

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 master en Hydraulique

# Couplage Wavelet-ANFIS pour la modélisation pluie-débit

**Bouchra Zineb KHEBRI**

Présentée et soutenue publiquement le 17/07/2017

## Composition du Jury :

Président	Mr A.BERMAD,	Grade : Professeur	Université : ENP
Promoteurs	Mr A.LEFKIR,	Grade : MCA	Université : ENSTP
	Mr A.AMIRECHE	Grade : MAA	Université : OEB
Examineurs	Mr K.HOUARI	Grade : MAA	Université : UMBB
	Mr S.BENGHERIFA	Grade: Doctorant	Université : ENP

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 master en Hydraulique

# Couplage Wavelet-ANFIS pour la modélisation pluie-débit

**Bouchra Zineb KHEBRI**

Présentée et soutenue publiquement le 17/07/2017

## Composition du Jury :

Président	Mr A.BERMAD,	Grade : Professeur	Université : ENP
Promoteurs	Mr A.LEFKIR,	Grade : MCA	Université : ENSTP
	Mr A.AMIRECHE	Grade : MAA	Université : OEB
Examineurs	Mr K.HOUARI	Grade : MAA	Université : UMBB
	Mr S.BENGHERIFA	Grade: Doctorant	Université : ENP

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, M. A.BERMAD, de m'avoir appris autant de choses, pour ses encouragements et ses conseils pour l'élaboration de ce travail 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 المويجات ANFIS - لمنطقة يسر نمذجة الأمطار والسيول مستجمعات المياه، في وسط الجزائر، ويحسن أداء نماذج ANFIS.

مقارنة بين نماذج المويجات ANFIS-والمويجات ANN-تبين أن NARX يعطي أفضل النتائج من بين النماذج 3. كلمات البحث: الهيدرولوجيا، المويجات، النمذجة، ANFIS, NARX.

## Abstract

Hydrological models are one of the tools used for reconstruction or simulation, the forecast for 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 frequential analysis of extremes: flows associated with a return period for a low or a flood (dimensioning of structures, floodwaters, bridges, Etc.) or the delimitation of flood zones (Flood Prevention Plan, etc.).

The use of the Wavelet - ANFIS coupling for the rainfall modeling of the Issers catchment area, located in the center of Algeria, improves the performance of ANFIS models.

A comparison between the Wavelet-ANFIS and Wavelet-ANN models shows that the NARX gives the best results between the 3 models.

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

## 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 – ANFIS pour la modélisation pluie-débit du bassin versant des Issers, situé au centre de l'Algérie, permet d'améliorer les performances des modèles ANFIS.

Une comparaison entre les modèles Wavelet-ANFIS et Wavelet-ANN montre que le NARX donne les meilleurs résultats entre les 3 modèles.

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

# Table de matières

## Liste des figures

## Liste des tableaux

## Liste des abréviations

## Introduction générale.....12

## Chapitre 1 : Modélisation hydrologique et modélisation pluie-débit

1.1	Introduction : .....	15
1.2	Les différentes approches de la modélisation pluie-débit .....	16
1.2.1	Modèles statistiques .....	17
1.2.1.1	Stochastique .....	17
1.2.2	Modèles physiques et déterministes.....	17
1.2.2.1	Modèles empiriques/ boîte noir.....	17
1.2.2.2	Modèles conceptuel.....	17
1.3	L'objet des modèles en hydrologie .....	17
1.4	Conclusion :.....	18

## Chapitre 2: Etat de l'art

2.1	Introduction : .....	20
2.2	Application du Réseau de neurones artificiels (ANN) en Hydrologie.....	20
2.2.1	Modélisation Pluie-débit.....	20
2.2.2	Modélisation de l'écoulement fluvial .....	22
2.2.3	Modélisation des eaux souterraines .....	23
2.3	Application de l'adaptive neuro-fuzzy inference system (ANFIS) en Hydrologie.....	24
2.4	Application de la transformée en wavelet en hydrologie .....	26
2.5	Conclusion.....	30

## Chapitre 3: Matériels & méthodes

3.1	Description de la zone d'étude .....	32
3.2	Critères de performances utilisés .....	33
3.2.1	Evaluation graphique .....	34
3.2.2	Evaluation statistique .....	34
3.2.2.1	Les régressions standard.....	34
3.2.2.2	Coefficient de détermination .....	34

3.2.3	Coefficient de NASH-SUTCLIEFFE .....	34
3.2.4	RMSE-observations standard deviation ratio (RSR) .....	35
3.3	Outil utilisé.....	35
3.4	Description des méthodes utilisés .....	35
3.4.1	Modèles basé sur les réseaux neurones artificiels.....	35
3.4.2	Modèle ANFIS (Adaptive neuro fuzzy inference system).....	39
3.4.3	Modèle basé sur le couplage Wavelet-(ANN ou ANFIS).....	41

#### **Chapitre 4: Observations & discussions**

4.1	Le taux de performance d'un modèle :.....	46
4.2	Application du modèle ANFIS avec FCM clustering .....	46
4.3	Application du modèle Wavelet-ANFIS avec FCM clustering .....	50
4.3.1	En utilisant la wavelet Haar pour l'étape de décomposition : .....	50
4.3.1	En utilisant la wavelet Symlet3 pour l'étape de décomposition : .....	55
4.3.2	En utilisant la wavelet Coiflet1 pour l'étape de décomposition : .....	59
4.4	Application du modèle MLP .....	69
4.5	Application du modèle NARX.....	69
	<b>Conclusion générale .....</b>	<b>73</b>
	<b>Références bibliographique.....</b>	<b>76</b>

## Liste des figures

Figure 1.2: classification des modèles mathématiques (Nourani 2007)

Figure 3.1: Carte des situations des stations hydro-climatologique du bassin versant de l'Isser

Figure 3.2: Pluie du bassin versant Isser

Figure 3.3 : Débit du bassin versant Isser

Figure 3.4: Diagramme du modèle ANN (MLP)

Figure 3.5 exemple d'un réseau avec une boucle fermé avec  $n=5$

Figure 3.6 : Détermination de  $y(t+1)$ , avec le NARX

Figure 3.7: Diagramme du modèle ANN ( NARX)

Figure 3.8: ANFIS architecture

Figure 3.9: Diagramme du modèle Wavelet-( ANN ou ANFIS)

Figure 4.1 : Pluie bruité et Pluie débruité en utilisant le Haar au premier niveau de décomposition

Figure 4.2 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant le Haar au premier niveau de décomposition

Figure 4.3 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au premier niveau de décomposition

Figure 4.4 : Pluie bruité et Pluie débruité en utilisant le Haar au deuxième niveau de décomposition

Figure 4.5 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant le Haar au deuxième niveau de décomposition

Figure 4.6 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au deuxième niveau de decomposition

Figure 4.7 : Pluie bruité et Pluie débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

Figure 4.8 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

Figure 4.9 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

Figure 4.10 : Pluie bruité et Pluie débruité en utilisant Symlet3 au premier niveau de décomposition

Figure 4.11 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au premier niveau de décomposition

Figure 4.12 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au premier niveau de décomposition

Figure 4.13 : Pluie bruité et Pluie débruité en utilisant Symlet3 au deuxième niveau de décomposition

Figure 4.14 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au deuxième niveau de décomposition

Figure 4.15 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au deuxième niveau de décomposition

Figure 4.16 : Pluie bruité et Pluie débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

Figure 4.17 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

Figure 4.18 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

Figure 4.19 : Pluie bruité et Pluie débruité en utilisant Coiflet1 au premier niveau de décomposition

Figure 4.20 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au premier niveau de décomposition

Figure 4.21 : ébit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au premier niveau de décomposition

Figure 4.22 : Pluie bruité et Pluie débruité en utilisant Coiflet1 au deuxième niveau de décomposition

Figure 4.23 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au deuxième niveau de décomposition

Figure 4.24 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au deuxième niveau de décomposition

Figure 4.25 : Pluie bruité et Pluie débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

Figure 4.26 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au troisième niveau de décomposition (niveau max)

Figure 4.27 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au troisième niveau de décomposition (niveau max)

Figure 4.28 : Débits simulés en fonction des débits observés pour Wavelet (Haar)-ANFIS

Figure 4.29: Débits observés et simulés en fonction du temps pour le modèle Wavelet (Haar)-ANFIS

## **Liste des tableaux**

Tableau 4.1: Intervalles d'appréciation des critères de validation (Yetoui, 2012)

Tableau 4.2: variation du nombre de cluster dans le modèle ANFIS choisi

Tableau 4.3 : Résultats obtenus avec le modèle Wavelet-ANFIS

Tableau 4.4 : Résultats obtenus avec le modèle MLP

Tableau 4.5 : Résultats obtenus avec le modèle Wavelet-MLP

Tableau 4.6 : Résultats obtenus avec le modèle NARX

Tableau 4.7 : Résultats obtenus avec le modèle Wavelet-NARX

Tableau 4.8 : Résumé des résultats obtenus avec les modèles Wavelet-NARX et Wavelet-ANFIS

# 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 master, nous nous intéresserons aux modèles hydrologiques pluie-débit et plus particulièrement l'utilisation du couplage Wavelet – ANFIS pour ensuite faire une comparaison avec les résultats obtenus avec la modélisation Wavelet-ANN (Artificial Neuronal Network) du bassin versant les Issers, Centre algérien présentée dans le mémoire de fin d'études.

Dans ce mémoire, nous examinerons :

- Dans le Chapitre 1, nous présenterons les différents modèles, leurs typologies;
- Le Chapitre 2 s'intéressera aux différentes applications des réseaux de neurones artificiels, ANFIS ainsi le couplage des wavelets avec les réseaux de neurones et l'ANFIS pour la modélisation hydrologique et la résolution des problèmes hydrologiques;
- Le Chapitre 3 présentera la région qui sera étudiée 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 4 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 mettre en avant les différentes approches pour la modélisation pluie-débit, ainsi que leurs classifications et leurs applications.

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.

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]

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.

### 1.2 Les différentes approches de la modélisation pluie-débit

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.

La typologie des modèles hydrologiques vise à classer les différents types de modèles disponibles selon quelques critères :

- Le pas de temps (Horaire, Journalier, Mensuel, Annuel),
- Fondement théorique comme le conceptuel (modèle à réservoirs), empirique (modèle ANN, ANFIS), théorique (modèle fondé sur la physique) et modèle mathématique
- Paramètres : estimés par calage et mesurés sur le terrain

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

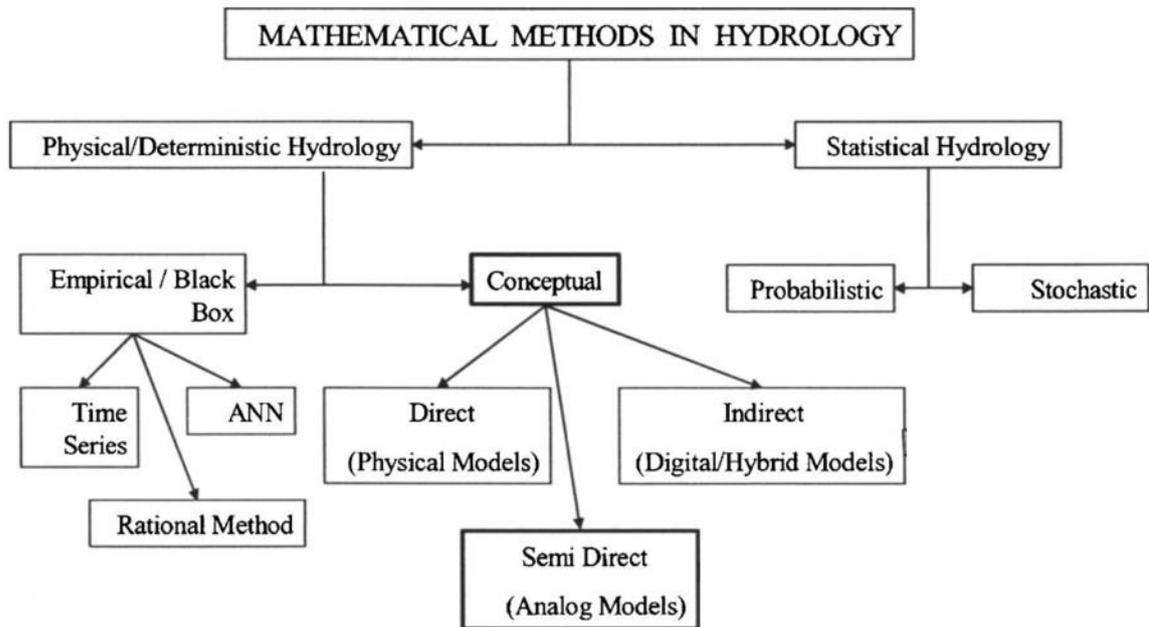


Figure 1.1: classification des modèles mathématiques (Nourani 2007)

### 1.2.1 Modèles statistiques

#### 1.2.1.1 Stochastique

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

### 1.2.2 Modèles physiques et déterministes

Le modèle déterministe permet de simuler les phénomènes physiques identifiables.

#### 1.2.2.1 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".

#### 1.2.2.2 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.

### 1.3 L'objet des modèles en hydrologie

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., 2001b] (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 [Boughton et Droop, 2003].

### **1.4 Conclusion :**

Aujourd'hui, divers modèles hydrologiques ont été développés à travers le monde pour étudier 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 de master nous allons nous focaliser sur les modèles réseaux de neurone artificiel (MLP et NARX) ainsi que le ANFIS de la famille des modèles empiriques (boîte noire) et leur couplage avec la wavelet. Dans le chapitre suivant nous allons faire une synthèse des principaux travaux réalisés dans le domaine de l'hydrologie et sur le modèles pluie-débit.

# **Chapitre 2**

## **Etat de l'art**

## Chapitre 2 Etat de l'art

### 2.1 Introduction :

Les prévisions à court terme et à long terme du débit sont très importantes pour l'élaboration de systèmes de prévision des inondations opérationnels, l'exploitation fiable des systèmes de réservoirs d'atténuation des inondations, la prédiction des quantités de sédiments transportées par les rivières vers les réservoirs et la gestion optimale des ressources en eau. En raison des capacités des systèmes de réseau neuronal artificiel (ANN) et du système d'inférence neuro-flou adaptatif (ANFIS) dans la modélisation de systèmes non linéaires complexes, les applications réussies de ces méthodes dans la modélisation des ressources en eau ont été largement rapportées, y compris la modélisation des pluies-débits (Mimikou and Rao 1983; Melching et al. 1991; Hsu et al. 1995; Lorrai and Sechi 1995; Shamseldin 1997; Sajikumar and Thandaveswara 1999; Tokar and Johnson 1999; Basha 2000; Anamala et al. 2000; Tokar and Markus 2000; Dibike and Solomatine 2000; Anctil et al. 2003; Rajurkar et al. 2004; Akbarpour 2004; Ahmat Nor 2005; Sajjad Khan and Coulibaly 2006; Junsawang et al. 2007), prévision des crues (Xiong et al. 1999; Yurekli et al. 2004; Bruen and Yang 2005; Jain and Srinivasulu 2006), relation stage-discharge (Bhattacharya and Solomatine 2000, Lohani et al. 2006), et prédiction des sédiments (Cigizoglu 2004; Bhattacharya and Solomatine 2006).

Dans ce chapitre, on va mettre l'accent sur l'application des réseaux de neurones artificiels, ANFIS ainsi le couplage des wavelets avec les réseaux de neurones et l'ANFIS pour la modélisation hydrologique et la résolution des problèmes hydrologiques.

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; ou Lørup *et al.*, 1998

### 2.2 Application du Réseau de neurones artificiels (ANN) en Hydrologie

#### 2.2.1 Modélisation Pluie-débit

La complexité du phénomène hydrologique est due à la présence des phases de transformations. 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).

### 2.2.2 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, Srivastava 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).

### 2.2.3 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 three layer 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.

### **2.3 Application de l'adaptive neuro-fuzzy inference system (ANFIS) en Hydrologie**

Les principaux travaux en utilisant l'ANFIS en hydrologie sont :

- Nayak et al. (2004) ont appliqué ANFIS pour modéliser la décharge quotidienne de la rivière Baitarani, en Inde, avec une superficie de captage de 14218 km<sup>2</sup> et comparé les résultats de son modèle avec les résultats des modèles ANN et autorégressifs en moyenne mobile (ARMA). Ils ont développé six modèles différents variant le nombre de décharges antécédentes de 1 à 6 dans les vecteurs d'entrée, pour trouver le nombre

optimal d'entrées. Le modèle ANFIS avec deux entrées a été jugé le meilleur par rapport aux cinq autres modèles. Le modèle ANFIS le plus performant a été rapporté pour surpasser ARMA mais était similaire en performance avec un modèle ANN avec deux neurones dans la couche cachée, bien que ANFIS était beaucoup mieux en estimation de pics par rapport à ANN.

- Singh et Deo (2007) ont mené une étude comparative entre le réseau neuronal de rétro-propagation avancée (FFBP), la fonction de base radiale (RBF), le réseau neuronal de régression généralisée (GRNN) et ANFIS dans la prévision quotidienne des flux. En général, RBF s'est avéré être un meilleur modèle par rapport aux autres modèles. Ils ont également conclu que FFBP pouvait être aussi bien que le modèle RBF.
- Zounemat-Kermani et Teshnehlab (2008) ont étudié le potentiel d'un ANFIS avec un moteur d'inférence Sugeno dans trois rivières. Pour un meilleur jugement, les résultats du réseau ont été comparés à un modèle autorégressif (AR). Ils ont conclu que ANFIS peut donner une meilleure performance de prévision que AR.
- Kurtulus et Razack (2010) ont comparé les méthodes ANNs et ANFIS pour la prédiction des rejets quotidiens des aquifères karstiques dans le sud-ouest de la France. L'approche ANFIS démontre une meilleure capacité de généralisation et des performances légèrement supérieures à celles de l'ANN, en particulier pour les débits de pointe.
- Talei et al. (2010a) ont étudié l'effet des intrants utilisés sur les prévisions de ruissellement par événement par ANFIS. Quinze modèles ANFIS ont été comparés, différenciés par le choix des précipitations et/ ou des intrants utilisés. Il a été constaté que les modèles utilisant uniquement des antécédents de précipitations en tant qu'entrées se sont mieux comportés en termes de qualité de l'entraînement pour les décharges à des délais plus importants (jusqu'à huit steps ahead), tandis que les modèles incluant  $Q(t-1)$  Les prévisions à des délais plus courts (jusqu'à deux steps ahead).
- Talei et al. (2010b) ont comparé une application du modèle ANFIS et de la gestion des eaux pluviales (SWMM) dans la modélisation Rainfall-Runoff (R-R) pour évaluer les capacités de ces méthodes pour un sous-bassin versant du bassin de Kranji à Singapour. Les résultats de cette étude montrent que la technique de diagnostic neuro-fuzzy sélectionnée (ANFIS) est comparable à la SWMM dans la modélisation R-R basée sur des événements. En outre, ANFIS se révèle mieux à l'estimation du débit maximal (les pics) par rapport au SWMM.
- Dorum et al. (2010) ont comparé les modèles ANN, ANFIS et multiregressional (MR) à la relation pluie-débit sur sept cours d'eau dans le bassin de Susurluk. Pour la plupart des stations, des résultats acceptables pour les modèles ANN et ANFIS ont été obtenus, avec des coefficients de détermination ( $R^2$ ) de 0,7587 et 0,8005, respectivement. Les valeurs élevées des erreurs prédites, appartenant aux valeurs de pics dans les stations où le flux multi-variable est vu, affecte négativement les valeurs de  $R^2$  et de l'erreur quadratique moyenne (RMSE).

## 2.4 Application de la transformée en wavelet en hydrologie

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.(1999) 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. 2008).

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 d'autres 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 threshold 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 conseillée 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 Yangté en Chine à l'aide du modèle hybride du réseau Wavelet-Réseaux 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 basée 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 runes 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. (2008)** ont élaboré un modèle prédicteur-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 décomposés ont été utilisées comme entrée du modèle ARMA pour la prédiction, ce qui améliore la précision de la prédiction.
- **Rao et Krishna (2009)** 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.
- **Nourani et al. (2009a, 2009b)** 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. Les auteurs ont également recommandé que WT peut être utilisé pour l'analyse des tendances dans les bassins hydrographiques.
- **Kisi (2009)** 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.

- **Rajae et al. (2010)** 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-flou. 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.
- **Shiri et Kisi (2010)** 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.
- **Kisi (2010)** 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.
- **Adamowski et Sun (2010)** 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.

- **Nourani et al.** (2011) 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.
- **Kisi et Shiri** (2011) 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.
- **Rajaei et al.** (2011) ont développé ANN, combinaison d'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 différentes 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.

- **Wang et al. (2011)** 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.

### **2.5 Conclusion**

L'état de l'art présenté ci-dessus a permis de voir les différentes méthodes qui ont été adopter, ainsi que les recommandations données par ces auteurs, ce qui va nous permettre de construire notre propre modèle qui tiendra compte de ces recommandations. C'est l'objet du chapitre suivant.

# **Chapitre 3**

## **Matériels & méthodes**

## Chapitre 3 Matériels & méthodes

### 3.1 Description de la zone d'étude

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 km<sup>2</sup> 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.

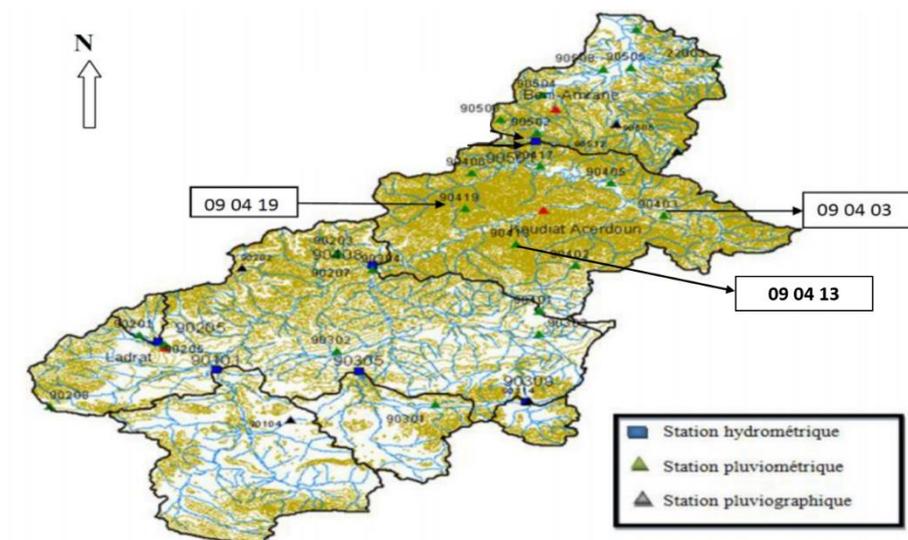


Figure 3.1: Carte des situations des stations hydro-climatologique du bassin versant de l'Isser

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).

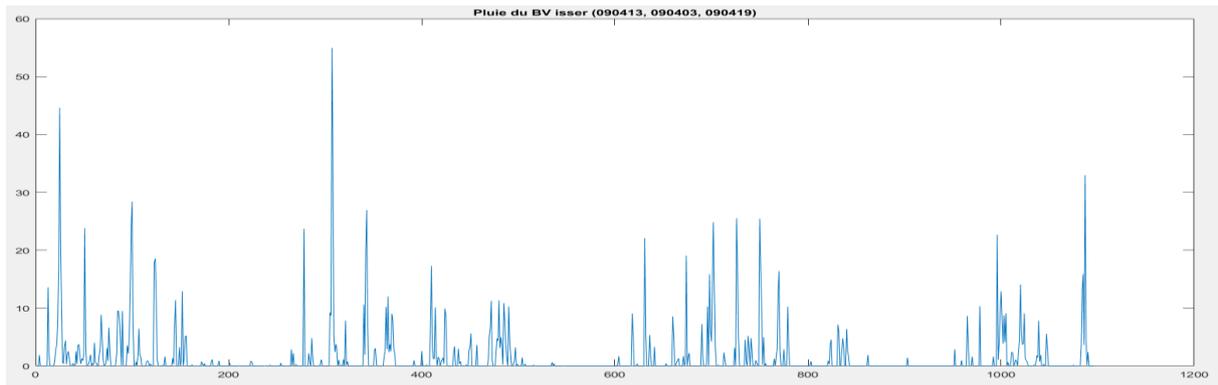


Figure 3.2: Pluie du bassin versant Isser

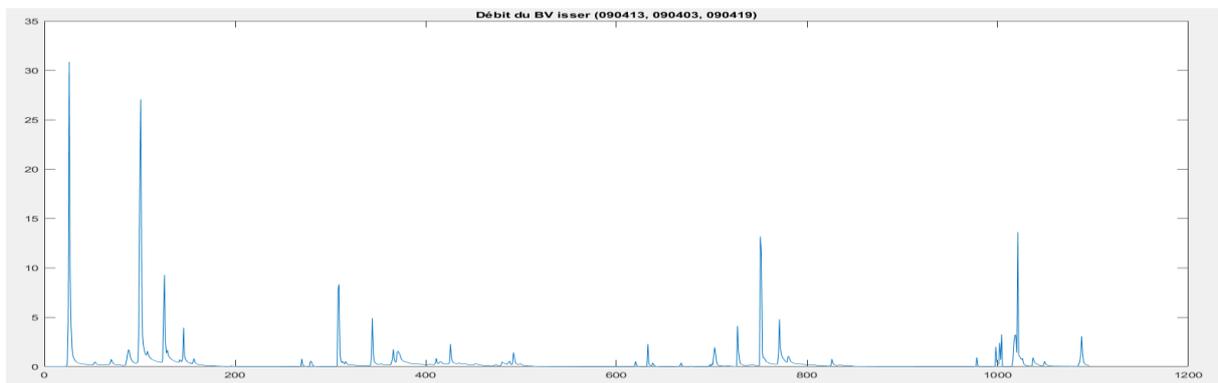


Figure 3.3 : Débit du bassin versant Isser

### 3.2 Critères de performances utilisés

Le modèle auquel on s'intéresse dans ce mémoire 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.

Dans cette étude, pour évaluer la précision de la méthodologie proposée et pour comparer différents modèles, on utilise les méthodes suivantes :

### 3.2.1 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.

### 3.2.2 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).

#### 3.2.2.1 Les régressions standard

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

#### 3.2.2.2 Coefficient de détermination

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

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

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.

### 3.2.3 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  $R^2$ , le NASH n'indique pas les sous/surestimations des modèles.

### 3.2.4 RMSE-observations standard deviation ratio (RSR)

La racine de l'erreur quadratique moyenne (RMSE), indique l'erreur dans les unités des variables étudiées. Elle est définie ci-dessous :

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

Une valeur de « 0 » de ces indices indique que le modèle simule bien la variable étudiée.

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.

### 3.3 Outil utilisé

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.
- Modèle ANFIS avec genfis3 (Fuzzy c-means clustering) + critère de performance
- Modèle couplage wavelet-ANFIS (wavelet niveaux de décompositions 1,2,3)

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

### 3.4 Description des méthodes utilisés

Ci-dessous on va expliquer les méthodes et les étapes à suivre pour chaque modèle

#### 3.4.1 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  $t-1$ ,  $t-2$ , ...,  $t-d$  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 3.4: 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 trainning 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 observées.
- 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.

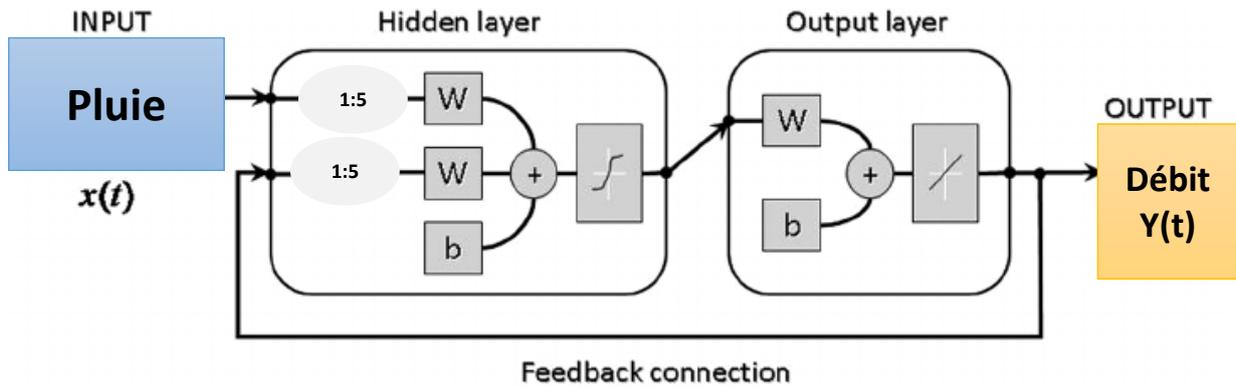


Figure 3.5 exemple d'un réseau avec une boucle fermé avec  $n=5$

- 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.

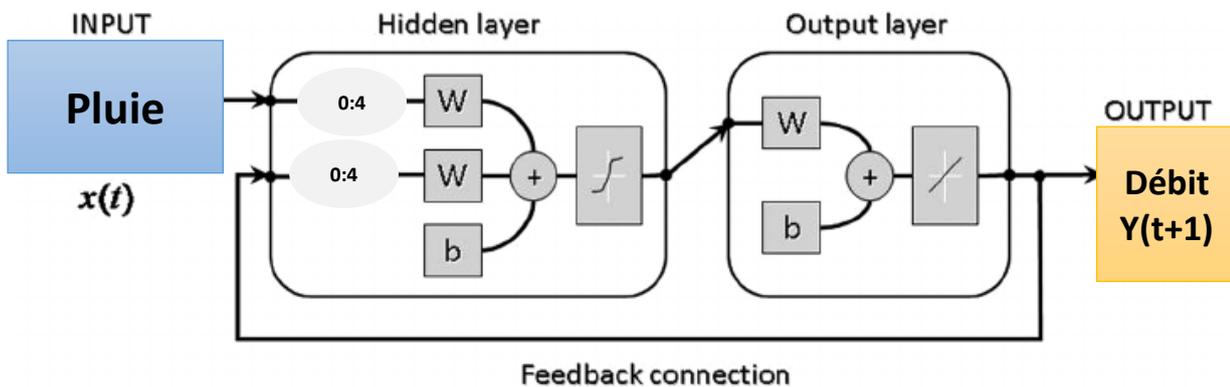


Figure 3.6 : Détermination de  $y(t+1)$ , avec le NARX

- 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 3.7: 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).

### 3.4.2 Modèle ANFIS (Adaptive neuro fuzzy inference system)

L'ANFIS en tant que modèle hybride est formé d'un système flou combiné avec un réseau d'avance (Jang et al., 1997).

Le système flou est créé selon les règles logiques des conditions et des sorties qui peuvent ne pas être analysées à l'aide d'un concept de probabilité conventionnel. Un système flou comprend cinq unités, la fuzzification, les règles, le réglage, le moteur d'inférence et la défuzzification. Parmi les différents moteurs d'inférences floues à usage nuisible, les schémas Sugeno et Mamdani (Jang et al., 1997) sont les moteurs les plus couramment utilisés dans lesquels le moteur Sugeno a été utilisé dans cette étude. Pour montrer le mécanisme typique d'ANFIS pour créer une fonction cible (sortie) de  $f$ , par exemple avec deux vecteurs d'entrée de  $x$  et  $y$ , on peut appliquer le moteur d'inférence Sugeno de la première commande, deux règles if-then fuzzy telles qu'écrites (Aqil et al. 2007):

Règle (1): Si  $\mu(x)$  est  $A_1$  et  $\mu(y)$  est  $B_1$ ; Alors  $f_1 = p_1x + q_1y + r_1$

Règle (2): Si  $\mu(x)$  est  $A_2$  et  $\mu(y)$  est  $B_2$ ; Alors  $f_2 = p_2x + q_2y + r_2$

Dans laquelle  $A_1, A_2$  et  $B_1, B_2$  sont respectivement les fonctions d'appartenance des entrées  $x$  et  $y$ .  $p_1, q_1, r_1$  et  $p_2, q_2, r_2$  sont des coefficients de la fonction cible. L'ANFIS effectue la modélisation à travers cinq couches. La première couche contient des neurones d'entrée qui fournissent un degré d'adhésion de  $\mu$  pour chaque valeur d'entrée. Compte tenu de la fonction d'adhésion gaussienne pour le  $i$ ème neurone, sa sortie pourrait être exprimée en suivant l'équation (Jang et Sun 1995):

$$Q_i^1 = \mu_{A_i}(x) = \frac{1}{1 + \left(\frac{(x - C_i)}{a_i}\right)^{2b_i}}$$

Dans lequel  $Q_i^k$  est sorti du  $i$ ème neurone dans la  $k$ ème couche ( $k = 1$  pour la première couche) et  $\{a_i, b_i, c_i\}$  sont un coefficient de base accordable.

Dans la deuxième couche, la sortie de chaque neurone sera le produit de l'entrée des valeurs à ces neurones comme (Jang et Sun 1995):

$$Q_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2$$

Chaque neurone de la troisième couche, calcule le poids relatif comme (Jang et Sun 1995):

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2$$

Le neurone  $i$  dans la quatrième couche calcule la ration de chaque règle en ce qui concerne la sortie du modèle sous la forme suivante (Jang et Sun 1995):

$$Q_i^4 = \bar{w}_i(p_i x + q_i y + r_i) = \bar{w}_i f_i$$

La sortie finale du modèle ANFIS est calculée par un neurone dans la cinquième couche comme (Jang et Sun 1995):

$$Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

L'ANFIS est étalonné par une approche de formation combinée pour optimiser les deux paramètres de base définis  $\{a_i, b_i, c_i\}$  et les paramètres conséquents définis  $\{p_i, q_i, r_i\}$ . Cet algorithme de formation hybride comprend à la fois la descente en gradient et les méthodes au moindre angle (Aqil et al., 2007). Dans le chemin vers l'avant de la formation, les sorties du

neurone continuant jusqu'à ce que la couche 4 et la méthode au moindre angle soient utilisées pour estimer les paramètres conséquents. Par la suite, les erreurs se propagent dans le chemin vers l'arrière pour mettre à jour les paramètres de base en utilisant la méthode de descente en gradient. Jang et Sun (1995) et Jang et al. (1997) peut être référé pour plus de détails concernant le modèle ANFIS et son algorithme de formation.

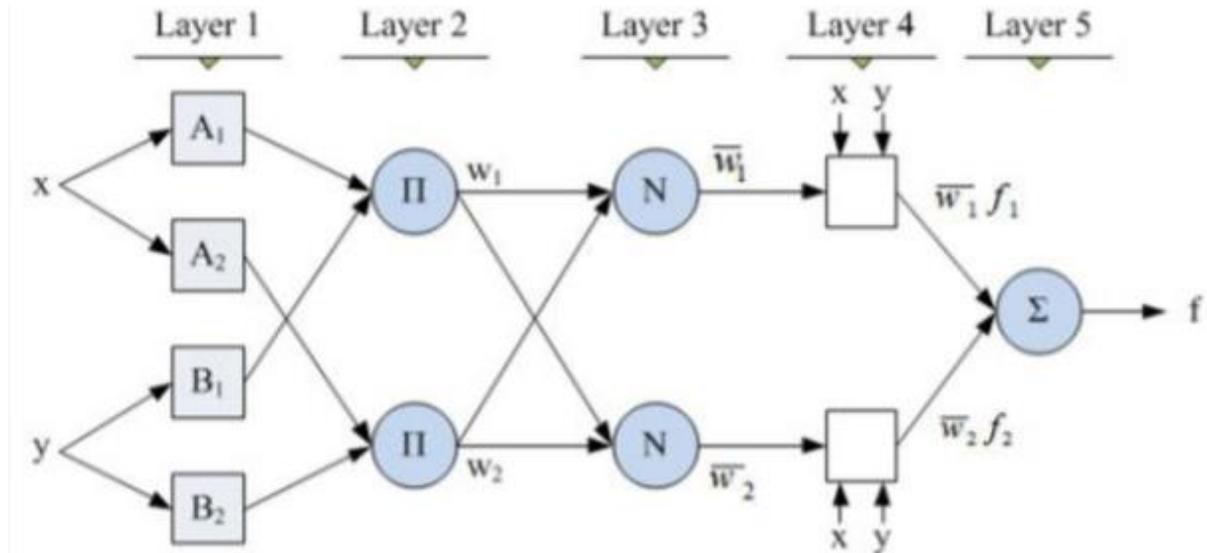


Figure 3.8: ANFIS architecture

### 3.4.3 Modèle basé sur le couplage Wavelet-(ANN ou ANFIS)

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) :

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

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, ..., 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).

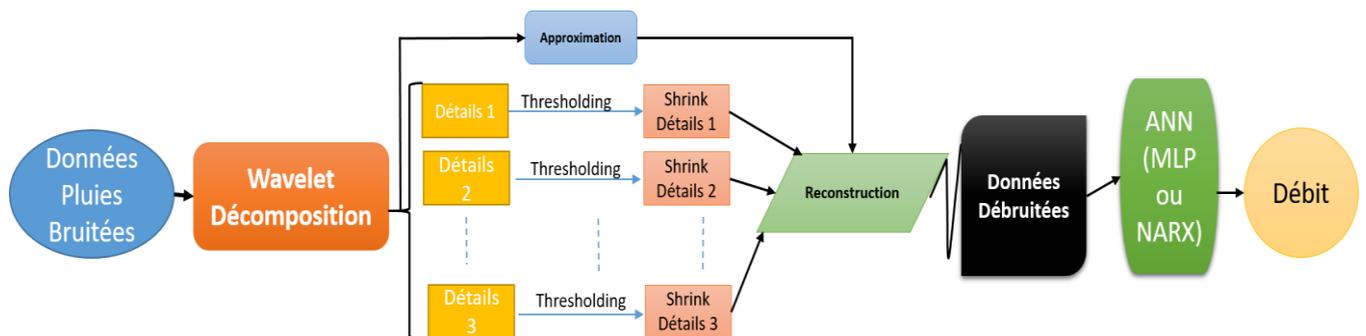


Figure 3.9: Diagramme du modèle Wavelet-( ANN ou ANFIS)

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) ou ANFIS et donc refaire les étapes mentionnées dans la partie ci-dessus.

# **Chapitre 4**

## **Observations & Discussions**

## Chapitre 4

### Observations & Discussions

#### 4.1 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 3 critères développés dans le chapitre 2, à savoir le RSR, le Nash et le  $R^2$  ou sur un critère graphique.

En fonction des valeurs des 2 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 4.1: Intervalles d'appréciation des critères de validation (Yetoui, 2012)

Taux de performance	Nash (NSE)	RSR
<b>Très bon</b>	$0,75 < NSE \leq 1,0$	$0,0 \leq RSR \leq 0,5$
<b>Bon</b>	$0,65 < NSE \leq 0,75$	$0,5 < RSR \leq 0,6$
<b>Satisfaisant</b>	$0,5 < NSE \leq 0,65$	$0,6 < RSR \leq 0,7$
<b>insatisfaisant</b>	$NSE \leq 0,5$	$RSR > 0,7$

Dans cette partie, on va appliquer sur la région des Isser en premier lieu le ANFIS en utilisant le FCM clustering et en second lieu le couplage wavelet-ANFIS, on va prendre comme input la pluie  $P_t$  et le débit  $Q_{t-1}$ .

#### 4.2 Application du modèle ANFIS avec FCM clustering

Le FCM clustering sert à extraire un ensemble de règles qui modélisent le comportement des données. C'est pour cela on va faire varier les nombres de cluster, qui sert à la base à déterminer le nombre de règles et les fonctions d'appartenance dans le FIS généré.

Tableau 4.2: variation du nombre de cluster dans le modèle ANFIS choisi

Nombre de cluster		NASH	RSR	$R^2$
15	training	0.8655	0.3668	0.8655
	validation	0.4997	0.7073	0.5936
25	training	0.9914	0.093	0.9914
	validation	-1.753	1.6592	0.3436
30	training	0.9175	0.2871	0.9175
	validation	0.0631	0.9679	0.6277
10	training	0.8812	0.3446	0.8812
	validation	0.2788	0.8492	0.4825
5	training	0.705	0.5431	0.705
	validation	0.4284	0.7561	0.4432

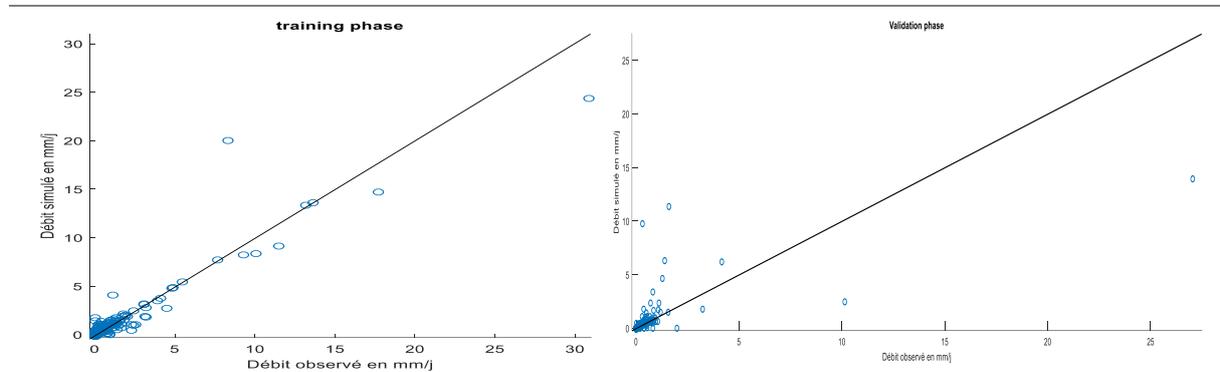
On remarque qu'on a de très bons résultats pour la partie training, mais pour la partie validation des résultats de RSR et NASH insatisfaisant

**Critères graphiques :** variation des débits simulé en fonction des débits observés

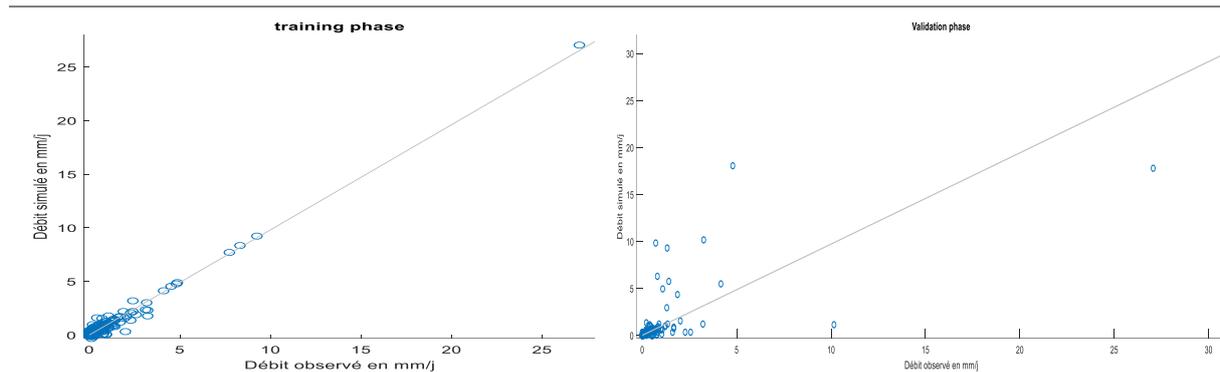
**Phase training**

**Phase validation**

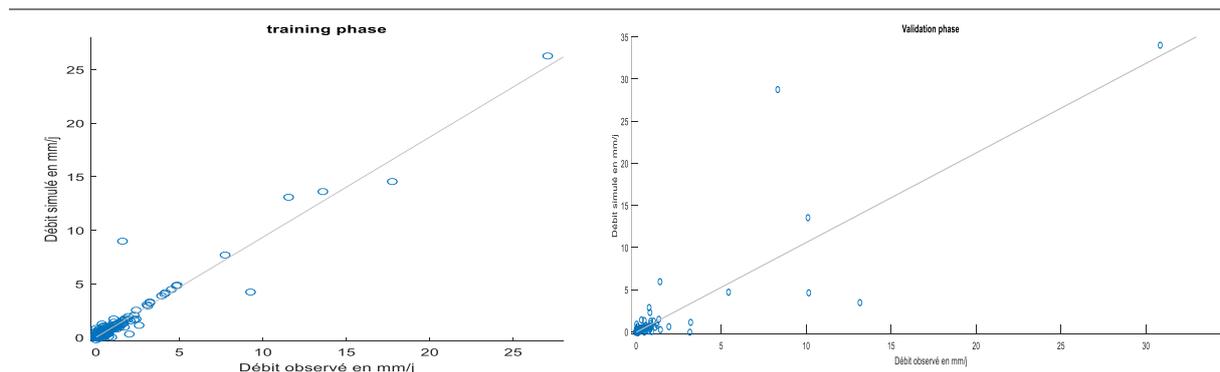
**Nombre de Cluster = 15**



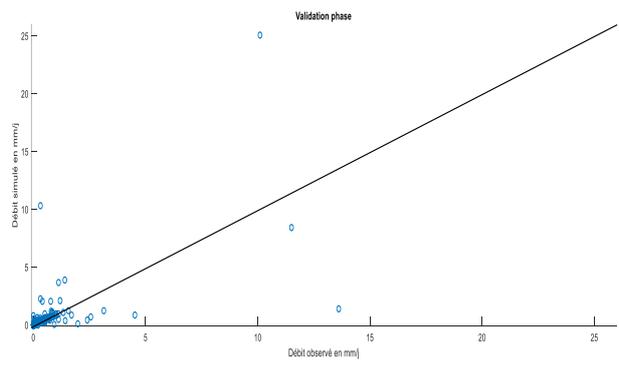
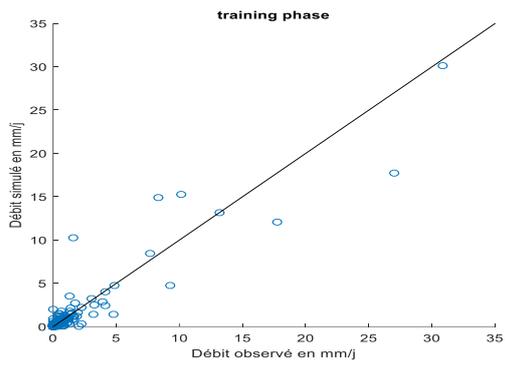
**Nombre de Cluster = 25**



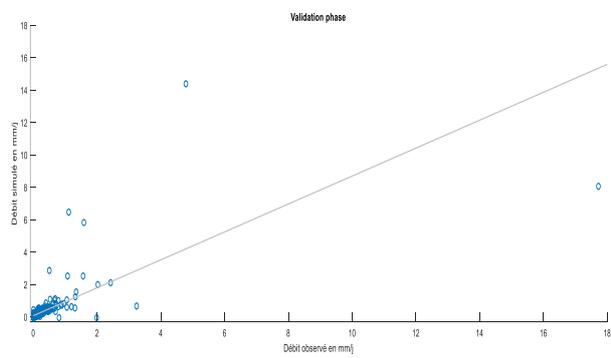
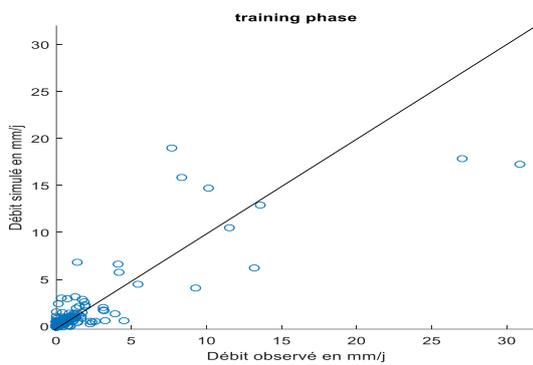
**Nombre de Cluster = 30**



**Nombre de Cluster = 10**



Nombre de Cluster = 5

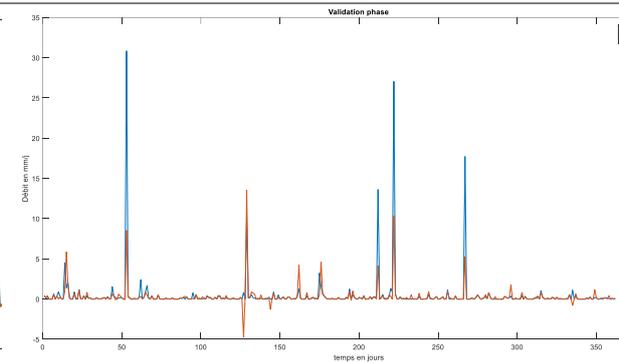
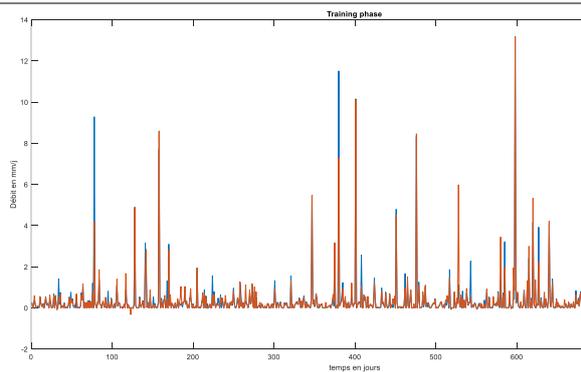


D'après les graphes présent ci-dessus, pour un nombre de cluster = 25, on voit bien que les données s'ajustent bien dans la phase training, mais non pas sur la phase calibration et cela peut être expliqué par les résultats obtenus en calculant le NASH et le RSR.

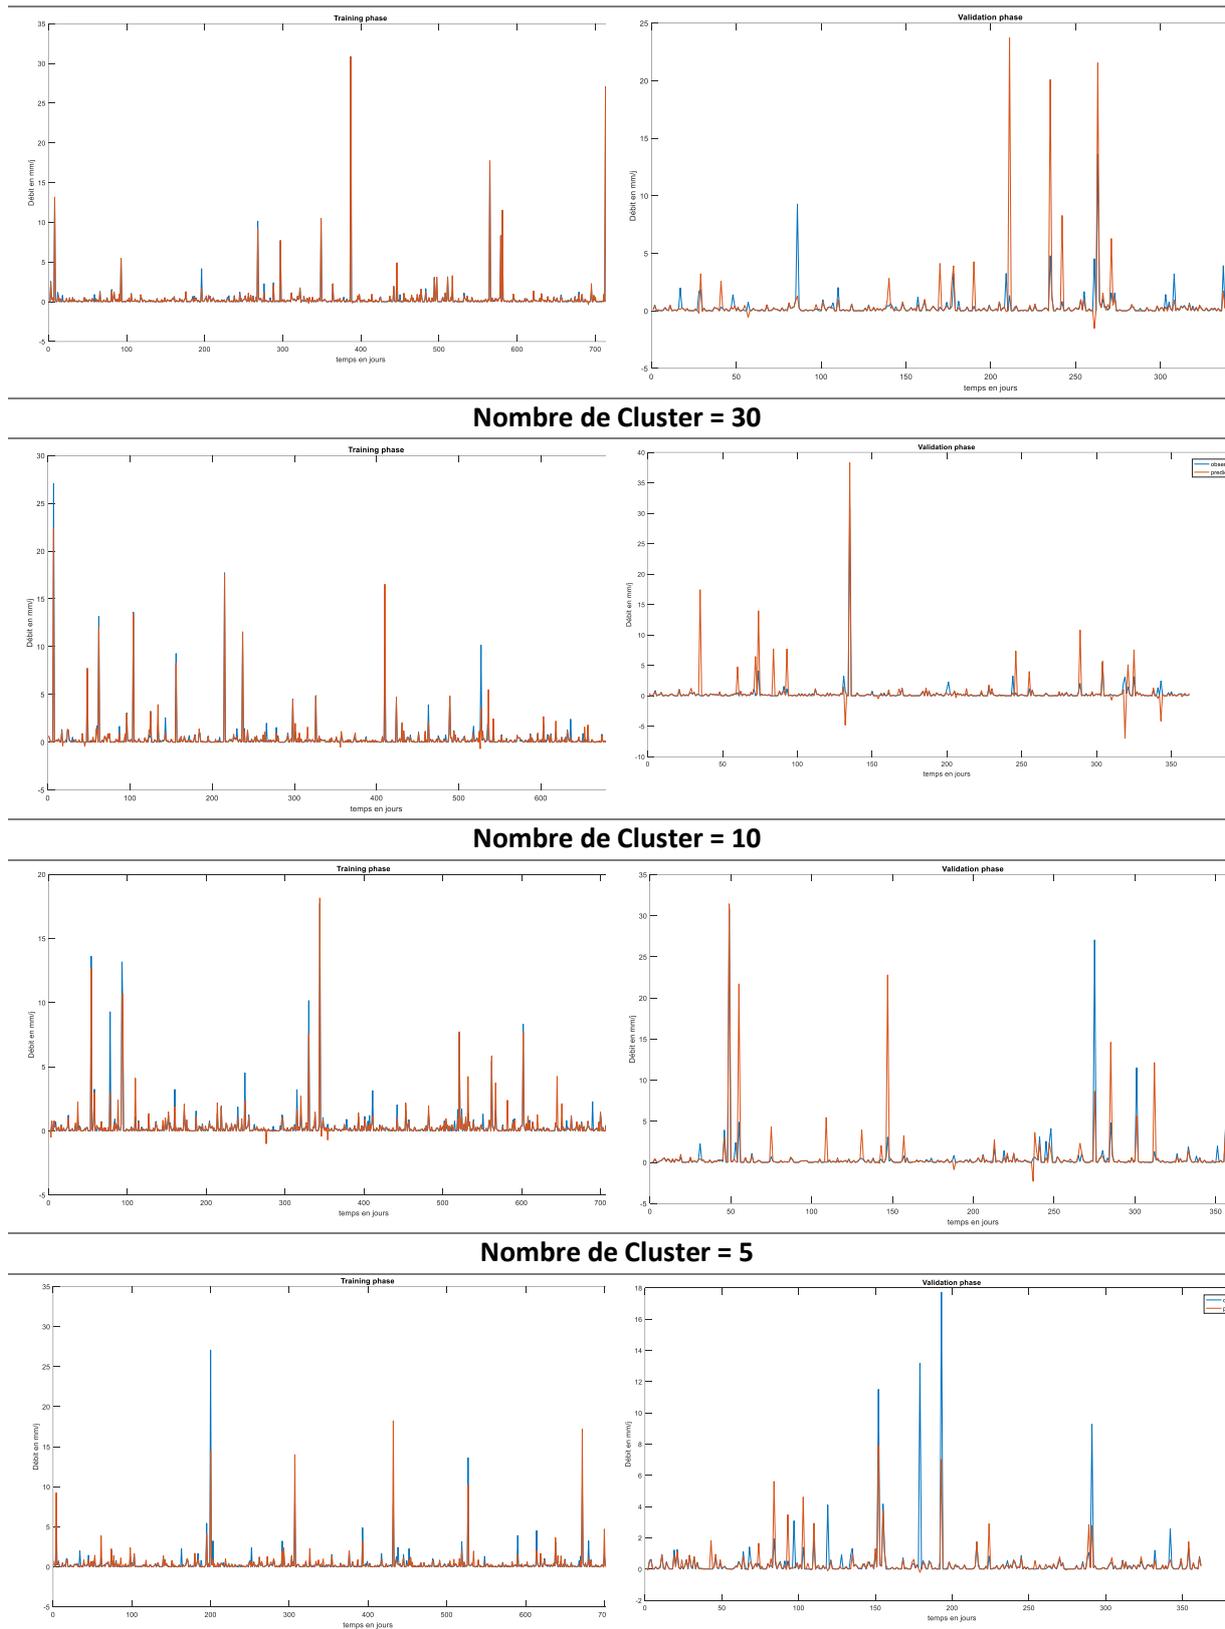
Phase training

Phase validation

Nombre de Cluster = 15



Nombre de Cluster = 25



D'après ces graphiques des débits observés et simulés en fonction du temps, on peut constater que ce modèle simule très bien les données pour la phase training, la meilleure simulation a été obtenue pour un nombre de cluster égale à 25, mais pour la phase validation, on remarque que des fois il simule des pics inexistant.

### 4.3 Application du modèle Wavelet-ANFIS avec FCM clustering

Dans cette partie, on va appliquer le couplage Wavelet avec notre modèle ANFIS avec FCM clustering. Pour cela on va d'abord débruité la pluie et le débit  $Q_t$  et  $Q_{t-1}$  et on commencera avec la décomposition en transformée wavelet, dans notre cas on va utiliser Haar, Symlet 3, Coiflet1 avec un niveau de décomposition de 1 à 3 (niveau maximale ç-à-d  $\log(1096)$ ), ensuite pour le threshold (seuil) on a opté pour Universal threshold qu'on va l'appliquer que sur les détails et après on va reconstruire le signal pour obtenir les graphiques suivants :

#### 4.3.1 En utilisant la wavelet Haar pour l'étape de décomposition :

- Niveau de décomposition 1 :

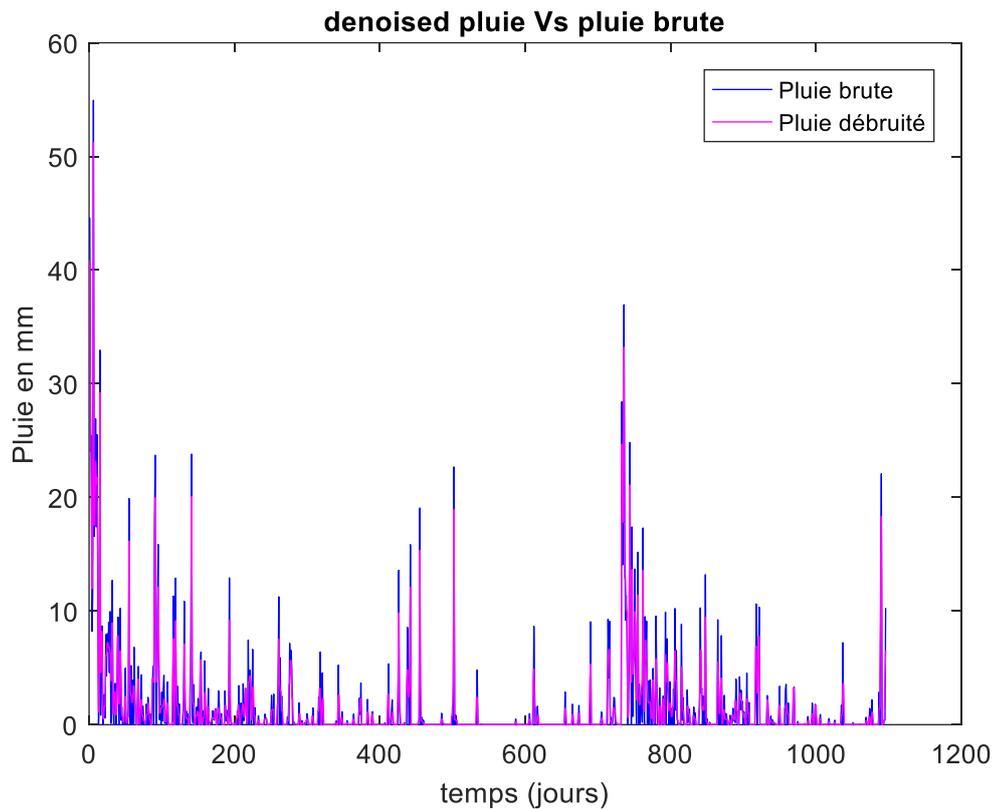


Figure 4.1 : Pluie bruitée et Pluie débruitée en utilisant le Haar au premier niveau de décomposition

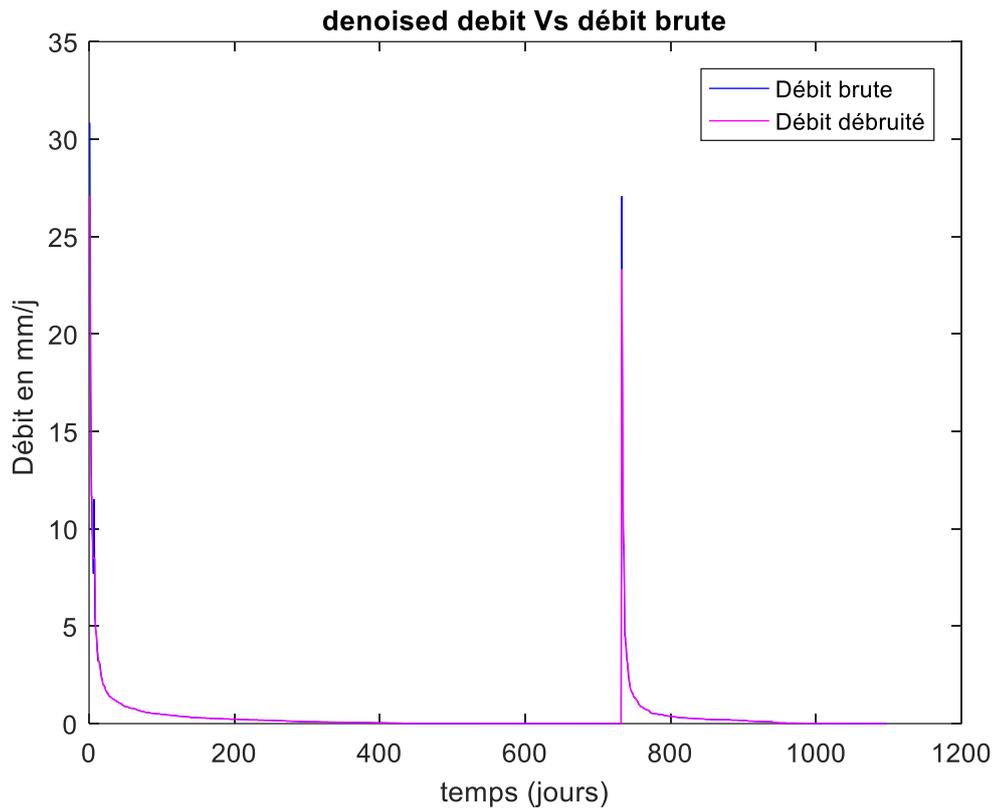


Figure 4.2 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant le Haar au premier niveau de décomposition

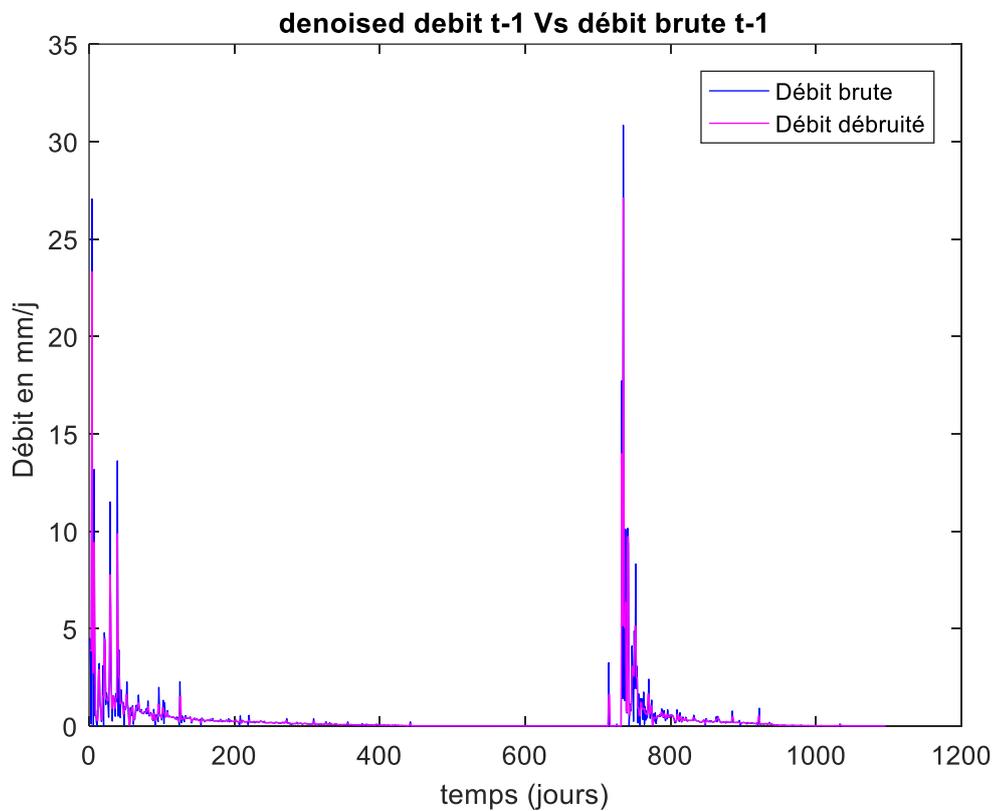


Figure 4.3 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au premier niveau de décomposition

- Niveau de décomposition 2 :

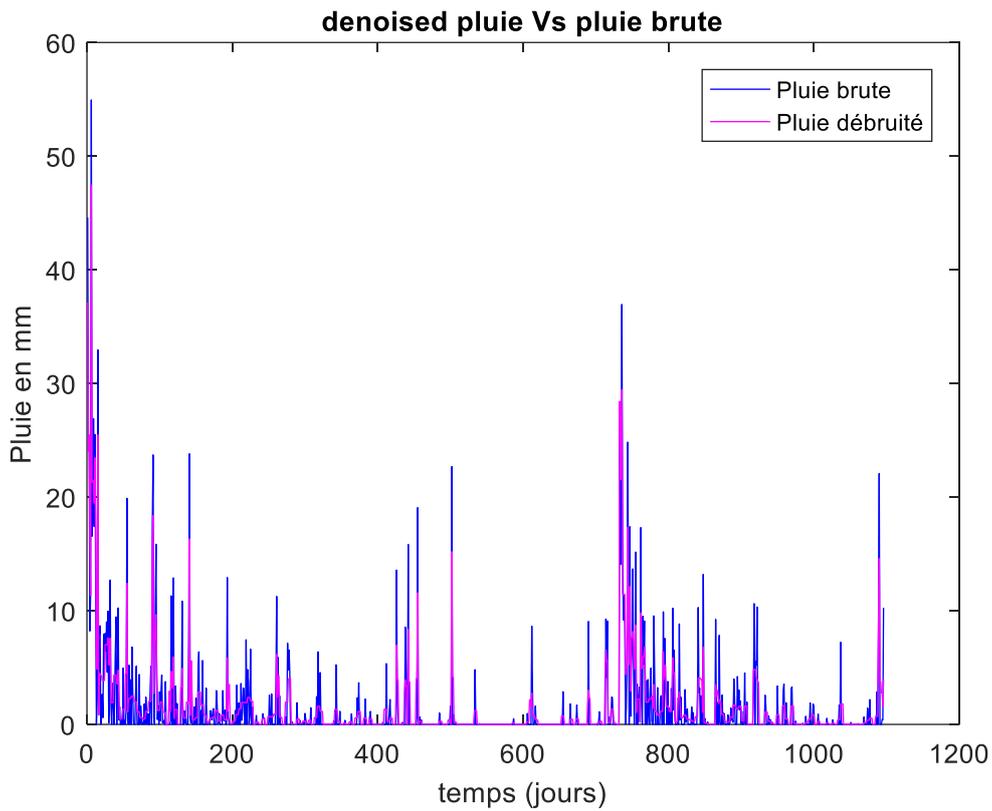


Figure 4.4 : Pluie bruitée et Pluie débruitée en utilisant le Haar au deuxième niveau de décomposition

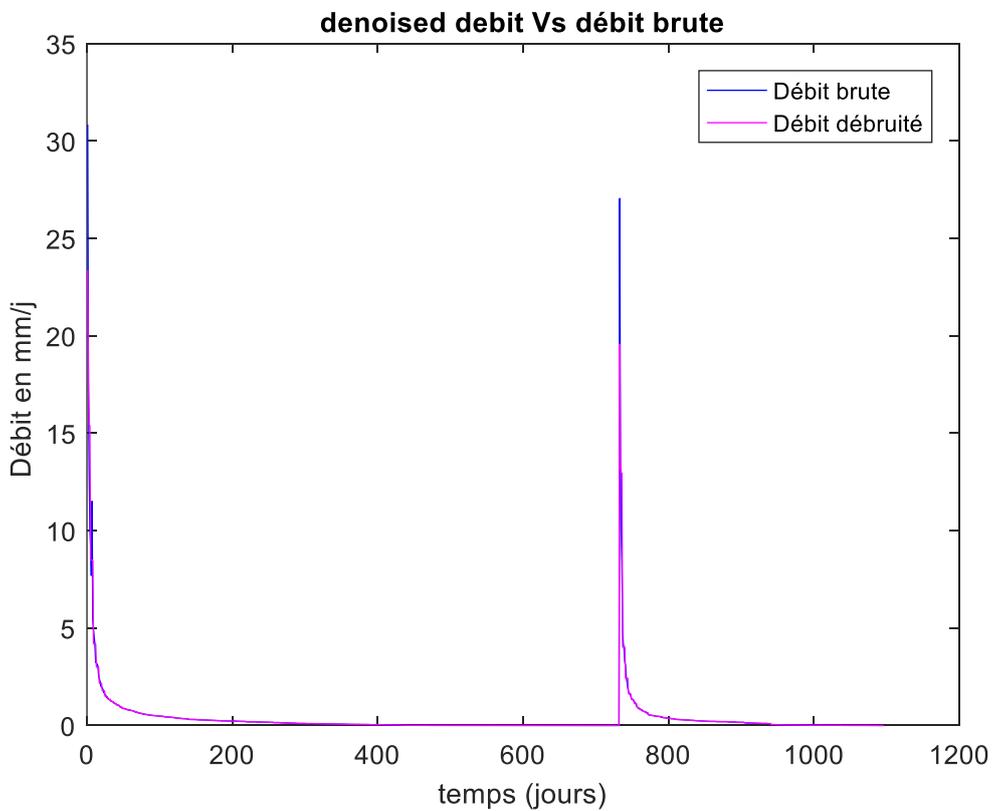


Figure 4.5 : Débit  $Q(t)$  bruitée et débit  $Q(t)$  débruitée en utilisant le Haar au deuxième niveau de décomposition

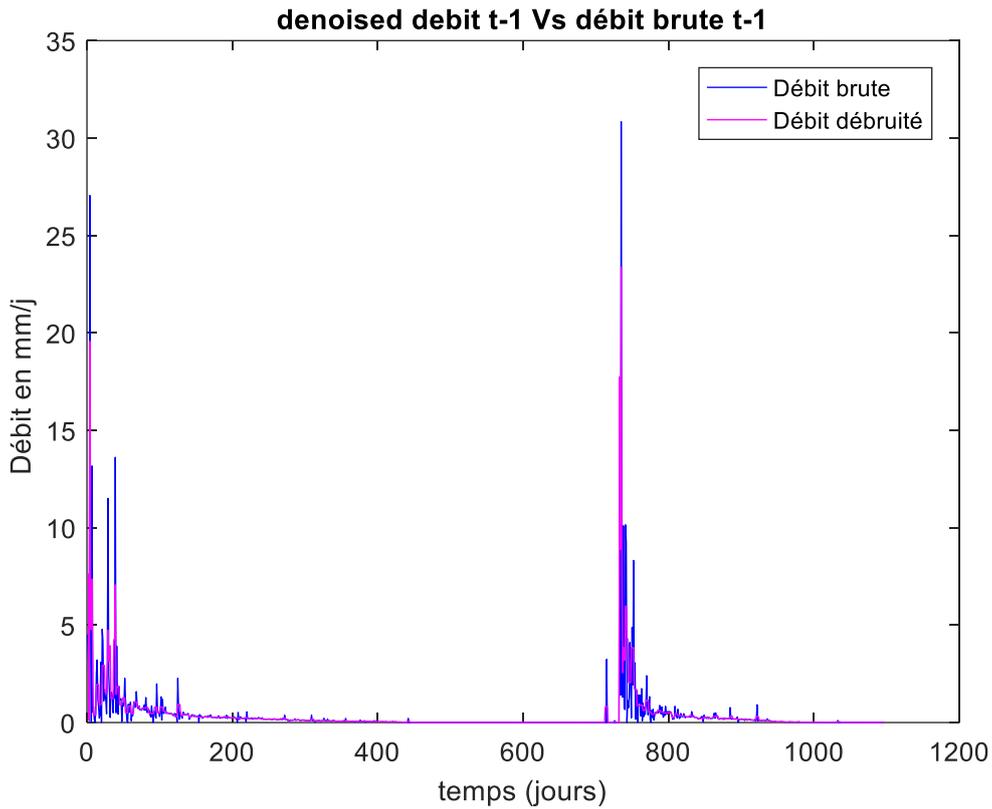


Figure 4.6 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au deuxième niveau de décomposition

- Niveau de décomposition 3 :

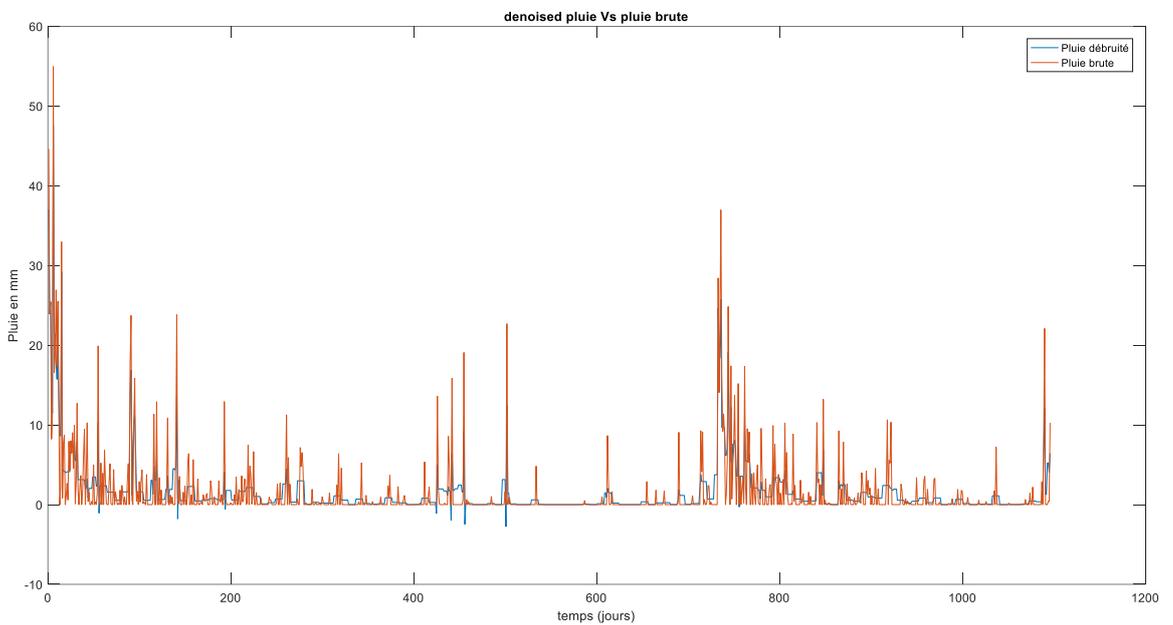


Figure 4.7 : Pluie bruité et Pluie débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

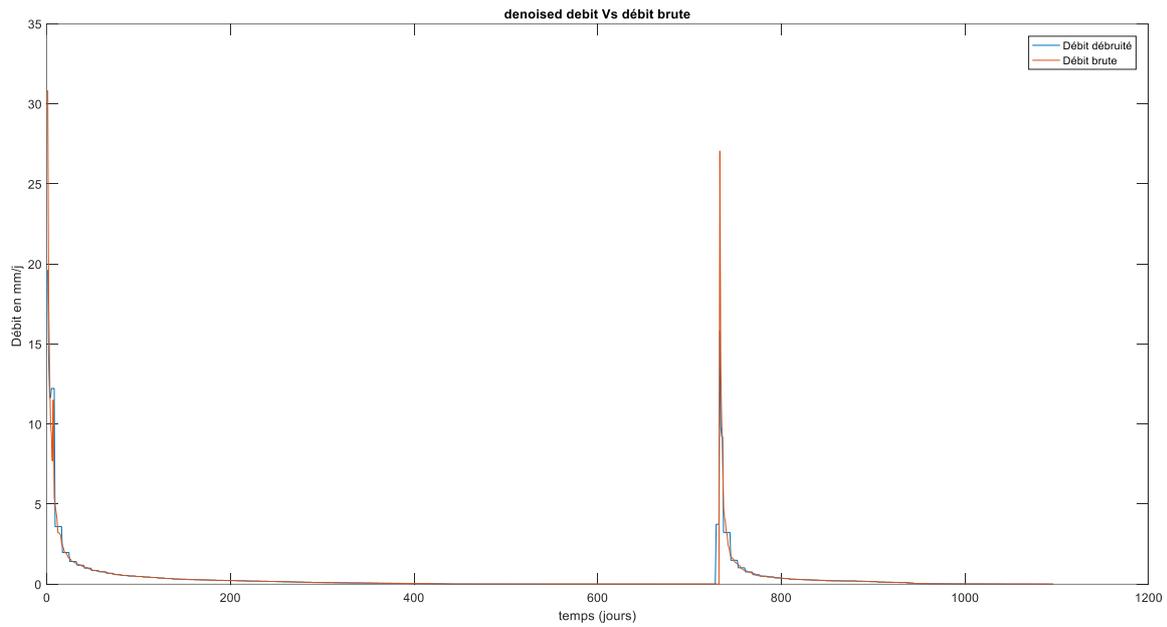


Figure 4.8 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

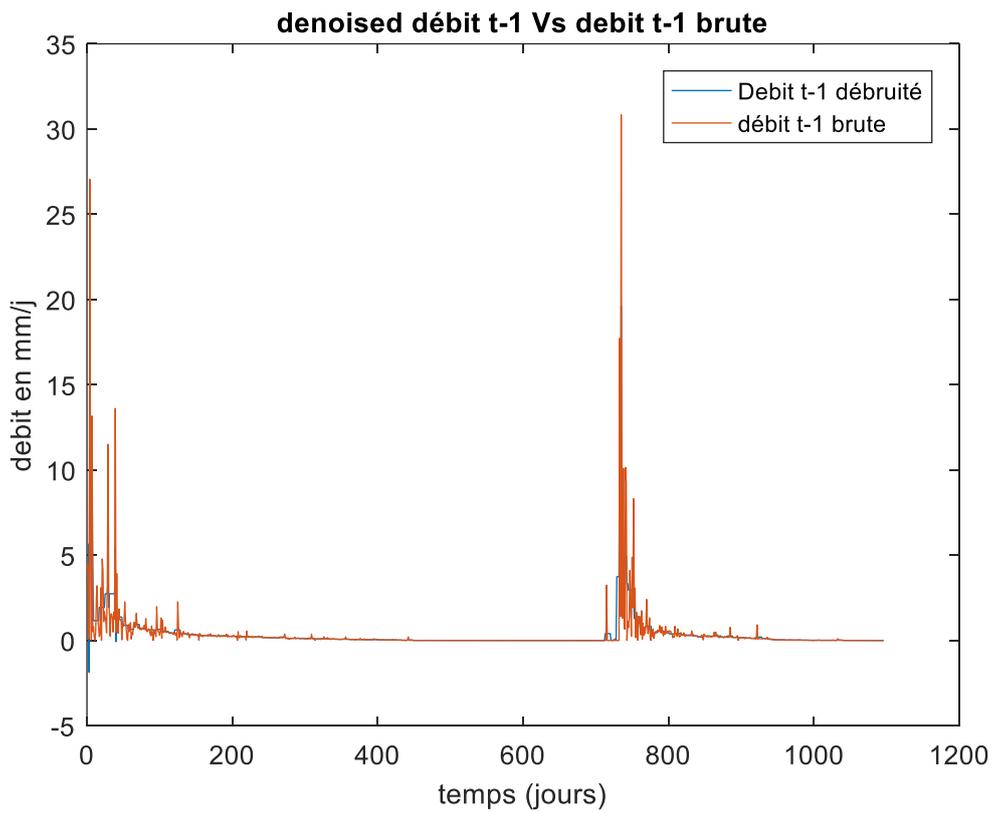


Figure 4.9 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant le Haar au troisième niveau de décomposition (niveau max)

4.3.1 En utilisant la wavelet Symlet3 pour l'étape de décomposition :

- Niveau de décomposition 1 :

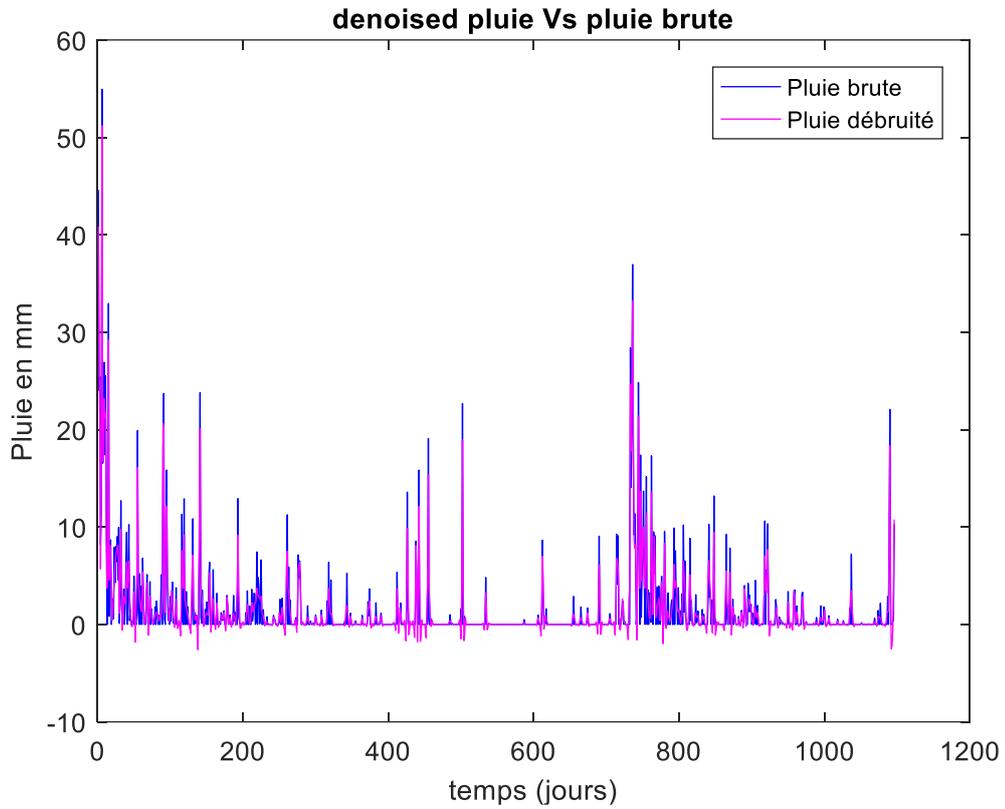


Figure 4.10 : Pluie bruité et Pluie débruité en utilisant Symlet3 au premier niveau de décomposition

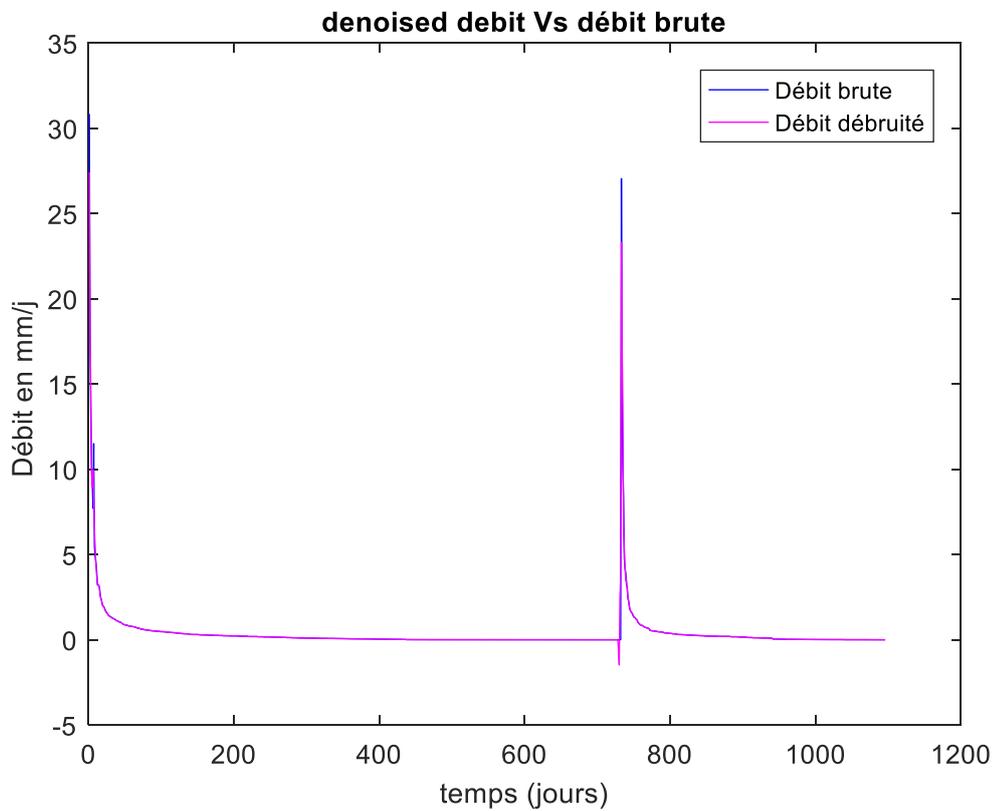


Figure 4.11 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au premier niveau de décomposition

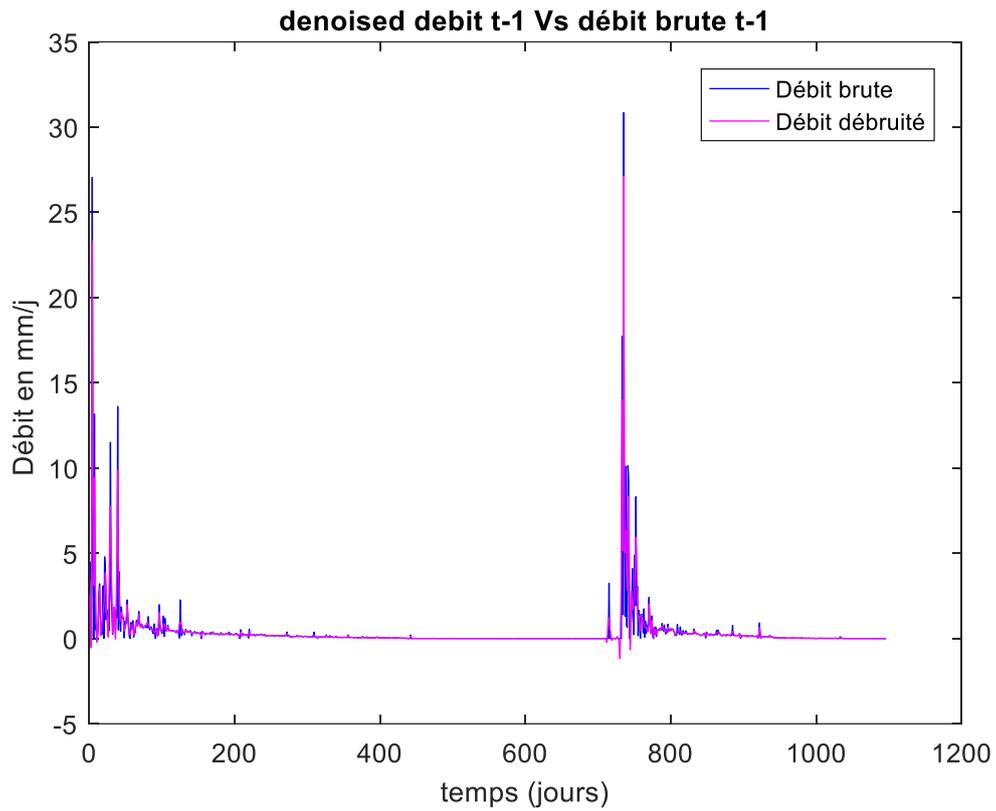


Figure 4.12 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au premier niveau de décomposition

- Niveau de décomposition 2 :

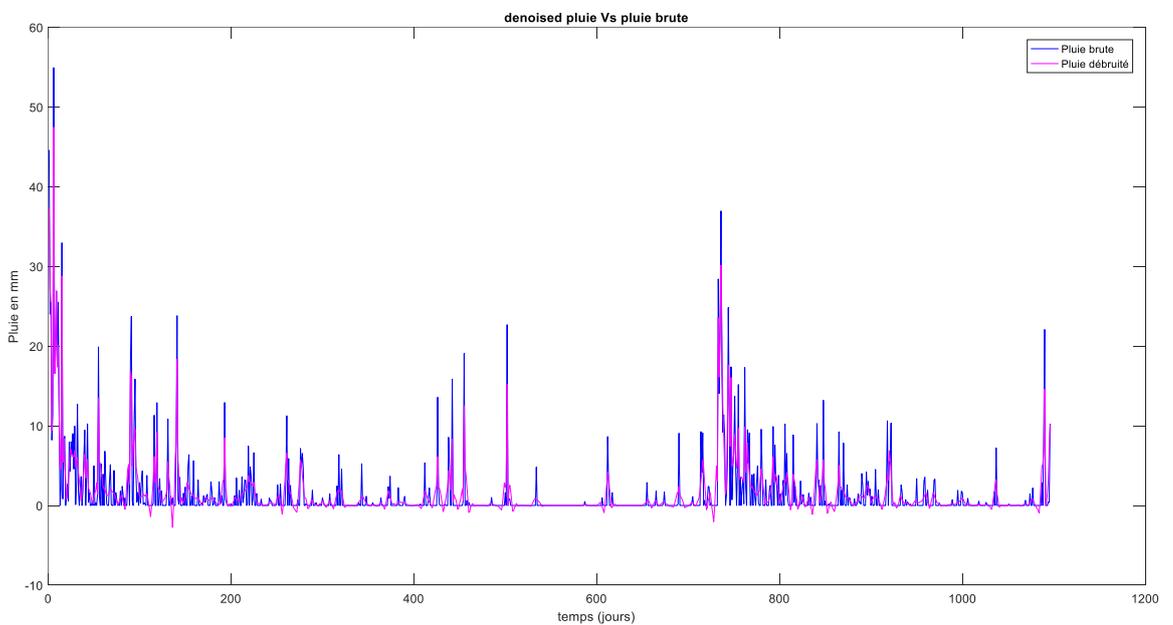


Figure 4.13 : Pluie bruité et Pluie débruité en utilisant Symlet3 au deuxième niveau de décomposition

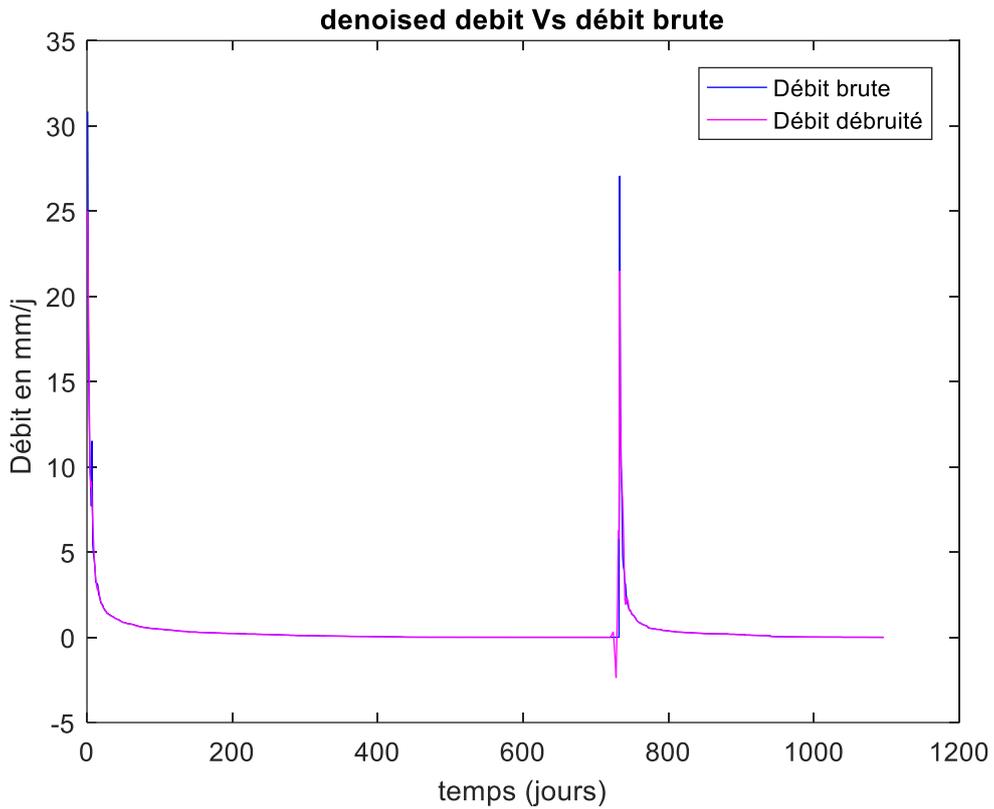


Figure 4.14 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au deuxième niveau de décomposition

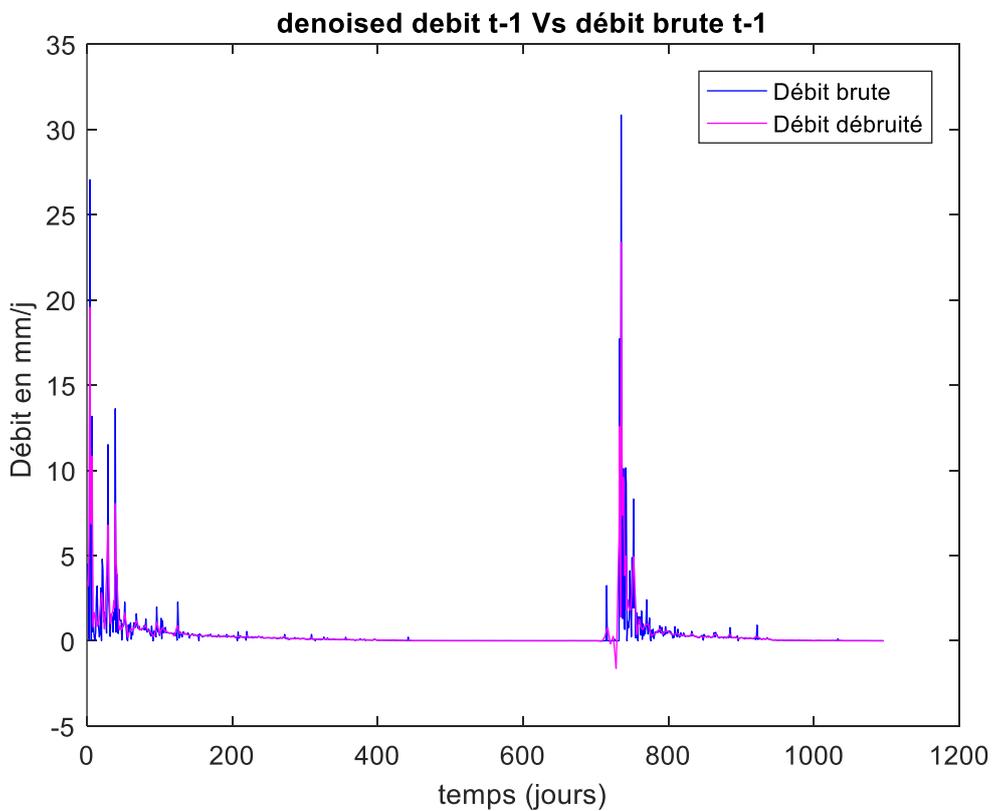


Figure 4.15 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au deuxième niveau de décomposition

- Niveau de décomposition 3 :

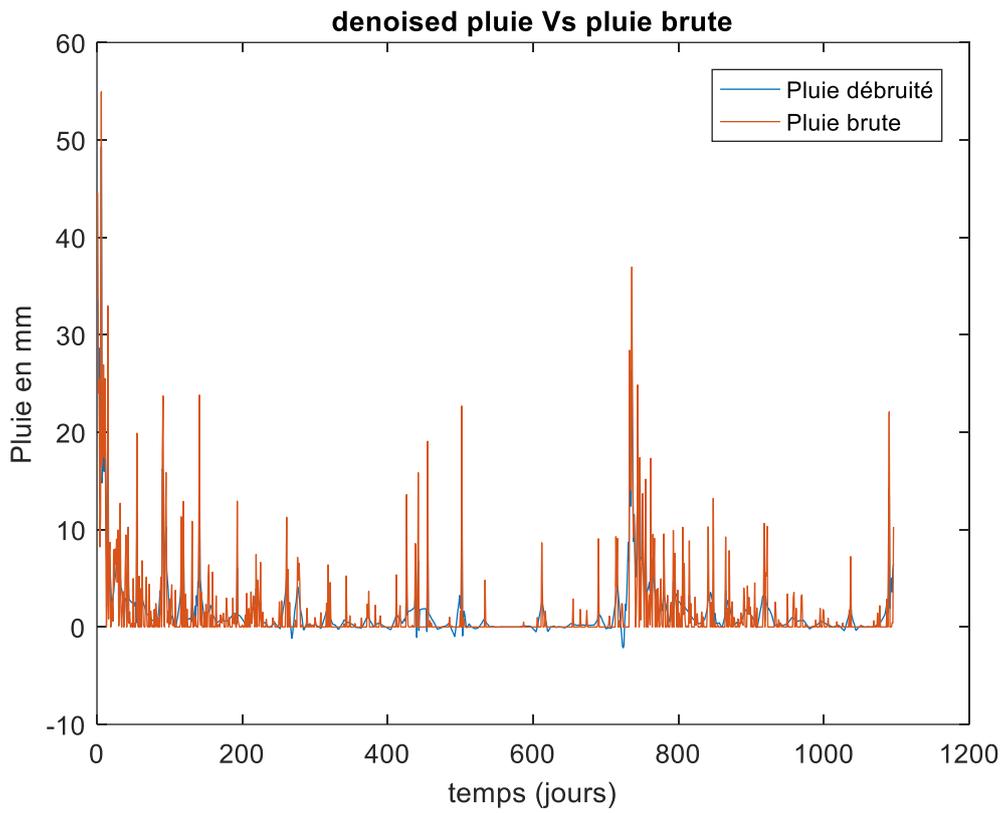


Figure 4.16 : Pluie bruité et Pluie débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

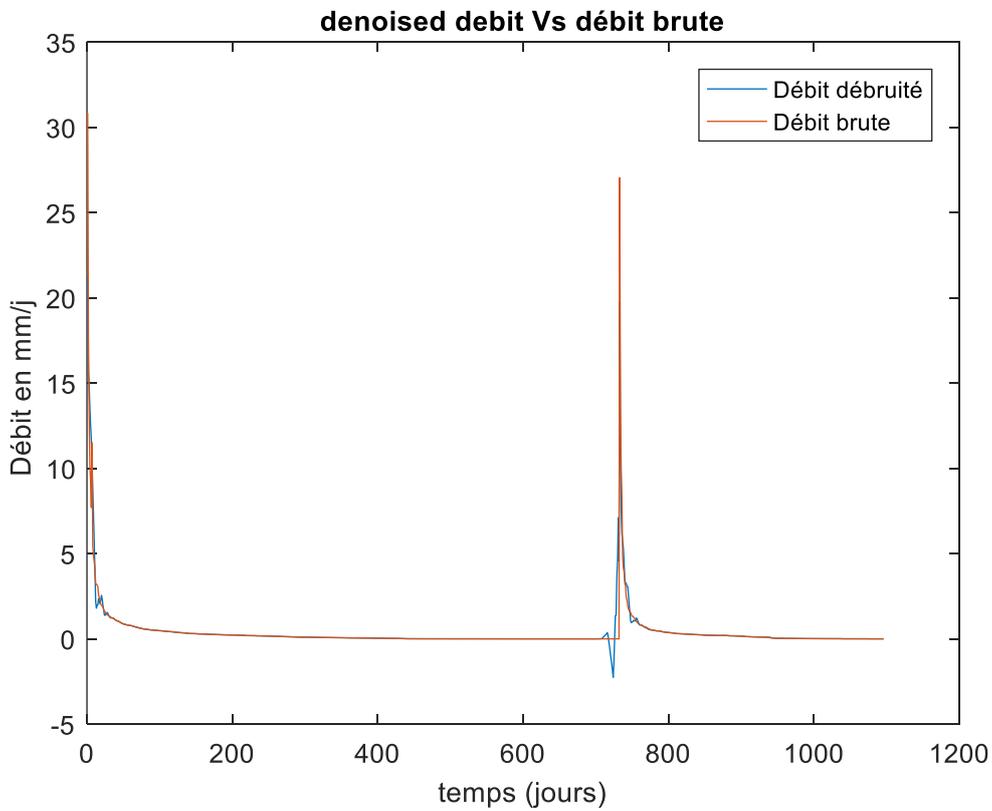


Figure 4.17 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

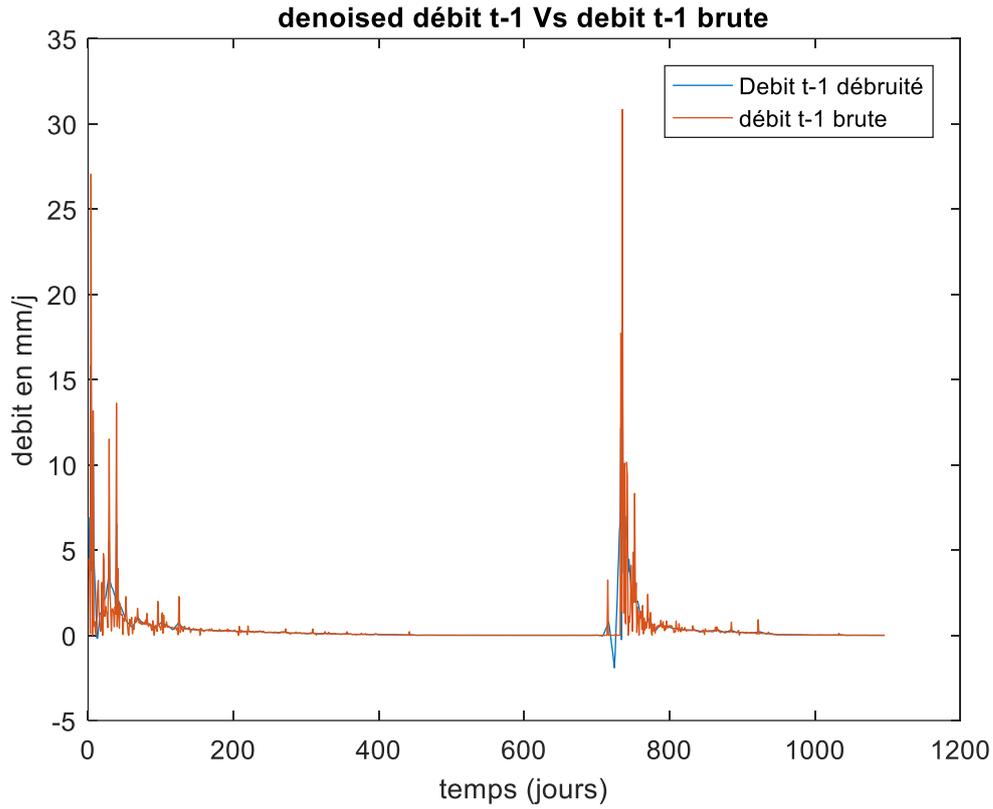


Figure 4.18 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

### 4.3.2 En utilisant la wavelet Coiflet1 pour l'étape de décomposition :

- Niveau de décomposition 1 :

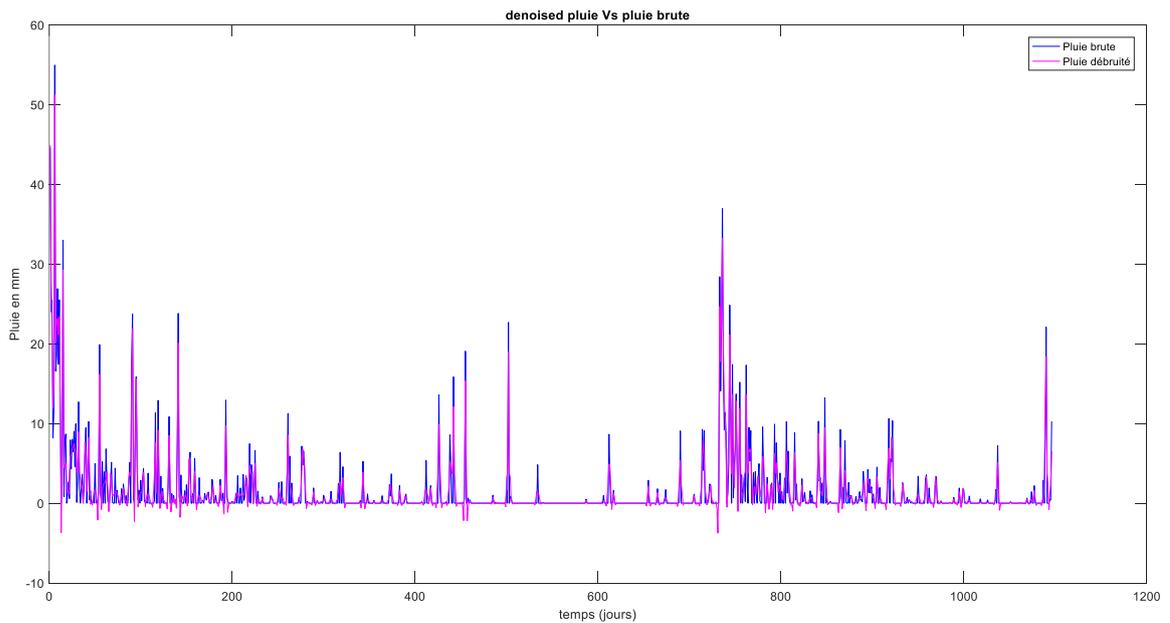


Figure 4.19 : Pluie bruité et Pluie débruité en utilisant Coiflet1 au premier niveau de décomposition

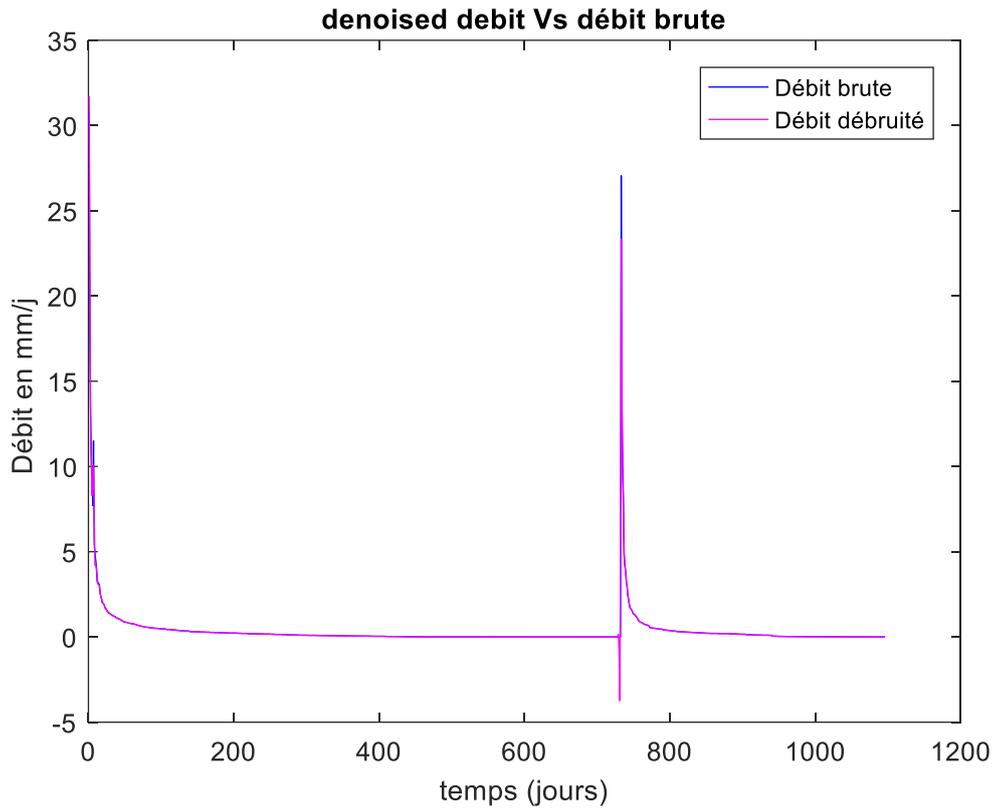


Figure 4.20 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au premier niveau de décomposition

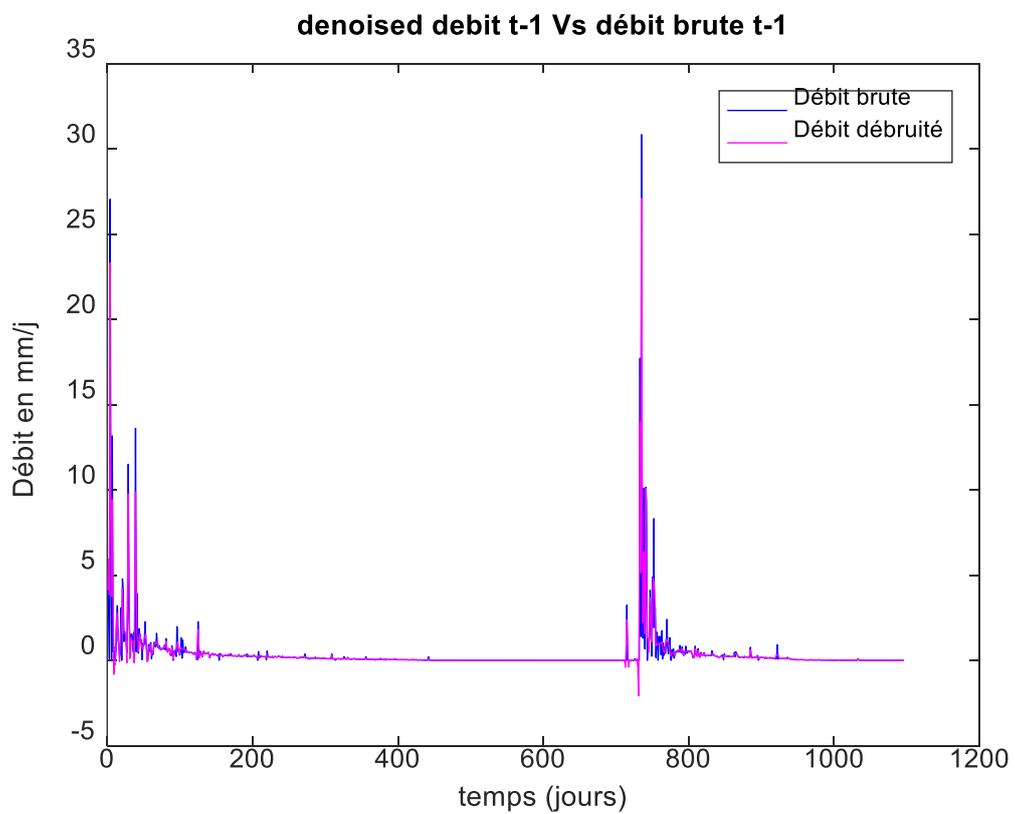


Figure 4.21 : ébit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au premier niveau de décomposition

- Niveau de décomposition 2 :

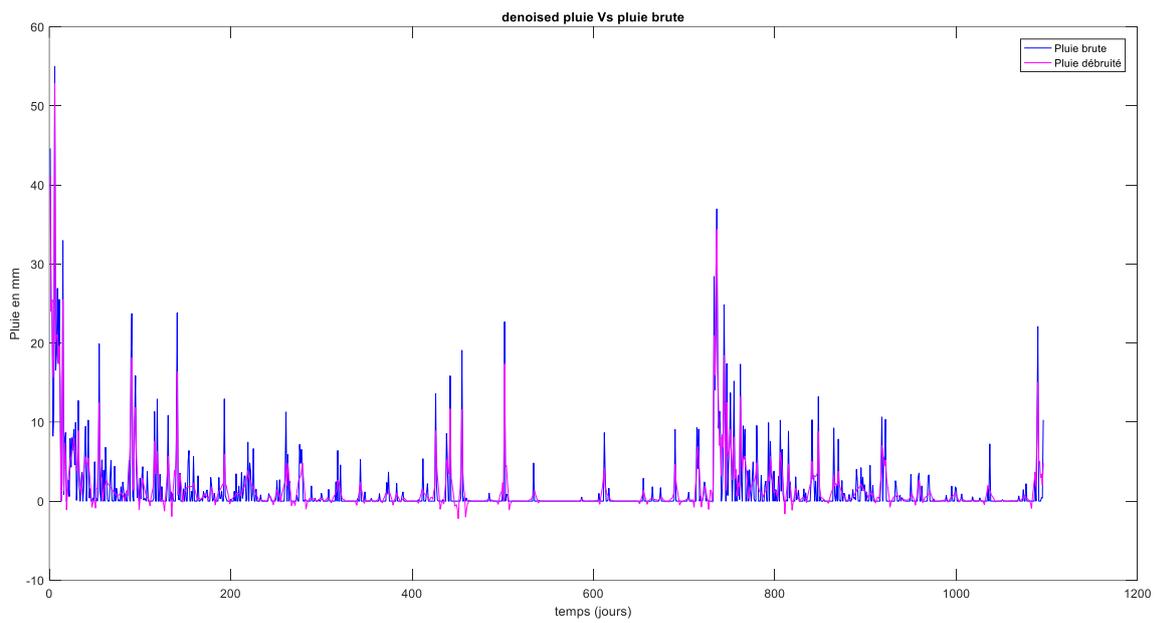


Figure 4.22 : Pluie bruité et Pluie débruité en utilisant Coiflet1 au deuxième niveau de décomposition

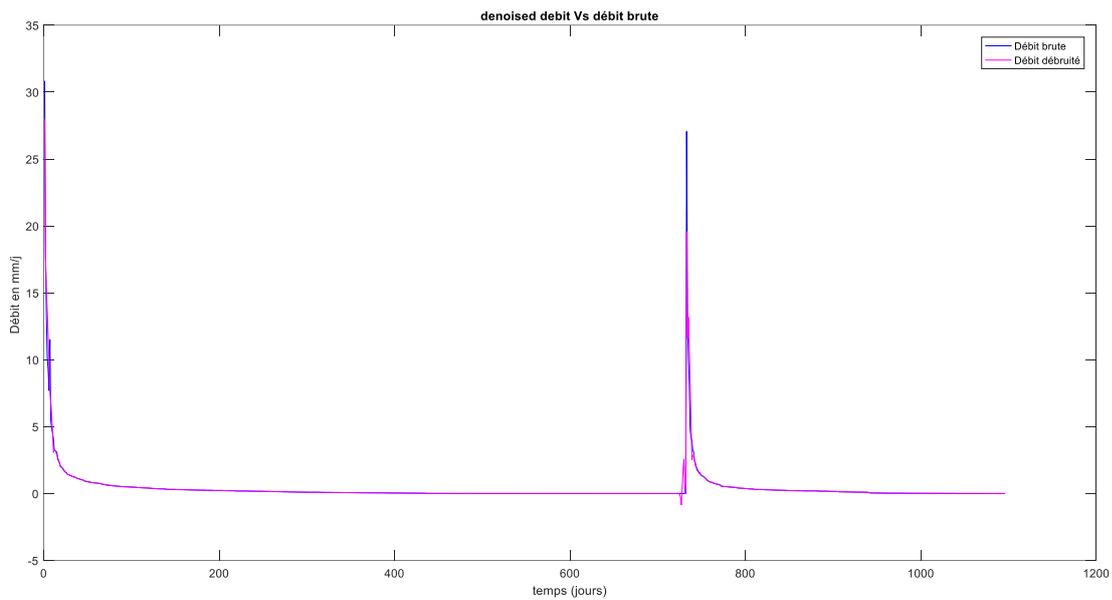


Figure 4.23 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au deuxième niveau de décomposition

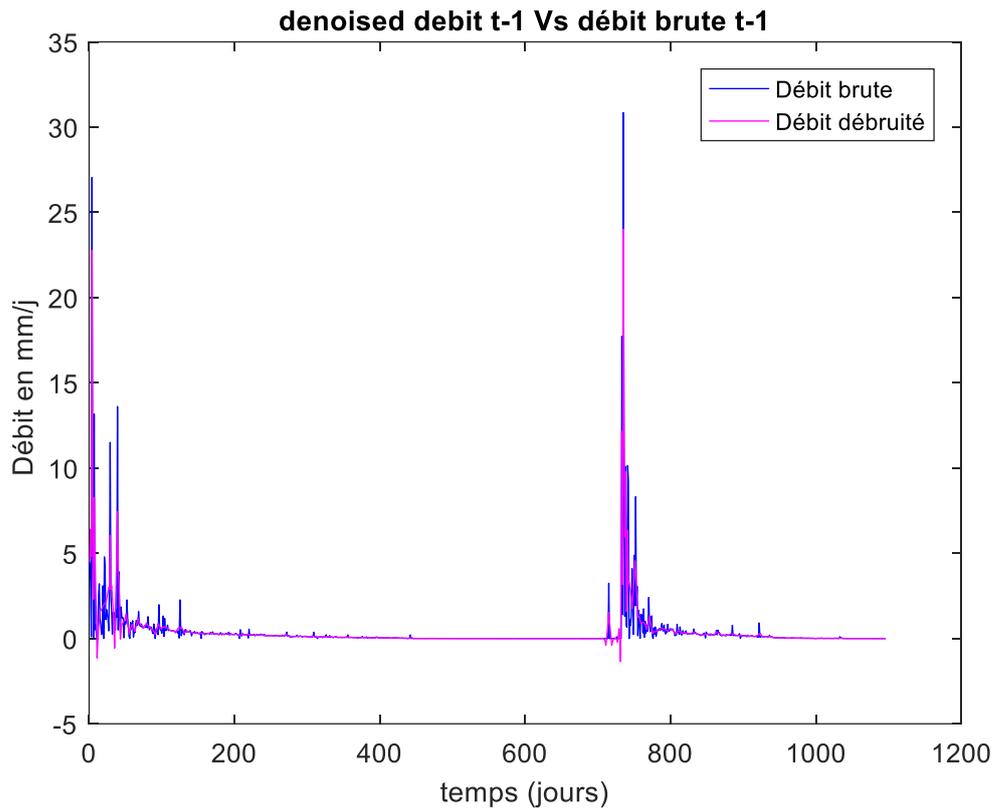


Figure 4.24 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au deuxième niveau de décomposition

- Niveau de décomposition 3 :

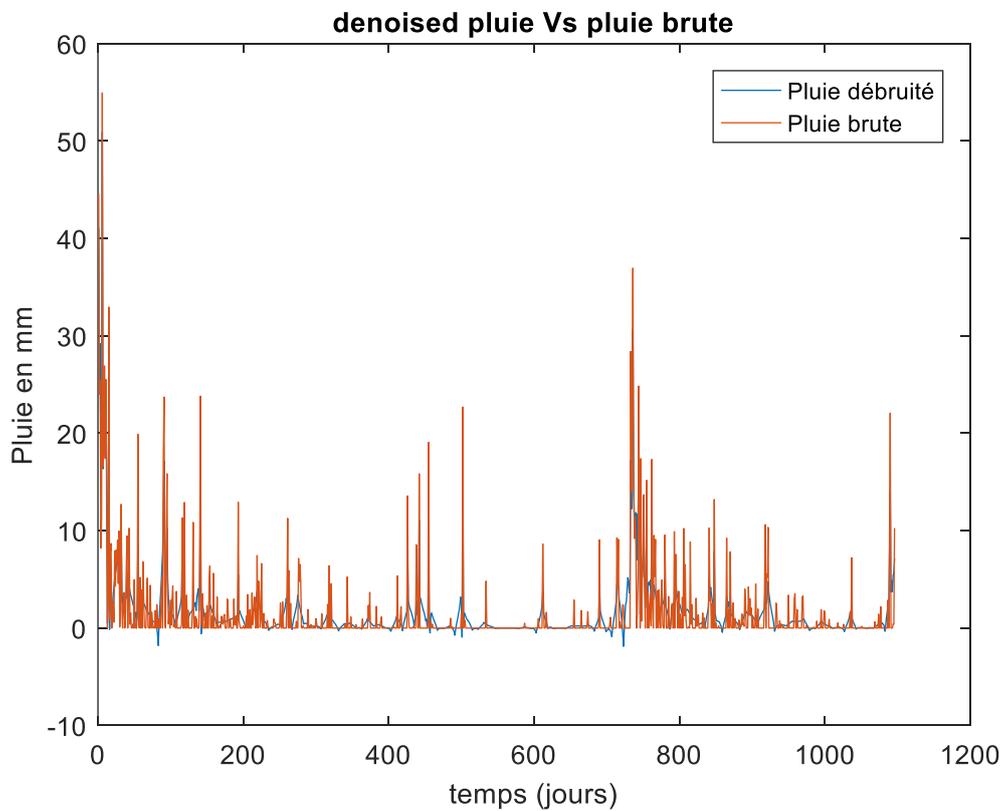


Figure 4.25 : Pluie bruité et Pluie débruité en utilisant Symlet3 au troisième niveau de décomposition (niveau max)

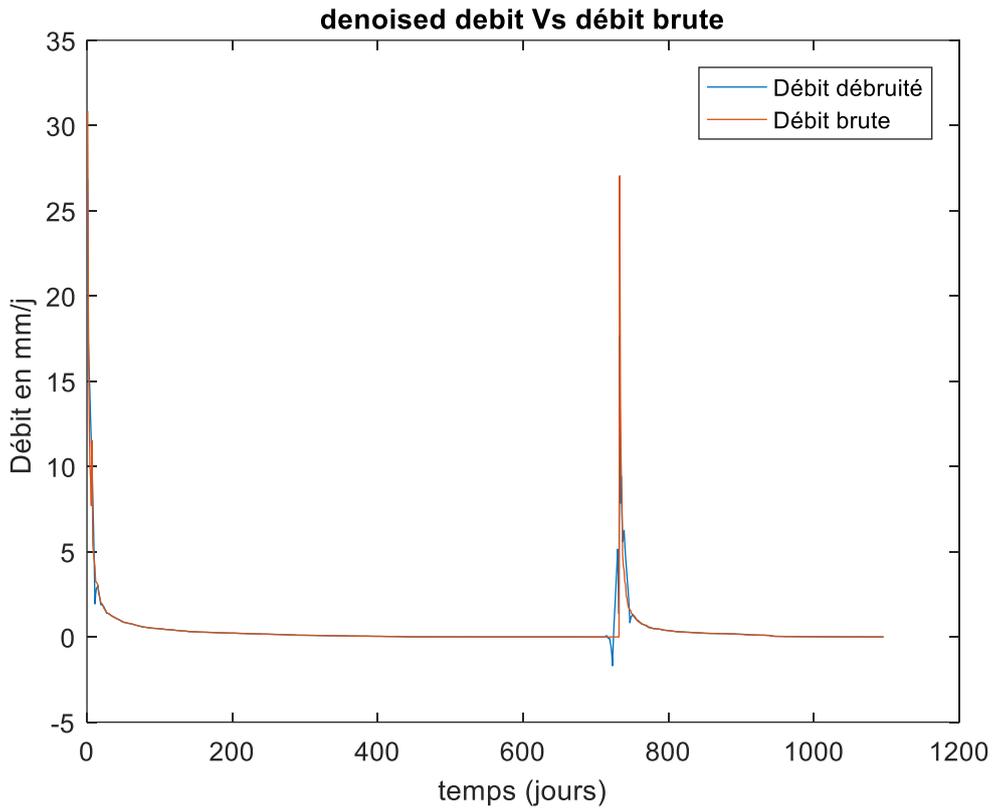


Figure 4.26 : Débit  $Q(t)$  bruité et débit  $Q(t)$  débruité en utilisant Coiflet1 au troisième niveau de décomposition (niveau max)

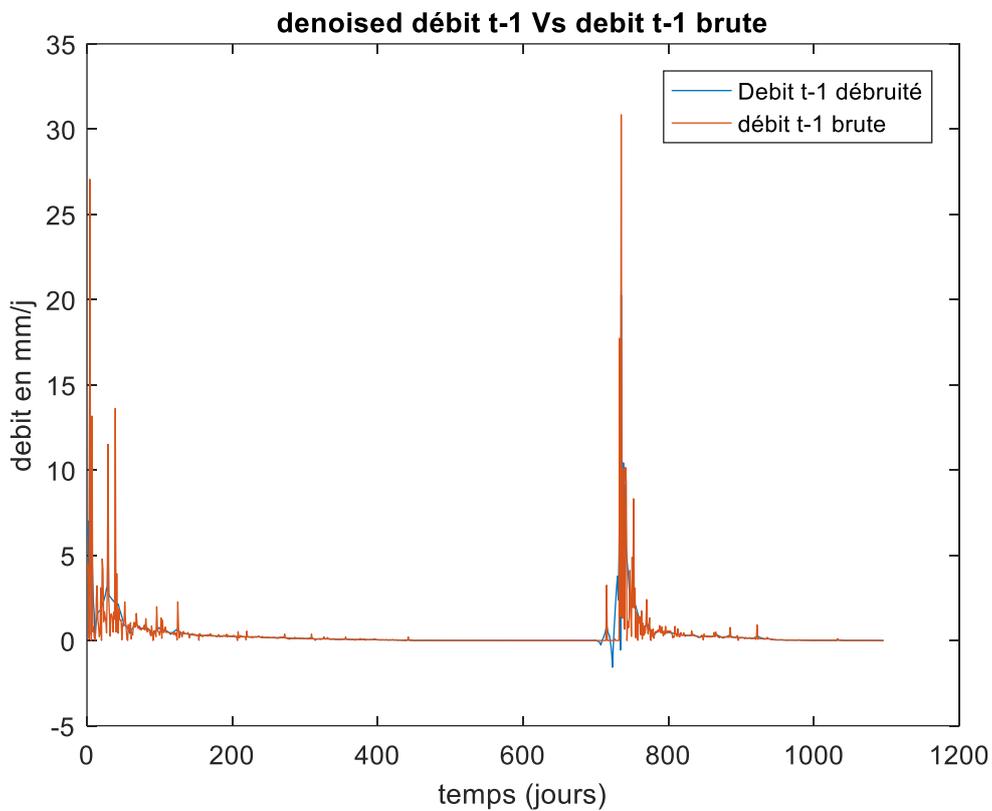


Figure 4.27 : Débit  $Q(t-1)$  bruité et débit  $Q(t-1)$  débruité en utilisant Coiflet1 au troisième niveau de décomposition (niveau max)

## Chapitre 4. Observations & Discussions

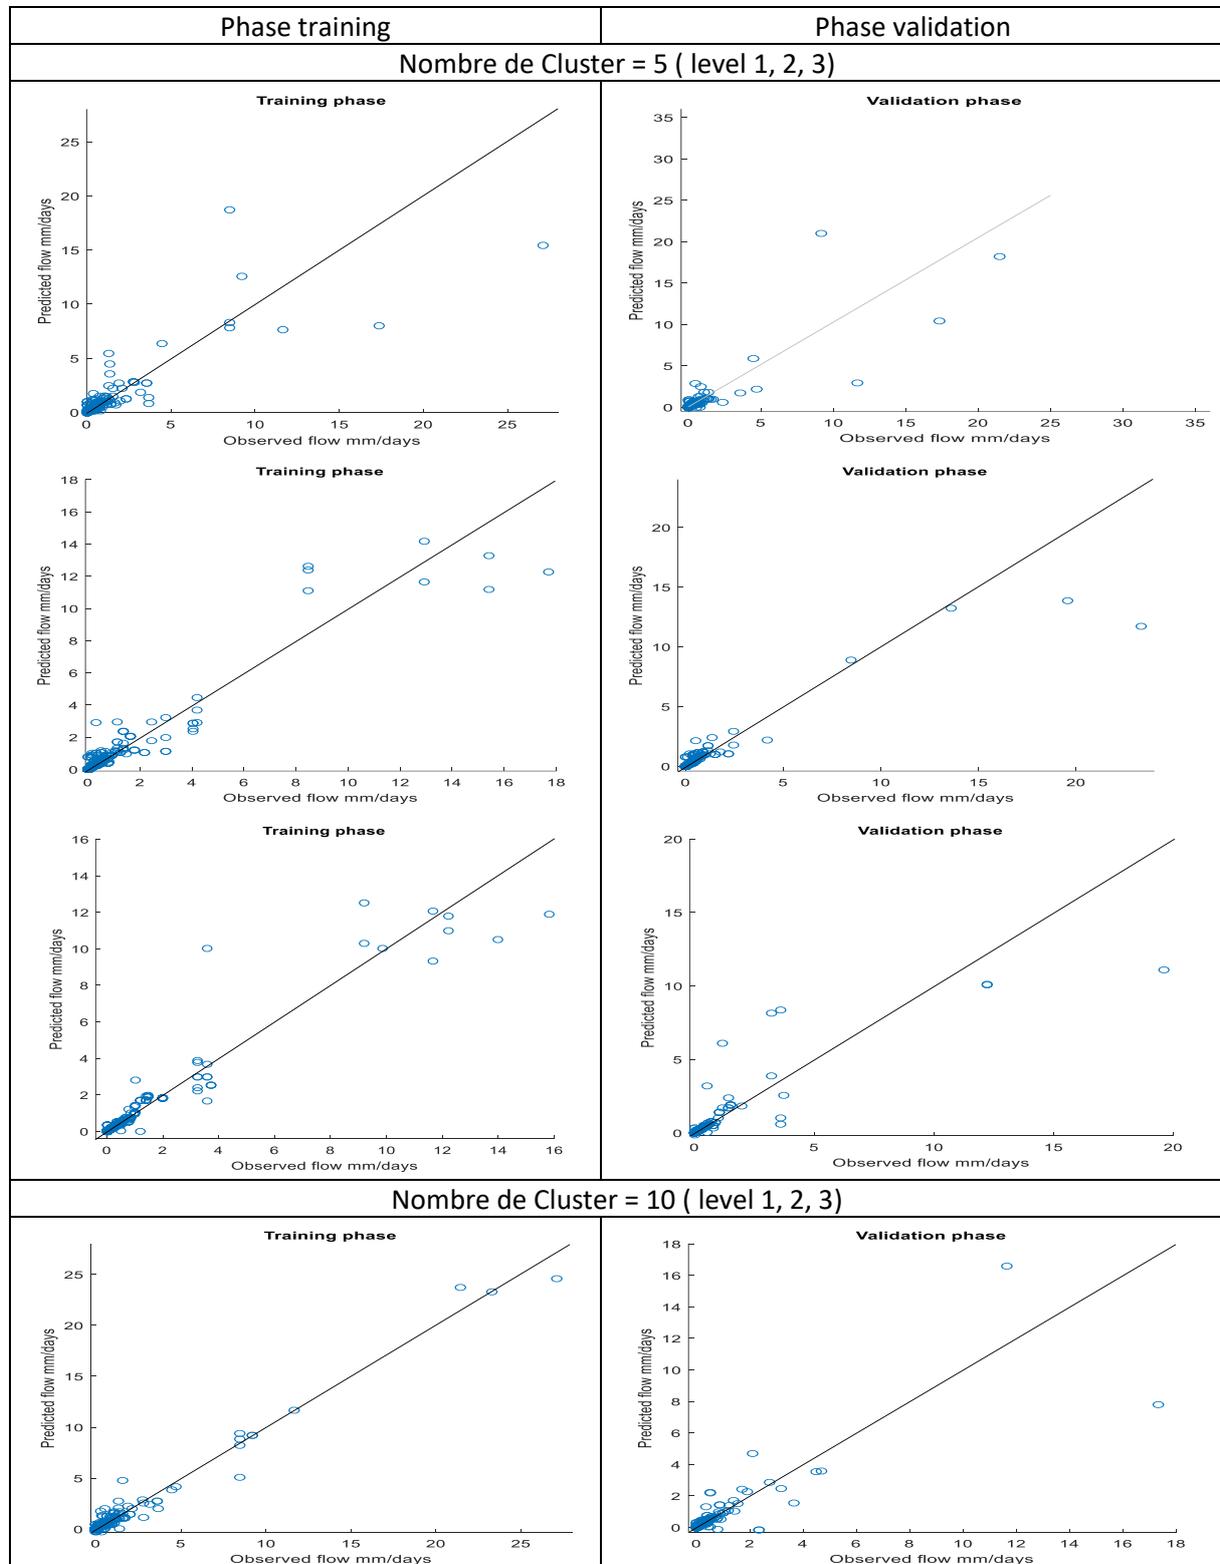
On obtient les résultats suivants :

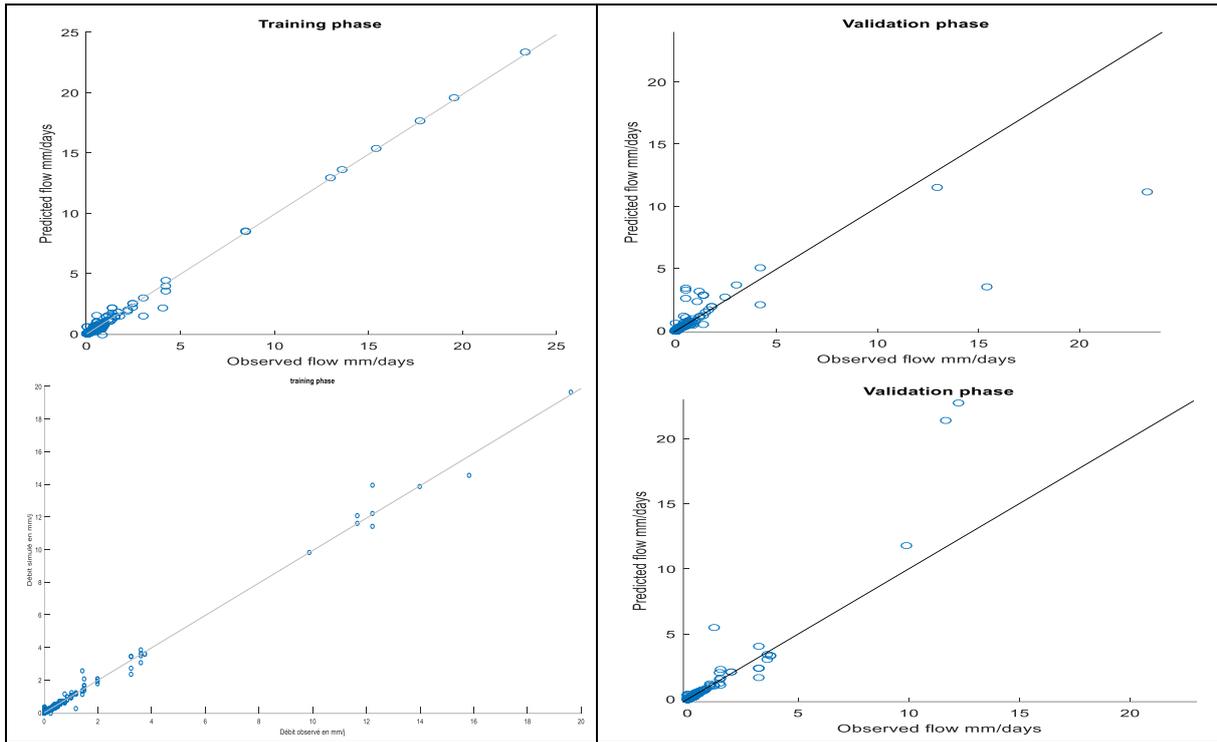
Tableau 4.3 : Résultats obtenus avec le modèle Wavelet-ANFIS

nombre de cluster			5			10			15			30		
	niveau de décomposition	étapes	NSE	RSR	R <sup>2</sup>	NSE	RSR	R <sup>2</sup>	NSE	RSR	R <sup>2</sup>	NSE	RSR	R <sup>2</sup>
<b>Haar</b>	1	training	0.8017	0.4453	0.8017	0.965	0.1872	0.965	0.8435	0.3956	0.8435	0.9947	0.0731	0.9947
		validation	0.7645	0.4852	0.7918	0.5616	0.6621	0.5759	0.5143	0.6969	0.6434	0.4737	0.7255	0.5474
	2	training	0.9511	0.2211	0.9511	0.9932	0.0826	0.9932	0.8907	0.3306	0.8907	0.9893	0.1036	0.9893
		validation	0.1947	0.8974	0.6377	0.3397	0.8126	0.6156	-0.4786	1.216	0.4079	0.3395	0.8127	0.721
	3	training	0.9685	0.1776	0.9685	0.9935	0.0804	0.9935	0.9957	0.0656	0.9957	0.9997	0.0186	0.9997
		validation	0.8227	0.4211	0.8478	0.7654	0.4843	0.794	0.8577	0.3772	0.859	0.4874	0.716	0.8208
<b>Coif1</b>	1	training	0.7693	0.4803	0.7693	0.8251	0.4182	0.8251	0.7863	0.4623	0.7863			
		validation	0.4994	0.7076	0.6009	0.2326	0.876	0.6544	0.5515	0.6697	0.5532			
	2	training	0.8729	0.3565	0.8729	0.9731	0.1639	0.9731	0.9313	0.2622	0.9313			
		validation	0.7451	0.5049	0.7487	0.5618	0.662	0.5654	0.6929	0.5541	0.7322			
	3	training	0.8607	0.3732	0.8607	0.8751	0.3535	0.8751	0.9877	0.1111	0.9877			
		validation	0.8464	0.3919	0.8575	0.6533	0.5888	0.6613	0.2121	0.8877	0.3756			
<b>Sym3</b>	1	training	0.8288	0.4138	0.8288	0.8228	0.4209	0.8228	0.9813	0.1367	0.9813			
		validation	0.0761	0.9612	0.3711	0.1432	0.9256	0.3409	0.3433	0.8104	0.3725			
	2	training	0.813	0.4324	0.813	0.9491	0.2256	0.9491	0.9632	0.1919	0.9632			
		validation	0.3281	0.8197	0.4285	0.5771	0.6503	0.6362	0.6082	0.6259	0.6107			
	3	training	0.8638	0.369	0.8638	0.9102	0.2997	0.9102	0.9565	0.2085	0.9565			
		validation	0.3949	0.7779	0.625	0.1247	0.9356	0.4965	0.6384	0.6013	0.7238			

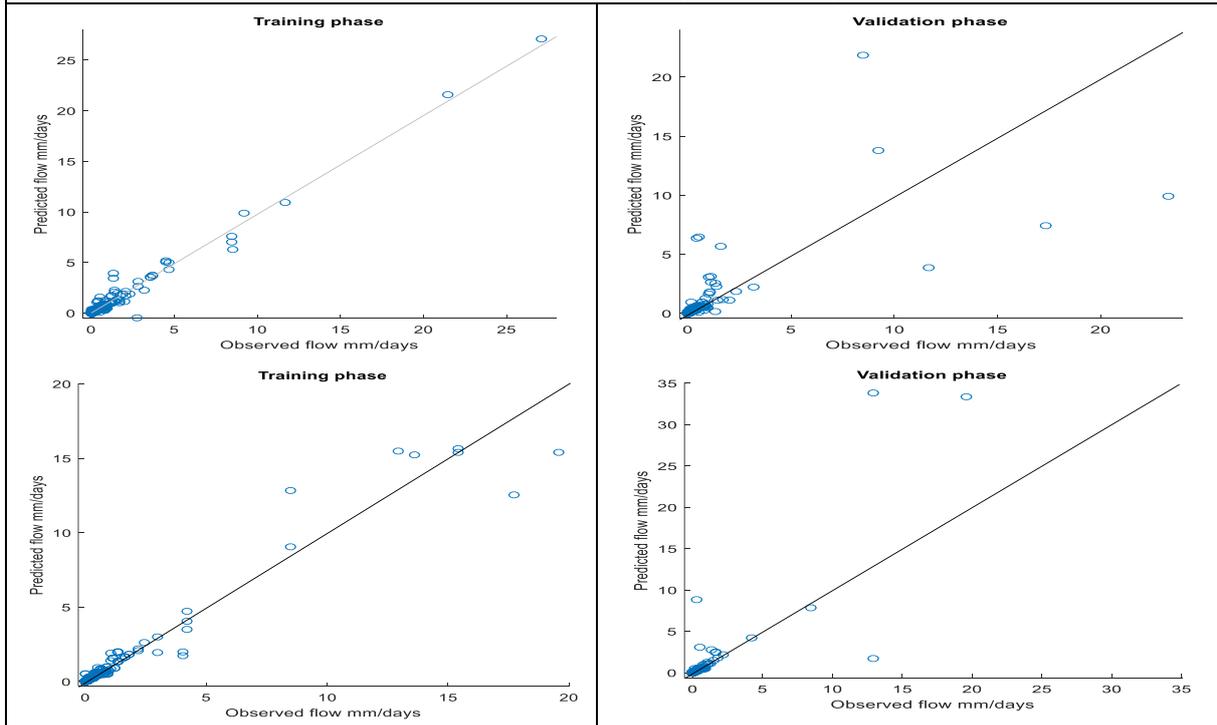
**Résultats  
insatisfaisants pour la  
phase calibration**

D'après le tableau, on remarque que les meilleurs résultats ont été obtenues avec la décomposition en wavelet Haar. Et on peut confirmer ces résultats avec le graphe des débits simulés en fonction des débits observés et le graphe des débits observés et simulés en fonction du temps





Nombre de Cluster = 15 ( level 1, 2, 3)



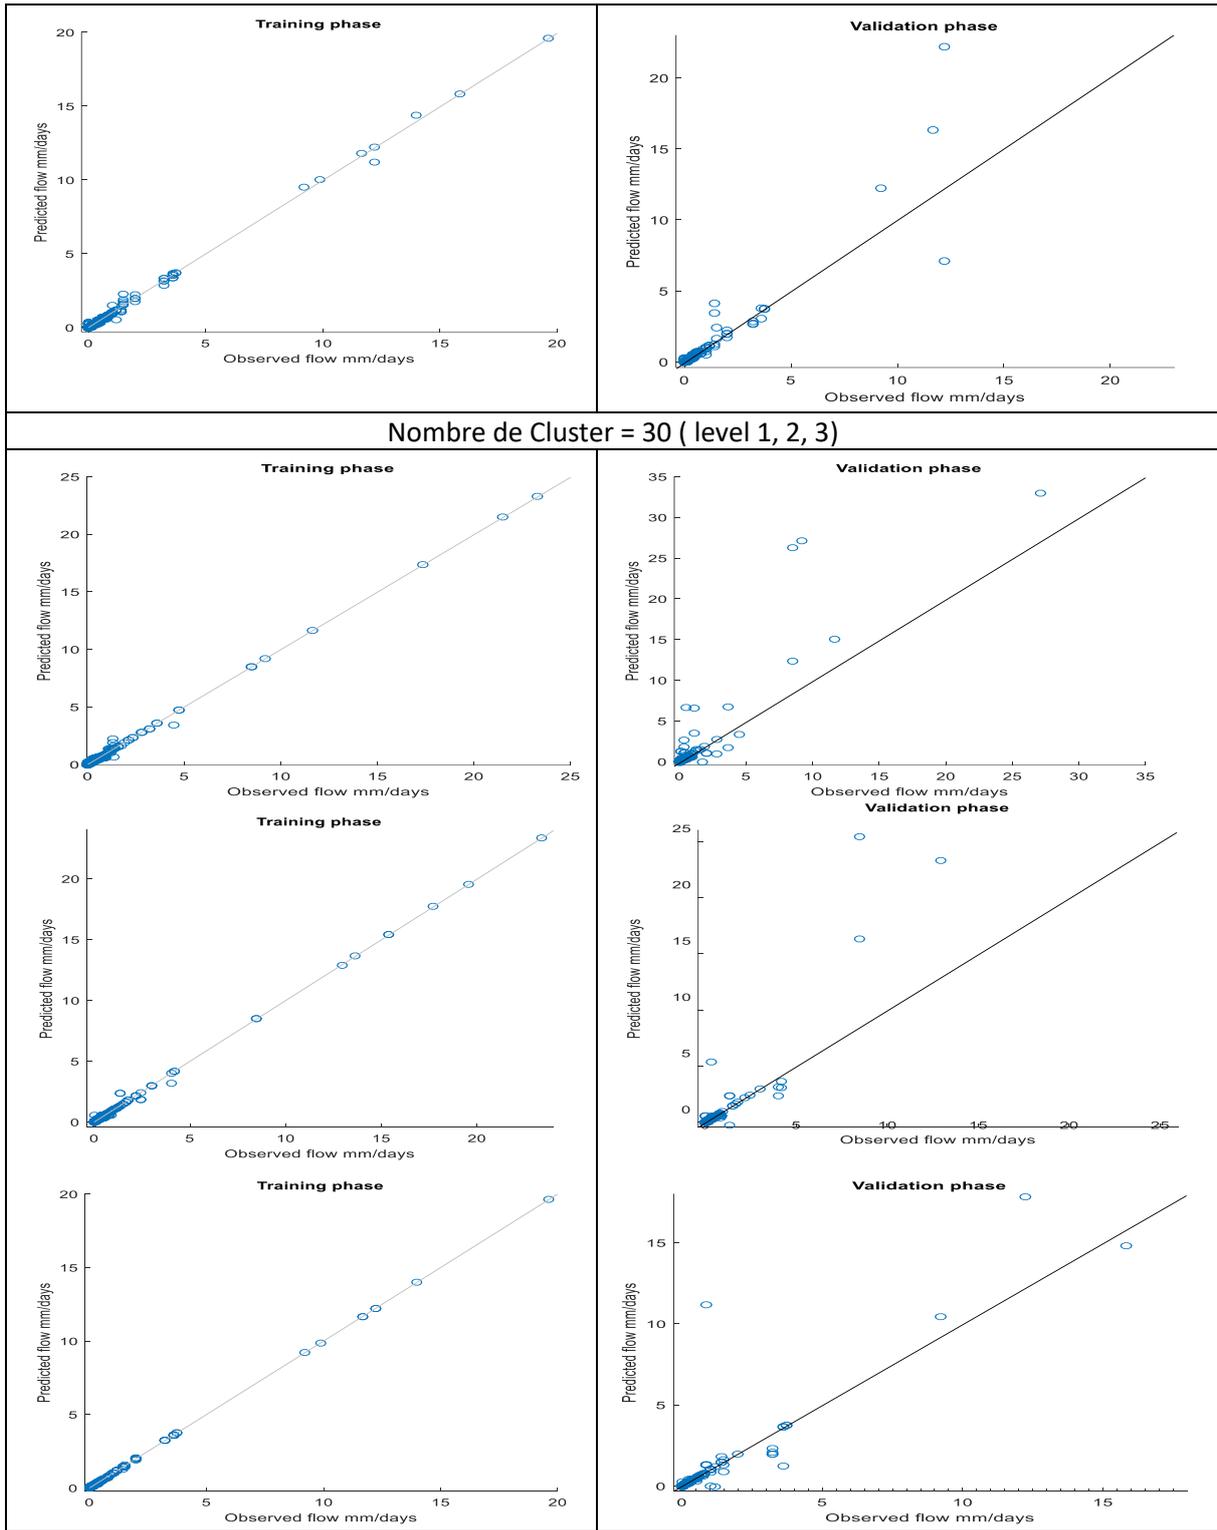


Figure 4.28 : Débits simulés en fonction des débits observés pour Wavelet (Haar)-ANFIS

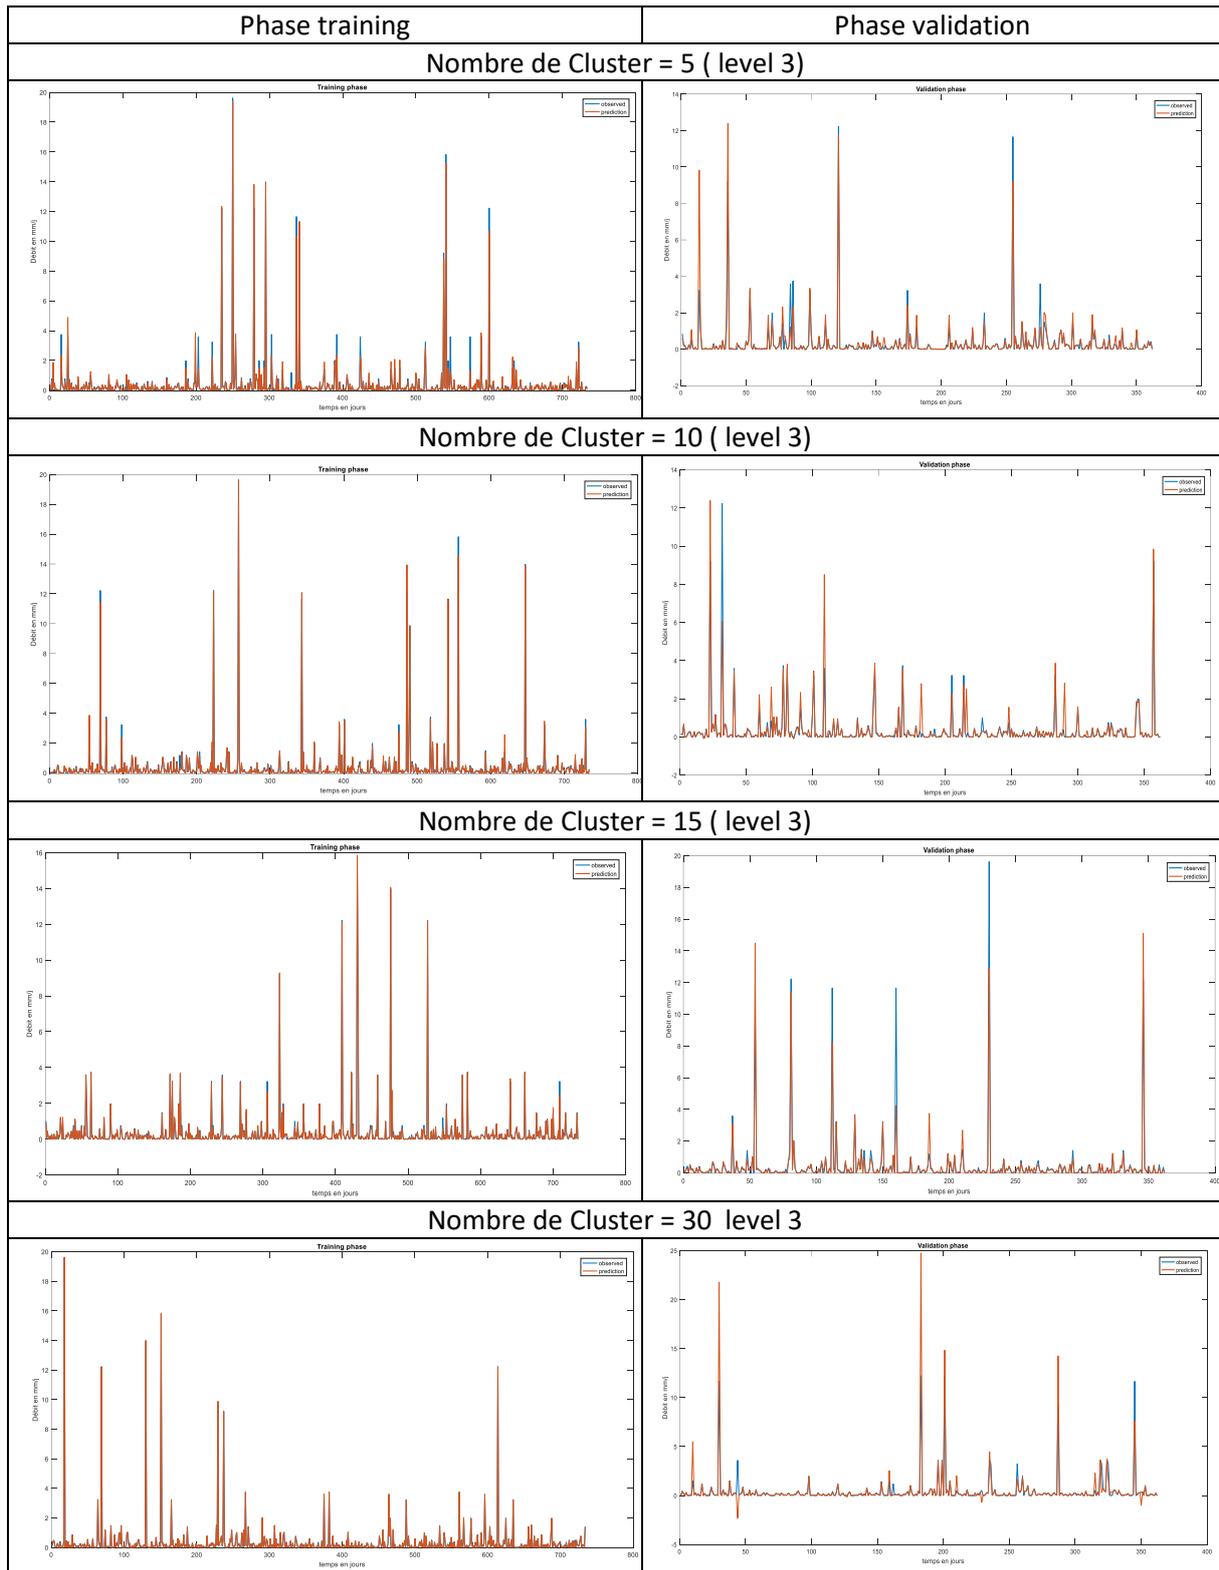


Figure 4.29: Débits observés et simulés en fonction du temps pour le modèle Wavelet (Haar )-ANFIS

On rappelle les résultats obtenus dans le projet de fin d'études « Couplage du Wavelet-ANN pour la modélisation pluie-débit » :

#### 4.4 Application du modèle MLP

❖ Sans Wavelet :

Tableau 4.4 : Résultats obtenus avec le modèle MLP

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R <sup>2</sup> %
14	5	training	0.6573	0.5854	8.32%	67.01%
		validation	-0.3	1.1402	19.03%	5.82%
16	4	training	0.735	0.5148	-24.71%	74.39%
		validation	-0.018	1.009	-11.12%	16.46%
10	6	training	0.6159	0.6197	20.07%	62.60%
		validation	-1.6955	1.6418	54.93%	1.44%

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

Tableau 4.5 : Résultats obtenus avec le modèle Wavelet-MLP

Nbre neurone	D	Nbre couche cachée=1	Nash	RSR	Pbias %	R <sup>2</sup> %
14	5	training	0.7699	0.4797	-7.43%	77.05%
		validation	0.1707	0.9107	12.25%	25.60%
16	4	training	0.7889	0.4595	-41.59%	80.74%
		validation	0.1003	0.9485	-51.08%	29.04%
10	6	training	0.639	0.6009	-17.58%	64.62%
		validation	0.3393	0.8129	-6.84%	34.21%

#### 4.5 Application du modèle NARX

❖ Sans wavelet :

Tableau 4.6 : Résultats obtenus avec le modèle NARX

Structure ANN	d		Nash	RSR	Pbias  %	R <sup>2</sup> %
Q(t+1) =f(Qt,	6-8-1	2 training	0.8563	0.3790	-18.62%	85.86%
		validation	0.1254	0.9352	-22.89%	28.05%

<b>Qt-1, Pt-1, Pt</b> <b>(4,n,1)</b>	4-8-1		training	0.9591	0.2022	1.45%	95.94%
			validation	-0.8516	1.3607	-12.49%	20.64%
	4-12-1		training	0.9668	0.1821	-0.40%	96.70%
			validation	-0.8990	1.3780	-20.94%	21.33%
<b>Q(t+1)</b> <b>=f (Qt,</b> <b>Qt-1, Pt</b> <b>,Pt-1,</b> <b>Pt-2, Qt-</b> <b>2)</b> <b>(6,n,1)</b>	6-10-1	3	training	0.9599	0.2002	-2.54%	96.00%
			validation	0.0677	0.9655	10.33%	34.88%
	6-8-1		training	0.3765	0.7897	0.68%	45.22%
			validation	0.3491	0.8068	-15.91%	36.18%
	6-12-1		training	0.8942	0.3252	-2.03%	91.22%
			validation	-0.9815	1.4076	-5.14%	14.26%
<b>Q(t+1)</b> <b>=f (Qt,</b> <b>Qt-1, Pt</b> <b>,Pt-1,</b> <b>Pt-2, Qt-</b> <b>2,Pt-3,</b> <b>Qt-3)</b> <b>(8,n,1)</b>	8-8-1	4	training	0.7678	0.4819	5.16%	76.89%
			validation	0.2221	0.8820	9.61%	34.03%
	8-11-1		training	0.9612	0.1970	-1.92%	96.12%
			validation	0.3170	0.8264	-4.44%	41.32%
	8-13-1		training	0.8560	0.3795	-15.13%	85.71%
			validation	0.3675	0.7953	-14.63%	44.73%
<b>Q(t+1)</b> <b>=f (Qt,</b> <b>Qt-1, Pt</b> <b>,Pt-1,</b> <b>Pt-2, Qt-</b> <b>2,Pt-3,</b> <b>Qt-3, Pt-</b> <b>4, Qt-4)</b> <b>(10,n,1)</b>	10-8-1	5	training	0.8710	0.3591	-1.56%	87.21%
			validation	0.2182	0.8842	0.14%	34.64%
	10-10-1		training	0.7327	0.5170	2.80%	74.80%
			validation	0.4565	0.7372	-5.08%	48.36%
	10-6-1		training	0.8405	0.3993	-2.12%	84.35%
			validation	0.2304	0.8773	-7.70%	34.12%

❖ **Avec Wavelet :**

Tableau 4.7 : Résultats obtenus avec le modèle Wavelet-NARX

Wavelet	Level decomp osition wavelet	ANN structure		Nash	RSR	Pbias  %	R <sup>2</sup> %
Haar	1	10-13-1	training	0.9466	0.2312	0.85%	94.66%
			validation	0.7560	0.4940	6.53%	75.73%
Haar	2	4-6-1	training	0.9427	0.2394	11.45%	94.46%
			validation	0.6051	0.6284	4.94%	64.37%
Haar	3	6-13-1	training	0.9469	0.2305	-0.33%	94.69%
			validation	0.6304	0.608	0.76%	64.79%
Coif1	1	8-6-1	training	0.9684	0.1777	1.54%	97.68%
			validation	0.7524	0.4976	10.26%	75.44%
Coif1	2	6-10-1	training	0.9766	0.1529	0.1042	97.74%
			validation	0.7975	0.4500	0.1899	80.19%
Coif1	3	10-11-1	training	0.9827	0.1315	4.77%	98.28%

			validation	0.8609	0.3729	6.04%	86.62%
<b>Sym3</b>	1	6-13-1	training	0.9510	0.2212	-5.03%	95.14%
			validation	0.6094	0.6250	-7.72%	72.15%
<b>Sym3</b>	2	8-15-1	training	0.9133	0.2944	-2.32%	91.45%
			validation	0.6833	0.5627	-2.09%	72.75%
<b>Sym3</b>	3	8-11-1	training	0.9645	0.1884	-2.02%	96.46%
			validation	0.7387	0.5112	1.13%	75.89%

Si on se base sur les critères d'évaluations numériques, on peut constater que le modèle MLP à une entrée P est le moins fiable, vu ces résultats insatisfaisants dans l'étape de validation.

Ci-dessous le tableau résumant les résultats obtenus en utilisant le wavelet-Narx et Wavelet-ANFIS

Tableau 4.8 : Résumé des résultats obtenus avec les modèles Wavelet-NARX et Wavelet-ANFIS

Wavelet	ANN		ANFIS (ncluster =15)	
	Level decomposition wavelet	ANN structure	R <sup>2</sup>	R <sup>2</sup>
<b>Haar</b>	training	10-13-1	0.9466	0.8435
	validation		0.7560	0.6434
<b>Haar</b>	training	4-6-1	0.9427	0.8907
	validation		0.6051	0.4079
<b>Haar</b>	training	6-13-1	0.9469	0.9957
	validation		0.6304	0.859
<b>Coif1</b>	training	8-6-1	0.9684	0.7863
	validation		0.7524	0.5532
<b>Coif1</b>	training	6-10-1	0.9766	0.9313
	validation		0.7975	0.7322
<b>Coif1</b>	training	10-11-1	0.9827	0.9877
	validation		0.8609	0.3756
<b>Sym3</b>	training	6-13-1	0.9510	0.9813
	validation		0.6094	0.3725
<b>Sym3</b>	training	8-15-1	0.9133	0.9632
	validation		0.6833	0.6107
<b>Sym3</b>	training	8-11-1	0.9645	0.9565
	validation		0.7387	0.7238

On remarque que dans la plupart des cas, le modèle Wavelet-NARX est plus performant que le modèle Wavelet-ANFIS, sauf dans le cas où on a utilisé Haar au niveau max de décomposition.

# **Conclusion générale**

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

Pour répondre à cette problématique nous avons d'abord traité les données manuellement et ensuite on a fait une modélisation pluie-débit avec le ANFIS, en variant le nombre de clusters entre 5 et 30. En appliquant ce modèle sur la région des Isser, ce modèle n'a pas donné de très bons résultats pour la phase de validation, puisqu'on a obtenu des coefficients de détermination variant entre 34% et 63%. Mais pour la phase training, de très bons résultats ont été observé avec un coefficient de détermination variant entre 70% et 99%.

Après nous avons considéré le couplage wavelet-ANFIS, avec l'utilisation des familles de wavelet Haar, Coif1,Sym3. Avec la wavelet Haar, nous avons obtenu d'excellents résultats pour un nombre de clusters variant entre 5 et 30 et un niveau de décomposition variant de 1 au niveau max (niveau3).

Pour le couplage Wavelet-ANFIS en utilisant Coiflet1 et Symlet3, nous avons obtenu de mauvais résultats pour la phase validation pour un nombre de clusters égal à 30. Mais pour un nombre de cluster égal à 5, 10, et 15 nous avons obtenu des résultats satisfaisants.

Ce que nous pourrions conclure pour cette partie, c'est que le débruitage en utilisant le Haar donne de bien meilleurs résultats qu'en utilisant le Coiflet1 et Symlet3.

Pour la seconde partie qui est la comparaison entre les résultats obtenu en utilisant le couplage Wavelet-ANFIS avec un nombre de clusters égal à 15 et le couplage Wavelet-ANN, on constate que le modèle MLP est le moins fiable entre les trois modèles choisis et on remarque aussi que dans la plupart des structures choisies le NARX est le plus performant sauf dans le cas où on a utilisé le Haar au niveau max de décomposition.

Comme voie d'amélioration du processus, on propose l'utilisation du gamma-test et gradient test,comme l'a recommandé Remesan (2008), car elle peut fournir des informations vitales qui pourraient aider à la modélisation. Il existe des combinaisons d'entrées  $2n-1$  positivement significatives, d'où le meilleur peut être déterminé en observant la valeur statistique gamma.

On peut aussi parler des recommandations de Sudheer (2002). Une nouvelle approche pour la conception d'un modèle de pluie-débit ANN a été présenté. La méthode utilise les propriétés statistiques de la série de données pour identifier un vecteur d'entrée approprié au réseau et forme le réseau avec un algorithme standard. Les résultats globaux de l'étude sont très

prometteurs, car ils entraînent une réduction significative du temps de calcul. À partir des discussions susmentionnées, on peut conclure que l'algorithme proposé par Sudheer (2002) conduirait facilement à un réseau plus compact, évitant ainsi une longue procédure d'essai et d'erreur. L'étude suggère que la sélection statistique d'un vecteur d'entrée intégré avec un algorithme d'optimisation standard pour les paramètres du réseau pendant la formation peut réduire considérablement le temps de calcul et minimiser ainsi l'effort mis dans le développement du modèle. Une mise en œuvre réussie de la méthodologie présentée peut conduire à certaines procédures d'automatisation dans le développement de modèles étant donné que la méthodologie proposée est basée sur les informations contenues dans la série de données elle-même et repose sur des propriétés statistiques claires en tant que règle de décision ; l'approche devient plus explicite et peut être adoptée pour n'importe quel bassin.

Les avantages spécifiques de l'approche sont les suivants:

- (1) il peut déterminer quelles entrées sont importantes pour le modèle en question ;
- (2) il utilise des informations précieuses sur la relation entre les séries chronologiques d'entrée et de sortie ;
- (3) il est plus simple et plus rapide à utiliser, car il n'est pas nécessaire de prétraiter de manière importante les données. Il soulage également le modèle d'une longue procédure d'essai et d'erreur qui nécessite une certaine connaissance des RNA.

# **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, Murraray KB, Watson JN (2001) Wavelet transform analysis of open channel wake flows. *J Eng Mech* 127(1):58–70
3. Ahmat Nor, N.I.B. 2005. Rainfall-runoff modelling using artificial neural network method. Ph.D. dissertation, Faculty of Civil Engineering, Malaysia Technology University.
4. Akbarpour, M. 2004. Simulation of rainfall-runoff process by artificial neural networks and HEC-HMS model (case study Zard River basin). Fourth International Iran and Russia Conference. Shahrekord University, pp. 1143–1148.
5. Altunkaynak A (2007) Forecasting surface water level fluctuations of Lake Van by artificial neural networks. *Water Resour Manag* 21:399–408. doi:10.1007/s11269-006-9022-6
6. Anamala, J., Zhang, B., and Govindaraju, R.S. 2000. Comparison of ANN's and empirical approaches predicting watershed runoff. *Journal of Water Resources Planning and Management*, 126(3): 56–66.
7. Anctil, F., Perrin, C., and Andreassian, V. 2003. ANN output updating of lumped conceptual rainfall-runoff forecasting models. *Journal of the American Water Resources Association*, 39(5): 1269–1279. doi:10.1111/j.1752-1688.2003.tb03708.x.
8. Aqil M, Kita I, Yano A, Nishiyama S (2007) Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *J Environ Manag* 85:215–223
9. 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.
10. Aziz, A.R.A., and Wong, K.F.V. (1992). “Neural network approach to the determination of aquifer parameters.” *Ground Water*, 30(2), 164–166.
11. Basha, H.A. 2000. Simple nonlinear rainfall-runoff model. *Journal of Hydraulic Engineering*, 5(1): 25–32.
12. Bergström, S. et Forsman, A., 1973. Development of a conceptual deterministic rainfall-runoff model. *Nordic Hydrology* 4, 147-170.
13. Bhattacharya, B., and Solomatine, D.P. 2000. Application of artificial neural network in stage-discharge relationship. 4th International Conference on Hydroinformatics, Iowa City, USA.

14. Bhattacharya, B., and Solomatine, D.P. 2006. Machine learning in sedimentation modeling. *Neural Networks*, 19(2): 208–214. doi:10.1016/j.neunet.2006.01.007.
15. Boughton, W. et Droop, O., 2003. Continuous simulation for design flood estimation-- a review. *Environmental Modelling & Software* 18(4), 309-318.
16. Birikundavyi et al (2002). Performance of Neural Networks in Daily Streamflow Forecasting
17. Bruen, M., and Yang, J. 2005. Functional networks in real-time flood forecasting-a novel application. *Advances in Water Resources*, 28(9): 899–909. doi:10.1016/j.advwatres.2005.03.001.
18. 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.
19. 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
20. CHEN, S.M., WANG, Y.M. & TSOU, I. *J Earth Syst Sci* (2013). Using artificial neural network approach for modelling rainfall–runoff due to typhoon. 122: 399. doi:10.1007/s12040-013-0289-8
21. Cigizoglu, H. 2004. Estimation and forecasting of daily suspended sediment data by multilayer perceptions. *Advances in Water Resources*, 27(2): 185–195. doi:10.1016/j.advwatres.2003.10.003.
22. Da Ros, D. et Borga, M. (1997). Adaptive use of a conceptual model for real time forecasting *Nordic Hydrology*, 28(3), 169-188.
23. Dibike, Y.B., and Solomatine, D.P. 2000. River flow forecasting using artificial neural networks. *Physics and Chemistry of the Earth*, 26(1): 1–7.
24. Donoho DL (1995) Denoising by soft-thresholding. *IEEE Trans Inf Theory* 41(3):613–617
25. Donoho DL, Johnstone IM (1995) Ideal spatial adaptation via wavelet shrinkage. *Biometrik* 81(3):425–455
26. Dorum, A., Yasar, A., Faik Sevimli, M., and Onüçyildiz, M. 2010. Modelling the rainfall–runoff data of Susurluk Basin. *Expert Systems with Applications*, 37(9): 6587–6593. doi:10.1016/j.eswa.2010.02.127.
27. El-Shafie A, Taha MR, Noureldin A (2007) A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water Resour Manag* 21:533–556
28. French, M. N., Krajewski, W. F., and Cuykendal, R. R. (1992). Rainfall forecasting in space and time using a neural network. “*J. Hydrol., Amsterdam*, 137, 1–37.
29. Goyal and C. Ojha, "Analysis of Mean Monthly Rainfall Runoff Data of Indian Catchments Using Dimensionless Variables by Neural Network," *Journal of*

- Environmental Protection, Vol. 1 No. 2, 2010, pp. 155-171.  
doi: 10.4236/jep.2010.12020.
30. 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.
31. Hsu, K., Gupta, H.V., and Sorooshian, S. 1995. Artificial neural network modeling of the rainfall-runoff process. Water Resources Research, 31(10): 2517–2530. doi:10.1029/95WR01955.
32. Huang et al (2004). Forecasting flows in Apalachicola River using neural networks.
33. Jain, A., and Srinivasulu, S. 2006. Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques. Journal of Hydrology (Amsterdam), 317(3–4): 291–306. doi:10.1016/j.jhydrol.2005.05.022.
34. Jang JSR, Sun CT (1995) Neuro-fuzzy modeling and control. Proc IEEE 83:378–406
35. Jang JSR, Sun CT, Mizutani E (1997) Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence, 3rd edn. Prentice-Hall, New Jersey
36. Johnson, V. M., and Rogers, L. L. (1995). “Location analysis in groundwater remediation using NN.” Groundwater, 33(5), 749–758.
37. Junsawang, P., Asavanant, J., and Lursinsap, C. 2007. Artificial neural network model for rainfall-runoff relationship. Proceeding of the 2nd Asian Simulation and Modelling (ASSIMOD2007), 9–11 January, Chaing Mai, Thailand. pp. 267–274
38. Kang, K. W., Kim, J. H., Park, C. Y., and Ham, K. J. (1993). “Evaluation of hydrological forecasting system based on neural network model.” Proc., 25th Congress of Int. Assoc. for Hydr. Res., International Association for Hydraulic Research, Delft, The Netherlands, 257–264.
39. Karunanithi, N., Grenney, W. J., Whitley, D., and Bovee, K. (1994). Neural networks for river flow prediction. J. Comp. in Civ. Engrg., ASCE, 8(2), 201–220.
40. Katleh, A M. 2008. Rainfall-runoff modeling using artificial neural networks (ANNs) : modeling and understanding. Caspian J. Env. Sci. Vol. 6 No. 1 pp 53-58.
41. 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.
42. 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
43. Kisi, O., 2004. River flow modeling using artificial neural networks. Journal of Hydrologic Engineering 9 (1), 60–63
44. Kisi O (2009) Neural networks and wavelet conjunction model for intermittent stream flow forecasting. J Hydrol Eng 14(8):773–782

45. Kisi O (2010) Daily suspended sediment estimation using neuro-wavelet models. *Int J Earth Sci* 99:1471–1482
46. Kisi O, Shiri J (2011) Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models. *Water Resour Manage* 25:3135–3152
47. Kumar et al (2004). River Flow Forecasting using Recurrent Neural Networks.
48. Kurtulus, B., and Razack, M. 2010. Modeling daily discharge responses of a large karstic aquifer using soft computing methods: artificial neural network and neuro-fuzzy. *Journal of Hydrology (Amsterdam)*, 381(1–2):101–111. doi:10.1016/j.jhydrol.2009.11.029.
49. Lamb, R., 1999. Calibration of a conceptual rainfall-runoff model for flood frequency estimation by continuous simulation. *Water Resources Research* 35(10), 3103-3114.
50. 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.
51. Linsley, R.K. (1982). Rainfall-runoff models - An overview. In: *Rainfall-runoff relationship*, V.P. Singh (Ed.), Water Resources Publications, 3-22.
52. 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
53. Li X, Ding J, Li H (1999) Combing neural network models based on wavelet transform. *J Hydraul* 2:1–4
54. Lohani, A.K., Goel, N.K., and Bhatia, K.K.S. 2006. Takagi-Sugeno fuzzy inference system for modeling stage-discharge relationship. *Journal of Hydrology*, 331(1–2): 146–160. doi:10.1016/j.jhydrol. 2006.05.007.
55. Lorrain, M., and Sechi, H.M. 1995. Neural networks for modeling rainfall-runoff transformations. *Water Resources Management*, 9(4): 299–313. doi:10.1007/BF00872489.
56. 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.
57. Markus, M., Salas, J. D., and Shin, H.-K. (1995). “Predicting streamflows based on neural networks.” *Proc., 1st Int. Conf. on Water Resour. Engrg.*, ASCE, New York, 1641–1646.
58. Mason, J. C., Price, R. K., and Tem‘me, A. (1996). “A neural network model of rainfall-runoff using radial basis functions.” *J. Hydr. Res., Delft, the Netherlands*, 34(4), 537–548.

59. 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
60. Melching, C.S., Yen, B.C., and Wenzel, H.G. 1991. Output reliability as guide for selection of rainfall-runoff models. *Journal of Water Resources Planning and Management*, 117(3): 383–393. doi:10.1061/(ASCE)0733-9496(1991)117:3(383).
61. Michel, MISITI. Wavelet Toolbox™ 4: user's guide. MATLAB The mathworks,2009. 153p.
62. Michel, MISITI. Wavelets and their Applications. iSTE. 2007. 352p
63. Mimikou, M., and Rao, A.R. 1983. Regional monthly rainfall-runoff model. *Journal of Water Resources Planning and Management*, 109(1): 75–93. doi:10.1061/(ASCE)0733-9496(1983)109:1(75).
64. 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.
65. 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.
66. Nayak, P.C., Sudheer, K.P., Rangan, D.M., and Ramasastri, K.S. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology (Amsterdam)*, 291(1–2): 52–66. doi:10.1016/j.jhydrol.2003.12.010.
67. Nayak, P., Rao, Y.R.S., Sudheer, K.P., 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resource Management* 20 (1), 77–90.
68. Nourani V, (2007) Liquid Analog Model for Laboratory Simulation of Rainfall–Runoff Process. *J. Hydrol. Eng.* 2007.12:246-255.
69. 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
70. Nourani V, Komasi M, Mano A (2009b) A multivariate ANN—Wavelet approach for rainfall-runoff modeling. *Water Resour Manage* 23:2877–2894
71. Nourani V, Kisi O, Komasi M (2011) Two hybrid artificial intelligence approaches for modeling rainfall—runoff process. *J Hydrol* 402:41–49
72. Nourani, V., Baghanam, A.H., Vousoughi, V.D., Alami, M.T., 2012. Classification of groundwater level data using SOM to develop ANN-based forecasting model. *Int. J. Soft Comput. Eng.* 2 (1), 2231–2307.

73. Nourani V, Baghanam AH, Rahimi AY, Nejad FH (2014) Evaluation of wavelet-based de-noising approach in hydrological models linked to artificial neural networks. In: Islam T, Srivastava PK, Gupta M, Mukherjee S, Zhu X (eds) Artificial intelligence techniques in earth and environmental science. Springer, Berlin, pp 209–241
74. 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.
75. 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.
76. Poff, N. L., Tokar, S., and Johnson, P. (1996). Stream hydrological and ecological responses to climate change assessed with an artificial neural
77. 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
78. 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
79. Rajurkar, M.P., Kothiyari, U.C., and Chaube, U.C. 2004. 2004, Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology (Amsterdam)*, 285(1-4): 96– 113. doi:10.1016/j.jhydrol.2003.08.011.
80. Raman, H., and Sunilkumar, N. (1995). Multi-variate modeling of water resources time series using artificial neural networks. *Hydrological Sci.*, 40, 145–163.
81. Ramsan et al. 2008. ANFIS and NNARX based Rainfall-Runoff Modeling. *IEEE*
82. Ranjithan, S., Eheart, J. W., and Rarret Jr., J. H. (1993). "Neural networks screening for groundwater reclamation under uncertainty." *Water Resour. Res.*, 29(3), 563–574.
83. Rao YRS, Krishna B (2009) Modelling hydrological time series data using wavelet neural network analysis. *IAHS Publication* 333:101–110
84. Ray K, *Hydrology for Engineers*. McGraw Hill, New York; 2nd Edition 1975. 416 p
85. RAUDKIVI, Arved J. *HYDROLOGY: An Advanced Introduction to hydrological Processes and Modelling*. PERGAMON PRESS, 1979. 479p. ISBN 0-08-024261-8
86. Rizzo, D. M., and Dougherty, D. E. (1994). "Characterization of aquifer properties using artificial neural networks: neural kriging." *Water Resour. Res.*, 30(2), 483–497.
87. Sajikumar, N., and Thandaveswara, B.S. 1999. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology (Amsterdam)*, 216(1–2): 32–55. doi:10.1016/S0022-1694(98)00273-X.

88. Sajjad Khan, M., and Coulibaly, P. 2006. Bayesian neural network for rainfall-runoff modeling. *Water Resources Research*, 42: W07409.
89. Sang YF, Wang D, Wu JC, Zhu QP, Wang L (2009a) Entropy-based wavelet de-noising method for time series analysis. *Entropy* 11:1123–1147
90. Sang YF, Wang D, Wu JC, Zhu QP, Wang L (2009b) The relationship between period's identification and noises in hydrological series data. *J Hydrol* 368:165–177
91. Shamseldin, A.Y. 1997. Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology (Amsterdam)*, 199(3– 4): 272–294. doi:10.1016/S0022-1694(96)03330-6.
92. 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
93. Singh, J., H. V. Knapp, and M. Demissie. 2004. Hydrologic modeling of the Iroquois River watershed using HSPF and SWAT.
94. Singh, P., and Deo, M.C. 2007. Suitability of different neural networks in daily flow forecasting. *Applied Soft Computing*, 7(3): 968–978. doi:10.1016/j.asoc.2006.05.003.
95. Srivastava et Jain, 1999. Application of ANN for Reservoir Inflow Prediction and Operation
96. Sudheer (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models.
97. Talei, A., Chua, L.H.C., and Wong, T.S.W. 2010a. Evaluation of rainfall and discharge inputs used by Adaptive Network-based Fuzzy Inference Systems (ANFIS) in rainfall–runoff modeling. *Journal of Hydrology (Amsterdam)*, 391(3–4): 248–262. doi:10.1016/j.jhydrol.2010.07.023.
98. Talei, A., Chua, L.H.C., and Quek, C. 2010b. A novel application of a neuro-fuzzy computational technique in event-based rainfall–runoff modeling. *Expert Systems with Applications*, 37(12): 7456–7468. doi:10.1016/j.eswa.2010.04.015.
99. Tokar, A.S., and Johnson, P.A. 1999. Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4(3): 232–239. doi:10.1061/(ASCE)1084-0699(1999)4:3(232).
100. Tokar, A.S., and Markus, M. 2000. Precipitation-runoff modeling using artificial neural network and conceptual models. *Journal of Hydrologic Engineering*, 5(2): 156–161. doi:10.1061/(ASCE) 1084-0699(2000)5:2(156).
101. 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
102. 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

103. Wang, W., Van Gelder, P.H.A.J.M., Vrijling, J.K. (2004a), Periodic autoregressive models applied to daily streamflow. Proceedings of the 6th International Conference on Hydroinformatics. World Scientific, Singapore, pp. 1334-1341.
104. Wang, W., Van Gelder, P.H.A.J.M., Vrijling, J.K., Ma, J. (2004b), Predictability of streamflow processes of the Yellow River. Proceedings of the 6th International Conference on Hydroinformatics. World Scientific, Singapore, pp. 1261-1268.
105. Wang W, Hu S, Li Y (2011) Wavelet transform method for synthetic generation of daily streamflow. *Water Resour Manage* 25:41–57
106. Wensheng W, Jing D (2003) Wavelet network model and its application to the prediction of hydrology. *Nature Sci* 1(1):67–71
107. 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.
108. Xiong, L., O'Connor, K.M., and Goswami, M. 1999. Application of the artificial neural network (ANN) in flood forecasting on a karstic catchment. [www.iahr.org](http://www.iahr.org).
109. 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.
110. Yang, X., Parent, E., Michel, C. et Roche, P.A. (1995). Comparison of real-time reservoir-operation techniques. *Journal of Water Resources Planning and Management*, 121(5), 345-351.
111. Yang, C. C., Prasher, S. O., Lacroix, R., Sreekanth, S., Patni, N. K., and Masse, L. (1997). "Artificial neural network model for subsurface drained farmland." *J. Irrig. and Drain. Engrg.*, ASCE, 123(4), 285– 292.
112. Yang, D., Herath, S. et Musiak, K. (2000). Comparison of different distributed hydrological models for characterization of catchment spatial variability. *Hydrological Processes*, 14(3), 403-416.
113. Yurekli, K., Kurunc, A., and Simsek, H. 2004. Prediction of daily maximum stream flow based on stochastic approaches. *Journal of Spatial Hydrology*, 4(2): 1–12.
114. 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
115. Zounemat-Kermani, M., and Teshnehlab, M. 2008. Using Adaptive Neuro-fuzzy Inference System for hydrological time series prediction. *Applied Soft Computing*, 8(2): 928–936. doi:10. 1016/j.asoc.2007.07.011.