs neurones, il y a différents chemins pour relier l'entrée à la sortie.

2.9.3 Résistance aux entrées aberrantes

Du fait des filtres saturants que constituent les fonctions d'activation sigmoïde, le réseau est résistant aux valeurs aberrantes qui pourraient se glisser dans les différentes séries hydrologiques. Néanmoins, un réseau de neurones est prisonnier des données qui ont servi à sa calibration. Pour cette raison, des analyses statistiques sont nécessaires afin de détecter et de remplacer les données aberrantes de nos différentes séries.

2.9.4 Non-unicité des modèles neuronaux par rapport aux paramètres

Dans un réseau neuronal artificiel, un même ensemble d'entrées et de sorties peut aboutir à des ensembles de paramètres très différents à chaque fois que le réseau est entraîné. Ça peut arriver aussi que deux ensembles de poids différents qui génèrent la même sortie mais on peut aboutir au même performances.

2.9.5 Adaptabilité

Les modèles neuronaux pourraient être conçus de manière à changer les poids de leurs synapses en temps réel, en fonction des changements environnementaux. Ils peuvent donc opérer dans un environnement non stationnaire.

2.9.6 Utilisation des données dans leur état brut

Le Réseau de neurones fonctionne avec les données telles qu'elles sont, sans transformation pour rendre leur série homogène ou stationnaire, ou pour changer leur échelle.

2.10 Limites et précautions dans la modélisation avec les réseaux neurones formels

2.10.1 Problème des minimas locaux

Pendant l'apprentissage, les paramètres tels que les poids et les biais peuvent converger vers des valeurs qui représentent des minimas locaux de la fonction coût et non un minimum global. Chitra, (1993) préconise trois approches pour éviter le plus possible les minimas locaux et s'approcher des minimas globaux :

- i. Réinitialiser plusieurs fois les différents poids et recommencer le processus d'apprentissage ;

- ii. Augmenter légèrement ces poids pour s'éloigner du minimum local et recommencer l'apprentissage ;
- iii. Utiliser les techniques plus complexes d'optimisation stochastique globale.

2.10.2 Problème de généralisation

Il est facile de résoudre le sous apprentissage, grâce à l'augmentation de la taille du réseau mais le sur-apprentissage, plusieurs méthodes ont tenté de le résoudre comme l'arrêt prématuré et la régularisation qu'on va détailler ci-dessous [Awadallah,1999].

2.10.3 Arrêt prématuré

Pour éviter les minima locaux et réduire le temps d'apprentissage, on peut utiliser l'arrêt prématuré qui s'appuie sur l'utilisation de beaucoup de neurones cachés. Elle agit indirectement sur le nombre effectif de paramètres. Elle est basée sur le concept statistique de la division d'échantillon l'apprentissage s'arrête quand l'erreur calculé sur la totalité des données subdivisé (Les données d'entrée du modèle sont subdivisées en trois : un groupe pour l'apprentissage, un deuxième pour la validation et un troisième pour le test) commence à augmenter de façon constante. Cette méthode est biaisée vers l'ensemble de validation, elle est beaucoup critiquée car ni le groupe de données d'apprentissage, ni celui de validation n'utilise la totalité de l'échantillon. [Awadallah,1999].

2.10.3.1 Régularisation

Si la taille de l'échantillon ne permet pas de prendre en compte une partie validation, grâce à la régularisation on peut introduire un nombre plutôt grand de neurones puis à optimiser le seul paramètre de régularisation par validation croisée. Cette méthode joue sur les normes de la matrice des paramètres et aide aussi à éviter le sur-apprentissage.

La régularisation consiste à introduire un terme de pénalité dans la fonction coût pour restreindre progressivement l'espace du vecteur des paramètres dans un voisinage de zéro.

[Awadallah,1999]

2.10.4 Limites conceptuelles pour la modélisation pluie-débit

Mis à part les limites des réseaux neurones mentionné ci-dessus, la conception des modèles réseaux neurones pour la modélisation pluie-débit a d'autres limites de type conceptuel à cause de leur appartenance aux modèles « boîtes noires ».

Qui dit modèle boîtes noires signifie que ces modèles ne permettent pas de connaître le processus à l'intérieur du modèle par exemple la signification physique des poids de ces modèles. On peut ajouter aussi d'autres limites celles de la qualité des données, des longues chroniques nécessaires, impossible d'utiliser ces modèles sur des bassins non jaugés.

2.11 Conclusion

Dans notre cas on va utiliser deux modèles : Le modèle Perceptrons multicouches (MLP) de la famille des modèles non bouclés et le modèle Nonlinear Autoregressive with External Exogenous (NARX) qui sera développé dans le chapitre 4. Afin d'améliorer leurs performances, ces modèles seront couplés à un nouvel outil de prétraitement de données en l'occurrence les wavelets « Ondelettes », objet du chapitre 3.

Chapitre 3

Transformée en Wavelets

Chapitre 3

La transformée en wavelet

3.1 Introduction :

Dans les années 1980, l'ingénieur J. Morlet, géophysicien, a découvert les wavelets. Ces dernières sont devenues comme des outils fondamentaux de l'analyse harmonique.

De nos jours, elles ont été utilisées dans de nombreux domaines tels que la physique, l'analyse numérique (pour la résolution d'équations aux dérivées partielles), les statistiques, le traitement du signal, la météorologie, le biomédicales, l'hydrologie, le processus du signal, la compression d'image, le code vocal, la reconnaissance des motifs, l'enquête sur le tremblement de terre et de nombreux autres domaines scientifiques non linéaires. Les recherches et les applications de l'analyse des wavelets ont déjà commencé dans l'hydrologie et les ressources en eau. L'article de Li et al.(1997) souligne les applications potentielles de l'analyse des wavelets à l'hydrologie et aux ressources en eau. Li et al.(1998) a sondé les prévisions d'intervalle de longue durée des séries chronologiques hydrologiques avec la combinaison de modèles de réseaux neuronaux basés sur la transformée en wavelet. Wang et al. (2000) ont proposé un modèle de simulation stochastique de transformation de wavelets, qui génère des séquences synthétiques de flux qui sont statistiquement similaires aux séquences observées de flux. Les caractéristiques de l'échelle multi-temps de la variable hydrologique ont été étudiées par Wang et al. (2002). L'analyse des wavelets a été un point de recherche chaud dans la prédiction de l'analyse des séries chronologiques en raison de sa fonction de multi-résolution (Zhou et al. 2002).

Ce chapitre sert à définir la transformée en wavelets en mettant l'accent sur leur application aux problèmes hydrologiques. Il présente une brève description de la transformée en wavelet (WT), les aspects mathématiques de la wavelet, et le rôle de transformée en wavelet par rapport à d'autres approches en hydrologie. Les lignes directrices pour l'application de WT aux problèmes hydrologiques sont présentées.

3.2 Qu'est-ce qu'une Wavelet <<Ondelette>> ?

Selon Yves Meyer, « *C'est le signal transitoire le plus simple que l'on puisse imaginer* ». Une wavelet est un objet mathématique relativement simple : il s'agit d'une fonction ψ , localisée et oscillante tel que l'intégrale de ψ doit être nulle.

Chaque wavelet possède des qualités comme la *symétrie* afin d'éviter le déphasage, le *nombre de moments nuls* en d'autre terme le nombre d'oscillations qui est utile pour la compression, la *régularité*, utile pour obtenir des signaux reconstruits lisses et réguliers.

La Wavelet principale qui va générer la famille des wavelets $\psi_{a,b}$ (Wavelets filles ou *atomes de base*) est appelée Wavelet mère ψ . Ce sont des copies dilatées, comprimées et translatées dans le temps de la wavelet mère. D'où la formule générale d'une wavelet fille :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a \in \mathbf{R}^+, b \in \mathbf{R}$$

3.3 Transformée en wavelet :

La transformée en wavelet est divisée en deux types :

3.3.1 Transformée en wavelet continue (CWT) :

3.3.1.1 Définitions :

La transformée en wavelets continue (CWT, Continuous Wavelet Transform) est une implémentation de la transformée en wavelets utilisant des échelles arbitraires ainsi que des wavelets pratiquement arbitraires. Les wavelets utilisés ne sont pas orthogonales et les données obtenues par cette transformée sont hautement corrélées.

La transformée en wavelet est définie mathématiquement comme l'intégrale sur tout le temps du signal multiplié par des versions décalées de ψ et à échelle de la fonction de wavelets.

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \psi^*\left(\frac{t-b}{a}\right) \cdot dt$$

Dans l'équation ci-dessus, le signal transformé est une fonction de deux variables, a et b , l'échelle et le facteur de translation, respectivement, de la fonction $\psi(t)$. * Correspond à un conjugué complexe. $\psi(t)$ est la fonction de transformation et s'appelle la wavelet mère, qui est définie mathématiquement comme :

$$\int_{-\infty}^{\infty} \psi(t) dt = 0$$

Les résultats du CWT sont de nombreux coefficients de wavelets C , qui sont fonction de l'échelle et de la position, exprimés de manière générale par l'équation suivante :

$$C(\text{scale}, \text{postion}) = \int_{-\infty}^{\infty} f(t) \psi(\text{scale}, \text{position}, t) dt$$

Multiplier chaque coefficient par la wavelet à échelle appropriée et décalée donne les wavelets constitutives du signal original.

Le paramètre d'échelle est défini par le ratio « 1/fréquence ». Les fréquences basses (échelles élevées) correspondent à une information globale d'un signal qui couvre généralement les signaux entiers, tandis que les fréquences élevées (bas échelles) correspondent à une information détaillée d'un motif caché dans le signal (qui dure habituellement relativement peu temps).




Figure 2.1 : wavelet transform

La CWT retourne un vecteur de dimension supérieure d'un à celle des données d'entrée. Pour des données 1D nous obtenons une image du plan temps-fréquence.

On peut ainsi aisément visualiser l'évolution fréquentielle pendant la durée du signal et comparer son spectre avec ceux d'autres signaux. Comme on utilise ici un ensemble de wavelets non-orthogonales, les données sont hautement corrélées, on a donc dans ce cas une redondance élevée.

Le signal d'origine est reconstruit en utilisant la transformée en wavelets inverse comme suit :

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_0^{\infty} \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \cdot CWT(a, b) \frac{da \cdot db}{a^2}$$

Avec C_ψ constante d'admissibilité.

3.3.1.2 Les étapes pour la création d'une CWT:

La génération de coefficients de wavelets pour une série temporelle comporte les cinq étapes mentionnées ci-dessous:

- i. Étant donné un signal X_t et une fonction de wavelet $\Psi_{j, k}$ on compare la wavelet à une section au début du signal (figure a).
- ii. Calculer le coefficient, $c_{j, k}$, qui est une indication de la corrélation entre Wavelet avec la section sélectionnée du signal.
- iii. Décalez la wavelet vers la droite et répétez les étapes (i) et (ii) jusqu'à ce que le signal entier soit recouvert (figure b)
- iv. Dilatation (échelle) de la wavelet et répétition des étapes (i) à (iii) (figure c)
- v. Répéter les étapes (i) à (iv) pour toutes les échelles pour obtenir des coefficients à toutes les échelles et à différentes sections du signal original.

L'image ci-dessous, résume les étapes (i), (iii) et (iv)




Figure 2.2 : génération des coefficients de wavelet

3.3.2 Transformée en wavelets discrètes (DWT):

Calculer les coefficients de wavelets à toutes les échelles possibles prend beaucoup de temps, et cela génère beaucoup de données. Si l'on choisit des échelles et des positions en fonction des pouvoirs de deux (échelles et positions dyadiques), l'analyse sera beaucoup plus efficace et exacte. Cette transformée s'appelle une wavelet discrète, et on peut la définir comme une implémentation utilisant un ensemble discret d'échelles et de translations de wavelets obéissant à certaines règles.

Cette transformée décompose le signal en un ensemble de wavelets mutuellement orthogonales, ce qui constitue la différence principale avec la transformée en wavelets continues. Elle a la forme suivante :

$$\psi_{m,n} \left(\frac{t-b}{a} \right) = \frac{1}{\sqrt{a_0^m}} \psi \left(\frac{t - nb_0 a_0^m}{a_0^m} \right)$$

Où :

m et n sont des nombres entiers qui contrôlent respectivement la dilatation et la translation de l'wavelets ;

b_0 est le paramètre de localisation et doit être supérieur à zéro ;

a_0 est une étape de dilatation fixe spécifiée supérieure à 1.

A partir de cette équation, on peut voir que l'étape de translation $nb_0a_0^m$ dépend de la dilatation, a_0^m . Le choix le plus courant et le plus simple pour les paramètres a_0 et b_0 sont 2 et 1 (pas de temps), respectivement. Cette puissance de deux échelles logarithmiques des translations et des dilatations est connue sous le nom d'arrangement de grille dyadique. La wavelet dyadique peut être écrite en notation plus compacte comme suit :

$$\psi_{m,n}(t) = 2^{-m/2} \cdot \psi(2^{-m}t - n)$$

Les wavelets dyadiques discrètes de cette forme sont habituellement choisies pour être orthonormées. Ceci permet une régénération complète du signal d'origine en tant qu'expansion d'une combinaison linéaire de translation et dilatation de wavelets orthonormées. Pour les séries temporelles discrètes x_i , où x_i se produit au moment discret i , la transformée en wavelets dyadiques devient :

$$T_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} \psi(2^{-m}i - n) x_i$$

Où $T_{m,n}$ = coefficient de wavelets pour la wavelet discrète de l'échelle $a = 2^m$ et l'emplacement $b = 2^m n$.

L'équation précédente considère une série temporelle finie, x_i , $i = 0, 1, 2, \dots, N-1$ et N est une puissance entière de 2: $N = 2^M$. Cela donne à la gamme de m et n , respectivement, $0 < n < 2^{M-m} - 1$ et $1 < m < M$. À la plus grande échelle de wavelets (c'est-à-dire 2^m , où $m = M$), une seule wavelet est nécessaire pour couvrir l'intervalle de temps et un seul coefficient est produit. À l'échelle suivante (2^{M-1}), deux wavelets couvrent l'intervalle de temps, donc deux coefficients sont produits, et donc jusqu'à $m = 1$, l'échelle a est 2^1 , c'est-à-dire $2^M / 2^1$, c'est-à-dire, des coefficients 2^m ou $N / 2$ sont nécessaires pour décrire le signal à cette échelle. Le nombre total de coefficients de wavelet pour une série temporelle discrète de longueur $N = 2^M$ est alors de $1 + 2 + 4 + 8 + \dots + 2^{M-1} = N-1$. [4]

DWT exploite deux ensembles de fonctions considérées comme des filtres passe-haut et passe-bas (voir figure ci-dessous). Les séries chronologiques originales sont transmises par des filtres passe-haut et passe-bas et séparées à différentes échelles. La série chronologique est décomposée en une qui montre sa tendance (l'approximation) et celle comprenant les fréquences élevées et les événements rapides (le détail).

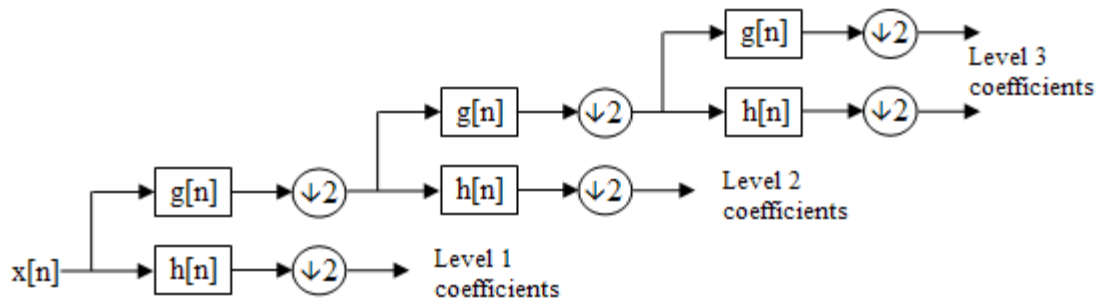


Figure 2.3: l'arbre de décomposition des wavelets

Pour procéder à une analyse à multi-résolution, on utilise l'algorithme **pyramidal** qui traduit le principe de l'arbre de décomposition et qui décompose le signal en "approximations" (S_1, S_2, S_3, \dots) et "détails" (D_1, D_2, D_3, \dots) à un ensemble (discret) d'échelles (exemple niveaux d'échelle 1 à 9 dans la figure ci-dessous)




Figure 2.4: Schéma d'un exemple d'algorithme pyramidal à 9 niveaux

3.4 Les familles des wavelets:

3.4.1 Haar & Daubechies wavelets

La famille dbN contient la wavelet Haar, db1, qui est la plus simple et certainement la plus ancienne des wavelets. Elle est discontinue, ressemblant à une forme carrée.




Figure 2.5: Haar wavelet

Cette famille de wavelets avec un paramètre, grâce à Daubechies, est la première à permettre de gérer des wavelets orthogonales avec un support compact et une régularité arbitraire. Nous appellerons N l'ordre de la wavelet dbN.

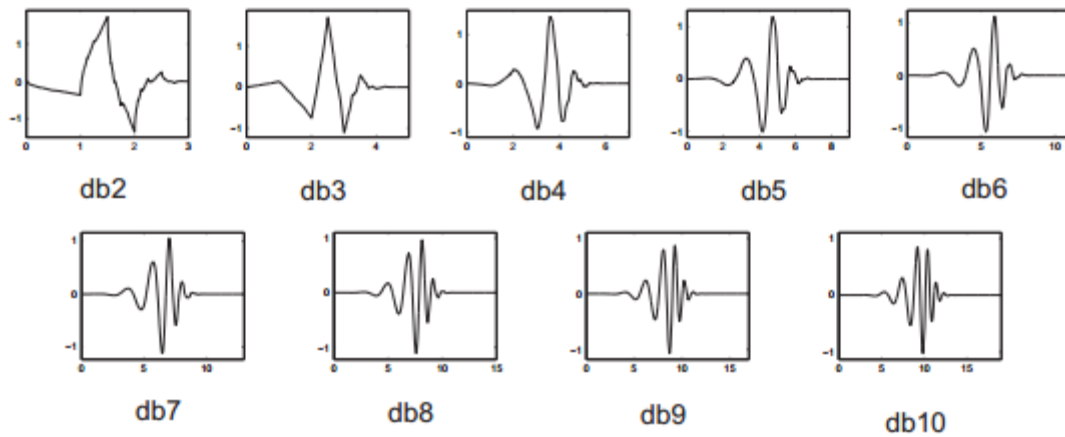


Figure 2.6 : La famille de Daubechies

3.4.2 Symlets

Symlets constituent une famille des wavelets presque symétriques proposées par Daubechies en modifiant la construction du dbN. Outre la symétrie, les autres propriétés des deux familles sont similaires. Les symlets des ordres 2 à 8 (sym1 est simplement la wavelet Haar) sont présentées dans la Figure ci-dessous :




Figure 2.7 : La famille de symlets

3.4.3 Coiflets

Construit par I. Daubechies à la demande de R. Coifman. La fonction wavelet a $2N$ moments égaux à 0 et la fonction de mise à l'échelle a $2N-1$ moments égal à 0. Les deux fonctions ont un support de longueur $6N-1$.




Figure 2.8 : la famille de Coiflets

3.4.4 Meyer wavelet

L'ondelette Meyer est l'une des premières ondelettes. Elle a été construite par Meyer au milieu des années 1980. C'est une ondelette orthogonale infiniment dérivable, mais elle n'a pas de support compact.




Figure 2.9 : Meyer wavelet

3.4.5 Biorthogonal wavelets with compact support

Les Wavelets biorthogonales élargissent les familles des ondelettes orthogonales. C'est un fait bien connu dans la communauté de la théorie des filtres que la symétrie et la reconstruction parfaite sont incompatibles (à l'exception de la wavelet Haar) lorsque les mêmes filtres de réponse aux impulsions finies sont utilisés pour la décomposition et pour le processus de reconstruction. Pour contourner cette difficulté, deux ondelettes sont introduites au lieu d'une.

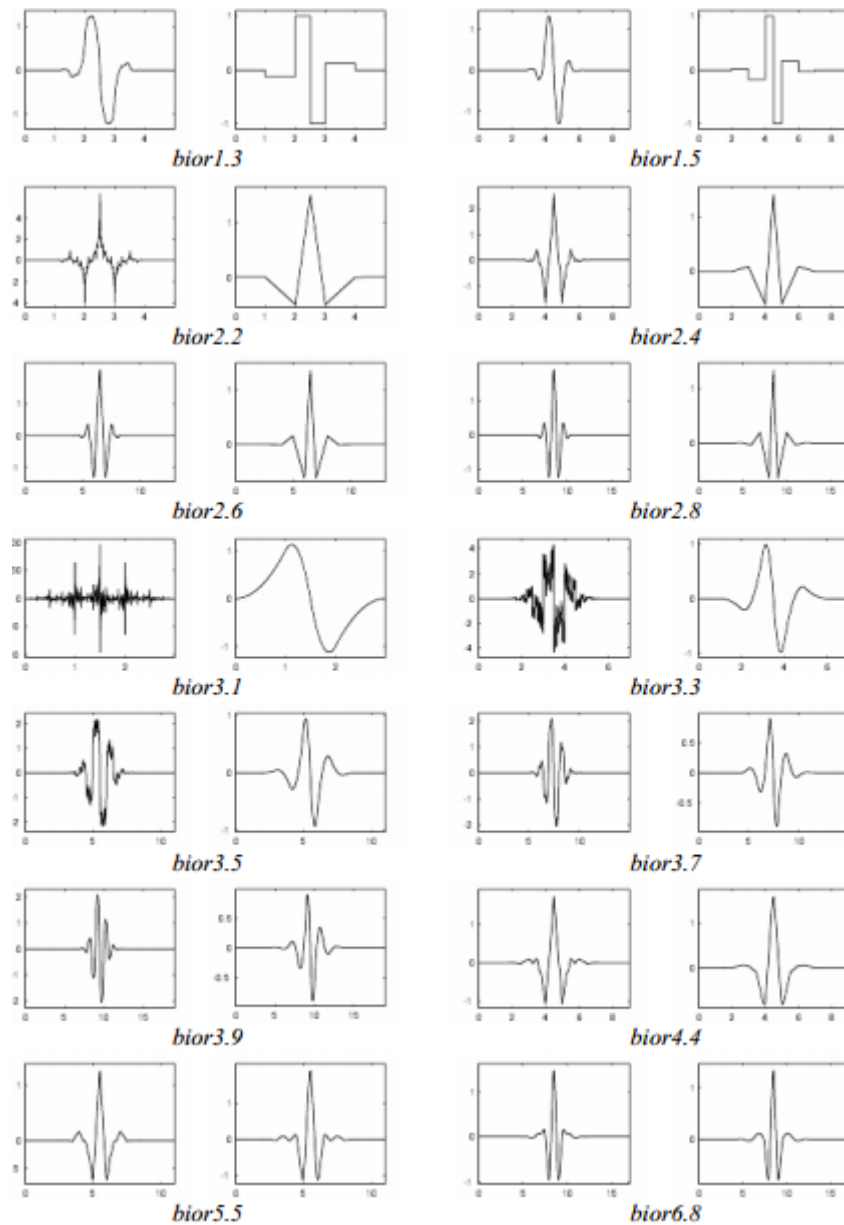


Figure 2.10 : Biorthogonal wavelet family

3.5 Compression et débruitage d'un signal :

L'un des deux des grands succès des ondelettes est la compression et le débruitage du signal, qui sont souvent considérés comme un problème particulièrement difficile. Dans cette partie du chapitre on va tenter d'expliquer les raisons en mettant l'accent sur les signaux unidimensionnels.

3.5.1 Principe de débruitage par wavelets

Le débruitage consiste à restaurer un signal utile à partir d'observations corrompues par un bruit additif. Le modèle statistique le plus simple de débruitage est le suivant :

$$Y_t = f(t) + \varepsilon_t, t=1, \dots, n$$

Où f est une fonction inconnue, $Y_{t_{1 \leq t \leq n}}$ les variables observées et $\varepsilon_{t_{1 \leq t \leq n}}$ est un bruit blanc gaussien centré avec une variance inconnue σ^2 . On doit reconstruire le signal $(f(t))_{1 \leq t \leq n}$ ou estimer la fonction f uniquement sur la base des données d'observations.

3.5.1.1 Débruitage : avant et après

Ci-dessous un exemple de débruitage d'un signal afin d'avoir un aperçu sur le débruitage d'un signal




Figure 2.11: exemple d'un avant (a) et après débruitage (b)

3.5.1.2 L'algorithme de débruitage

L'algorithme basique de débruitage est très simple et comporte trois étapes :

1. Décomposition ;
2. Sélection ou seuil (thresholding) des coefficients ;
3. Reconstruction.

En commençant par le signal, nous le décomposons d'abord sur une base de wavelets orthogonales à l'aide de la transformée discrète et les familles de wavelet (dbN, dmey, sym, bior,....etc) qu'on a déjà détaillé dans le point 3.4 de ce chapitre. Ensuite, nous sélectionnons une partie des coefficients à travers le seuillage (thresholding) et nous conservons les coefficients d'approximation d'un niveau convenablement choisi. Enfin, en utilisant des coefficients de seuil (threshold), nous reconstruisons un signal en leur appliquant la transformée discrète inverse. Le signal obtenu de cette manière est le signal débruité.

3.5.2 Méthodes de débruitage :

Il existe de nombreuses variantes des estimateurs basés sur le seuil du coefficient de wavelets. Ils diffèrent principalement par (Misiti,2007):

- **La stratégie de seuillage** : global, niveau par niveau, local dans le temps, par blocs ;

- **Le type de seuillage :** dur, doux et autres régularisations. Un ingrédient utilisé par les solutions de rechange de base est l'utilisation du seuil « doux » au lieu du seuil « dur » utilisé précédemment. Le seuil doux rend cette fonction continue en réduisant les coefficients conservés. Il est défini par :

$$\begin{cases} \delta_{\text{soft},\lambda}(y) = (y - \text{sign}(y)\lambda), \text{ si } |y| > \lambda \\ \delta_{\text{soft},\lambda}(y) = 0 & \text{sinon} \end{cases}$$

Tout en étant égal, cela conduit à des estimateurs plus lisses, moins sensibles au bruit ;

- **Le choix de la valeur des seuils ;**
- **La stratégie de construction de l'estimateur :**
 - Il peut être direct ou bayésien. Dans ce dernier cas, nous formulons des hypothèses a priori sur la répartition des coefficients. La modélisation typique consiste à considérer un mélange de populations reflétant l'idée que certains coefficients sont dus au bruit et d'autres au signal. On déduit le seuil sur la base de la perte moyenne a posteriori. On peut montrer que les seuils doux et durs peuvent être interprétés d'un point de vue bayésien par des fonctions de perte convenablement sélectionnées.
 - Il peut être basé sur la recherche des estimateurs minimax (moins robustes) ou simplement sur minimax avec une perte logarithmique,
 - Il peut être adapté à diverses fonctions de perte et à un choix particulier de F

3.5.2.1 Exact minimax

C'est une méthode qui utilise des seuils précomputés pour minimiser un terme constant dans la limite supérieure pour le risque minimax d'estimer une fonction en utilisant un estimateur à seuil.

3.5.2.2 Universal thresholding

La stratégie finalement adoptée consiste à limiter les coefficients de Y, non en fonction des coefficients de f avec le seuil σ , mais directement avec un seuil T déterminé de manière appropriée selon le modèle de bruit.

Dans le cas du bruit blanc gaussien, l'estimateur \hat{f} est obtenu en conservant uniquement les coefficients de Y tel que $|d_i| > \sigma \sqrt{2 \log(n)}$ et en remplaçant les autres par 0 est satisfaisant car cela conduit à des résultats presque aussi bons (jusqu'à un facteur logarithmique). Seuil universel donné par Donoho et Johnstone à $T = \sigma \sqrt{2 \log(n)}$.

Ainsi, la procédure est interprétée comme le réglage de tous les coefficients, qui peuvent être attribuables au bruit, à zéro. Parfois, il s'avère également trop sélectif dans la pratique et d'autres seuils ont été développés qui ne présentent pas cet inconvénient.

3.5.2.3 SURE

Un sélecteur de seuil basé sur l'estimation de risque impartiale de Stein a été proposé par Donoho et Johnstone et appelé SureShrink. Le sélecteur SureShrink spécifie une valeur de seuil t_j pour chaque niveau de résolution j dans une transformée en ondelettes.

3.6 Application de la transformée en wavelet en hydrologie

En raison de sa capacité à élucider à la fois des informations spectrales et temporelles dans le signal. L'analyse des transformées en wavelet est devenue un outil d'analyse populaire.

Ci-dessous, on va résumer certaines applications de la transformée en wavelet en Hydrologie :

- **Addison,2001** a utilisé dans un article l'analyse de transformée en wavelets à une variété de flux de sillage de canal ouvert. La localisation des caractéristiques a été effectuée en utilisant une transformation continue en wavelet et l'analyse statistique turbulente et le seuil des composantes du signal turbulent sont entrepris en utilisant une transformée en wavelet discrète. Il a constaté que la transformée en wavelets continue est la méthode recommandée pour la détection des caractéristiques dans les signaux temporels de la vitesse du fluide.
- **Wensheng et Ding,2003** ont effectué une prédiction à plusieurs échelles du niveau des eaux souterraines à Pékin et une décharge quotidienne du bassin du fleuve Yangtze en Chine à l'aide du modèle hybride du réseau Wavelet-Réseau Neuronal. Grâce à un algorithme à trous (transformée en wavelet stationnaire) et à des résultats de prévision du réseau neuronal à trois couches, des résultats ont été réalisés. Ils ont utilisé douze ans de données mensuelles peu profondes au niveau des eaux souterraines, 9 ans pour l'étalonnage et 3 ans pour la validation. Les données de décharge quotidienne de 8 ans ont été utilisées pour la formation et 2 ans pour les tests. Les comparaisons ont révélé que le modèle augmente la précision prévue et prolonge la durée de la prédiction. Le modèle WLNN proposé s'est concentré sur l'amélioration de la précision et la prolongation de la période de prévision.
- **Kim et Valdes,2003** ont développé un modèle non linéaire pour la prévision de la sécheresse basé sur une conjonction de transformées de wavelet et de réseaux de neurones dans le bassin de la rivière Conchos au Mexique. Les résultats indiquent que le modèle de conjonction utilisant une transformée en wavelets dyadiques améliore significativement la capacité du réseau neuronal dans la prévision.
- **Cannas et al.,2005** ont étudié la prévision des cours de la rivière 1 mois à l'avance avec les réseaux de neurones et l'analyse des wavelets en utilisant les données mensuelles de ruissellement pour le bassin de Tirso, en Italie. L'ensemble de données ont été divisées en trois parties, les 40 premières années ont été utilisées pour la formation, les 9 prochaines années pour la validation croisée et les 20 dernières années pour les tests. La reconstruction des données a été effectuée par des réseaux traditionnels d'alimentation, réseaux MLP. Pour les séries temporelles non saisonnières et saisonnières des rivières

d'écoulement, les meilleurs résultats ont été obtenus à l'aide du regroupement de données et de la combinaison DWT. Les tests ont montré que les réseaux de neurones formés avec des données prétraitées présentaient une meilleure performance.

- **Zhou et al.** ont élaboré un modèle prédictif-correcteur de débit mensuel basé sur la décomposition des wavelets en utilisant des enregistrements de décharges mensuelles de 52 ans dans la station Yichang de la rivière Yangtse. Les données de la série temporelle décomposées ont été utilisées comme entrée du modèle ARMA pour la prédiction, ce qui améliore la précision de la prédiction. (Zhou et al. 2008)
- **Rao et Krishna** ont procédé à la modélisation à l'aide des données de la Série météorologique hydrologique adoptant Wavelet-Neural Network pour quatre rivières qui coulent vers l'ouest en Inde, à savoir Kollur (22 années de données de 1981 à 2002), Seethanadi (26 ans de données de 1973 à 1998), Varahi (26 ans 1978-2003) et Gowrihole (données de 25 ans de 1979 à 2003). Les résultats de la modélisation quotidienne du flux et de la série mensuelle des eaux souterraines indiquent que les performances des modèles WNN sont plus efficaces que les modèles ANN. (Rao, 2009)
- **Nourani et al.** ont étudié la modélisation pluie-débit en utilisant l'approche Wavelet-ANN pour les prédictions de l'écoulement écoulé 1 jour avant le bassin hydrographique de Ligvanchai à Tabriz, en Iran. Les séries quotidiennes de pluviométrie et de ruissellement pendant 21 ans ont été utilisées. Les séries chronologiques ont été décomposées jusqu'à quatre niveaux en utilisant Haar, Daubechies (db2), Symlet (sym3) et Coiflet (coif1). L'étude a montré que les débits de ruissellement à court et à long terme pourraient être prédits considérablement. Les résultats du modèle montrent que Haar est la meilleur par rapport aux autres. Ils ont également recommandé que WT peut-être utilisé pour l'analyse des tendances dans les bassins hydrographiques. [2009a, 2009b]
- **Kisi** a développé un modèle de neuro-wavelets (NW) en combinant deux méthodes de DWT et réseau neuronal artificiel (ANN), pour une prévision de flux intermittent de 1 jour et les résultats ont été comparés à ceux du modèle ANN. Des données de flux intermittent provenant de deux stations de la région de la Thrace, la partie européenne de la Turquie, dans la partie nord-ouest du pays, ont été utilisées dans l'étude. Dans le modèle NW, les séries chronologiques originales ont été décomposées en cinq composantes de séries de sous-éléments par l'algorithme de Mallat DWT. Les coefficients de corrélation entre chaque série de sous-séries et les séries temporelles de flux intermittent originales ont été trouvés.
Ces valeurs de corrélation fournissent des informations pour la détermination de composants efficaces de wavelets sur flux. La nouvelle série de sous-séries ayant un coefficient de corrélation élevé a été utilisée comme entrée pour le modèle ANN. Le modèle NW était beaucoup mieux que l'ANN en estimation de débit élevé. Les résultats des tests ont montré que le DWT pourrait augmenter considérablement la précision du modèle ANN en modélisant les flux intermittents. [Kisi, 2009]
- **Rajae et al.** ont étudié la prédiction de la charge quotidienne de sédiments en suspension 1 jour à l'avance avec un modèle de combinaison de wavelets et de neuro-

flou utilisant des données chronologiques de décharge et des charges sédimentées en suspension dans une station de jaugeage de la rivière Pecos aux États-Unis. Les résultats ont montré que l'analyse des wavelets et le modèle neuro-flou ont eu de meilleures prédictions que Sediment rating curve (SRC) neuro-floue. La charge cumulative de sédiments en suspension estimée par cette technique était plus proche des données réelles. Le modèle WNF prend en considération les caractéristiques périodiques et stochastiques du phénomène des sédiments en suspension et peut fournir des constructions appropriées qui ne sont pas clairement observées dans le SRC suspendu. Le modèle pourrait également être utilisé pour stimuler le phénomène d'hystérésis, alors que la méthode SRC est incapable dans cet événement. [Rajae, 2010]

- **Shiri et Kisi** ont étudié les prévisions à court terme et à long terme en utilisant un modèle de conjonction wavelets neuro-floues pour prédire les flux quotidiens, mensuels et annuels de la station de Derecikviran sur la rivière Filyos dans la région de la mer Noire occidentale en Turquie en utilisant 31 Années de flux de données. Les résultats obtenus ont montré que les modèles neuro-fuzzy (NF) et wavelet-neuro-flou (WNF) augmentaient la précision des modèles NF unique, en particulier dans la prévision du flux annuel. De plus, les modèles NF et WNF ont été comparés les uns aux autres en ajoutant des composants de périodicité aux entrées. Les résultats de comparaison ont indiqué que l'ajout d'un composant de périodicité augmentait généralement la précision des modèles. [Shiri et Kisi, 2010]
- **Kisi** a développé des modèles de neuro-wavelets pour l'estimation quotidienne des sédiments en suspension pour deux stations sur la rivière de la langue à Montana à l'aide des flux quotidiens de courant et des données sur les sédiments en suspension. Les résultats de comparaison révèlent que le modèle développé pourrait augmenter la précision de l'estimation. [Kisi,2010]
- **Adamowski et Sun** ont étudié une méthode basée sur le couplage de la transformée en wavelets discrètes (WA) et ANN pour les applications de prévisions de flux dans les rivières non pérennes dans les bassins hydrographiques semi-arides aux débits de 1 et 3 jours pour deux rivières différentes à Chypre. La transformée en wavelets discrète a été utilisée pour décomposer les données des séries temporelles de flux en huit niveaux de coefficients de wavelets qui sont utilisés comme intrants pour les modèles de réseaux neuronaux artificiels Levenberg Marquardt pour prévoir l'écoulement. Le modèle WA-ANN fournit des résultats plus précis que l'ANN régulière. [Adamowski et Sun,2010]
- **Nourani et al.** ont étudié deux hybrides pour deux bassins hydrographiques situés en Azerbaïdjan, en Iran. Approches d'intelligence artificielle pour la modélisation du processus de pluie-débit. Deux modèles hybrides basés sur l'IA qui sont fiables dans la saisie des caractéristiques de périodicité du processus sont introduits pour la modélisation. Dans le premier modèle, la SARIMAX (moyenne saisonnière automatique intégrée régressive avec entrée exogène) - modèle ANN, un ANN est utilisé pour trouver la relation non linéaire entre les résidus du modèle SARIMAX linéaire ajusté. Dans le deuxième modèle, le modèle wavelet-ANFIS, WT est lié au concept ANFIS et les principales séries temporelles de deux variables (pluie et débit) sont

décomposées en séries temporelles multifréquences par WT. Par la suite, ces séries chronologiques sont imposées comme données d'entrée à l'ANFIS pour prédire la décharge de ruissellement un pas en avance. Les résultats obtenus ont montré que, bien que les modèles proposés puissent prédire les débits à court et à long terme en considérant les effets de la saisonnalité, le deuxième modèle est relativement plus approprié car il utilise les séries chronologiques multiscalaires des données sur les précipitations et les eaux de ruissellement dans la couche d'entrée ANFIS.

[Nourani,2011]

- **Kisi et Shiri** ont développé un modèle de prévision des précipitations en utilisant la programmation génétique wavelet et la conjonction WNF. Ils ont constaté que le modèle de programmation génétique de wavelets hybrides était de meilleure performance que le modèle hybride-oscillant hétéro-neuro-flou. [Kisi et Shiri, 2011]
- **Rajae et al.** ont développé ANN, combinaison analyse de wavelets et ANN (WANN), la régression multilinéaire (MLR) et les modèles SRC pour les suspensions quotidiennes Modelage de la charge de sédiments (S) dans la station de mesure de l'Iowa aux États-Unis. Dans le WANN Modèle, DWT a été lié à la méthode ANN. À cette fin, le temps observé Une série de décharges de rivière (Q) et S ont été décomposées en cinq niveaux par DWT qui ont été imposés comme contribution à ANN pour prédire 1 jour à venir S. Une wavelet de Morlet complexe Une technique a été appliquée pour analyser la construction de wavelets de Q et S. quotidiens. Le nombre de nœuds dans l'entrée dans le modèle WANN a été déterminé par $(i + 1) \times 2$, Car ce modèle utilise deux variables (Q et S) et chaque série temporelle est décomposée en $i, i=(1,2,\dots, 5)$ séries temporelles détaillées et séries temporelles d'approximation.
Cette étude visait à examiner les effets de l'utilisation des différents types de wavelet mère sur l'efficacité du modèle WANN proposé. Sept différents wavelets de la mère étaient Utilisés [à savoir, Daubechies-2 (db2) (la plus populaire), la wavelet Haar (Wavelet simple) et une wavelet irrégulière telle que Bior1.1, Rboi1.1, Coif1, Sym1 et Mayer wavelets].
Ils ont constaté que, en augmentant le niveau de décomposition, en niveaux supérieurs au niveau 1, Diminue la performance du modèle, car les niveaux élevés de décomposition entraînent un nombre élevé de paramètres avec des relations non linéaires complexes dans la technique de l'ANN. Le modèle WANN était plus précis dans la prévision de la S et sa performance était meilleure que les modèles ANN, MLR et SRC. [Rajae,2011]
- Wang et al. ont utilisé une méthode de transformée en wavelets pour la génération synthétique du flux quotidien dans la rivière Jinsha en Chine. Les séquences de flux quotidiens avec différentes composantes de fréquence sont décomposées dans la série des coefficients de wavelets à différents niveaux de résolution en utilisant un algorithme de décomposition en wavelets. Sur la base de ces sous-ensembles échantillonnés, un grand nombre de séquences synthétiques quotidiennes de flux de flux sont obtenues en utilisant un algorithme de reconstruction de wavelets. Ils ont conclu que cette méthode nouvellement développée est capable de générer des séquences de flux en fonction des distributions de probabilité et du type de structure de dépendance. [Wang, 2011]

3.7 Conclusion

Le rôle de transformée en wavelet (WT) dans diverses branches de l'hydrologie a été examiné dans le dernier point et a constaté que WT est un outil robuste dans l'analyse de nombreux processus hydrologiques non linéaires et non stationnaires tels que les pluie-débit, le flux, la modélisation des eaux souterraines, les précipitations, les évaporations. Toutefois, WT tend à être des données (signal) intensives et prudentes sur les propriétés statistiques de l'ensemble de donnée.

Chapitre 4

Etude de cas

Chapitre 4 Etude de cas

4.1 Introduction

Lorsque les méthodes classiques pour la modélisation des séries chronologiques hydrologiques ne répondent plus aux besoins pratiques du fait de leurs limites exposant à des caractéristiques non stationnaires et à des échelles multi-temps, la méthode de débruitage du seuil des wavelets (WTD) proposée par Donoho (1995) peut être utilisée comme une alternative fiable. Dans les pratiques hydrologiques, la méthode WTD est connue pour être plus influente que les méthodes conventionnelles, car elle peut contribuer à l'illumination des caractéristiques localisées des séries temporelles non stationnaires à la fois dans les domaines temporel et fréquentiel (Jansen 2006). Il n'y a eu que quelques recherches axées sur l'utilisation des approches de débruitage des données basées sur les wavelet dans la modélisation hydrologique (par exemple, Nejad et Nourani 2012, Nourani et al., 2014).

Dans ce chapitre, on va d'abord présenter les régions qui seront étudiées dans ce mémoire, les données qu'on va utiliser et aussi les étapes à suivre pour bien appliquer les modèles choisis. On va parler aussi de la procédure de débruitage dont le seuillage constitue l'étape la plus importante qui détruit les signaux détaillés en les rétrécissant.

4.2 Données :

Les données qu'on présentera ci-dessous proviennent de trois régions différentes : l'Ouest de la France, le Nord Algérien et le Nord-est Algérien.

4.2.1 Le Léguer, Belle-Isle-en-Terre, France

Situé à l'Ouest de la France (figure 4.1), Le Guic et le Guer se rejoignent au niveau de Belle-Isle-en-Terre et forment le Léguer. Ce bassin versant (figure 4.2) s'entend sur une surface de 260 kilomètres carrés, avec une lame d'eau écoulee dans son bassin versant annuellement de 568 mm.



Figure 4.1: Positionnement de la région Belle-Isle-en-Terre en France

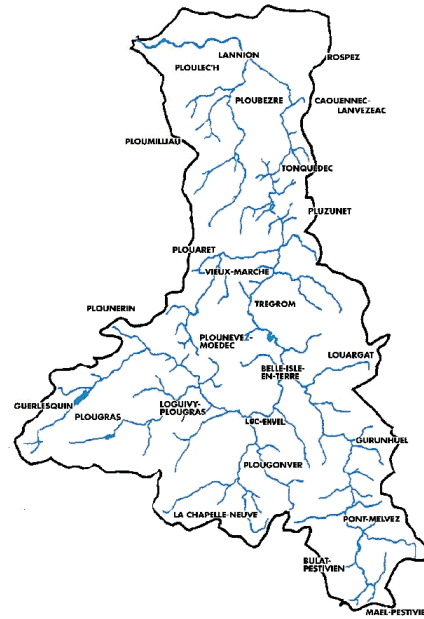


Figure 4.2: Bassin versant le L'éguer

Pour ce bassin on dispose d'une série historique de 730 données journalières de la pluie et des débits (en m^3/s et en mm/j) de la période du 01/01/1991 au 31/12/1992. Les données hydrographiques, correspondantes sont données par les figures 4.3 et 4.4 suivantes :




Figure 4.3 : Données de la pluie de la région de Belle-Isle-en-Terre




Figure 4.4 : Données de Débit (en mm/j) de la région de Belle-Isle-en-Terre

4.2.2 Région de Zardezas, Skikda, Algérie

Situé au Nord-est de l'Algérie (figure 4.5) dans le côtier constantinois, d'une superficie de 345 km², Le bassin versant de Zardezas est un sous bassin versant du Safsaf. Oued Bou Hajeb et oued Khemakhem constituent le bassin versant de Zardesas et se ramifient en plusieurs affluents.

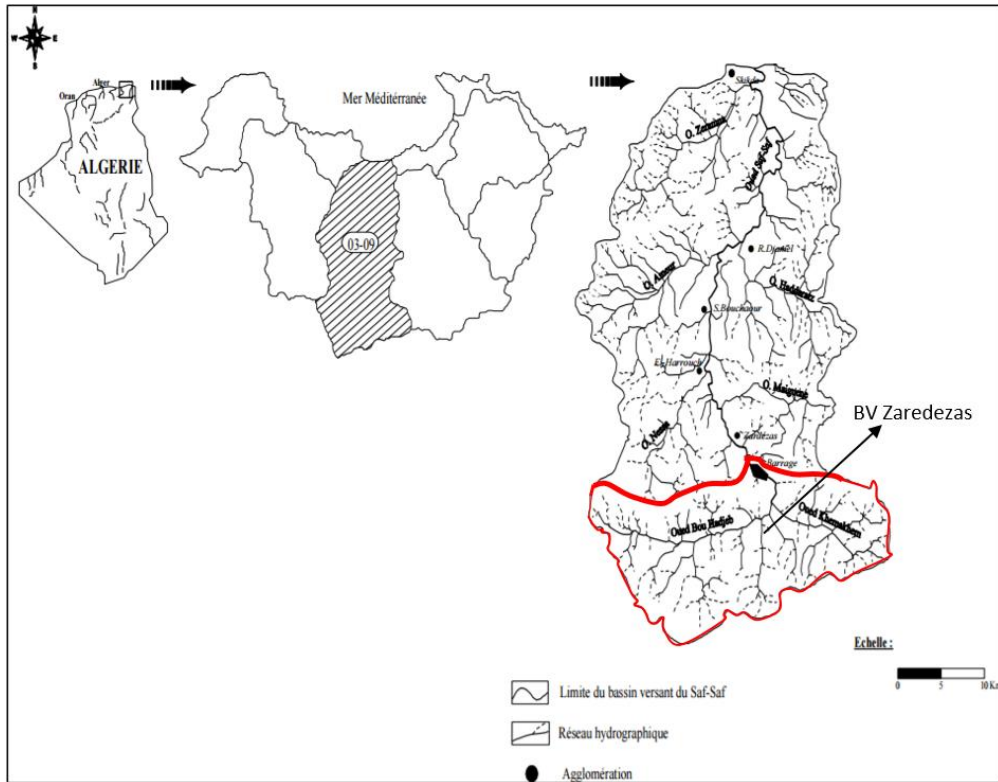


Figure 4.5: Positionnement de Zardezas et du bassin versant

Le climat est de type méditerranéen, froid et relativement humide en hiver et chaud en été. On dispose d'une série historique de 2 191 données journalières de la pluie et des débits (en m³/s et en mm/j) de la période du 01/01/1990 au 01/01/1996. Les données hydrographiques, correspondantes sont données par les figures 4.6 et 4.7 suivantes :




Figure 4.6: Pluie journalière du BV de Zardezas




Figure 4.7: Débit en mm/j du BV de Zardzas

4.2.3 Région des Isser, Algérie

Situé au nord de l'Algérie, le bassin de l'ISSER est limité au Nord par la mer et le bassin versant du Côtier Algérois, au sud-ouest par le bassin du Cheliff, au Sud Est par le bassin de Chott Hodna et à l'Est par le bassin de la Soummam. Avec une superficie de 4 170 km² la délimitation de ce bassin est entre Ain Boucif jusqu'à l'embouchure du bassin, Oued Mellah et l'Oued Hammam constituent l'ISSER et se ramifient en plusieurs affluents.

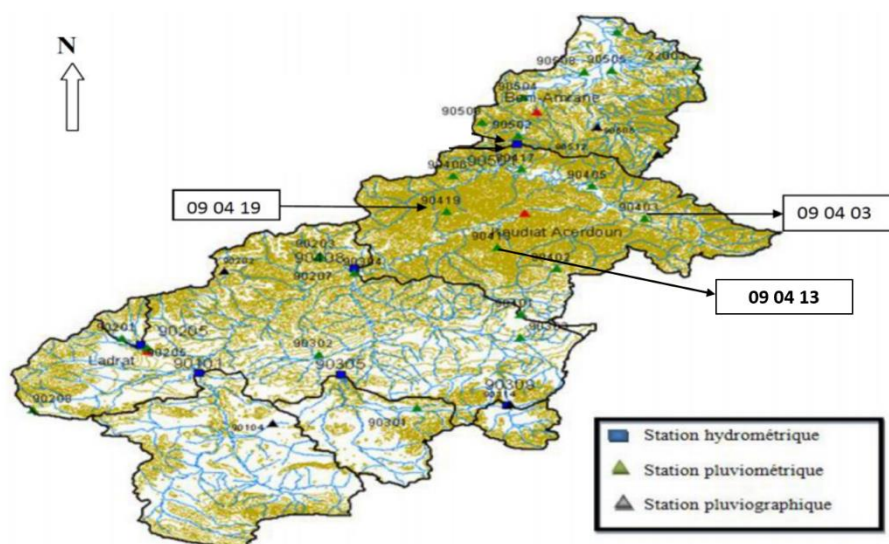


Figure 4.8 : Carte des situations des stations hydro-climatologique du bassin versant de l'Isser

Le climat du bassin est méditerranéen, froid et humide en hiver, chaud et sec en été. La pluviométrie moyenne varie entre 600 et 800 mm par an. Les données nécessaires pour ce type d'étude sont les chroniques concomitantes de pluie, et de débits liquides au même pas de temps (journalier), c'est pour cela on dispose d'une série de 1096 données de la période 01/01/1992 au 01/01/1996, qui sont déjà traitée en calculons la pluie moyenne enregistrées dans les stations (090403, 090413, 090419).




Figure 4.9: Pluie du bassin versant Isser




Figure 10 : Débit du bassin versant Isser

4.3 Méthodes

4.3.1 Les modèles proposés

Ci-dessous on va expliquer les méthodes et les étapes à suivre pour les modèles ANN et les modèles hybrides (Wavelet-ANN)

4.3.1.1 Modèles basé sur les réseaux neurones artificiels

Le réseau de neurones artificiels (ANN), en tant que fonction d'autoapprentissage et auto-adaptatif, a démontré une grande capacité à modéliser et à prévoir des séries chronologiques hydrologiques non linéaires. Par exemple, Altunkaynak (2007) a indiqué que les réseaux de neurones peuvent modéliser avec succès la relation complexe entre les précipitations et les niveaux d'eau consécutifs et ont comparé les résultats obtenus avec les résultats du modèle ARIMA. En tant que modèle hybride, un système adaptatif d'inférence neuro-flou (ANFIS) a été proposé par El-Shafie et al. (2007) pour prévoir l'afflux pour le fleuve Nil au barrage d'Assouan.

Les ANN offrent une approche efficace pour traiter de grandes quantités de données dynamiques, non linéaires et bruyantes, surtout lorsque les relations physiques sous-jacentes ne sont pas entièrement comprises. Cela les rend parfaitement adaptés aux problèmes de modélisation des séries chronologiques d'une nature basée sur les données.

En général, les avantages des ANN sur d'autres modèles statistiques et conceptuels peuvent être classés comme suit :

- L'application de l'ANN ne nécessite pas une connaissance préalable du processus car les ANN ont des propriétés de boîte noire.
- Les ANN ont la propriété intrinsèque de la non-linéarité puisque les neurones activent un filtre non linéaire appelé fonction d'activation.
- Les ANN peuvent avoir une entrée multiple ayant des caractéristiques différentes, ce qui peut représenter la variabilité temps-espace.

C'est pour cela qu'on testera deux types de Réseaux de neurones artificiels, le premier est un réseau de neurones non bouclé et le deuxième est récurrent sur chacun de nos trois bassins versants et les comparer avec les résultats du modèle basé sur un couplage Wavelet-ANN.

Étant donné que les séquences d'apprentissage ANN consistent à accorder les valeurs des poids et des biais choisis au hasard du réseau, pour optimiser ces performances, il est possible d'obtenir différents résultats dans chaque procédure de training. Les différents biais et poids appliqués sur les nœuds des couches cachées et sorties sont réglés au cours de la phase d'étalonnage de la modélisation. Cependant, afin de réduire l'impact du caractère aléatoire des poids initiaux dans l'algorithme BP (back propagation), les procédures de training peuvent être répétées plusieurs fois pour chaque entrée avec la structure du réseau spécifique et les données ciblées.

❖ Réseau non bouclé Perceptrons multicouches (MLP):

Dans le cas d'un réseau neurone Perceptron multicouches, les données se subdivisent, en général, en trois groupes : le premier groupe c'est pour le training, le deuxième groupe pour la validation et le troisième pour le test. Dans notre cas, on a subdivisé les données en deux blocs :

- Un ensemble de deux tiers des données globales pour le calage du modèle, c'est la phase d'apprentissage ;
- Un autre ensemble pour la validation du modèle sur un jeu de données n'ayant pas participé au calage du modèle.

En effet, la phase de test a été effectuée sur l'ensemble de données.

Dans le cadre de la modélisation basée sur le réseau neurone non bouclé, il faut souligner deux points importants : premièrement, l'architecture, c'est-à-dire le nombre de neurones dans l'entrée et les couches cachées, et deuxièmement, le nombre d'itérations de l'apprentissage (epoch). Une sélection appropriée de ces deux paramètres améliore l'efficacité du modèle dans les étapes de training et de vérification. En outre, un nombre d'itérations élevé et une mauvaise qualité ou une quantité de données pourraient entraîner un sur ajustement du réseau pendant l'étape du training. Si cela se produit, le modèle ne peut pas généraliser de manière adéquate les nouvelles données en dehors de l'ensemble de training.

Ci-dessous les étapes à suivre, pour la création, training et validation d'un réseau neurone MLP

- 1) En premier lieu, on commence par importer les données de pluies et débits observé de la région à étudier.

Vu que les données de la pluie et débit sont non linéaires et stationnaires, on opte pour un modèle Non-linear input-output, qui se base sur la pluie au temps $t-1, t-2, \dots, t-d$ comme entrée.

- 2) Ensuite fixer le nombre de couches cachée, le nombre de neurones dans une couche cachée et une fonction de training (apprentissage) pour cela on a trois fonctions d'apprentissage :

- **Bayesian Regularization backpropagation** : Cet algorithme nécessite généralement plus de temps, mais peut entraîner une bonne généralisation pour les ensembles de données difficiles, petits ou bruyants. La formation s'arrête selon la minimisation du poids adaptatif (régularisation).
- **Scaled conjugate gradient backpropagation** : Cet algorithme nécessite moins de mémoire. La formation s'arrête automatiquement lorsque la généralisation cesse de s'améliorer, comme l'indique une augmentation de l'erreur carrée moyenne des échantillons de validation.
- **Levenberg-Marquardt backpropagation** : Cet algorithme nécessite généralement plus de mémoire mais moins de temps. La formation s'arrête automatiquement lorsque la généralisation cesse de s'améliorer, comme l'indique une augmentation de l'erreur carrée moyenne des échantillons de validation.

L'algorithme utilisé dans notre cas est le Levenberg-Marquardt avec Backpropagation pour un nombre de neurones entre 3 à 15 pour les couches de neurones cachées.

- 3) Créer le réseau neurone feedforward ;
- 4) Préparer les données pour le training et la simulation et configurer le réseau ;
- 5) Initialiser les poids et biais (pour la backpropagation les poids s'initialise et changent automatiquement en tenant en compte l'erreur) ;
- 6) L'apprentissage du réseau ;
- 7) Valider le réseau (post-training analysis) ;
- 8) Utiliser le réseau pour faire la modélisation.

Ci-dessous un diagramme résumant le processus du modèle multicouches perceptrons (MLP)



Figure 4.11: Diagramme du modèle ANN (MLP)

❖ **Réseau bouclé NARX (Nonlinear Autoregressive with External (Exogenous) Input (NARX)) :**

Le réseau autorégressif non linéaire avec des entrées exogènes (NARX) est un réseau dynamique récurrent, avec des connexions de retour associant plusieurs couches du réseau. Le modèle NARX est basé sur le modèle ARX linéaire, qui est couramment utilisé dans la modélisation des séries temporelles.

L'équation qui définit le modèle NARX est :

$$y(t) = f \left(y(t-1), y(t-2), y(t-3), \dots, y(t-n_y), \dots, x(t-1), x(t-2), x(t-3), \dots, x(t-n_x) \right)$$

Où la valeur suivante du signal de sortie dépendant $y(t)$ est régressée sur les valeurs précédentes du signal de sortie et les valeurs précédentes d'un signal d'entrée indépendant (exogène).

Il existe de nombreuses applications pour le réseau NARX. Il peut être utilisé comme prédicteur, pour prédire la prochaine valeur du signal d'entrée. Il peut également être utilisé pour le filtrage non linéaire, dans lequel la sortie ciblée est une version sans bruit du signal d'entrée. L'utilisation du réseau NARX est présentée dans une autre application importante, la modélisation des systèmes dynamiques non linéaires.

Pour les étapes à suivre, nous citerons :

- 1) On commence par importer les données de pluies et débits observés de la région à étudier.
- 2) L'algorithme utilisé dans notre cas, on utilise une Backpropagation avec le programme de Levenberg-Marquardt.
- 3) Création d'un réseau non linéaire autorégressif avec des entrées externes. On choisit le nombre de neurone dans la couche cachée et le n (par exemple $n=5$) de l'équation précédente pour les données de la pluie et des débits observés.
- 4) Préparation des données pour le training et la simulation.
- 5) Division des données en trois groupes, pour le training, validation et test.
- 6) L'apprentissage du réseau et tester le réseau.
- 7) Une fois $y(t)$ est disponible, on ferme la boucle du réseau.




Figure 4.12 exemple d'un réseau avec une boucle fermé avec $n=5$

- 8) Pour déterminer $y(t+1)$, on supprime 1 delay (retard), donc on aura 0:4 au lieu de 1:5 et on lance l'apprentissage.




Figure 4.13 : Détermination de $y(t+1)$, avec le NARX

- 9) Valider le réseau (post-training analysis)
- 10) Utiliser le réseau pour faire la modélisation.

Ci-dessous, un diagramme du modèle NARX onestep ahead ($y(t+1)$).



Figure 4.14: Diagramme du modèle ANN (NARX)

Grace au modèle NARX non seulement on peut prédire le débit à $t+1$ appelé « onestep ahead prediction » mais aussi prédire à $t+m$ le débit (multistep ahead prediction).

4.3.1.2 Modèle basé sur le couplage Wavelet-ANN (Réseaux neurones artificiels)

Dans la méthode proposée dans cette étude, on applique d'abord une approche de débruitage basée sur les wavelets sur les données brutes ; les bruits aberrants et systématiques des séries temporelles sont identifiés et rétrécis pour produire des séries chronologiques hydrologiques lisses. La grandeur du retrait est contrôlée selon une valeur de seuil.

o Procédure de débruitage des Wavelets

La méthode de débruitage des données des wavelets basée sur le seuillage pour obtenir des signaux détériorés a été introduite par Donoho (1995). Dans ce procédé, d'abord un signal est décomposé en différents sous-signaux à différentes résolutions en contrôlant les coefficients de mise à l'échelle et de décalage par la transformée en wavelets. De cette façon, des propriétés de localisation fiables capturées dans les domaines du temps et de la fréquence peuvent être fournies. Deuxièmement, une règle de seuillage est appliquée sur les sous-signaux. Les facteurs de base qui doivent être respectés dans cette méthode comprennent: la sélection d'une wavelet mère, le niveau de décomposition, la règle de seuil (thresholding) et estimation précise de la règle de seuil (treshold). Pour une wavelet mère $\psi(t)$, la fonction base en wavelets peut être considérée comme suit (Nourani,2014) :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a \in \mathbb{R}^+, b \in \mathbb{R}$$

Dans cette équation a, b et R indiquent respectivement des facteurs d'échelle et de décalage et le domaine du nombre réel et $\psi_{a,b}(t)$ est l'ondelette successive. La transformée en wavelet du signal f(t), peut être donnée comme suit :

$$\omega_f(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt$$

La transformée en wavelets d'une série temporelle f(t) décompose la wavelet sous divers niveaux de résolution. En appliquant une transformée en wavelets successives, le signal principal de f (t) est reconstruit en utilisant une transformée inverse en utilisant les coefficients de wavelets de $\omega_f(a, b)$ comme (Sang et al., 2009a)

$$f(t) = \left[\int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega \right]^{-1} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{a^2} \omega_f(a, b) \psi_{a,b}(t) da db$$

La technique de seuillage à base de wavelets comme approche d'évacuation des données largement utilisée se déroule par trois étapes (Donoho 1995) :

- 1) D'abord, une wavelet mère appropriée et un niveau de résolution raisonnable de N sont choisis pour la période spécifiée du processus d'étude pour décomposer les séries temporelles principales d'une sous-série d'approximation au niveau N et N sous-séries détaillées via une transformée en wavelet.
- 2) Dans la deuxième étape, les valeurs absolues de la sous-série détaillée en niveau de résolution de i $d_i(t)$ ($i = 1, 2, \dots, N$) qui sont inférieures à un seuil spécifié de T seront changées en Zéro, mais si les valeurs des sous-séries détaillées au même niveau de résolution dépassent ce seuil spécifié, leur différence avec la valeur de seuil est considérée comme la valeur modifiée des sous-séries détaillées. Où la procédure de seuillage peut être démontrée mathématiquement par (Donoho 1995):

$$d_i(t) = \begin{cases} \text{sgn}(d_i(t))(|d_i(t)| - T) & |d_i(t)| > T \\ 0 & |d_i(t)| < T \end{cases}$$

Où i réfère à l'i ème niveau de résolution. L'équation précédente applique le seuillage à tous les niveaux de résolution sur les sous-séries détaillées, mais les sous-séries d'approximation ne sont pas incluses dans cette procédure de seuillage. Donoho et Johnstone (1995) ont proposé une formule pour déterminer une valeur de seuil optimale générale pour les signaux qui incluent des bruits blancs gaussiens comme suit :

$$T = \hat{\sigma} \sqrt{2 \log_e(n)}$$

Où n est le nombre d'échantillons dans le signal bruyant et $\hat{\sigma}$ est l'écart type des bruits qui peuvent être obtenus comme (Donoho et Johnstone, 1995) :

$$\hat{\sigma} = \frac{\text{median}(|d_i(t)|)}{0.6745}$$

Donc, cela $|d_i(t)|$ représente un coefficient de wavelets détaillé des séries temporelles principales du premier niveau.

- 3) À la troisième étape, la sous-série détériorée (lissée) peut être reconstruite par des sous-séries détaillées modifiées à tous les niveaux de résolution et sous-séries d'approximation au niveau de résolution N par la transformée en wavelets inverse.

Les étapes mentionnées ci-dessus vont être utilisées pour débruiter les données de la pluie et du débit.

Comme cela a été montré dans le diagramme ci-dessous, la procédure de débruitage n'est pas appliquée sur la sous-série d'approximation dans laquelle cette sous-série inclut des fluctuations à grande échelle tendances et effectives du processus et ne sont pas affectées par la sous-série de débruitage des échelles plus petites. De toute évidence, en changeant le niveau de décomposition (N), le degré de fluctuations de grande échelle inclus dans les sous-ensembles d'approximation inchangés est modifié. Dans cette étude, la méthode de seuillage général (universel) a été appliquée pour la procédure de débruitage dans laquelle, dans cette méthode, le seuil est appliqué à toutes les sous-séries de détail. Cependant, il existe d'autres méthodes sophistiquées qui, comme algorithmes de seuil basés sur le niveau, n'apparaissent que dans certains sous-ensembles de détail (certains niveaux d'échelle) plutôt que pour tous les niveaux d'échelle (Nourani et al., 2014).

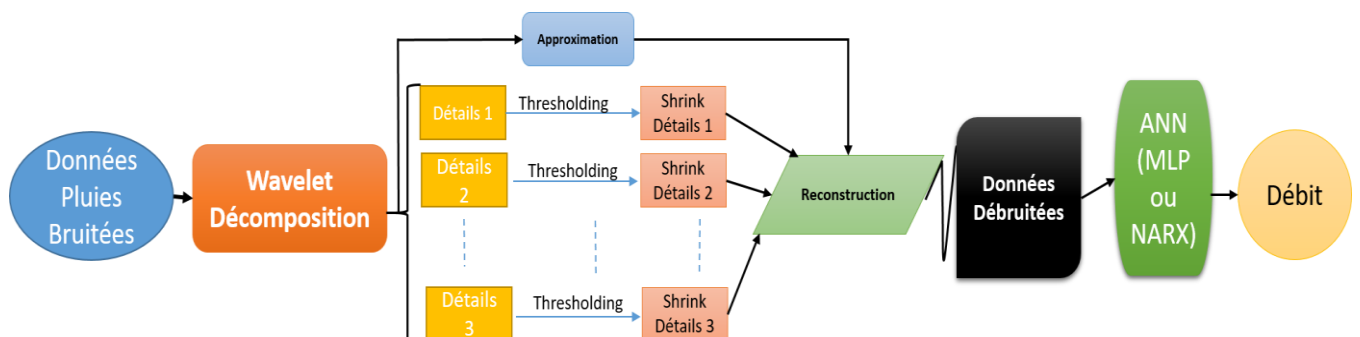


Figure 4.15: Diagramme du modèle Wavelet-ANN (MLP)

La validité de la détermination du seuil dans les séries chronologiques hydrologiques a été un grand défi et de nombreuses méthodes classiques telles que Fixed Threshold, SURE et MINIMAX pour déterminer les seuils de signaux détaillés de wavelets ont rencontré certains inconvénients. Le premier inconvénient est que les méthodes classiques de détermination du seuil dans les séries chronologiques hydrologiques sont généralement appropriées pour l'analyse de la distribution normale des bruits. La deuxième condition problématique est que les bruits séparés des séries hydrologiques d'origine sont généralement bien auto-corrélés. Et enfin, pour différentes méthodes, les valeurs de seuil des signaux détaillés d'ondelettes sont assorties (Sang et al. 2009b). Par conséquent, une plus grande procédure d'essai est nécessaire pour déterminer la valeur seuil appropriée sans considérer comment la distribution de bruit est la valeur de seuil influence la procédure de désenfumage des séries chronologiques hydrologiques dans deux aspects différents. Tout d'abord, si la valeur de seuil est correcte, la

réduction du bruit serait faible. Inversement si la valeur de seuil est grande, en conséquence, le bruit serait supprimé, mais les informations principales des séries chronologiques seraient également supprimées. Par conséquent, le seuil approprié ne supprime pas seulement le bruit mais aussi la partie principale de la série temporelle. Ainsi, la détermination de la valeur de seuil appropriée conduit à une performance supérieure dans la phase de prévision.

Après l'étape du wavelet et threshold (Prétraitement), on considère les nouvelles données obtenues par le prétraitement comme une entrée des modèles ANN (NARX et MLP) et donc refaire les étapes mentionnées dans la partie (4.3.1.1).

4.4 Outil informatique de mise en œuvre des modèles :

Pour la mise en œuvre de nos modèles, nous avons utilisé matlab. Dans la mesure où la toolbox de matlab ne répond pas à nos objectifs de modélisation, nous avons été amenés à développer notre propre programme dans Matlab composé des sous programmes suivants :

- Le débruitage avec la transformée en wavelet niveau 1 (décomposition en transformée de wavelet, threshold et reconstruction) ;
- Le débruitage avec la transformée en wavelet niveau 2 ;
- Le débruitage avec la transformée en wavelet niveau 3 ;
- Perceptron multicouches avec non-linéaire input-output + critères de performances ;
- Modèle NARX + critères de performances.

Cet outil informatique, nous a permis d'effectuer les simulations nécessaires à notre étude.

4.5 Critères de validation choisis

Estimer les performances d'un modèle à simuler les débits d'un bassin est l'étape la plus délicate dans ce procédé. La comparaison entre les données observées et celles simulées par le modèle est une étape importante pour une bonne qualité de simulation.

La méthode du double échantillon est la méthode la plus conseillée, cette méthode consiste à subdiviser les données en deux ensembles, une partie pour le calage (généralement les deux tiers des données globales), et le tester sur l'autre partie (la validation).

Deux types de critères vont être utilisés :

- Critère graphique : les graphes $Q_{\text{predicted}} = f(Q_{\text{observed}})$, c'est l'ajustement graphique des données observées et données simulées. Ça permet de donner une observation visuelle.
- Les autres critères qu'on va utiliser sont : NASH, RSR, Pbias, R^2 (détaillés dans le chapitre 1).

Chapitre 5

Analyse des résultats

Chapitre 5 Analyse des résultats

5.1 Le taux de performance d'un modèle :

Dans ce chapitre nous analyserons les résultats des modèles pour évaluer leur performance. Cette performance est évaluée sur la base de 4 critères développés dans le chapitre 1, à savoir le RSR, le Nash, le Pbias et le R^2 ou sur un critère graphique.

En fonction des valeurs des 3 premiers critères, on peut distinguer quatre taux de performance d'un modèle : Très Bon, Bon, Satisfaisant et Non satisfaisant comme le montre le tableau suivant :

Tableau 5.1: Intervalles d'appréciation des critères de validation (Yetoui, 2012)

Taux de performance	Nash (NSE)	RSR	PBIAS : Débits liquide (%)
Très bon	$0,75 < NSE \leq 1,0$	$0,0 \leq RSR \leq 0,5$	$ PBIAS < 15$
Bon	$0,65 < NSE \leq 0,75$	$0,5 < RSR \leq 0,6$	$15 \leq PBIAS < 30$
Satisfaisant	$0,5 < NSE \leq 0,65$	$0,6 < RSR \leq 0,7$	$30 \leq PBIAS < 55$
insatisfaisant	$NSE \leq 0,5$	$RSR > 0,7$	$ PBIAS \geq 55$

L'application de ce tableau à nos modèles pour chacune des 3 régions donne les résultats qualitatifs suivants (les valeurs chiffrées sont présentées en Annexe).

5.2 Région de Belle-Isle-en-Terre, France :

5.2.1 Les modèles Réseaux neurones artificiels (ANN)

❖ Modèles Multicouches perceptrons (MLP) : (Non linéaire input-output)

Pour ce premier modèle, on a comme entrée la pluie au temps t-1, t-2, t-3,...,t-d, ci-dessous la pluie journalière de la région de Belle-Isle-en-Terre de la période du 01/01/1992 au 01/01 /1995 (730 données).

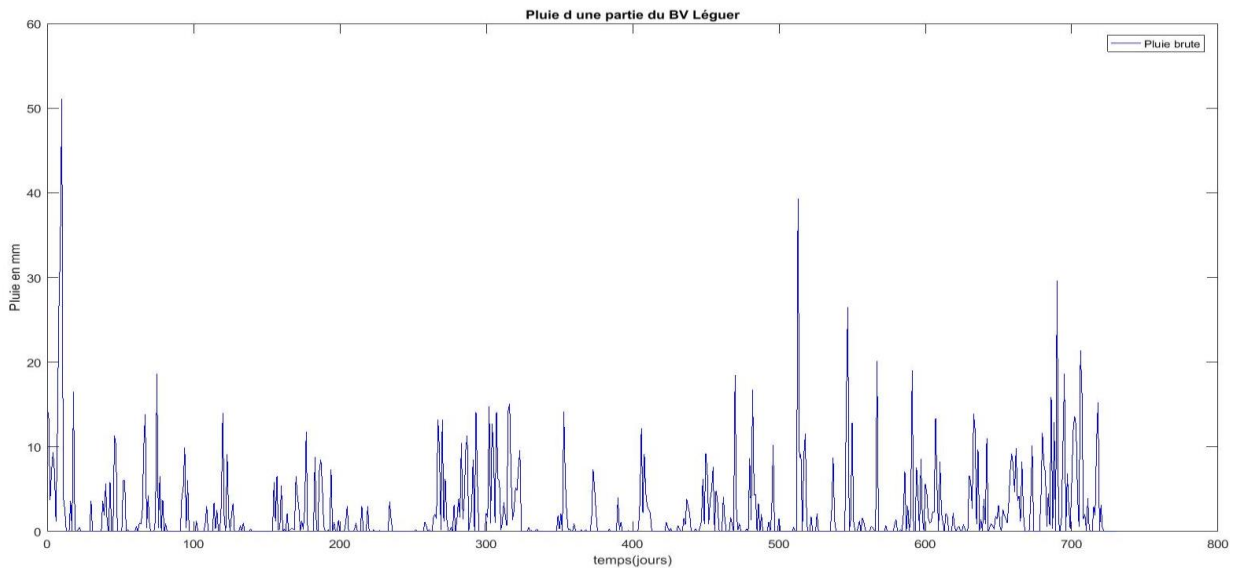


Figure 5.1 Pluie journalière du BV du Léguer:

Le modèle programmé, se base sur le diagramme suivant :



L’autoapprentissage se fait grâce à la backpropagation pour initialiser les poids et les biais et les réajuster à chaque fois et à l’algorithme de Levenberg-Marquardt, Rappelons que dans notre cas on a subdivisé les données en deux blocs, les deux tiers pour le training (apprentissage) et l’autre partie pour la validation, pour le test, on a préféré tester toutes les données.

Pour le critère numérique, on dispose des figures suivantes pour l’un des cas (10-14-1 ζ -à-d $d=5$ et nombre de neurone=14) :




Figure 5.2: Débit observé et Débit simulé pour la partie validation selon le modèle MLP (non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer




Figure 5.3: Débit observé et Débit simulé pour la partie validation selon le modèle MLP (non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer




Figure 5.4: Débit observé et Débit simulé pour le test selon le modèle MLP non linear inpput-output pour la structure 10-14-1 pour le BV du Léguer

Selon les graphiques, on remarque que le modèle ne simule pas bien les débits et surtout dans la partie validation (les débits qui varient entre 0 et 4 mm/j).

Le tableau ci-dessous montre qu'aussi bien pour le critère Nash et que celui du RSR, le modèle MLP est insatisfaisant pour les phases training, validation et test du modèle pluie débit malgré la variation du nombre de neurones et le retard d (delay).

La dernière colonne montre que le coefficient de détermination R^2 ne dépasse pas 50%, excepté pour la phase training du modèle avec 14 neurones et le retard de 5 pour laquelle ce coefficient atteint 50,9%. Nous allons voir si le fait de le coupler avec la wavelet va améliorer sa performance.

Tableau 5.2 : Performance du modèle ANN selon les 4 critères de performance (Nash, RSR, Pbias et R²) pour le BV du Léguer

Nombre neurones	Retard d	Nombre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	Training	Insatisfaisant	Insatisfaisant	Satisfaisant	50,90%
		Validation	Insatisfaisant	Insatisfaisant	Très Bon	22,15%
		Test	Insatisfaisant	Insatisfaisant	Bon	33,04%
16	4	Training	Insatisfaisant	Insatisfaisant	Bon	47,03%
		Validation	Insatisfaisant	Insatisfaisant	Très Bon	21,31%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	30,54%
10	6	Training	Insatisfaisant	Insatisfaisant	Très Bon	49,87%
		Validation	Insatisfaisant	Insatisfaisant	Très Bon	22,54%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	33,86%

❖ **Wavelet (Coif1 niveau de décomposition maximal = 3)**

Dans cette partie, on va d'abord débruité la pluie et le débit pour cela on commence avec la décomposition en transformée wavelet, dans notre cas on a utilisé Coiflet 1 avec le niveau de décomposition maximale ç-à-d log(730) c'est le niveau trois , ensuite pour le threshold (seuil) on a opté pour Universal threshold qu'on l'applique que sur les détails et après on va reconstruire le signal pour obtenir les graphiques suivants :




Figure 5.5 : Avant et après le débruitage de la série de données de la pluie pour le BV du Léguer

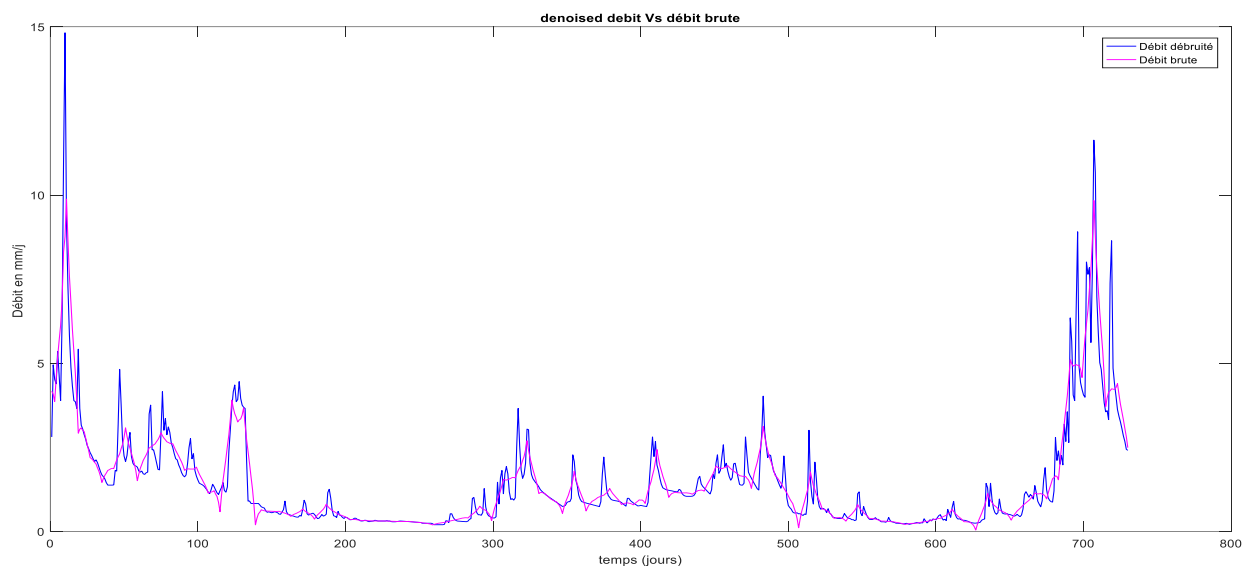


Figure 5.6 : Avant et après le débruitage de la série de données du débit pour le BV du Léguer

Le tableau ci-dessous, montre qu'avec le couplage, les résultats ne s'améliorent pas, ce qui peut s'expliquer par le faite que le modèle MLP ne prend pas en compte le facteur débit.

Tableau 5.3 : Performance du modèle Wavelet-ANN selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Nombre neurones	Retard D	Nombre couche cachée=1	Nash	RSR	Pbias %	R^2 %
14	5	training	Insatisfaisant	Insatisfaisant	Très Bon	49,23%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	27,28%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	34,55%
16	4	training	Insatisfaisant	Insatisfaisant	Très Bon	49,90%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	17,16%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	28,60%
10	6	training	Insatisfaisant	Insatisfaisant	Très Bon	49,12%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	25,40%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	35,40%

Pour confirmer cette idée, les graphiques ci-dessous, montre le débit observé et simulé pour la phase training, validation et test :




Figure 5.7 Débit observé et Débit simulé pour le training (apprentissage) selon le modèle Wavelet-ANN pour la structure 10-14-1 pour le BV du Léguer




Figure 5.8 : Débit observé et Débit simulé pour la validation selon le modèle wavelet-ANN (MLP) pour la structure 10-14-1 pour le BV du Léguer




Figure 5.9 : Débit observé et Débit simulé pour le test selon le modèle wavelet-ANN (MLP) pour la structure 10-14-1 pour le BV du Léguer

On remarque qu’effectivement, il n’y a pas eu de changement, même dans le graphique.

❖ **Modèles Narx**

Pour évaluer le critère numérique, on dispose des figures du débit dans la phase de training et validation et test suivantes pour l’un des cas (4-6-1 ç-à-d d=2 et nombre de neurone=6) :




Figure 5.10 Le débit simulé et le débit observé en fonction du temps (jours) de la partie training pour le BV du Léguer




Figure 5.11 Le débit simulé et le débit observé en fonction du temps (jours) de la partie validation pour le BV du Léguer




Figure 5.12 : Le débit simulé et le débit observé en fonction du temps (jours) de la partie testing pour le BV du Léguer

Nous remarquons à première vue que le modèle simule bien les données qu'on a inséré.

Nous avons simulé quatre structures du modèle NARX (4, n,1 ; 6, n,1 ; 8, n,1 ; 10, n,1) et pour chaque structure on a varié le nombre de neurones de 2 à 15 et nous avons retenu 3 résultats pour chaque structure. Ainsi il ressort du tableau de simulation ci-dessous que le taux de performance de ces modèles est très bon et le coefficient de détermination sont très élevés.

Les quatre structures présentées sont performantes. Nous allons voir si le couplage avec la wavelet influera significativement sur cette performance.

Tableau 5.4 Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R²) pour le BV du Léguer

Structure ANN	Retard d		Nash	RSR	Pbias %	R ² %	
Q(t+1) = f(Qt, Qt-1, Pt-1, Pt) (4,n,1)	6-8-1	training	Très Bon	Très Bon	Très Bon	96.94%	
		validation	Très Bon	Très Bon	Très Bon	92.26%	
		test	Très Bon	Très Bon	Très Bon	94.48%	
	4-8-1	2	training	Très Bon	Très Bon	Bon	94.77%
			validation	Très Bon	Très Bon	Très Bon	82.43%
			test	Très Bon	Très Bon	Bon	88.13%
	4-12-1	training	Très Bon	Très Bon	Très Bon	96.43%	
		validation	Très Bon	Très Bon	Très Bon	86.79%	
		test	Très Bon	Très Bon	Très Bon	91.48%	
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2) (6,n,1)	6-10-1	training	Très Bon	Très Bon	Très Bon	96.27%	
		validation	Très Bon	Très Bon	Bon	81.77%	
		test	Très Bon	Très Bon	Très Bon	88.20%	
	6-8-1	3	training	Très Bon	Très Bon	Très Bon	94.64%
			validation	Très Bon	Très Bon	Très Bon	88.40%
			test	Très Bon	Très Bon	Très Bon	91.40%
	6-12-1	training	Très Bon	Très Bon	Très Bon	97.46%	
		validation	Très Bon	Très Bon	Très Bon	85.41%	
		test	Très Bon	Très Bon	Très Bon	91.17%	
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1)	8-8-1	training	Très Bon	Très Bon	Très Bon	96.23%	
		validation	Très Bon	Très Bon	Très Bon	91.59%	
		test	Très Bon	Très Bon	Très Bon	93.70%	
	8-11-1	4	training	Très Bon	Très Bon	Très Bon	96.73%
			validation	Très Bon	Très Bon	Très Bon	88.88%
			test	Très Bon	Très Bon	Très Bon	92.06%
	8-13-1	training	Très Bon	Très Bon	Très Bon	97.41%	
		validation	Très Bon	Très Bon	Très Bon	90.87%	
		test	Très Bon	Très Bon	Très Bon	93.86%	
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-	10-8-1	5	training	Très Bon	Très Bon	Très Bon	96.96%
			validation	Très Bon	Très Bon	Très Bon	90.16%
			test	Très Bon	Très Bon	Très Bon	93.20%

2, Qt-2,Pt-3, Qt-3, Pt-4, Qt-4)	10-10-1	training	Très Bon	Très Bon	Très Bon	95.96%
		validation	Très Bon	Très Bon	Très Bon	86.98%
(10,n,1)	10-6-1	test	Très Bon	Très Bon	Très Bon	89.72%
		training	Très Bon	Très Bon	Très Bon	97.31%
		validation	Très Bon	Très Bon	Très Bon	87.77%
		Test	Très Bon	Très Bon	Très Bon	92.05%

❖ Couplage Wavelet-ANN (NARX)

Le couplage Wavelet-ANN a été appliqué aux structures (6,n,1 ; 8 ,n ,1 ; 10,n,1) précédentes selon la décomposition en transformée wavelet en utilisant le Haar, daubechies 2 , coiflet 1 et symlet 3 (figures ci-dessous) avec trois niveaux de décomposition (du niveau 1 au niveau max).




Figure 5.13: Pluie journalière du BV Léguer débruitée en utilisant sym3




Figure 14 Débit en mm/j du BV Léguer debruité en utilisant sym3

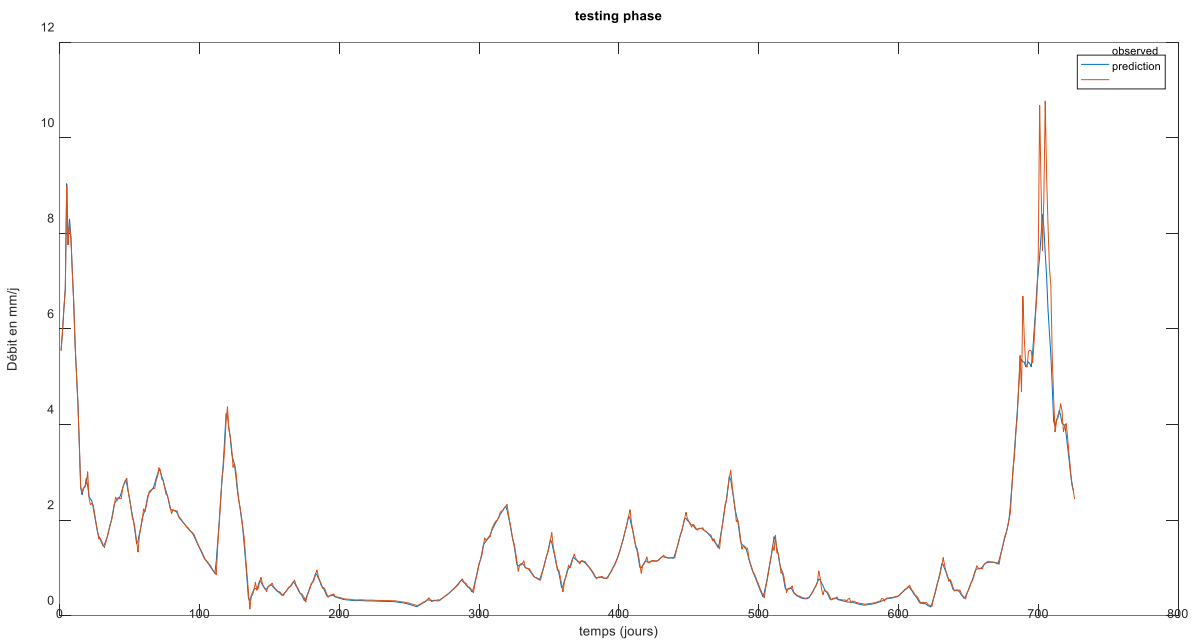


Figure 5.15 : Le débit simulé et le débit observé en fonction du temps (jours) de la partie testing pour le BV du Léguer




Figure 5.16 : : Le débit simulé et le débit observé en fonction du temps (jours) de la partie training pour le BV du Léguer




Figure 5.17 : : Le débit simulé et le débit observé en fonction du temps (jours) de la partie validation pour le BV du Léguer

L'analyse du tableau ci-dessous des résultats de simulations montre que le taux de performance des modeles est toujours très bon ce qui montre que dans ce cas la wavelet n'influe pas significativement du fait que les performances du modeles NARX étaient déjà très bonnes.

Tableau 5.5 Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R^2) pour le BV du Léguer

Wavelet	Level decomposition	Structure neuronal d		Nash	RSR	Pbias %	R ² %
Haar	1	8-11-1 4	training	Très Bon	Très Bon	Très Bon	95.09%
			validation	Très Bon	Très Bon	Très Bon	85.84%
			test	Très Bon	Très Bon	Très Bon	90.26%
Haar	2	8-15-1 4	training	Très Bon	Très Bon	Très Bon	95.26%
			validation	Très Bon	Très Bon	Très Bon	91.89%
			test	Très Bon	Très Bon	Très Bon	93.11%
Haar	3	8-8-1 4	training	Très Bon	Très Bon	Très Bon	95.35%
			validation	Très Bon	Très Bon	Très Bon	90.93%
			test	Très Bon	Très Bon	Très Bon	92.94%
Db2	1	6-8-1 3	training	Très Bon	Très Bon	Très Bon	97.39%
			validation	Très Bon	Très Bon	Très Bon	91.22%
			test	Très Bon	Très Bon	Très Bon	93.76%
Db2	2	8-9-1 4	training	Très Bon	Très Bon	Très Bon	97.63%
			validation	Très Bon	Très Bon	Très Bon	95.81%
			test	Très Bon	Très Bon	Très Bon	95.54%
Db2	3	8-9-1 4	training	Très Bon	Très Bon	Très Bon	99.18%
			validation	Très Bon	Très Bon	Très Bon	99.16%
			test	Très Bon	Très Bon	Très Bon	99.14%
Coif1	1	6-13-1 3	training	Très Bon	Très Bon	Très Bon	98.24%
			validation	Très Bon	Très Bon	Très Bon	90.73%
			test	Très Bon	Très Bon	Très Bon	93.53%
Coif1	2	8-8-1 4	training	Très Bon	Très Bon	Très Bon	98.40%
			validation	Très Bon	Très Bon	Très Bon	95.06%
			test	Très Bon	Très Bon	Très Bon	96.14%
Coif1	3	10-11-1 5	training	Très Bon	Très Bon	Très Bon	99.40%
			validation	Très Bon	Très Bon	Très Bon	98.80%
			test	Très Bon	Très Bon	Très Bon	99.03%
Sym3	1	6-7-1 3	training	Très Bon	Très Bon	Très Bon	97.96%
			validation	Très Bon	Très Bon	Très Bon	94.75%
			test	Très Bon	Très Bon	Très Bon	96.29%
Sym3	2	8-12-1 4	training	Très Bon	Très Bon	Très Bon	99.00%
			validation	Très Bon	Très Bon	Très Bon	97.60%
			test	Très Bon	Très Bon	Très Bon	98.03%
Sym3	3	10-14-1 5	training	Très Bon	Très Bon	Très Bon	99.61%
			validation	Très Bon	Très Bon	Très Bon	98.41%
			Test	Très Bon	Très Bon	Très Bon	98.89%

Maintenant on va comparer les résultats des graphes, $Q_{\text{predicted}}=f(Q_{\text{observé}})$ et voir s'il y'a eu lieu un changement lors du couplage Wavelet-ANN (NARX).

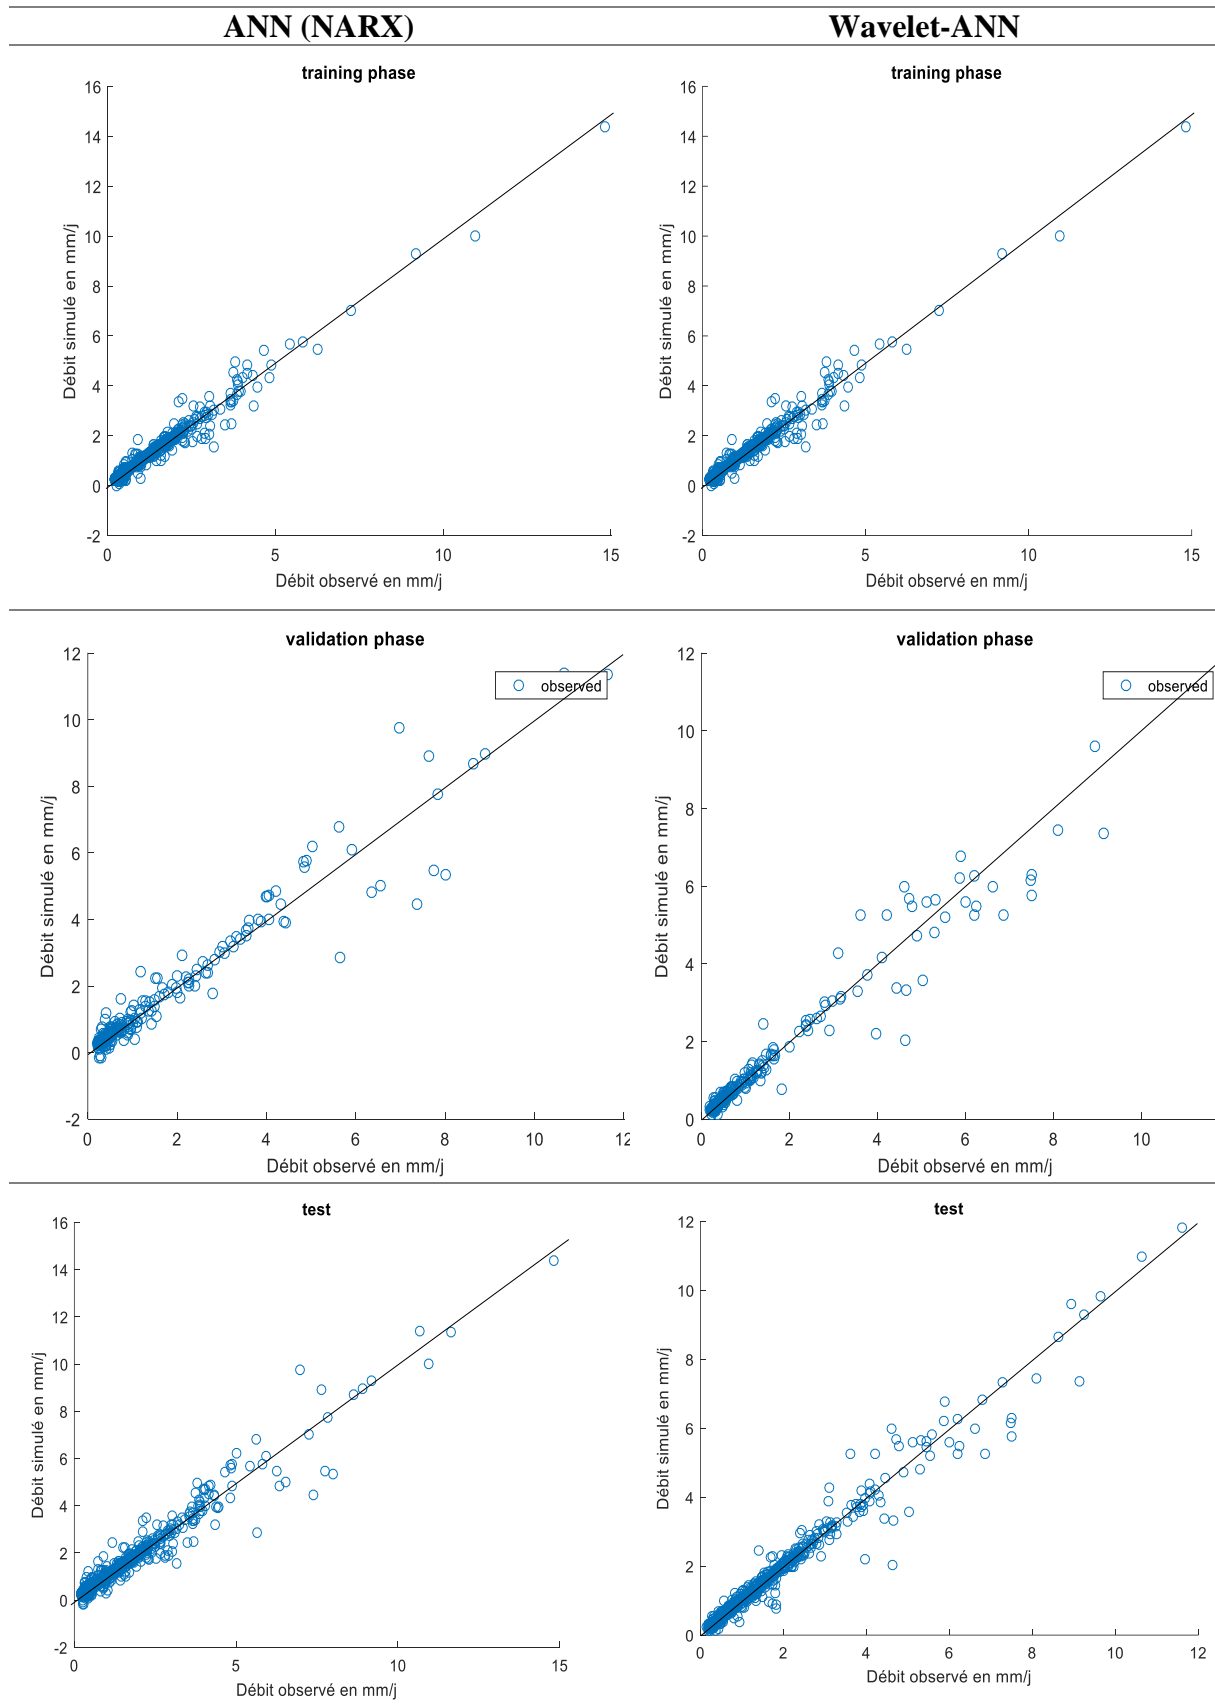


Figure 18: Variation des graphes $Q_{predicted}=f(Q_{observed})$, dans le training, validation et test pour le BV du Léguer

A part les quelques points dans la partie training (pour un débit observé entre 0 et 5 mm/jr) et dans la partie de validation. Aucune grande amélioration n'a été aperçu.

5.3 Région de Zardezas, Algérie :

❖ Modèles Multicouches perceptrons (MLP) :

Pour ce modèle, on a comme entrée la pluie au temps $t-1, t-2, t-3, \dots, t-d$, ci-dessous la pluie journalière de la région de Zardezas de la période du 01/01/1990 au 01/01/1996 (2191 données).




Figure 5.19 Pluie journalière du BV de Zardezas

Selon les graphiques, on remarque que le modèle ne simule pas bien les débits et surtout dans la partie validation (elle contient beaucoup de débits élevés).

Le tableau ci-dessous montre qu'aussi bien pour le critère Nash et que celui du RSR, le modèle MLP est insatisfaisant pour les phases training, validation et test du modèle pluie débit malgré la variation du nombre de neurones et le retard d (delay).

La dernière colonne montre que le coefficient de détermination R^2 ne dépasse pas 45. Nous allons voir si le fait de le coupler avec la wavelet va améliorer sa performance.

Tableau 5.6 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R^2) du BV de Zardezas

Structure ANN	D	Nbre couche cachée=1	Nash	RSR	Pbias	R^2
					%	%
10-14-1	5	training	Insatisfaisant	Insatisfaisant	Satisfaisant	33,68%
		validation	Insatisfaisant	Insatisfaisant	Insatisfaisant	31,19%
		Test	Insatisfaisant	Insatisfaisant	Satisfaisant	32,00%
8-16-1	4	training	Insatisfaisant	Insatisfaisant	Très Bon	30,92%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	26,28%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	28,98%
12-10-1	6	training	Insatisfaisant	Insatisfaisant	Très Bon	37,90%
		validation	Insatisfaisant	Insatisfaisant	Bon	43,90%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	38,60%

Wavelet (Coif1 niveau de decomposition maximale =3)

On remarque une légère amélioration dans le R^2 , mais ce n'est pas le cas dans le RSR et Nash, à part pour la structure 14-5-1 dans la partie de validation, y'a eu une amélioration du RSR de la valeur 0,8854 vers la valeur 0,6979 et pour le Nash de 0,216 à 0,513. Malgré cette améliorations le modèle reste insatisfaisant. Le tableau ci-dessous montre les résultats du couplage wavelet-MLP pour la région de Zardezas.




Figure 5.20 : Débruitage en utilisant coif1 pour la série de pluie




Figure 5.21 : Débruitage en utilisant coif1 pour la série du débit

Tableau 5.7 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV de Zardezas

Structure ANN	D	Nbre couche cachée=1	Nash	RSR	Pbias	R ²
					%	%
10-14-1	5	training	Insatisfaisant	Insatisfaisant	Très Bon	54,71%
		validation	Satisfaisant	Satisfaisant	Très Bon	52,28%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	52,42%
8-16-1	4	training	Insatisfaisant	Insatisfaisant	Très Bon	51,11%
		validation	Insatisfaisant	Insatisfaisant	Bon	45,71%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	47,54%
12-10-1	6	training	Insatisfaisant	Insatisfaisant	Très Bon	56,26%
		validation	Insatisfaisant	Insatisfaisant	Bon	44,50%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	50,15%

❖ Modèles Narx :

Nous avons simulé quatre structures du modèle NARX (4, n,1 ; 6, n,1 ; 8, n,1 ; 10, n,1) et pour chaque structure on a varié le nombre de neurones de 2 à 15 et nous avons retenu 3 résultats pour chaque structure. Ainsi il ressort du tableau de simulation ci-dessous que le taux de performance de ces modèles pour les structures 4-n-1 sont insuffisante pour la validation mais satisfaisante pour le test et la validation, sauf dans la première structure où n=8 le modèle est Pour les autres structures le training est bon voir même très bon et même celle du test. Mais le critère de validation de validation est satisfaisant.

Les quatre structures présentées sont performantes. Nous allons voir si le couplage avec la wavelet influera significativement sur cette performance.

Tableau 5.8 : Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV de Zardezas

Structure Nbre de neurone n ANN	d		Nash	RSR	Pbias	R ²	
					%	%	
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt) (4, n,1)	6-8-1	training	Bon	Bon	Très Bon	70.75%	
		validation	Satisfaisant	Satisfaisant	Très Bon	51.45%	
		test	Satisfaisant	Satisfaisant	Très Bon	62.86%	
	4-8-1	2	training	Bon	Bon	Bon	65.43%
			validation	Insatisfaisant	Insatisfaisant	Bon	42.17%
			test	Satisfaisant	Satisfaisant	Bon	54.21%
	4-12-1		training	Très Bon	Très Bon	Bon	76.97%
			validation	Insatisfaisant	Insatisfaisant	Bon	42.25%
			test	Satisfaisant	Satisfaisant	Bon	62.29%
Q(t+1) =f (Qt, Qt-1,	6-10-1	3	training	Très Bon	Très Bon	Très Bon	79.52%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	44.43%

Pt, Pt-1, Pt-2, Qt-2) (6, n,1)	6-8-1	test	Satisfaisant	Satisfaisant	Très Bon	62.56%	
		training	Bon	Bon	Très Bon	67.85%	
		validation	Insatisfaisant	Insatisfaisant	Bon	46.34%	
	6-12-1	test	Satisfaisant	Satisfaisant	Très Bon	59.10%	
		training	Très Bon	Très Bon	Très Bon	79.51%	
		validation	Insatisfaisant	Insatisfaisant	Bon	44.86%	
		Test	Satisfaisant	Bon	Très Bon	64.66%	
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1	8-8-1	Training	Bon	Bon	Très Bon	70.04%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	41.45%	
		Test	Satisfaisant	Satisfaisant	Très Bon	56.73%	
	8-11-1	4	training	Bon	Bon	Très Bon	69.48%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	47.02%	
		test	Satisfaisant	Satisfaisant	Très Bon	59.85%	
	8-13-1	training	Bon	Bon	Très Bon	76.26%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	42.86%	
		test	Insatisfaisant	Insatisfaisant	Très Bon	57.45%	
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3, Pt-4, Qt-4) (10,n,1)	10-8-1	training	Très Bon	Très Bon	Satisfaisant	78.77%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	48.41%	
		test	Satisfaisant	Satisfaisant	Bon	60.22%	
	10-10-1	5	training	Très Bon	Très Bon	Très Bon	81.74%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	47.96%	
		test	Satisfaisant	Satisfaisant	Très Bon	62.79%	
	10-6-1	training	Très Bon	Très Bon	Très Bon	79.12%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	47.71%	
			Test	Satisfaisant	Satisfaisant	Très Bon	63.87%

Wavelet-ANN (NARX)

Dans le tableau ci-dessous, On remarque une amélioration dans le R². La plupart des résultats est devenu satisfaisante après l'introduction du wavelet.

Tableau 5.9 Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV de Zardezas

Wavelet	Level decomposition	ANN structure		Nash	RSR	Pbias	R ²
	wavelet					%	%
Haar	1	8-11-1	training	Très Bon	Très Bon	Très Bon	79.81%
			validation	Satisfaisant	Satisfaisant	Très Bon	61.32%
			test	Bon	Bon	Très Bon	71.32%
	2	8-11-1	training	Très Bon	Très Bon	Très Bon	87.72%
			validation	Satisfaisant	Satisfaisant	Très Bon	64.02%
			test	Bon	Bon	Très Bon	75.52%
	3	6-11-1	training	Très Bon	Très Bon	Très Bon	85.12%
			validation	Bon	Bon	Très Bon	66.03%
			test	Très Bon	Très Bon	Très Bon	75.81%
Db2	1	8-9-1	training	Très Bon	Très Bon	Très Bon	85.59%
			validation	Bon	Bon	Très Bon	67.29%
			test	Très Bon	Très Bon	Très Bon	78.63%
	2	8-15-1	training	Très Bon	Très Bon	Très Bon	95.12%
			validation	Satisfaisant	Satisfaisant	Très Bon	69.98%
			test	Très Bon	Très Bon	Très Bon	84.23%
	3	8-6-1	training	Très Bon	Très Bon	Très Bon	93.88%
			validation	Bon	Bon	Très Bon	72.95%
			test	Très Bon	Très Bon	Très Bon	85.37%
Coif1	1	10-12-1	training	Très Bon	Très Bon	Bon	88.91%
			validation	Bon	Bon	Bon	69.04%
			test	Très Bon	Très Bon	Bon	80.41%
	2	8-8-1	training	Très Bon	Très Bon	Satisfaisant	93.11%
			validation	Très Bon	Très Bon	Satisfaisant	84.21%
			test	Très Bon	Très Bon	Satisfaisant	88.98%
	3	10-11-1	training	Très Bon	Très Bon	Satisfaisant	93.58%
			validation	Très Bon	Très Bon	Satisfaisant	84.95%
			test	Très Bon	Très Bon	Satisfaisant	89.25%
Sym3	1	10-7-1	training	Très Bon	Très Bon	Très Bon	88.89%
			validation	Satisfaisant	Satisfaisant	Très Bon	67.05%
			test	Très Bon	Très Bon	Très Bon	79.24%
	2	8-9-1	training	Très Bon	Très Bon	Très Bon	97.77%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	53.79%
			test	Bon	Bon	Très Bon	76.87%
	3	8-9-1	training	Très Bon	Très Bon	Très Bon	98.15%
			validation	Bon	Bon	Très Bon	70.82%
			Test	Très Bon	Très Bon	Très Bon	85.80%

Maintenant on va comparer les résultats des graphes, $Q_{\text{predicted}}=f(Q_{\text{observé}})$ et voir s'il y'a eu lieu un changement lors du couplage Wavelet-ANN (NARX).

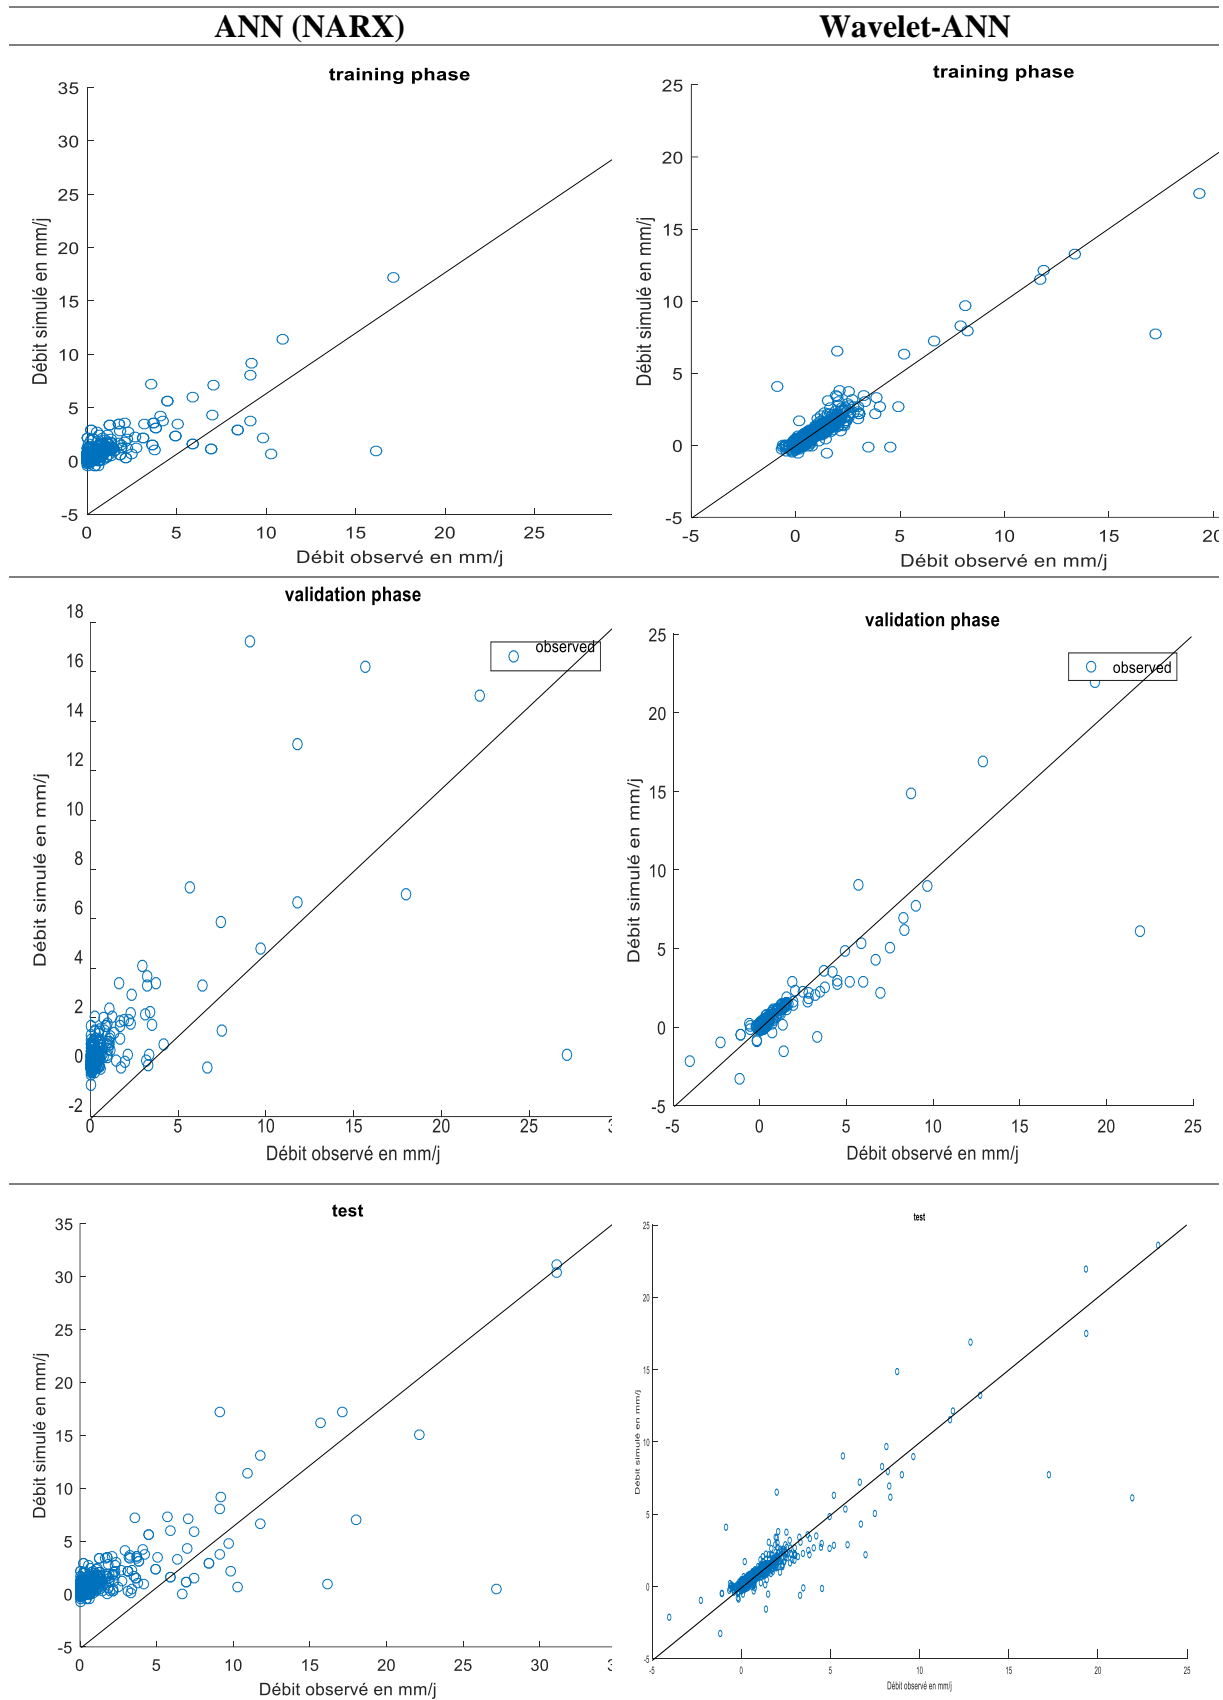


Figure 22: Variation des graphes $Q_{predicted}=f(Q_{observed})$, dans le training, validation et test pour le BV du Léguer

A part les quelques points dans la partie training (pour un débit observé entre 0 et 5 mm/jr) et dans la partie de validation. Aucune grande amélioration n'a été aperçue.

5.4 Région des Isser, Algérie :

❖ Modèles Multicouches perceptrons (MLP) :




Figure 23 Pluie du bassin versant Isser

Dans cette région pour le modèle MLP, on a obtenu des résultats insatisfaisants pour les quatre structures.

Tableau 5.10 : Performance du modèle MLP selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV des Isser

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	training	Bon	Bon	Très Bon	67,01%
		validation	Insatisfaisant	Insatisfaisant	Bon	5,82%
		Test	Insatisfaisant	Insatisfaisant	Très Bon	51,70%
16	4	training	Bon	Bon	Très Bon	74,39%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	16,46%
		Test	Satisfaisant	Satisfaisant	Très Bon	61,50%
10	6	training	Satisfaisant	Satisfaisant	Bon	62,60%
		validation	Insatisfaisant	Insatisfaisant	Satisfaisant	1,44%
		Test	Insatisfaisant	Insatisfaisant	Satisfaisant	32,75%

❖ Wavelet (Coif1 niveau de decomposition max 3)

Comme les autres régions, la wavelet couplé au modèle MLP n'a pas abouti à un résultat, appart l'amélioration des phases d'apprentissage (training) de toute les structures.

Tableau 5.11 : Performance du modèle Wavelet-MLP selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV Isser

Nbre neurones	D	Nbre couche cachée=1	Nash	RSR	Pbias	R ²
					%	%
14	5	training	Très Bon	Très Bon	Très Bon	77,05%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	25,60%
		Test	Bon	Bon	Très Bon	70,34%
16	4	training	Très Bon	Très Bon	Très Bon	80,74%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	29,04%
		Test	Bon	Bon	Très Bon	73,86%
10	6	training	Satisfaisant	Satisfaisant	Très Bon	64,62%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	34,21%
		Test	Satisfaisant	Satisfaisant	Très Bon	61,16%

❖ Modèles Narx :

Toujours le même problème que la région précédente. Le modèle NARX est insatisfaisant pour la validation peu importe la structure de ce modèle avec un R² ne dépassant pas les 50% dans la validation mais pour l'étape de training et test est satisfaisant.

Tableau 5.12 : Performance du modèle NARX selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV Isser

Structure ANN	d	Nash	RSR	Pbias	R ²		
				%	%		
Q(t+1) = f(Qt, Qt-1, Pt-1, Pt) (4, n,1)	4-6-1	training	Très Bon	Très Bon	Très Bon	85.86%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	28.05%	
		Test	Bon	Bon	Très Bon	72.85%	
	4-8-1	2	training	Très Bon	Très Bon	Très Bon	95.94%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	20.64%	
		Test	Satisfaisant	Satisfaisant	Très Bon	69.94%	
	4-12-1	training	Très Bon	Très Bon	Très Bon	96.70%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	21.33%	
		Test	Satisfaisant	Satisfaisant	Très Bon	70.05%	
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2) (6, n,1)	6-6-1	training	Très Bon	Très Bon	Très Bon	96.00%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	33.88%	
		Test	Très Bon	Très Bon	Très Bon	80.92%	
	6-8-1	3	training	Insatisfaisant	Insatisfaisant	Très Bon	45.22%
		validation	Insatisfaisant	Insatisfaisant	Très Bon	36.18%	
		test	Insatisfaisant	Insatisfaisant	Très Bon	42.84%	
	6-12-1	training	Très Bon	Très Bon	Très Bon	91.22%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	14.26%	
		test	Satisfaisant	Satisfaisant	Très Bon	66.99%	
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1)	8-8-1	4	training	Très Bon	Très Bon	76.89%	
		validation	Insatisfaisant	Insatisfaisant	Très Bon	33.03%	
		test	Bon	Bon	Très Bon	67.03%	

1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1)	8-11-1		training	Très Bon	Très Bon	Très Bon	96.12%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	41.32%
			test	Très Bon	Très Bon	Très Bon	84.73%
	8-13-1		training	Très Bon	Très Bon	Très Bon	85.71%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	43.73%
			test	Très Bon	Très Bon	Très Bon	77.06%
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3, Pt-4, Qt-4) (10,n,1)	10-8-1		training	Très Bon	Très Bon	Très Bon	87.21%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	34.64%
			test	Très Bon	Très Bon	Très Bon	75.40%
	10-10-1	5	training	Bon	Bon	Très Bon	73.80%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	48.36%
			test	Bon	Bon	Très Bon	68.33%
	10-6-1		training	Très Bon	Très Bon	Très Bon	84.35%
			validation	Insatisfaisant	Insatisfaisant	Très Bon	33.12%
			Test	Bon	Bon	Très Bon	72.99%

❖ Modele Wavelet-NARX

Quand on applique le couplage Wavelet-ANN au structures (6,n,1 ; 8 , n , 1 ; 10,n,1) précédentes selon la décomposition en transformée wavelet en utilisant le Haar, Daubechies 2, Coiflet 1 et Symlet 3 avec trois niveaux de decomposition (du niveau 1 au niveau max), on constate dans le tableau des résultats de simulations ci-dessous que le taux de performance des modèles s'est amélioré pour toutes les structures ANN pour la validation et les performances du modèle sont statisfaisants et même très bons ce qui montre que dans ce cas la wavelet influe significativement sur les performances du modèles, et cela est dû à la présence de beaucoup de piques de bruit et la variation du débit dans les données de la région des Isser. Le tableau ci-dessous montre les résultats en utilisant un couplage wavelet-ANN pour la région des isser.

Tableau 5.13: Performance du modèle Wavelet-NARX selon les 4 critères de performance (Nash, RSR, Pbias et R²) du BV Isser

Wavelet	Level decomposition	ANN structure	Nash	RSR	Pbias		R ²
					%	%	
Haar	1	10-13-1	training	Très Bon	Très Bon	Très Bon	94.66%
			validation	Très Bon	Très Bon	Très Bon	75.73%
			test	Très Bon	Très Bon	Très Bon	91.10%
	2	4-6-1	training	Très Bon	Très Bon	Très Bon	94.46%
			validation	Satisfaisant	Satisfaisant	Très Bon	64.37%
			test	Très Bon	Très Bon	Très Bon	88.99%
	3	6-13-1	training	Très Bon	Très Bon	Très Bon	94.69%
			validation	Satisfaisant	Satisfaisant	Très Bon	63.79%
			test	Très Bon	Très Bon	Très Bon	90.32%
Db2	1	6-8-1	training	Très Bon	Très Bon	Très Bon	92.08%
			validation	Bon	Bon	Très Bon	72.72%

			test	Très Bon	Très Bon	Très Bon	88.54%
	2	10-15-1	training	Très Bon	Très Bon	Très Bon	95.83%
			validation	Très Bon	Très Bon	Très Bon	75.45%
			test	Très Bon	Très Bon	Très Bon	92.73%
	3	6-11-1	training	Très Bon	Très Bon	Très Bon	92.92%
			validation	Bon	Bon	Très Bon	74.89%
			test	Très Bon	Très Bon	Très Bon	89.79%
Coif1	1	8-6-1	training	Très Bon	Très Bon	Très Bon	97.68%
			validation	Très Bon	Très Bon	Très Bon	75.44%
			test	Très Bon	Très Bon	Très Bon	93.46%
	2	6-10-1	training	Très Bon	Très Bon	Très Bon	97.74%
			validation	Très Bon	Très Bon	Bon	80.19%
			test	Très Bon	Très Bon	Très Bon	95.09%
	3	10-11-1	training	Très Bon	Très Bon	Très Bon	98.28%
			validation	Très Bon	Très Bon	Très Bon	86.62%
			test	Très Bon	Très Bon	Très Bon	96.91%
Sym3	1	6-13-1	training	Très Bon	Très Bon	Très Bon	95.14%
			validation	Satisfaisant	Satisfaisant	Très Bon	72.15%
			test	Très Bon	Très Bon	Très Bon	90.15%
	2	8-15-1	training	Très Bon	Très Bon	Très Bon	91.45%
			validation	Bon	Bon	Très Bon	72.75%
			test	Très Bon	Très Bon	Très Bon	87.62%
	3	8-11-1	training	Très Bon	Très Bon	Très Bon	96.46%
			validation	Bon	Bon	Très Bon	75.89%
			Test	Très Bon	Très Bon	Très Bon	93.34%

Maintenant on va comparer les résultats des graphes, $Q_{\text{predicted}}=f(Q_{\text{observé}})$ et voir s'il y'a eu lieu un changement lors du couplage Wavelet-ANN (NARX).

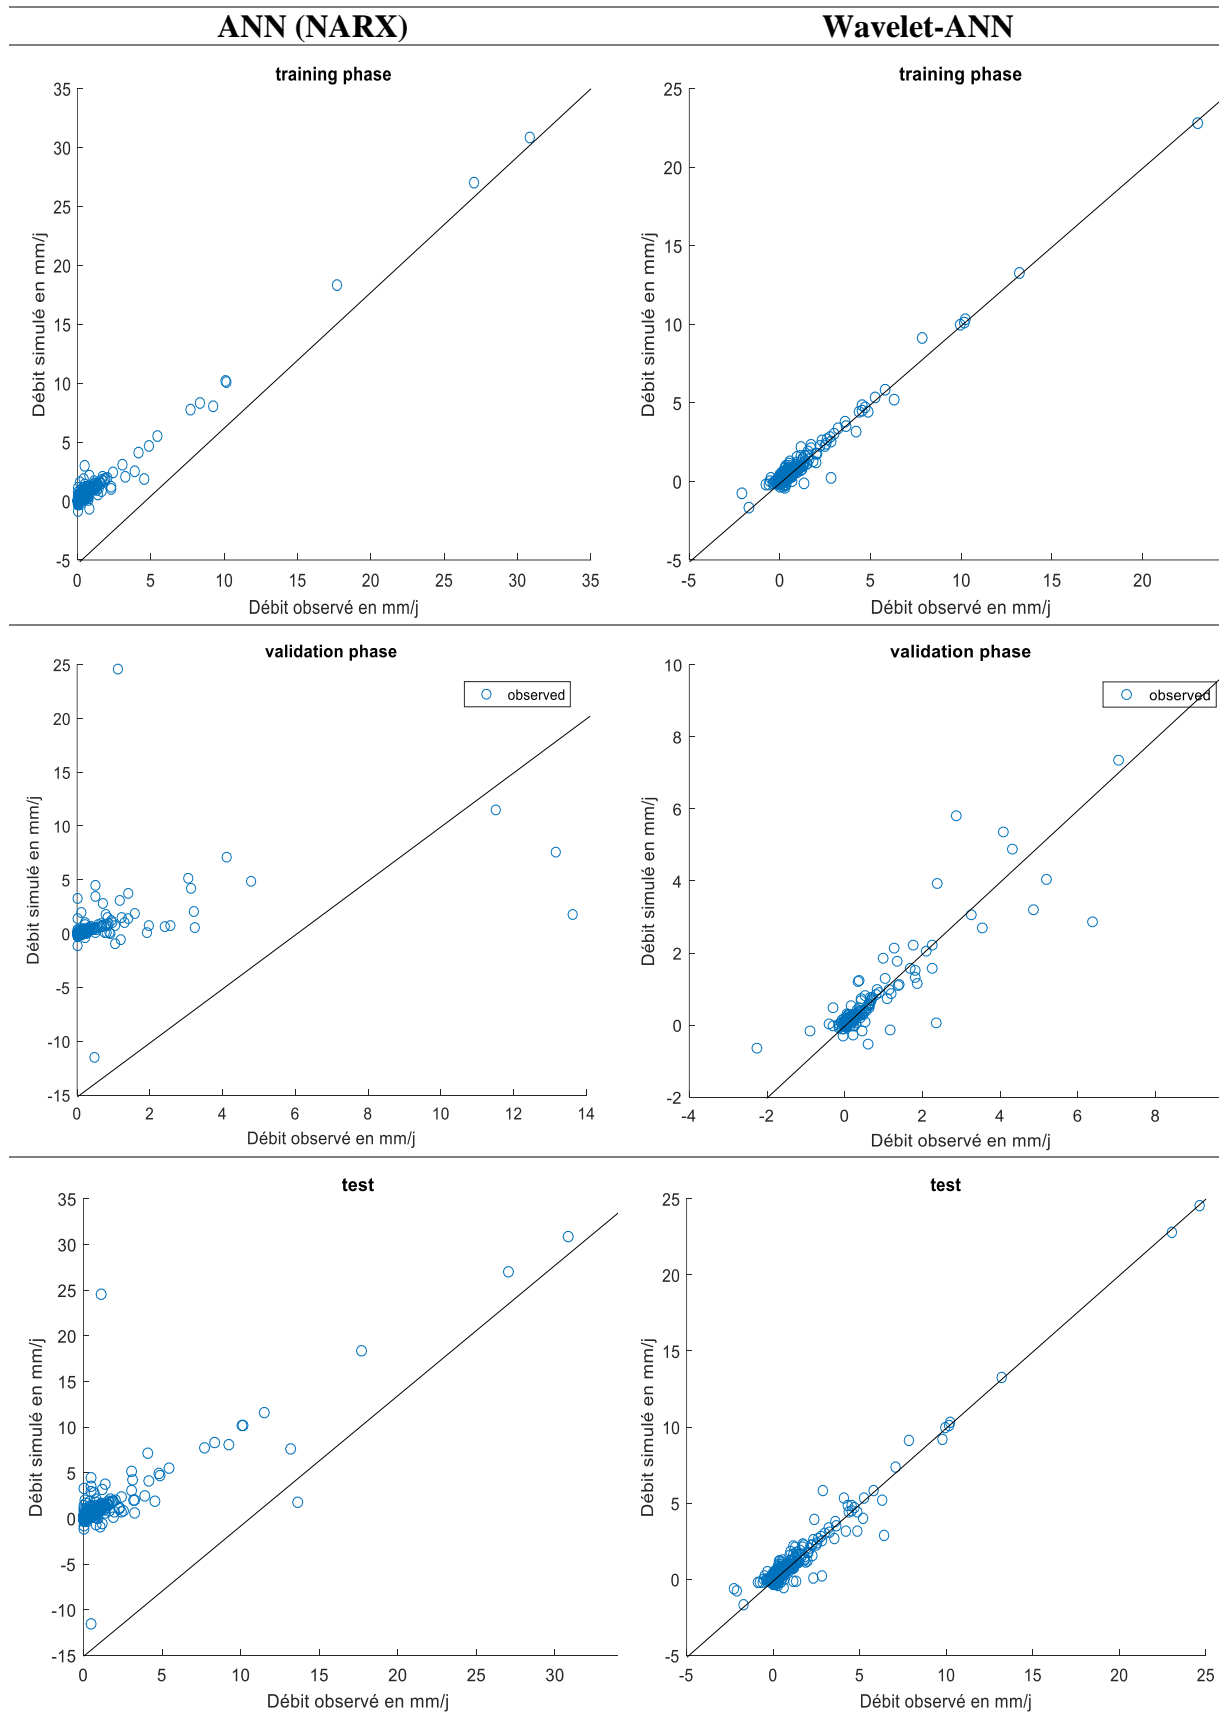


Figure 24: Variation des graphes $Q_{predicted}=f(Q_{observed})$, dans le training, validation et test pour le BV du Léguer

On remarque que la courbe s'affine bien pour le wavelet-NARX et que la globalité des valeurs des débits sont comprises entre 0mm/jr et 5mm/jr.

Conclusion générale

Le but de ce mémoire était de répondre à la question concernant le couplage wavelet- ANN pour la modélisation pluie-débit pour voir si le prétraitement avec les wavelet augmente les performances des modèles pluie-débit.

Pour répondre à cette problématique nous avons d'abord fait une modélisation pluie-débit avec les réseaux de neurones artificiels, deux modèles ont été choisis, le premier c'est le Perceptron multicouches pour les non-linear input-output. Ce modèle n'a pas donné de bons résultats pour les 3 régions (Belle-Isle-sur-Terre, zardezas, les Isser) avec des coefficients de détermination ne dépassant pas les 50% en phase training, 40% en test et 22% en validation pour la première région, les 37% en phase training, les 38% en test et les 44% en validation pour la deuxième région et pour la dernière région 74% en phase training, les 61% en test et les 16% en validation, ces résultats ne sont pas satisfaisant car le paramètre du débit n'est pas inclus dans les inputs. Le deuxième modèle NARX a donné de bons résultats sur l'ensemble des 3 régions, pour la première région entre 94 et 97% pour le training, 87 et 92 % pour la validation et pour le test entre 92 et 94%. Pour la deuxième région, entre 60 et 71% pour le training, 42 et 51 % pour la validation et pour le test entre 60 et 67% et pour la dernière région, entre 70 et 97% pour le training, 14 et 81 % pour la validation et pour le test entre 66 et 77%.

L'utilisation du couplage Wavelet – ANN (Artificial Neuronal Network) pour la modélisation pluie-débit sur les trois bassins versants (région Belle-Isle-sur-Terre Ouest de la France, Zardezas, Nord-Est algérien et les Isser, Centre algérie) a donné des résultats différents pour chaque bassin versant. Pour le premier bassin le couplage wavelet avec le MLP non linear input-output on a utilisé le coiflet1 au niveaux max= log(la longueur de la serie) dans ces trois cas il est estimé à 3, le couplage n'a pas amélioré les performances du modèle mais pour le couplage wavelet-NARX avec l'utilisation des familles de wavelet Haar, Db2, Coif1, Sym3 pour la première région entre 94 et 99% pour le training, 85 et 98 % pour la validation et pour le test entre 92 et 99%, le meilleur résultat a été obtenu avec coiflet1 au niveau max de décomposition avec une structure de réseau neurone (10-11-1). Pour la deuxième région, le couplage wavelet avec le MLP non linear input-output on a utilisé le coiflet1 au niveaux max, le couplage a amélioré les résultats mais pas d'une façon significative entre 54 et 56% pour le training, 44 et 52 % pour la validation et pour le test entre 47 et 52% ,mais pour le couplage wavelet-NARX avec l'utilisation des mêmes familles de wavelet que la première région les performances du modèle atteignent les 98% pour le training, les 88% validation et pour le test 89%.

Conclusion générale

Pour la dernière région, le couplage wavelet avec le MLP non linear input-output, le training varie entre 64% et 77%, validation entre 25 et 34% et pour le test il atteint les 80%. Mais pour le couplage wavelet-NARX avec l'utilisation des mêmes familles de wavelet que les deux régions les performances du modèle atteint les 98% dans certains cas pour le training et les 86% validation et pour le test 96%. Le meilleur résultat a été obtenu avec coiflet1 avec une structure de réseau neurone (10-11-1)

Références bibliographiques

Références bibliographiques

1. Adamowski J, Sun K (2010) Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *J Hydrol* 390: 85–91
2. Addison PS, Murrary KB, Watson JN (2001) Wavelet transform analysis of open channel wake flows. *J Eng Mech* 127(1):58–70
3. ASCE Task Committee on Application of Artificial neural networks in Hydrology, —Artificial neural networks in hydrology (I & II), *Journal of Hydrologic Engineering*, 5(2), April 2000, pp. 115-136.
4. Awadallah, Ayman. Hydro-Climatologie Globale Pour La Prévisions des Crues Du Nil Au Moyen De Fonctions De Transfert Avec Bruit et de réseaux de neurones artificiels.250p
Thèse de doctorat : Génie civil : Montréal, Ecole Polytechnique de Montréal,1999
5. Benkaci, Tarik. Modélisation Pluie-Débit mensuelle et journalière par les modèles conceptuels et les modèles neuro-flous (application aux bassins Algériens).222p
Thèse de doctorat : Sciences agronomiques : Alger, Institut national agronomique d'Alger : 2006
6. Bergström, S. et Forsman, A., 1973. Development of a conceptual deterministic rainfall-runoff model. *Nordic Hydrology* 4, 147-170.
7. Cameron, D.S., Beven, K.J., Tawn, J., Blazkova, S. et Naden, P., 1999. Flood frequency estimation by continuous simulation for a gauged upland catchment (with uncertainty). *Journal of Hydrology* 219(3-4), 169-187.
8. Cannas B, Fanni A, Sias G, Tronchi S, Zedda MK (2005) River flow forecasting using neural networks and wavelet analysis. *Eur Geosci Union, Vienna, Austria* 7:24–29
9. CHITRA, S. P. (1993). Use neural network for problem solving. *Chemical Engineering Progress*, Vol. 2, pp. 44-51.
10. Da Ros, D. et Borga, M. (1997). Adaptive use of a conceptual model for real time forecasting *Nordic Hydrology*, 28(3), 169-188.
11. FORTIN, V., OURDA, T. B. M. J., RASMUSSEN, P.F., et BOBEE, B. (1997). Revue bibliographique des méthodes de prévision des débits. *Revue des sciences de l'eau*, Vol.10, n°4, pp. 461-487.
12. Gupta, H. V., S. Sorooshian, and P. O. Yapo. 1999. Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. *J. Hydrologic Eng.* 4(2): 135-143
13. Halff, A. H., Halff, H. M., and Azmoodeh, M. (1993). Predicting runoff from rainfall using neural networks. *Proc. Engrg. Hydrol, ASCE, New York*, 760–765.

14. JOHANNET, A. (2006). Les réseaux de neurones formels. Cours, Travaux dirigés et travaux pratiques. Ecole des Mines d'Alès, Alès, France, 54 p.
15. Kauark-Leite, L.A. et Nascimento, N.O. (1993). Développement, utilisation et incertitudes des modèles conceptuels en hydrologie. Séminaire Eaux - Environnement n° 3, Modélisation du comportement des polluants dans les hydrosystèmes, Paris, 191-219.
16. Kim T, Valdes JB (2003) Nonlinear model for drought forecasting based on a conjunction of wavelet transform and neural networks. *J Hydrol Eng* 8(6):319–328
17. Kisi O (2009) Neural networks and wavelet conjunction model for intermittent stream flow forecasting. *J Hydrol Eng* 14(8):773–782
18. Kisi O (2010) Daily suspended sediment estimation using neuro-wavelet models. *Int J Earth Sci* 99:1471–1482
19. Kisi O, Shiri J (2011) Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models. *Water Resour Manage* 25:3135–3152
20. Lamb, R., 1999. Calibration of a conceptual rainfall-runoff model for flood frequency estimation by continuous simulation. *Water Resources Research* 35(10), 3103-3114.
21. Lavabre, J., Sempere Torres, D. et Cernesson, F. (1993). Changes in the hydrological response of a small Mediterranean basin a year after a wildfire. *Journal of Hydrology*, 142,273-299.
22. Linsley.K et al *Hydrology for Engineers: Second Edition* Ray.
23. Linsley, R.K. (1982). Rainfall-runoff models - An overview. In: *Rainfall-runoff relationship*, V.P. Singh (Ed.), Water Ressources Publications, 3-22.
24. Li X, Ding J, Li H (1997) Wavelet analysis and its potential application to hydrology and water resources. *J Sichuan Union Univ (Eng Sci)* 1(4):49–52
25. Li X, Ding J, Li H (1999) Combing neural network models based on wavelet transform. *J Hydraul* 2:1–4
26. Lørup, J.K., Refsgaard, J.C. et Mazvimavi, D. (1998). Assessing the effects of land use change on catchment runoff by combined use of statistical tests and hydrological modelling:Case studies from Zimbabwe. *Journal of Hydrology*, 205, 147-163.
27. Mason, J. C., Price, R. K., and Tem'eme, A. (1996). "A neural network model of rainfall-runoff using radial basis functions." *J. Hydr. Res., Delft, the Netherlands*, 34(4), 537–548.
28. MATHEVET, Thibault. Quels modèles Pluie-Débit globaux au pas de temps horaire ? : Développement empiriques et comparaison de modèles sur un large échantillon de bassins versants. 463p.

- Thèse de doctorat: Science de l'eau: Paris, Ecole Nationale du Génie Rural, des Eaux et Forêts : 2005
29. Michel, MISITI. Wavelet Toolbox™ 4: user's guide. MATLAB The mathworks, 2009. 153p.
 30. Michel, MISITI. Wavelets and their Applications. iSTE. 2007. 352p
 31. Nascimento, N.O. (1995). Appréciation à l'aide d'un modèle empirique des effets d'action anthropiques sur la relation pluie-débit à l'échelle du bassin versant.
Thèse de Doctorat, CERGRENE/ENPC, Paris, 550 p.
 32. Nash, J.E. et Sutcliffe, J.V. (1970). River flow forecasting through conceptual models. Part I -A discussion of principles. *Journal of Hydrology*, 27(3), 282-290.
 33. Nourani V, Alami TM, Aminfar MH (2009a) A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Eng Appl Artif Intell* 22:466–472
 34. Nourani V, Komasi M, Mano A (2009b) A multivariate ANN—Wavelet approach for rainfall-runoff modeling. *Water Resour Manage* 23:2877–2894
 35. Nourani V, Kisi O, Komasi M (2011) Two hybrid artificial intelligence approaches for modeling rainfall—runoff process. *J Hydrol* 402:41–49
 36. PARIZEAU, M. (2004). Réseaux de neurones. GIF-21140 et GIF-64326. Université Laval. 115 p.
 37. PERRIN, Charles. Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative. 287p.
Thèse de doctorat: Mécanique des Milieux Géophysiques et Environnement: Antony, Cemagref: 2000.
 38. Perrin, C., C. Michel, and V. Andréassian, Does a large number of parameters enhance model performance? Comparative assessment of common catchment model structures on 429 catchments, *Journal of Hydrology*, 242 (3-4), 275-301, 2001.
 39. Poff, N. L., Tokar, S., and Johnson, P. (1996). Stream hydrological and ecological responses to climate change assessed with an artificial neural
 40. Rajae T, Mirbagheri SA, Nourani V, Alikhani A (2010) Prediction of daily-suspended sediment load using wavelet and neuro-fuzzy combined model. *Int J Environ Sci Tech* 7(1):93-110
 41. Rajae T et al (2011) River suspended sediment load prediction: application of ANN and wavelet conjunction model. *ASCE J Hydrol Eng* 16(8):613–627
 42. Rakem Y. Analyse critique et reformulation mathématique d'un modèle pluie-débit empirique (GR4J). 267p.
Thèse de doctorat, Ecole Nationale des Ponts et Chaussées: 1999
 43. Raman, H., and Sunilkumar, N. (1995). Multi-variate modeling of water resources time series using artificial neural networks. *Hydrological Sci.*, 40, 145–163.

44. Rao YRS, Krishna B (2009) Modelling hydrological time series data using wavelet neural network analysis. IAHS Publication 333:101–110
45. RAUDKIVI, Arved J. HYDROLOGY: An Advanced Introduction to hydrological Processes and Modelling. PERGAMON PRESS, 1979. 479p. ISBN 0-08-024261-8
46. ROUSSILLON, C. (2004). Prédiction de température par Réseaux de neurones. Lycée Victor Hugo, BESANCON, 48 p.
47. Sétra, Calage et validation des modèles de Traffic, Juillet 2010, Service d'études sur les transports, les routes et leurs aménagements.
48. Shiri J, Kisi O (2010) Short term and long-term stream flow forecasting using a wavelet and neuro-fuzzy conjunction model. J Hydrol 394:486–493
49. Singh, J., H. V. Knapp, and M. Demissie. 2004. Hydrologic modeling of the Iroquois River watershed using HSPF and SWAT.
50. Wang W, Yuan P, Ding J (2000) Wavelet analysis and its applications to the stochastic simulation of daily discharge process. J Hydraulics 11:43–48
51. Wang W, Ding J, Xiang H (2002) The multi-time scale analysis of hydrological time series with wavelet transform. J Sichuan Univ 35(4):14–17
52. Wang W, Hu S, Li Y (2011) Wavelet transform method for synthetic generation of daily streamflow. Water Resour Manage 25:41–57
53. Wensheng W, Jing D (2003) Wavelet network model and its application to the prediction of hydrology. Nature Sci 1(1):67–71
54. Uhlenbrook, S., Seibert, J., Leibundgut, C. et Rodhe, A. (1999). Prediction uncertainty of conceptual rainfall-runoff models caused by problems in identifying model parameters and structure. Hydrological Sciences Journal, 44(5), 779-797.
55. Xu, C.Y. et Vandewiele, G. (1995). Parsimonious monthly rainfall-runoff models for humid basins with different input requirements. Advances in Water Resources 18, 39-48.
56. Yang, X., Parent, E., Michel, C. et Roche, P.A. (1995). Comparison of real-time reservoir-
57. operation techniques. Journal of Water Resources Planning and Management, 121(5), 345-351.
58. Yang, D., Herath, S. et Musiak, K. (2000). Comparison of different distributed hydrological
59. models for characterization of catchment spatial variability. Hydrological Processes, 14(3), 403-416.
60. Zhou HC, Peng Y, Liang G-H (2008) The research of monthly discharge predictor corrector model based on wavelet decomposition. Water Resour Manage 22:217–227

Annexe

Chapitre 5

Région Région de Belle-Isle-en-Terre, France

- **Modèle non bouclé (Non linéaire Input-Output) :**
 - ❖ **Sans wavelet**

Nombre neurones	Retard d	Nbre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	training	0.278	0.8497	32.62%	50.90%
		validation	-0.2341	1.1109	-12.55%	22.15%
		Test	0.0096	0.9952	16.55%	33.04%
16	4	training	0.2806	0.8482	23.19%	47.03%
		validation	-0.4072	1.1863	-23.81%	21.31%
		Test	-0.0772	1.0379	6.55%	30.54%
10	6	training	0.3697	0.7939	-32.34%	49.87%
		validation	-0.0525	1.0259	-51.52%	22.54%
		Test	0.1473	0.9234	-39.19%	33.86%

- ❖ **Avec wavelet en utilisant la coiflet 1 au 3ieme niveau de décomposition maximale**

Nombre neurones	Retard D	Nombre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	training	0.3862	0.7835	-18.92%	49.23%
		validation	-0.2843	1.1333	-68.14%	27.28%
		Test	0.0274	0.9862	-36.42%	34.55%
16	4	training	0.4622	0.7333	-11.15%	49.90%
		validation	-0.2634	1.124	-45.25%	17.16%
		Test	0.0771	0.9607	-23.21%	28.60%
10	6	training	0.4351	0.7516	11.49%	49.12%
		validation	0.171	0.9105	-16.07%	25.40%
		Test	0.2926	0.8411	1.65%	35.40%

- **Modèle récurrent : NARX**

- ❖ **Sans wavelet**

Structure ANN	Nbre neurone	d		Nash	RSR	Pbias %	R ² %
Q(t+1) = f(Qt, Qt-1, Pt-1, Pt) (4,n,1)	6-8-1	2	training	0.9694	0.1749	-0.21%	96.94%
			validation	0.9203	0.2824	2.41%	92.26%
			test	0.9442	0.2362	0.67%	94.48%
	4-8-1		training	0.9022	0.3128	19.39%	94.77%
			validation	0.8148	0.4303	12.49%	82.43%
			test	0.8574	0.3776	17.06%	88.13%
	4-12-1		training	0.9643	0.1889	0.17%	96.43%
			validation	0.8678	0.3636	-0.87%	86.79%
			test	0.9148	0.2919	-0.18%	91.48%
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2) (6,n,1)	6-10-1	3	training	0.9414	0.2421	11.86%	96.27%
			validation	0.7635	0.4863	20.04%	81.77%
			test	0.8497	0.3877	14.61%	88.20%
	6-8-1		training	0.9464	0.2316	0.14%	94.64%
			validation	0.8833	0.3416	-0.90%	88.40%
			test	0.9139	0.2935	-0.21%	91.40%
	6-12-1		training	0.9742	0.1605	1.25%	97.46%
			validation	0.8520	0.3847	4.13%	85.41%
			test	0.9113	0.2979	2.22%	91.17%
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1)	8-8-1	4	training	0.9602	0.1996	3.85%	96.23%
			validation	0.9062	0.3063	6.51%	91.59%
			test	0.9322	0.2603	4.75%	93.70%
	8-11-1		training	0.9652	0.1866	-4.31%	96.73%
			validation	0.8597	0.3745	-10.58%	88.88%
			test	0.9106	0.2991	-6.43%	92.06%
	8-13-1		training	0.9712	0.1697	-4.91%	97.41%
			validation	0.9030	0.3114	-5.35%	90.87%
			test	0.9359	0.2532	-5.06%	93.86%
Q(t+1) = f(Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3, Pt-4, Qt-4) (10,n,1)	10-8-1	5	training	0.9695	0.1747	0.30%	96.96%
			validation	0.8947	0.3245	-3.11%	90.16%
			test	0.9304	0.2638	-0.86%	93.20%
	10-10-1		training	0.9439	0.2369	-11.95%	95.96%
			validation	0.7723	0.4772	-20.91%	86.98%
			test	0.8543	0.3817	-15.00%	89.72%
	10-6-1		training	0.9731	0.1639	-0.17%	97.31%
			validation	0.8663	0.3657	-2.25%	87.77%
			Test	0.9173	0.2875	-0.88%	92.05%

❖ Avec wavelet

Wavelet	Level decomposition	Structure neuronal d		Nash	RSR	Pbias %	R ² %
Haar	1	8-11-1 4	training	0.9455	0.2334	-6.80%	95.09%
			validation	0.8575	0.3775	-1.43%	85.84%
			test	0.9002	0.316	-4.98%	90.26%
Haar	2	8-15-1 4	training	0.9518	0.2197	-2.72%	95.26%
			validation	0.8984	0.3187	-8.26%	91.89%
			test	0.9241	0.2754	-4.68%	93.11%
Haar	3	8-8-1 4	training	0.9534	0.2158	0.79%	95.35%
			validation	0.9081	0.3031	2.24%	90.93%
			test	0.929	0.2665	1.28%	92.94%
Db2	1	6-8-1 3	training	0.9738	0.1617	0.37%	97.39%
			validation	0.8937	0.3261	-5.30%	91.22%
			test	0.9329	0.2591	-1.54%	93.76%
Db2	2	8-9-1 4	training	0.9763	0.1539	-0.29%	97.63%
			validation	0.9009	0.3148	-8.91%	95.81%
			test	0.9377	0.2495	-3.34%	95.54%
Db2	3	8-9-1 4	training	0.9912	0.094	-2.11%	99.18%
			validation	0.9903	0.0984	-3.71%	99.16%
			test	0.9907	0.0963	-2.65%	99.14%
Coif1	1	6-13-1 3	training	0.9824	0.1326	-0.44%	98.24%
			validation	0.8697	0.361	-6.31%	90.73%
			test	0.9242	0.2752	-2.43%	93.53%
Coif1	2	8-8-1 4	training	0.984	0.1266	0.08%	98.40%
			validation	0.9283	0.2677	-5.94%	95.06%
			test	0.9547	0.2128	-2.05%	96.14%
Coif1	3	10-11-1 5	training	0.994	0.0776	-0.02%	99.40%
			validation	0.9862	0.1175	1.51%	98.80%
			test	0.9898	0.1008	0.50%	99.03%
Sym3	1	6-7-1 3	training	0.9796	0.1429	0.36%	97.96%
			validation	0.9466	0.2312	2.42%	94.75%
			test	0.9627	0.1933	1.06%	96.29%
Sym3	2	8-12-1 4	training	0.9900	0.0998	-0.19%	99.00%
			validation	0.9653	0.1863	-2.74%	97.60%
			test	0.9772	0.151	-1.10%	98.03%
Sym3	3	10-14-1 5	training	0.9961	0.0626	0.18%	99.61%
			validation	0.9810	0.138	2.88%	98.41%
			Test	0.9879	0.1098	1.10%	98.89%

Région de Zardesas, Algérie

- **Modèle non bouclé (Non linéaire Input-Output) :**

- ❖ **Sans wavelet**

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	training	0.0118	0.9941	37.92%	33.68%
		validation	0.216	0.8854	73.47%	31.19%
		Test	0.0942	0.9517	50.69%	32.00%
16	4	training	-1.3476	1.5322	-58.67%	30.92%
		validation	-0.8136	1.3467	-28.87%	26.28%
		Test	-1.1322	1.4602	-47.97%	28.98%
10	6	training	0.2697	0.8546	-1.7%	37.9%
		validation	0.4348	0.7518	27.8%	43.9%
		Test	0.3363	0.8147	8.9%	38.6%

- ❖ **Avec wavelet (coiflet1 niveau de décomposition max=3)**

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R ² %
14	5	training	0.3916	0.78	-15.80%	54.71%
		validation	0.513	0.6979	14.59%	52.28%
		Test	0.4449	0.7451	-5.18%	52.42%
16	4	training	0.483	0.719	1.09%	51.11%
		validation	0.4468	0.7438	29.32%	45.71%
		Test	0.4671	0.73	10.95%	47.54%
10	6	training	0.385	0.7842	-14.09%	56.26%
		validation	0.4276	0.7566	19.64%	44.50%
		Test	0.4037	0.7722	-2.29%	50.15%

- **Modèle récurrent : NARX**

- ❖ **Sans wavelet**

Structure ANN	Nbre neurone n	d		Nash	RSR	Pbias %	R ² %
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt) (4,n,1)	6-8-1	2	training	0.7071	0.5412	-4.79%	70.75%
			validation	0.5118	0.6987	6.83%	51.45%
			test	0.6285	0.6095	-0.64%	62.86%
	4-8-1		training	0.6510	0.5907	20.54%	65.43%
			validation	0.3502	0.8061	24.90%	42.17%
			test	0.5300	0.6856	22.09%	54.21%
	4-12-1		training	0.7669	0.4828	22.50%	76.97%
			validation	0.3892	0.7815	28.76%	42.25%
			test	0.6149	0.6206	24.73%	62.29%
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2) (6,n,1)	6-10-1	3	training	0.7928	0.4552	-21.23%	79.52%
			validation	0.3134	0.8286	-16.91%	44.43%
			test	0.5999	0.6326	-19.69%	62.56%
	6-8-1		training	0.6783	0.5672	-4.60%	67.85%
			validation	0.4611	0.7341	17.44%	46.34%
			test	0.5909	0.6396	3.27%	59.10%
	6-12-1		training	0.7947	0.4531	8.35%	79.51%
			validation	0.4117	0.7670	22.41%	44.86%
			Test	0.6406	0.5995	13.37%	64.66%
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1)	8-8-1	4	Training	0.6974	0.5501	-19.93%	70.04%
			validation	0.3501	0.8062	-7.45%	41.45%
			Test	0.5576	0.6651	-15.48%	56.73%
	8-11-1		training	0.6895	0.5572	-19.35%	69.48%
			validation	0.4599	0.7349	-9.97%	47.02%
			test	0.5971	0.6347	-16.01%	59.85%
	8-13-1		training	0.7299	0.5197	-76.71%	76.26%
			validation	0.1313	0.9321	-76.52%	42.86%
			test	0.4890	0.7148	-76.64%	57.45%
Q(t+1) =f (Qt, Qt-1, Pt, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3, Pt-4, Qt-4) (10,n,1)	10-8-1	5	training	0.7809	0.4680	34.80%	78.77%
			validation	0.1167	0.9398	10.89%	48.41%
			test	0.5136	0.6974	26.27%	60.22%
	10-10-1		training	0.8165	0.4283	-5.80%	81.74%
			validation	0.1361	0.9295	-15.99%	47.96%
			test	0.5427	0.6763	-9.43%	62.79%
	10-6-1		training	0.7911	0.4570	-2.46%	79.12%
			validation	0.3536	0.8040	0.62%	47.71%
			Test	0.6151	0.6204	-1.36%	63.87%

❖ Avec wavelet

Wavelet	Level decomposition	Structural neuronal		Nash	RSR	Pbias %	R ² %
Haar	1	8-11-1 4	training	0.7952	0.4526	-20.40%	79.81%
			validation	0.5776	0.6499	-15.33%	61.32%
			test	0.7058	0.5424	-18.59%	71.32%
Haar	2	8-11-1 4	training	0.8745	0.3543	11.46%	87.72%
			validation	0.5898	0.6405	6.88%	64.02%
			test	0.747	0.503	9.82%	75.52%
Haar	3	6-11-1 3	training	0.8477	0.3903	-7.35%	85.12%
			validation	0.6568	0.5858	-2.78%	66.03%
			test	0.7578	0.4921	-5.73%	75.81%
Db2	1	8-9-1 3	training	0.8549	0.381	-13.70%	85.59%
			validation	0.6727	0.5721	0.29%	67.29%
			test	0.7858	0.4628	-8.78%	78.63%
Db2	2	8-15-1 4	training	0.951	0.2213	4.37%	95.12%
			validation	0.6309	0.6076	5.63%	69.98%
			test	0.8312	0.4109	4.80%	84.23%
Db2	3	8-6-1 4	training	0.9385	0.248	-3.51%	93.88%
			validation	0.6981	0.5495	-6.68%	72.95%
			test	0.85	0.3873	-4.58%	85.37%
Coif1	1	10-12-1 5	training	0.8846	0.3397	24.01%	88.91%
			validation	0.6853	0.561	27.24%	69.04%
			test	0.8003	0.4468	25.17%	80.41%
Coif1	2	8-8-1 4	training	0.9117	0.2972	33.01%	93.11%
			validation	0.834	0.4074	35.84%	84.21%
			test	0.8792	0.3475	34.02%	88.98%
Coif1	3	6-8-1 3	training	0.9164	0.2891	40.70%	93.58%
			validation	0.8358	0.4052	30.88%	84.95%
			test	0.8811	0.3448	37.31%	89.25%
Sym3	1	10-7-1 5	training	0.8887	0.3336	-4.04%	88.89%
			validation	0.6281	0.6098	-1.84%	67.05%
			test	0.7857	0.463	-3.26%	79.24%
Sym3	2	8-9-1 4	training	97.77%	14.93%	-1.27%	97.77%
			validation	0.4075	0.7698	5.63%	53.79%
			test	0.7448	0.5052	1.24%	76.87%
Sym3	3	8-9-1 4	training	0.9811	0.1374	-6.80%	98.15%
			validation	0.6945	0.5527	-1.58%	70.82%
			Test	0.8553	0.3803	-4.95%	85.80%

Region les isser, Algeria

- **Modèle non bouclé (Non linéaire Input-Output) :**
 - ❖ **Sans wavelet**

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R² %
14	5	training	0.6573	0.5854	8.32%	67.01%
		validation	-0.3	1.1402	19.03%	5.82%
		Test	0.4782	0.7223	11.45%	51.70%
16	4	training	0.735	0.5148	-24.71%	74.39%
		validation	-0.018	1.009	-11.12%	16.46%
		Test	0.5941	63.7%	-20.73%	61.50%
10	6	training	0.6159	0.6197	20.07%	62.60%
		validation	-1.6955	1.6418	54.93%	1.44%
		Test	0.1834	0.9036	30.26%	32.75%

- ❖ **Wavelet (Coif1 lvl 3)**

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R² %
14	5	training	0.7699	0.4797	-7.43%	77.05%
		validation	0.1707	0.9107	12.25%	25.60%
		Test	0.7017	0.5462	-1.76%	70.34%
16	4	training	0.7889	0.4595	-41.59%	80.74%
		validation	0.1003	0.9485	-51.08%	29.04%
		Test	0.7104	0.5382	-44.33%	73.86%
10	6	training	0.639	0.6009	-17.58%	64.62%
		validation	0.3393	0.8129	-6.84%	34.21%
		Test	0.6051	0.6284	-14.49%	61.16%

- **Modèle récurrent : NARX**

- ❖ **Sans wavelet**

Structure ANN	d		Nash	RSR	Pbias %	R ² %	
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt) (4,n,1)	6-8-1	2	training	0.8563	0.3790	-18.62%	85.86%
			validation	0.1254	0.9352	-22.89%	28.05%
			Test	0.7234	0.5259	-19.79%	72.85%
	4-8-1		training	0.9591	0.2022	1.45%	95.94%
			validation	-0.8516	1.3607	-12.49%	20.64%
			Test	0.6297	0.6086	-2.38%	69.94%
	4-12-1		training	0.9668	0.1821	-0.40%	96.70%
			validation	-0.8990	1.3780	-20.94%	21.33%
			Test	0.6273	0.6105	-6.05%	70.05%
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt-2, Qt-2) (6,n,1)	6-10-1	3	training	0.9599	0.2002	-2.54%	96.00%
			validation	0.0677	0.9655	10.33%	33.88%
			Test	0.7976	0.4499	1.00%	80.92%
	6-8-1		training	0.3765	0.7897	0.68%	45.22%
			validation	0.3491	0.8068	-15.91%	36.18%
			test	0.3719	0.7925	-3.88%	42.84%
	6-12-1		training	0.8942	0.3252	-2.03%	91.22%
			validation	-0.9815	1.4076	-5.14%	14.26%
			test	0.5530	0.6686	-2.88%	66.99%
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3) (8,n,1)	8-8-1	4	training	0.7678	0.4819	5.16%	76.89%
			validation	0.2221	0.8820	9.61%	33.03%
			test	0.6687	0.5756	6.38%	67.03%
	8-11-1		training	0.9612	0.1970	-1.92%	96.12%
			validation	0.3170	0.8264	-4.44%	41.32%
			test	0.8440	0.3950	-2.61%	84.73%
	8-13-1		training	0.8560	0.3795	-15.13%	85.71%
			validation	0.3675	0.7953	-13.63%	43.73%
			test	0.7672	0.4825	-14.72%	77.06%
Q(t+1) =f (Qt, Qt-1, Pt-1, Pt-2, Qt-2, Pt-3, Qt-3, Pt-4, Qt-4) (10,n,1)	10-8-1	5	training	0.8710	0.3591	-1.56%	87.21%
			validation	0.2182	0.8842	0.14%	34.64%
			test	0.7523	0.4977	-1.09%	75.40%
	10-10-1		training	0.7327	0.5170	2.80%	73.80%
			validation	0.4565	0.7372	-5.08%	48.36%
			test	0.6826	0.5634	0.63%	68.33%
	10-6-1		training	0.8405	0.3993	-2.12%	84.35%
			validation	0.2304	0.8773	-7.70%	33.12%
			Test	0.7296	0.5200	-3.66%	72.99%

❖ Avec wavelet

Wavelet	Level decomposition wavelet	ANN structure		Nash	RSR	Pbias %	R ² %
Haar	1	10-13-1	training	0.9466	0.2312	0.85%	94.66%
			validation	0.7560	0.4940	6.53%	75.73%
			test	0.9109	0.2984	2.41%	91.10%
Haar	2	4-6-1	training	0.9427	0.2394	11.45%	94.46%
			validation	0.6051	0.6284	4.94%	64.37%
			test	0.8891	0.3331	9.54%	88.99%
Haar	3	6-13-1	training	0.9469	0.2305	-0.33%	94.69%
			validation	0.6304	0.608	0.76%	63.79%
			test	0.9031	0.3113	-0.03%	90.32%
Db2	1	6-8-1	training	0.9206	0.2818	-2.35%	92.08%
			validation	0.7179	0.5312	4.44%	72.72%
			test	0.8854	0.3385	-0.42%	88.54%
Db2	2	10-15-1	training	0.9583	0.2043	-1.95%	95.83%
			validation	0.7531	0.4969	1.33%	75.45%
			test	0.9272	0.2698	-0.94%	92.73%
Db2	3	6-11-1	training	0.9291	0.2663	-3.20%	92.92%
			validation	0.7384	0.5114	-9.24%	74.89%
			test	0.8975	0.3201	-4.94%	89.79%
Coif1	1	8-6-1	training	0.9684	0.1777	1.54%	97.68%
			validation	0.7524	0.4976	10.26%	75.44%
			test	0.9343	0.2563	3.87%	93.46%
Coif1	2	6-10-1	training	0.9766	0.1529	0.1042	97.74%
			validation	0.7975	0.4500	0.1899	80.19%
			test	0.9496	0.2245	0.1286	95.09%
Coif1	3	10-11-1	training	0.9827	0.1315	3.77%	98.28%
			validation	0.8609	0.3729	6.04%	86.62%
			test	0.9688	0.1765	4.39%	96.91%
Sym3	1	6-13-1	training	0.9510	0.2212	-5.03%	95.14%
			validation	0.6094	0.6250	-7.72%	72.15%
			test	0.8989	0.3179	-5.78%	90.15%
Sym3	2	8-15-1	training	0.9133	0.2944	-2.32%	91.45%
			validation	0.6833	0.5627	-2.09%	72.75%
			test	0.876	0.3521	-2.26%	87.62%
Sym3	3	8-11-1	training	0.9645	0.1884	-2.02%	96.46%
			validation	0.7387	0.5112	1.13%	75.89%
			Test	0.933	0.2589	-1.12%	93.34%