

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 d'Hydraulique

Mémoire de projet de fin d'études

pour l'obtention du diplôme d'ingénieur d'état en Hydraulique

**Modélisation de la Salinité des cours d'eau par les  
méthodes heuristiques et métaheuristiques : Cas  
de l'Oued Tafna**

Réalisé par :

Nabil HOCINI

Tarik AMAMRA

Sous la direction de Pr. Abdelmalek BERMAD

Présenté et soutenu publiquement le 20/06/2016

**Composition du Jury:**

Président	Dr .Abdelouhab LEFKIR	ENSTP
Promoteur	Pr. Abdelmalek BERMAD	ENP
Examineur	Mme.Amel HAMRICHE	Doctorante.ENP
Examineur	Mr .Houari KHEMISSI	MAA.UMBB
Examineur	Mr.Moula ZABOT	Doctorant.USTHB



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 d'Hydraulique

Mémoire de projet de fin d'études

pour l'obtention du diplôme d'ingénieur d'état en Hydraulique

**Modélisation de la Salinité des cours d'eau par les  
méthodes heuristiques et métaheuristiques : Cas  
de l'Oued Tafna**

Réalisé par :

Nabil HOCINI

Tarik AMAMRA

Sous la direction de Pr. Abdelmalek BERMAD

Présenté et soutenu publiquement le 20/06/2016

**Composition du Jury:**

Président	Dr .Abdelouhab LEFKIR	ENSTP
Promoteur	Pr. Abdelmalek BERMAD	ENP
Examineur	Mme.Amel HAMRICHE	Doctorante.ENP
Examineur	Mr .Houari KHEMISSI	MAA.UMBB
Examineur	Mr.Moula ZABOT	Doctorant.USTHB

## ملخص

تهدف هذه الدراسة إلى إعداد نموذج لتركيز الأملاح في مياه وادي تافنة الواقع في غرب الجزائر، وتعرف هذه المنطقة بارتفاع ملوحة مياهها. نمذجة هذه الظاهرة هي خطوة تمهيدية لأية دراسة تقدير ملوحة المياه، وتسمح بتقدير حجم المشكلة، وبعد ذلك النظر في الحلول. أساليب النمذجة المستخدمة في هذه الدراسة هي الانحدار الخطي، الشبكات العصبية ونظام ANFIS.

الكلمات الدالة: الملوحة، تافنة، الانحدار الخطي، الشبكات العصبية، النمذجة، ANFIS.

## Abstract

The study is about modeling in daily time the salt concentration of the water of the oued Tafna located in western Algeria, this area is known for the high salinity of its water. Modeling this phenomenon is a preliminary step for any quantification study of salinity whose interest the evaluation of the extent of the problem, and then consider solutions. The modeling methods used in this study are linear regression, neural networks and ANFIS system.

Key words: Salinity, Tafna, regression, neural networks, ANFIS, Modeling.

## Résumé

L'étude consiste à modéliser au pas de temps journalier la concentration saline de l'eau de l'oued du bassin versant de la Tafna, situé dans l'ouest algérien, cette région est connue pour le taux de salinité élevé de ses eaux. La modélisation de ce phénomène est une étape préliminaire pour toute étude de quantification de la salinité qui a pour intérêt l'évaluation de l'ampleur du problème, et de là envisager des solutions. Les méthodes de modélisation utilisées dans cette étude sont la régression linéaire, les réseaux de neurones et le système ANFIS.

Mots clés : Salinité, Tafna, régression, réseaux de neurones, ANFIS, modélisation.

## **Remerciements**

Nous tenons à remercier notre encadreur le professeur BERMAD qui nous a guidé durant la réalisation de ce travail. Nos remerciements vont également au docteur LEFKIR pour les précieux conseils qu'il nous a apporté.

Nous remercions aussi les membres du jury, d'avoir lu notre manuscrit, et d'avoir fait des remarques précieuses sur notre travail.

# Sommaire

Nomenclature

liste des tableaux

liste des figures

<b>Introduction générale</b>	<b>17</b>
<b>1 Généralité sur La salinité</b>	<b>18</b>
1.1 Introduction . . . . .	18
1.2 La salinité . . . . .	18
1.3 la salinisation des cours d'eau . . . . .	18
1.4 Les variations naturelles de la salinité . . . . .	20
1.5 L'Unité de Mesure de Salinité . . . . .	20
1.6 Classes de salinité . . . . .	20
1.6.1 La Conductivité électrique (CE) . . . . .	20
1.6.2 Le sodium . . . . .	21
1.6.3 Les chlorures et les sulfates . . . . .	22
1.6.4 Le bore . . . . .	22
1.6.5 Le bicarbonate . . . . .	22
1.6.6 Autres éléments à considérer . . . . .	22
1.7 Effet de la salinité sur l'environnement : . . . . .	22
1.7.1 L'effet de la salinité sur les propriétés du sol : . . . . .	22
1.7.1.1 Action du sodium échangeable : . . . . .	23
1.7.1.2 Formation de la croûte superficielle : . . . . .	23
1.7.1.3 L'effet sur la perméabilité : . . . . .	23
1.7.1.4 Effet sur le complexe adsorbant : . . . . .	23
1.7.2 L'effet de la salinité sur la croissance des végétaux : . . . . .	23
1.7.2.1 Effet osmotique: . . . . .	23
1.7.2.2 Toxicité d'ions particuliers: . . . . .	23
1.7.2.3 Influence de la salinité sur le métabolisme des végétaux : . . . . .	24
1.8 Mesure de La Salinité . . . . .	24
1.8.1 Définitions . . . . .	24
1.8.2 Historique . . . . .	24
1.8.3 Mesurer la salinité avec un salinomètre . . . . .	25
<b>2 La Modélisation Hydrologique</b>	<b>26</b>
2.1 Quelques définitions . . . . .	26
2.2 Objectifs de la modélisation . . . . .	26

2.3	Facteurs caractéristiques de la modélisation . . . . .	27
2.4	Les grandes étapes de la modélisation . . . . .	27
2.5	Définition de la simulation . . . . .	27
2.6	Les modèles hydrologiques . . . . .	28
2.6.1	La modélisation comme outil de recherche . . . . .	28
2.6.2	La modélisation comme outil de prévision . . . . .	28
2.7	Classification des modèles. . . . .	28
2.7.1	Classification selon le mode de conception . . . . .	28
2.7.1.1	Les modèles de connaissance . . . . .	28
2.7.1.2	Les modèles “boîte noire” . . . . .	29
2.7.1.3	Les modèles “boîte grise” . . . . .	29
2.8	Le calage et validation d’un modèle . . . . .	29
2.9	Modèle de régression . . . . .	29
2.9.1	Introduction . . . . .	29
2.9.2	Comment effectuer une régression ? . . . . .	30
2.9.3	Le modèle linéaire . . . . .	30
2.9.3.1	Applications . . . . .	30
2.10	Les réseaux de neurones artificiels . . . . .	31
2.10.1	Introduction . . . . .	31
2.10.2	Avantages . . . . .	31
2.10.3	Inconvénients . . . . .	32
2.10.4	Types et structures des réseaux de neurones artificiels (RNA) . . . . .	32
2.10.4.1	Types de RNA . . . . .	32
2.10.4.2	Structure d’un RNA . . . . .	33
2.10.5	Fonctions d’activation de RNA . . . . .	36
2.10.5.1	Fonction binaire à seuil . . . . .	36
2.10.5.2	Fonction à rampe avec saturation . . . . .	37
2.10.5.3	Fonction sigmoïde . . . . .	37
2.10.6	Modes d’apprentissage des réseaux de neurones artificiels (RNA) . . . . .	38
2.11	Les systèmes Neuro-flous . . . . .	39
2.11.1	Introduction . . . . .	39
2.11.2	Définitions . . . . .	39
2.11.3	Le système neuro-flou coopératif . . . . .	40
2.11.4	Le système de neuro-flou concurrent . . . . .	42
2.11.5	Le système neuro-flou hybride . . . . .	42
2.11.6	ANFIS ( Adaptive-Network-based Fuzzy Inference System) . . . . .	43
2.11.6.1	Modélisation . . . . .	43
2.11.6.2	Améliorations potentielles d’un système ANFIS . . . . .	44
2.12	Critères d’évaluation d’un modèle . . . . .	45
2.12.1	Principaux critères objectifs . . . . .	46
2.12.1.1	Le critère de Nash Sutcliffe (Nash et Sutcliffe, 1970) . . . . .	46
2.12.1.2	Nash modifié . . . . .	46
2.12.1.3	L’erreur quadratique moyenne (RMSE: Root Mean Square Error) . . . . .	47
2.12.1.4	Percent bias PBIAS . . . . .	47
2.12.1.5	Le coefficient de détermination . . . . .	47
2.12.1.6	Le taux de performance des critères . . . . .	48

---

<b>3</b>	<b>Présentation du bassin versant de la Tafna</b>	<b>49</b>
3.1	Dispositions physique, géomorphologique et géologique du bassin de la Tafna . . . . .	49
3.1.1	Situation géographique . . . . .	49
3.1.2	Situation hydrographique . . . . .	52
3.2	Caractéristiques morphométriques . . . . .	53
3.2.1	Caractéristiques de forme . . . . .	53
3.2.1.1	Indice de compacité de Gravelius ( $K_c$ ) . . . . .	53
3.2.1.2	Le rectangle équivalent . . . . .	53
3.2.2	Caractéristiques topographiques . . . . .	54
3.2.2.1	La courbe hypsométrique . . . . .	54
3.2.3	Le réseau hydrographique . . . . .	57
3.2.3.1	Densité du drainage ( $D_b$ ) . . . . .	57
3.2.3.2	Coefficient de torrentialité . . . . .	57
3.3	Caractéristiques climatiques . . . . .	58
3.3.1	Le climat . . . . .	58
3.3.1.1	Les précipitations . . . . .	58
3.3.1.2	La température . . . . .	59
3.4	Caractéristiques de L'écoulement superficiel . . . . .	59
3.4.1	Variabilité mensuelle de l'écoulement . . . . .	59
3.5	Caractéristiques géologiques . . . . .	60
3.6	La végétation . . . . .	60
<b>4</b>	<b>Modélisation de la salinité de l'oued Tafna</b>	<b>61</b>
4.1	Analyse et critique des données . . . . .	61
4.2	Traitement statistique des données . . . . .	62
4.2.1	Détection de valeurs singulières Test de Grubbs et Beck . . . . .	62
4.3	Application des modèles . . . . .	64
4.3.1	Le modèle de régression . . . . .	64
4.3.2	Les réseaux de neurones . . . . .	66
4.3.3	Les systèmes Neuro-Flous . . . . .	72
4.4	Approche mensuelle . . . . .	74
4.4.1	Mois de mars . . . . .	74
4.4.1.1	Modèle de régression . . . . .	74
4.4.1.2	Modèle Réseau de neurones . . . . .	76
4.4.1.3	Modèle Neuro-Flou . . . . .	77
4.4.2	Mois de mai . . . . .	79
4.4.2.1	Modèle de régression linéaire . . . . .	79
4.4.2.2	Le modèle réseau de neurones . . . . .	80
4.4.2.3	Le modèle Neuro-flou . . . . .	82
4.5	Approche saisonnière . . . . .	83
4.5.1	Saison janvier-février-mars . . . . .	83
4.5.1.1	Modèle de régression . . . . .	83
4.5.1.2	Modèle Réseau de neurones . . . . .	85
4.5.1.3	Modèle Neuro-Flou . . . . .	87
4.5.2	Saison humide . . . . .	89
4.5.2.1	Modèle de régression . . . . .	89
4.5.2.2	Modèle Réseau de neurones . . . . .	91

---



4.5.2.3	Modèle Neuro-Flou . . . . .	93
4.6	Conclusion . . . . .	95
	<b>Conclusion générale</b>	<b>96</b>
	<b>Bibliographie</b>	<b>97</b>
	<b>Annexes</b>	<b>98</b>
A	Tableaux des résultats des critères numériques	99
B	Graphiques de comparaison de l'observé et du simulé	111
C	Courbe hypsométrique	133

# Nomenclature

*SAR* : Sodium Adsorption Ration

*S* : Salinité

*C* : Conductivité

*RNA* : Réseau de neurone Artificiel

*SIF* : Système d'inférence Artificiel

*ANSIF* : Adaptive-Network-Basd Fuzzy inference system

*E* : critère de Nash Sutcliff

*RMSE* : Root Mean Squard Error

*RSR* : Root Mean Squard Error observation standard deviation ration

*STDEV* : Ecart type

*PBIAS* : Percent bias

$R^2$  : Coefficient de détermination

$K_c$  : Indice de compacité de gravelius

$L_R$  : Longueur du rectangle équivalent

$l_R$  : Largeur du rectangle équivalent

$H_{max}$  : Altitude maximale

$H_{min}$  : Altitude minimale

$H_{moy}$  : Altitude moyenne

$H_{med}$  : Altitude médiane

$I_p$  : Indice de pente de Roche

$I_g$  : Indice de pente globale

$D_s$  : Diamètre spécifique

$D_d$  : Densité de drainage

$C_t$  : Coefficient de torrentialité

$C_s$  : Concentration saline

$Q_l$  : Débit liquide

# liste des tableaux

2.1	Régression (statistiques)	30
2.2	comparaison entre la logique floue et les réseaux de neurones	40
2.3	Qualité des modèles en fonction des valeurs des différents critères pour un pas de temps journalier	48
3.1	Répartition des surfaces partielles en fonction des altitudes (Sources ANRH)	54
3.2	Classification du bassin versant d'après l'ORSTOM	57
3.3	Caractéristiques morphométriques du bassin versant	58
3.4	Les températures mensuelles	59
3.5	Variation mensuelle du débit (1977-1991)	59
4.1	Add caption	63
4.2	Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de mars	74
4.3	Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de mars	74
4.4	Résultats des critères numériques de la phase du calage, modèle RN, mois de mars	76
4.5	Résultats des critères numériques de la phase de la validation, modèle RN, mois de mars	76
4.6	Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de mars	77
4.7	Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de mars	77
4.8	Résultats des critères numériques de la phase du calage, modèle régression, mois de mai	79
4.9	Résultats des critères numériques de la phase de la validation, modèle régression, mois de mai	79
4.10	Résultats des critères numériques phase du calage, modèle RN, mois de mai	80
4.11	Résultats des critères numériques phase de la validation, modèle RN, mois de mai	80
4.12	Résultats des critères numériques phase du calage, modèle ANFIS, mois de mai	82
4.13	Résultats des critères numériques phase de la validation, modèle ANFIS, mois de mai	82
4.14	Résultats des critères numériques phase du calage, modèle régression, saison jan-fév-mar	83

---

4.15	Résultats des critères numériques phase de la validation, modèle régression, saison jan-fév-mar . . . . .	84
4.16	Résultats des critères numériques phase du calage, modèle RN, saison jan-fév-mar . . . . .	85
4.17	Résultats des critères numériques phase de la validation, modèle RN, saison jan-fév-mar . . . . .	85
4.18	Résultats des critères numériques phase du calage, modèle ANFIS, saison jan-fév-mar . . . . .	87
4.19	Résultats des critères numériques phase de la validation, modèle ANFIS, saison jan-fév-mar . . . . .	87
4.20	Résultats des critères numériques phase du calage, modèle régression, saison humide . . . . .	89
4.21	Résultats des critères numériques phase de la validation, modèle régression, saison humide . . . . .	89
4.22	Résultats des critères numériques phase du calage, modèle RN, saison humide . . . . .	91
4.23	Résultats des critères numériques phase de la validation, modèle RN, saison humide . . . . .	91
4.24	Résultats des critères numériques phase du calage, modèle ANFIS, saison humide . . . . .	93
4.25	Résultats des critères numériques phase de la validation, modèle ANFIS, saison humide . . . . .	93
A.1	Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Novembre . . . . .	99
A.2	Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Novembre . . . . .	99
A.3	Résultats des critères numériques de la phase du calage, modèle RN, mois de Novembre . . . . .	99
A.4	Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Novembre . . . . .	100
A.5	Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Novembre . . . . .	100
A.6	Résultats des critères numériques de la phase de la validation, modèle RN, mois de Novembre . . . . .	100
A.7	Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Décembre . . . . .	100
A.8	Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Décembre . . . . .	101
A.9	Résultats des critères numériques de la phase du calage, modèle RN, mois de Décembre . . . . .	101
A.10	Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Décembre . . . . .	101
A.11	Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Décembre . . . . .	101
A.12	Résultats des critères numériques de la phase de la validation, modèle RN, mois de Décembre . . . . .	102

---

A.13 Résultats des critères numériques de la phase du calage, modèle AN-FIS, mois de Janvier . . . . .	102
A.14 Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Janvier . . . . .	102
A.15 Résultats des critères numériques de la phase du calage, modèle RN,mois de Janvier . . . . .	103
A.16 Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Janvier . . . . .	103
A.17 Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Janvier . . . . .	103
A.18 Résultats des critères numériques de la phase de la validation, modèle RN,mois de Janvier . . . . .	104
A.19 Résultats des critères numériques de la phase du calage, modèle AN-FIS, mois de Février . . . . .	104
A.20 Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Février . . . . .	104
A.21 Résultats des critères numériques de la phase du calage, modèle RN,mois de Février . . . . .	105
A.22 Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Février . . . . .	105
A.23 Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Février . . . . .	105
A.24 Résultats des critères numériques de la phase de la validation, modèle RN,mois de Février . . . . .	105
A.25 Résultats des critères numériques de la phase du calage, modèle AN-FIS, mois de Avril . . . . .	106
A.26 Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Avril . . . . .	106
A.27 Résultats des critères numériques de la phase du calage, modèle RN,mois de Avril . . . . .	106
A.28 Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Avril . . . . .	106
A.29 Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Avril . . . . .	106
A.30 Résultats des critères numériques de la phase de la validation, modèle RN,mois de Avril . . . . .	107
A.31 Résultats des critères numériques de la phase du calage, modèle AN-FIS, Saison Novembre Décembre . . . . .	107
A.32 Résultats des critères numériques de la phase du calage, modèle régression linéaire, Saison Novembre Décembre . . . . .	107
A.33 Résultats des critères numériques de la phase du calage, modèle RN, Saison Novembre Décembre . . . . .	107
A.34 Résultats des critères numériques de la phase de la validation, modèle ANFIS, Saison Novembre Décembre . . . . .	108
A.35 Résultats des critères numériques de la phase de la validation, modèle régression linéaire, Saison Novembre Décembre . . . . .	108
A.36 Résultats des critères numériques de la phase de la validation, modèle RN,Saison Novembre Décembre . . . . .	108

---

A.37 Résultats des critères numériques de la phase du calage, modèle AN-FIS, Saison Avril MAI . . . . .	108
A.38 Résultats des critères numériques de la phase du calage, modèle régression linéaire, Saison Avril MAI . . . . .	109
A.39 Résultats des critères numériques de la phase du calage, modèle RN, Saison Avril MAI . . . . .	109
A.40 Résultats des critères numériques de la phase de la validation, modèle ANFIS, Saison Avril MAI . . . . .	109
A.41 Résultats des critères numériques de la phase de la validation, modèle régression linéaire, Saison Avril MAI . . . . .	109
A.42 Résultats des critères numériques de la phase de la validation, modèle RN, Saison Avril MAI . . . . .	110

# liste des figures

1.1	Les sources naturelles de la salinité . . . . .	19
1.2	Les sources anthropiques de la salinité . . . . .	19
1.3	Un salinomètre . . . . .	25
2.1	Structure d'un neurone simple . . . . .	34
2.2	Réseau de neurones mono-couche . . . . .	35
2.3	Réseau de neurones multicouches . . . . .	35
2.4	Fonction d'activation binaire à seuil . . . . .	36
2.5	Fonction d'activation à rampe avec saturation . . . . .	37
2.6	Fonction d'activation sigmoïde . . . . .	37
2.7	Système Neuro-flou pour régler une fonction d'appartenance . . . . .	40
2.8	Système neuro-flou en série avec prétraitement neuronal . . . . .	41
2.9	Système neuro-flou en parallèle . . . . .	41
2.10	Principe de fonctionnement du neuro-flou hybride . . . . .	42
2.11	L'architecture de ANFIS . . . . .	43
2.12	Etape de synthèse d'une identification floue sous ANFIS de Matlab . . . . .	44
3.1	Situation géographique du bassin de la Tafna . . . . .	50
3.2	Codes et noms des bassins versants de l'Algérie (Hamlet, 2005) . . . . .	50
3.3	Situation géographique du bassin de la Tafna dans l'ensemble Oranie Chott Chergui . . . . .	51
3.4	Contexte géographique du bassin de la Tafna (Hamlet, 2005) . . . . .	51
4.1	Evolution du débit liquide dans le temps . . . . .	61
4.2	Evolution de la concentration saline dans le temps . . . . .	62
4.3	Organigramme résumant le travail effectué . . . . .	64
4.4	Interface de l'application Curve Fitting Tool . . . . .	65
4.5	Interface d'entrée de l'application NNFT . . . . .	66
4.6	Interface de sélection des entrées et des sorties . . . . .	66
4.7	Interface de répartition des données . . . . .	67
4.8	Architecture du réseau de neurones . . . . .	67
4.9	Lancement de l'apprentissage . . . . .	68
4.10	Performances du réseau de neurones . . . . .	68
4.11	État d'avancement de l'apprentissage . . . . .	69
4.12	Coefficient de corrélation des phases de création du RN . . . . .	69
4.13	Évaluation du RN et extension du jeu de données . . . . .	70
4.14	Génération du code Matlab du RN . . . . .	70
4.15	Interface de l'application ANFIS . . . . .	72
4.16	Choix de la fonction d'appartenance et du nombre de règles floues . . . . .	73
4.17	Comparaison observé-simulé . . . . .	73

---

4.18	Comparaison observé-simulé phase de calage, modèle de régression, mois de mars . . . . .	75
4.19	Comparaison observé-simulé phase de la validation, modèle de régression, mois de mars . . . . .	75
4.20	Comparaison observé-simulé phase du calage, modèle RN, mois de mars	76
4.21	Comparaison observé-simulé phase de la validation, modèle RN, mois de mars . . . . .	77
4.22	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de mars . . . . .	78
4.23	Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de mars . . . . .	78
4.24	Comparaison observé-simulé phase du calage, modèle de régression, mois de mai . . . . .	79
4.25	Comparaison observé-simulé phase de la validation, modèle de régression, mois de mai . . . . .	80
4.26	Comparaison observé-simulé phase du calage, modèle RN, mois de mai	81
4.27	Comparaison observé-simulé phase de la validation, modèle RN, mois de mai . . . . .	81
4.28	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de mai . . . . .	82
4.29	Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de mai . . . . .	83
4.30	Comparaison observé-simulé phase du calage, modèle régression, saison jan-fév-mar . . . . .	84
4.31	Comparaison observé-simulé phase de la validation, modèle régression, saison jan-fév-mar . . . . .	85
4.32	Comparaison observé-simulé phase du calage, modèle RN, saison jan-fév-mar . . . . .	86
4.33	Comparaison observé-simulé phase de la validation, modèle RN, saison jan-fév-mar . . . . .	87
4.34	Comparaison observé-simulé phase du calage, modèle ANFIS, saison jan-fév-mar . . . . .	88
4.35	Comparaison observé-simulé phase de la validation, modèle ANFIS, saison jan-fév-mar . . . . .	88
4.36	Comparaison observé-simulé phase du calage, modèle régression, saison humide . . . . .	90
4.37	Comparaison observé-simulé phase de la validation, modèle régression, saison humide . . . . .	90
4.38	Comparaison observé-simulé phase du calage, modèle RN, saison humide	92
4.39	Comparaison observé-simulé phase de la validation, modèle RN, saison humide . . . . .	92
4.40	Comparaison observé-simulé phase du calage, modèle ANFIS, saison humide . . . . .	94
4.41	Comparaison observé-simulé phase de la validation, modèle ANFIS, saison humide . . . . .	94
B.1	Comparaison observé-simulé phase de calage, modèle de régression, mois de Janvier . . . . .	111

---



B.2	Comparaison observé-simulé phase de la validation, modèle de régression,mois de Janvier . . . . .	112
B.3	omparaison observé-simulé phase du calage, modèle RN, mois de Janvier	112
B.4	Comparaison observé-simulé phase de la validation, modèle RN, mois de Janvier . . . . .	113
B.5	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Janvier . . . . .	113
B.6	Comparaison observé-simulé phase de la validation, modèle ANFIS,mois de Janvier . . . . .	114
B.7	Comparaison observé-simulé phase de calage, modèle de régression,mois de Février . . . . .	114
B.8	Comparaison observé-simulé phase de la validation, modèle de régression,mois de Février . . . . .	115
B.9	Comparaison observé-simulé phase du calage, modèle RN, mois de Février . . . . .	115
B.10	Comparaison observé-simulé phase de la validation, modèle RN, mois de Février . . . . .	116
B.11	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Février . . . . .	116
B.12	Comparaison observé-simulé phase de la validation, modèle ANFIS,mois de Février . . . . .	117
B.13	Comparaison observé-simulé phase de calage, modèle de régression,mois de Avril . . . . .	117
B.14	Comparaison observé-simulé phase de la validation, modèle de régression,mois de Avril . . . . .	118
B.15	Comparaison observé-simulé phase du calage, modèle RN, mois de Avril	118
B.16	Comparaison observé-simulé phase de la validation, modèle RN, mois de Avril . . . . .	119
B.17	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Avril . . . . .	119
B.18	Comparaison observé-simulé phase de la validation, modèle ANFIS,mois de Avril . . . . .	120
B.19	Comparaison observé-simulé phase de calage, modèle de régression,mois de Novembre . . . . .	120
B.20	Comparaison observé-simulé phase de la validation, modèle de régression,mois de Novembre . . . . .	121
B.21	Comparaison observé-simulé phase du calage, modèle RN, mois de Novembre . . . . .	121
B.22	Comparaison observé-simulé phase de la validation, modèle RN, mois de Novembre . . . . .	122
B.23	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Novembre . . . . .	122
B.24	Comparaison observé-simulé phase de la validation, modèle ANFIS,mois de Novembre . . . . .	123
B.25	Comparaison observé-simulé phase de calage, modèle de régression,mois de Décembre . . . . .	123
B.26	Comparaison observé-simulé phase de la validation, modèle de régression,mois de Décembre . . . . .	124

---

B.27	Comparaison observé-simulé phase du calage, modèle RN, mois de Décembre . . . . .	124
B.28	Comparaison observé-simulé phase de la validation, modèle RN, mois de Décembre . . . . .	125
B.29	Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Décembre . . . . .	125
B.30	Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de Décembre . . . . .	126
B.31	Comparaison observé-simulé phase de calage, modèle de régression, Saison Avril Mai . . . . .	126
B.32	Comparaison observé-simulé phase de la validation, modèle de régression, Saison Avril Mai . . . . .	127
B.33	Comparaison observé-simulé phase du calage, modèle RN, Saison Avril Mai . . . . .	127
B.34	Comparaison observé-simulé phase de la validation, modèle RN, Saison Avril Mai . . . . .	128
B.35	Comparaison observé-simulé phase du calage, modèle ANFIS, Saison Avril Mai . . . . .	128
B.36	Comparaison observé-simulé phase de la validation, modèle ANFIS, Saison Avril Mai . . . . .	129
B.37	Comparaison observé-simulé phase de calage, modèle de régression, Saison Novembre Décembre . . . . .	129
B.38	Comparaison observé-simulé phase de la validation, modèle de régression, Saison Novembre Décembre . . . . .	130
B.39	Comparaison observé-simulé phase du calage, modèle RN, Saison Novembre Décembre . . . . .	130
B.40	Comparaison observé-simulé phase de la validation, modèle RN, Saison Novembre Décembre . . . . .	131
B.41	Comparaison observé-simulé phase du calage, modèle ANFIS, Saison Novembre Décembre . . . . .	131
B.42	Comparaison observé-simulé phase de la validation, modèle ANFIS, Saison Novembre Décembre . . . . .	132
C.1	Courbe hypsométrique du bassin versant de la TAFNA . . . . .	133

---

# Introduction générale

Les eaux de l'Ouest Algérien présentent un taux de salinité très élevé, que ça soit les eaux de surface ou les eaux souterraines, les quantités de sels qu'elles contiennent peuvent les rendre non potable, et ne peut être utilisée pour l'irrigation de nombreuses cultures.

Plusieurs facteurs influencent cette concentration saline importante, ces derniers peuvent être naturels ou dus à l'activité humaine.

Le premier facteur naturel est la géologie du bassin versant. Ajouté à ça, la rareté des épisodes pluvieux, ce qui mène à un débit faible presque sur toute l'année, et si ce dernier est faible durant plusieurs jours successifs, on voit la salinité grimper. D'autres facteurs ont leur part d'influence, l'ensoleillement à titre d'exemple, qui favorise l'évaporation de l'eau, et on voit la concentration des sels dissous s'accroître ; il y a aussi la végétation, qui a tendance à freiner l'écoulement superficiel de l'eau, ce qui donne le temps aux sels de se dissoudre dans l'eau qui peut arriver à saturation.

Les rejets domestiques et industriels ont aussi leur part d'influence dans l'accroissement de la concentration en sels, mais ne sont pas à prendre en compte dans les régions peu peuplées.

Nous avons eu un jeu de données de la part de l'ANRH, sur le débit liquide et la concentration saline, nous les avons analysé et critiqué en appliquant le test de Grubbs & Beck.

Pour modéliser la relation débit liquide-concentration saline, nous avons utilisé trois méthodes, la régression simple, l'ajustement par réseau de neurones et les systèmes neuro-flou, le modèle qui aura les meilleurs critères de performance sera retenu.

Pour cette étude, nous avons adopté le plan suivant :

- Nous avons consacré le premier chapitre à définir le phénomène étudié, qui est la salinité, et les éléments la constituant.
- Dans le second chapitre, on présente les théories des modèles utilisés dans notre étude, qui sont la régression linéaire, les réseaux de neurones artificiels et les systèmes neuro-flous.
- Le troisième chapitre est dédié à la présentation du bassin hydrographique de la Tafna, nous avons cité les caractéristiques climatiques, morphométriques, géologiques et les caractéristiques de l'écoulement superficiel.
- Concernant le quatrième et dernier chapitre, nous l'avons dédié à l'analyse et critique des données et à l'établissement d'un modèle de prévision de la concentration saline à partir des débits reconstitués du cours d'eau de la Tafna, dans le but de connaître les jours où l'eau ne peut pas être consommée.

# Chapitre 1

## Généralité sur La salinité

### 1.1 Introduction

L'eau constitue l'une des principales richesses sur lesquelles reposent la prospérité du pays dans l'avenir, ainsi que la réussite de son développement économique et social. En effet, ce développement exige un accroissement important des mobilisations de cette ressource et la multiplication des efforts pour répondre aussi aux besoins de la population qu'à ceux des secteurs économiques.

Ainsi, l'eau constitue à la fois un élément essentiel et un facteur stratégique pour l'aménagement du territoire. Sa présence et sa disponibilité conditionnent de manière déterminante la répartition de la population et des activités.

Malheureusement, cette ressource est menacée par la pollution provoquée par les rejets industriels et urbains, ajoutant à cela la pollution naturelle due au ruissellement qui, sur un sol sec lessive les terrains plus ou moins chargés en sels minéraux avec comme conséquence une minéralisation poussée des eaux pouvant modifier leurs compositions chimiques et dépasser les limites de la consommation ou de l'utilisation. La composition chimique des eaux dépend de la nature des terrains traversés par l'eau, lors de son parcours dans l'ensemble des bassins versants.

En présence des conditions climatiques défavorables, l'eau dissout au cours de son cheminement, les différents éléments constitutifs des terrains ainsi ce qu'on appelle salinité des cours d'eaux.

Cette salinité n'est qu'un apport chimique, ses principaux composants sont des sels minéraux exprimés par la somme des anions et des cations.[3]

### 1.2 La salinité

La salinité est l'une des caractéristiques physico-chimiques de l'eau. Elle désigne la quantité de sels (chlorure de sodium, chlorure de magnésium, sulfate de magnésium, etc.) dissous dans un liquide, notamment l'eau qui est un puissant solvant pour de nombreux minéraux.

### 1.3 la salinisation des cours d'eau

La salinisation concerne une grande partie des rivières, surtout dans les régions endoréiques (les bassins fermés, sans exutoire vers la mer). La salinité dans ce type

de contexte peut résulter de processus d'origine naturelle ou anthropique. Le processus naturel est enclenché par le dépôt de sels sur le sol, en particulier dans les environnements arides. Il s'agit le plus souvent d'aérosols météoriques ou de sels précipités suite à l'évaporation. Ces sels sont temporairement stockés dans le sous-surface ( zone non-saturée superficielle) avant de migrer vers la nappe sous-jacente . une fois en solution dans l'eau qui draine la nappe . la salinité de l'aquifère qui alimente la rivière peut être due à d'autres mécanismes de salinisation ( dissolution de minéraux salifères, mélange avec des saumures... ) .[12]

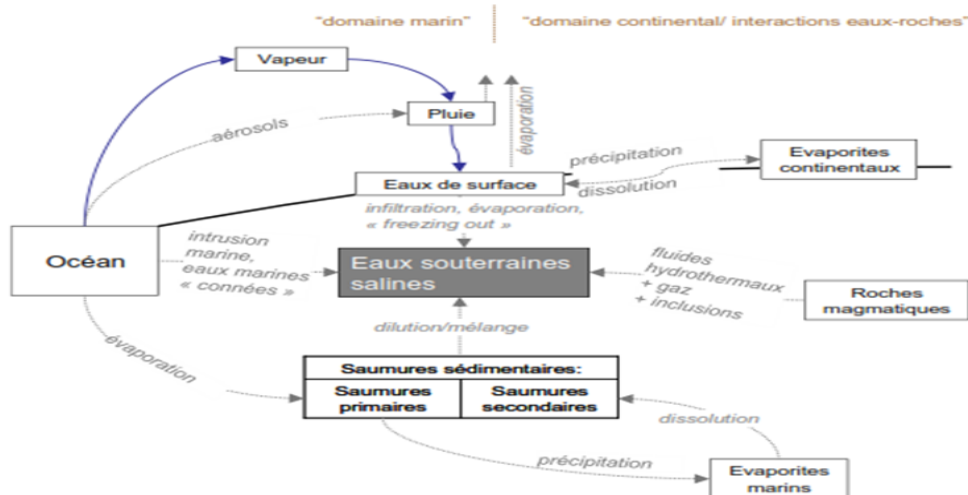


Figure 1.1: Les sources naturelles de la salinité

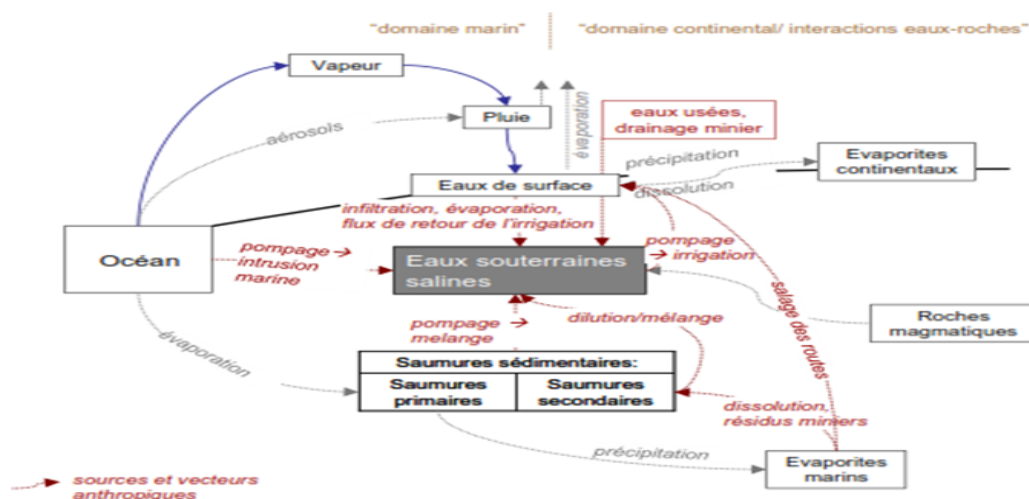


Figure 1.2: Les sources anthropiques de la salinité

## 1.4 Les variations naturelles de la salinité

La salinité varie au cours du temps en fonction des apports d'eau douce, et des conditions hydrodynamiques de transport et mélange. Les apports d'eau douce par les fleuves ou les précipitations ont tendance à diminuer la salinité, alors qu'à l'inverse, l'évaporation qui dépend de la vitesse du vent et de l'humidité de l'air (un air sec accroît l'évaporation) aura tendance à l'augmenter. Au large, par grande profondeur, la salinité des eaux de fond varie très peu, par contre, en surface elle est soumise à une variabilité induite par le climat (équilibre entre précipitation et évaporation) et à ses évolutions de l'échelle saisonnière à inter annuelle.

La mise en évidence d'une évolution sur le long terme des salinités est complexe car elle nécessite des séries temporelles sur plusieurs années voire même décennies avec une résolution temporelle qui prenne en compte la variabilité à haute fréquence (quelques jours).

## 1.5 L'Unité de Mesure de Salinité

La concentration en sel est donnée par le TDS (Quantité Totale de Matière Dissoutes) exprimé en mg de sel par litre d'eau (mg/L) ou en gramme de sel par mètre cube d'eau (g/m<sup>3</sup>) (i.e. mg/L = g/m<sup>3</sup> = ppm).

La concentration en sel peut aussi être mesurée grâce à la conductivité électrique de l'eau d'irrigation (ECi). La conductivité électrique est exprimée en millimhos par centimètre (mmhos/cm) ou deciSiemens par mètre (dS/m) ou microsiemens par centimètre (i.e.  $1\text{dS/m} = 1000\mu\text{S/cm}$ ).

La relation entre la concentration en sel (C) et la conductivité électrique (EC) est approximativement:  $C = 640\text{ EC}$ .

Une autre technique pour estimer la concentration en sel se fait en mesurant la conductivité électrique de l'eau extraite d'un échantillon de sol saturé (ECe).

La relation approximative entre la conductivité électrique de l'eau d'irrigation (ECi) et la salinité du sol est  $\text{ECe} = 1.5\text{ ECi}$ , si environ 15 pour cent de l'eau appliquée est drainée à la racine des récoltes.

## 1.6 Classes de salinité

### 1.6.1 La Conductivité électrique (CE)

- Classe 1 (C1)  $250\mu\text{S/cm}$  basse salinité .
- Classe 2 (C2)  $250\mu\text{S/cm}$  à  $750\mu\text{S/cm}$  salinité modéré .
- Classe 3 (C3)  $750\mu\text{S/cm}$  à  $2250\mu\text{S/cm}$  haute salinité .
- Classe 4 (C4) au dessus de  $2250\mu\text{S/cm}$  très haute salinité .

Une CE de  $750\mu\text{S/cm}$  est la limite approximative pour la croissance du gazon sans avoir à appliquer des traitements spéciaux pour la salinité incluant des pratiques culturales particulières. En contrepartie, une CE inférieure à  $400\mu\text{S/cm}$  est considérée adéquate pour la croissance de la plupart des gazons.

L'eau présentant une conductivité électrique comprise dans la classe C2 peut être

utilisée pour irriguer les sols présentant un bon drainage et pour les gazons peu sensibles à des conditions de salinité. L'eau d'irrigation se situant dans la classe C3 ne devrait pas être utilisée dans les sols où le drainage est faible. De plus, ce type d'eau ne doit pas servir à irriguer les plantes sensibles aux sels même sur les sols ayant un bon drainage. La classe C4 comprend les eaux qui ne sont pas propres à l'irrigation.[6]

### 1.6.2 Le sodium

Parmi les sels dissous dans l'eau, le sodium (Na) requiert plus d'attention. De hautes concentrations en sodium peuvent être dommageables pour le gazon en modifiant les conditions physiques du sol.

L'analyse de la concentration du sodium dans l'eau d'irrigation ne peut être faite seule. En effet, l'influence du sodium dépend des concentrations en calcium et en magnésium. Aussi, plutôt que de parler de concentration en sodium, nous parlons plutôt d'une valeur qui tient compte des effets mutuels du sodium, du calcium et du magnésium. Il s'agit du ratio d'adsorption du sodium par le sol, le SAR (Sodium adsorption ratio).

On utilise le SAR pour classer les risques reliés au sodium dans les sources d'eau d'irrigation. L'eau caractérisée par un SAR supérieur à 10 aura tendance à produire une accumulation de sodium dans le sol. Le sodium agit au niveau de la défloculation du sol argileux ce qui entraîne une diminution de la macro-porosité (air) et du taux d'infiltration de l'eau. Cette action sur la structure du sol est particulièrement néfaste pour les gazons fortement piétinés.

À l'aide du SAR, on divise les eaux d'irrigation en quatre classes. La classification est basée principalement sur l'effet du sodium sur les conditions physiques du sol. [3]

Classe SAR ( Sodium Adsorption Ratio):

- Classe S1 SAR de 10 et moins bas taux de sodium .
- Classe S2 SAR de 10,1 à 18 taux moyen de sodium .
- Classe S3 SAR de 18,1 à 26 haut taux de sodium .
- Classe S4 SAR au-dessus de 26,1 très haut taux de sodium .

Classe S1 - l'eau peut être utilisée sur pratiquement n'importe quel type de sol avec un risque minimal d'accumuler du sodium à un niveau dommageable.

Classe S2 - l'eau présente un danger appréciable d'accumuler du sodium à un niveau dommageable pour les sols ayant une texture fine et une capacité d'échange cationique (CEC) élevée. Par contre, l'eau peut être utilisée dans les sols sableux ayant une bonne perméabilité.

Classe S3 - peut produire des niveaux dommageables de sodium dans pratiquement tout les types de sols. L'utilisation d'amendements tel que le gypse pourraient être nécessaires pour échanger les ions sodium. De plus, les pratiques culturales augmentant le drainage seront requises plus fréquemment.

Classe S4 - cette eau est généralement inadéquate pour l'irrigation.

### 1.6.3 Les chlorures et les sulfates

Lorsqu'ils sont présents dans l'eau d'irrigation, ces éléments contribuent à augmenter la concentration des sels solubles. Des concentrations excessives de chlorures et de sulfates peuvent causer des brûlures sur le bout des feuilles du gazon et voire même entraîner la mort des plants. Des concentrations de 250 à 400 ppm sont considérées comme indésirables pour l'irrigation des plantes sensibles aux sels. Heureusement, les sels de chlorure et de sulfate sont rapidement solubles. Ils peuvent donc être lessivés dans les sols qui se drainent bien. [3]

### 1.6.4 Le bore

Le bore (B) est un élément mineur essentiel à la croissance de la plante mais il n'est requis qu'en minime quantité. Le bore est soluble dans l'eau et on le retrouve dans plusieurs sources d'eau utilisées pour l'irrigation. Lorsque sa concentration dans l'eau excède 1 à 2 ppm, le bore peut être toxique pour le gazon. De plus, le bore a tendance à s'accumuler dans le sol en formant des complexes chimiques qui sont difficiles à lessiver.

### 1.6.5 Le bicarbonate

L'abondance des ions bicarbonates ( $\text{HCO}_3^-$ ) dans l'eau d'irrigation mérite aussi d'être évaluée. Dans le cas où l'eau d'irrigation contient un taux élevé de bicarbonates, on constate une tendance à la précipitation du calcium et du magnésium ce qui fait augmenter le SAR. On considère que l'eau d'irrigation est inadéquate pour l'irrigation lorsque la concentration résiduelle de  $\text{NaHCO}_3$  est supérieure à 2,5 mEq / L. Par contre, si la concentration est en dessous de 1,25 mEq / L, l'eau est probablement sécuritaire. [3]

### 1.6.6 Autres éléments à considérer

D'autres éléments mineurs comme le chrome, le nickel, le mercure et le sélénium peuvent être potentiellement toxiques. Pour la plupart, ils se retrouvent principalement dans les effluents municipaux et industriels.

## 1.7 Effet de la salinité sur l'environnement :

### 1.7.1 L'effet de la salinité sur les propriétés du sol :

Une grande quantité de sels solubles peut affecter les propriétés pédologiques, notamment la dispersion des colloïdes, la stabilité structurale et la chute de la perméabilité hydraulique. [1]

Les ions responsables de la salinité du sol altèrent les propriétés physico-chimiques des sols et entraînent une dégradation de la structure et de la texture qui devient défavorable à la vie végétale.



### 1.7.1.1 Action du sodium échangeable :

Lorsque le sodium est présent en quantité importante sur le complexe d'échange, le sol devient instable et acquiert une capacité de gonflement. Ce dernier entraîne une diminution de la porosité et la dispersion conduit au colmatage des pores par les particules colloïdales .[11]

### 1.7.1.2 Formation de la croûte superficielle :

La formation de la croûte de battance entraîne une modification de la structure du sol susceptible de se répercuter sur les écoulements des eaux et par la suite elle influence sur le métabolisme et le développement des végétaux. L'humectation rapide du sol provoque la compression de l'air dans les pores fermés et l'éclatement des agrégats et par conséquent l'érosion et l'imperméabilisation des surfaces [9].

### 1.7.1.3 L'effet sur la perméabilité :

La perméabilité est liée à la texture, à l'état du complexe adsorbant et aussi au taux de matière organique et de calcaire .[9]

### 1.7.1.4 Effet sur le complexe adsorbant :

La salinité agit sur le complexe adsorbant par les cations échangeable ( $\text{Na}^+$  et  $\text{Mg}^{++}$ ) ce qui provoque le lessivage des bases, la destruction des ponts calciques et comme conséquence une forte vitesse d'infiltration des eaux. Le complexe adsorbant devient saturée en  $\text{Na}^+$  et qui provoque la dispersion d'argiles (fraction fine) diminuant ainsi la porosité (aération) et emmagasinement de l'eau .[9]

## 1.7.2 L'effet de la salinité sur la croissance des végétaux :

L'irrigation avec de l'eau salée peut affecter la croissance des plantes de 2 façons :

### 1.7.2.1 Effet osmotique:

La solution du sol est plus concentrée en sel que la plante ce qui empêche le végétal de puiser l'eau du sol sauf cas particuliers.

### 1.7.2.2 Toxicité d'ions particuliers:

Des concentrations excessives d'ions chlorures et sodium peuvent causer une toxicité dans la plante par :

- Absorption par les racines

Les ions chlorites peuvent être absorbés par les racines provoquant une brûlure dans Les bords des feuilles, le « bronzage » et le jaunissement prématuré des feuilles.

- Absorption par les feuilles

Les dommages dus au sel de cette manière ne font que brûler ou tuer les feuilles en contact direct avec la solution salée. Ces dommages sont plus importants lorsque l'irrigation se produit par temps chaud et sec et que l'évaporation concentre les sels à la surface des feuilles.

### 1.7.2.3 Influence de la salinité sur le métabolisme des végétaux :

La salinité cause des maladies dites "maladies non parasitaires" ou maladies physiologiques ou abiotiques .[9]

## 1.8 Mesure de La Salinité

### 1.8.1 Définitions

La salinité est le poids en grammes de résidu solide contenu dans un kilogramme d'eau de mer quand tous les carbonates ont été transformés en oxydes, le brome et l'iode remplacés par le chlore, et que toute la matière organique a été complètement oxydée.

Cette détermination étant difficile à réaliser, une méthode plus simple a été recherchée.

### 1.8.2 Historique

Dittmar a analysé 77 échantillons d'eau de mer prélevés par le Challenger pendant son tour du monde (1873-1876). Il en a déduit en 1884 une loi, dite loi de Dittmar :

Dans l'eau de mer, quelle que soit la salinité, à condition qu'elle ne soit pas trop faible, les proportions relatives des principaux constituants sont pratiquement constantes et le dosage de l'un d'eux donne la teneur des autres et aussi la salinité.

En 1903 Knudsen a mis au point une méthode chimique pour mesurer la salinité et la densité. La salinité (S) est, d'après la loi de Dittmar, proportionnelle à la chlorinité (Cl). Nous considérons actuellement que :

$$S = 1.806655Cl \quad (1.1)$$

La chlorinité est déterminée en précipitant les halogènes par du nitrate d'argent. Le dosage se fait en valeur relative par rapport à une eau de référence. Cette eau, dite « eau standard », est préparée par le Laboratoire Hydrographique de Copenhague. Sa chlorinité est proche de 19,381 g/kg qui correspond à une salinité de 35 g/kg.

Après avoir remarqué qu'à pression atmosphérique la conductivité de l'eau de mer variait avec la salinité et la température, en 1930 Frank Wenner conçoit les premiers salinomètres de laboratoire. Ils mesurent le rapport entre la conductivité de l'eau standard et de l'eau à analyser à une même température connue ( $15^{\circ}C$ ). Depuis, la mesure de la salinité S se fait toujours en calculant d'abord ce rapport de conductivité R15. Dans le cas de mesures obtenues avec des capteurs de conductivité, une correction doit être apportée en fonction de la température t et, éventuellement, de la pression p. La salinité S est donc une fonction du rapport de conductivité R, de la température t et de la pression p :[4]

$$S = f(R, t, p) \quad (1.2)$$

La conductivité est l'inverse de la résistivité. La conductivité de l'eau de mer est :

$$C = 42.914R(Cestenmilli - Siemensparcm) \quad (1.3)$$

### 1.8.3 Mesurer la salinité avec un salinomètre

La méthode de détermination de la salinité par la conductimétrie est à la base de l'utilisation des salinomètres : elle est rapide, simple et précise.

Deux types de salinomètres sont généralisés : le salinomètre à électrodes et le salinomètre à induction. Dans un salinomètre à électrodes, ces dernières sont en contact direct avec l'eau de mer, introduite dans une cellule immergée dans un bain thermostaté. La température est réglée à  $\pm 0,001^{\circ}C$  afin d'obtenir une précision de  $\pm 0,001$  en salinité. Dans un salinomètre à induction, l'eau de mer est introduite dans une cellule où elle forme un anneau conducteur mettant en liaison deux transformateurs. L'un, alimenté par un oscillateur de fréquence élevée (10 kHz), crée un courant induit dans l'anneau d'eau de mer. Ce courant crée à son tour, au bornes du secondaire du deuxième transformateur, une tension que l'on amplifie et que l'on mesure. Ces appareils ont un encombrement plus réduit que les modèles à électrodes, mais ont une précision légèrement moindre.[4]



Figure 1.3: Un salinomètre

# Chapitre 2

## La Modélisation Hydrologique

### 2.1 Quelques définitions

- D'après le Dictionnaire de l'environnement, le modèle est "une représentation simplifiée, relativement abstraite, d'un processus, d'un système, en vue de le décrire, de l'expliquer ou de le prévoir".
- Un modèle est une simplification de la réalité car s'il en avait tous les attributs, il s'agirait non plus d'un modèle mais de la réalité .
- La modélisation, n'est rien d'autre que la pensée organisée en vue d'une finalité pratique. Modèle est synonyme de théorie, mais avec une connotation pratique : modèle, c'est une théorie orientée vers l'action qu'elle doit servir .
- La modélisation est une technique de création d'une représentation standard. Ainsi, elle permet d'établir un modèle explicatif d'un phénomène ou comportement en recensant les variables ou facteurs explicatifs et l'importance relative de chacune de ces variables .
- Représentation mathématique de la relation qui lie les entrées et les sorties d'un processus par des équations.  
Si les équations du modèle sont algébriques, on parlera de modèle statistique. Si ces équations sont des équations différentielles ou des équations aux différences récurrentes, le modèle est dit dynamique.[2]

### 2.2 Objectifs de la modélisation

Pourquoi modéliser ?

Cette question doit avoir une réponse, non seulement pour justifier la démarche, mais aussi pour sélectionner l'approche modélisatrice la plus appropriée.

La modélisation peut avoir trois objectifs :

- Décrire (résumer) les données ;
- Prédire (simuler), c'est-à-dire utiliser le système pour générer de nouvelles valeurs,
- Expliquer (comprendre) c'est-à-dire comprendre la réalité.

Selon que l'on souhaite parvenir à l'un ou l'autre de ces objectifs, la modélisation sera réalisée selon des modalités différentes.

## 2.3 Facteurs caractéristiques de la modélisation

Les champs d'application de la modélisation sont aussi divers que les champs de la connaissance. Parmi les facteurs caractéristiques de la modélisation hydrologique, mentionnons :

- La diversité des processus en jeu (physiques et chimiques).
- La complexité des systèmes étudiés.
- La présence de multiples échelles tant spatiales que temporelles.
- La difficulté de procéder à des mesures extensives et dans des conditions variées.

Cette complexité inhérente à la modélisation hydrologique implique qu'il n'existe pas une mais de multiples modélisations possibles et que le lien entre le modèle et l'objectif de son application est particulièrement important. Autrement dit, il n'existe pas de modèle universel applicable sans discernement.

## 2.4 Les grandes étapes de la modélisation

Elle se déroule en 5 grandes étapes :

- on se fixe les objectifs de la modélisation ;
- on fait l'inventaire des informations (données externes : axiomes, loi, hypothèses, théorie... données expérimentales) ;
- on réalise un modèle (construction en fonction des axiomes et hypothèses) ;
- on identifie les paramètres du modèle ;
- on valide en confrontant le modèle à la réalité ;
- on tire des conclusions.

## 2.5 Définition de la simulation

La simulation est une méthode de mesure et d'étude consistant à remplacer un phénomène, un système par un modèle plus simple mais ayant un comportement analogue (Larousse).

Grâce à la simulation de plus en plus détaillée, on peut prédire le comportement des systèmes complexes, de simuler des phénomènes naturels...

L'objectif d'un modèle de simulation peut être simplement descriptif : étudier le comportement d'un système sous différentes hypothèses d'évolution de l'environnement, ou aussi décisionnel : en simulant plusieurs décisions envisagées afin de choisir la meilleure ou la moins mauvaise.[2]

## 2.6 Les modèles hydrologiques

Un modèle est une représentation d'un phénomène physique. afin d'en avoir une meilleure compréhension ou d'analyser l'influence qu'il exerce. La représentation peut être physique, analogique ou mathématique. Dans le premier cas. le modèle est une maquette qui reproduit d'une manière adéquate la réalité. Les modèles analogiques utilisent les similitudes qui existent entre le phénomène à étudier et un autre phénomène physique. La méthode la plus utilisée est l'analogie entre le courant électrique et le flux d'eau. Dans ce cas. le modèle est le résultat de l'expression analytique de la complexité observée ou supposée et se présente généralement sous la forme d'un ensemble d'équations. La modélisation mathématique est un outil essentiel pour la connaissance des phénomènes naturels. Ils essaient d'établir un lien entre les variables d'entrée et de sortie par des relations mathématiques .[7]

Au cours de ces dernières années, les efforts de la recherche pour la compréhension du cycle de l'eau dans les milieux naturels (bassins versants. rivières, nappes. etc.), associés aux développements de l'informatique, se sont concrétisés par l'apparition d'une multitude de modèles mathématiques. On peut distinguer trois types d'utilisation des modèles mathématiques en hydrologie :

### 2.6.1 La modélisation comme outil de recherche

La modélisation peut être utilisée pour interpréter des données mesurées. Différents scénarios de fonctionnement hydrologique des bassins versants peuvent être confrontés aux mesures.

### 2.6.2 La modélisation comme outil de prévision

Elle nous donne une anticipation des évolutions futures du débit d'un cours d'eau. Il s'agit de l'utilisation opérationnelle la plus courante des modèles hydrologiques. Dans la plupart des cas cependant, les modèles développés sont basés sur des régressions linéaires entre les variables indépendantes (Ex : pluie, débits amont) et les variables dépendantes (débits aval), et font peu appel aux connaissances sur les processus hydrologiques. [2]

## 2.7 Classification des modèles.

### 2.7.1 Classification selon le mode de conception

On distingue trois sortes de modèles en fonction des informations mises en jeu pour leur conception :

#### 2.7.1.1 Les modèles de connaissance

les modèles de connaissance sont construits à partir d'une analyse physique, chimique, biologique (ou autre suivant le type du processus), en appliquant soit les lois générales, fondées sur des principes (lois de la mécanique, de l'électromagnétisme, de la thermodynamique, de la physique quantique, etc.), soit les lois empiriques (finance, économie), qui régissent les phénomènes intervenant au sein des processus

étudiés. Ces modèles ne comportent généralement pas de paramètres ajustables, ou des paramètres ajustables en très petit nombre.

Dans la pratique, il est toujours souhaitable d'établir un modèle de connaissance des processus que l'on étudie. Néanmoins, il arrive fréquemment que le processus soit trop complexe, ou que les phénomènes qui le régissent soient trop mal connus, pour qu'il soit possible d'établir un modèle de connaissance suffisamment précis pour l'application considérée. On est alors amené à concevoir des modèles purement empiriques, fondés exclusivement sur les résultats de mesures effectuées sur le processus.[2]

### 2.7.1.2 Les modèles "boîte noire"

les modèles "boîte noire" sont construits essentiellement sur la base de mesures effectuées sur les entrées et les sorties du processus à modéliser. La modélisation consiste alors à utiliser, pour représenter les relations entre les entrées et les sorties, des équations (algébriques, différentielles, ou récurrentes) paramétrées, et à estimer les paramètres, à partir des mesures disponibles, de manière à obtenir la meilleure précision possible avec le plus petit nombre possible de paramètres ajustables. Dans ce mémoire, nous désignerons fréquemment l'estimation des paramètres sous le terme d'apprentissage. [2]

### 2.7.1.3 Les modèles "boîte grise"

lorsque des connaissances, exprimables sous forme d'équations, sont disponibles, mais insuffisantes pour concevoir un modèle de connaissance satisfaisant, on peut avoir recours à une modélisation "boîte grise" (ou modélisation semi-physique) qui prend en considération à la fois les connaissances et les mesures. Une telle démarche peut concilier les avantages de l'intelligibilité d'un modèle de connaissance avec la souplesse d'un modèle comportant des paramètres ajustables.[2]

## 2.8 Le calage et validation d'un modèle

En hydrologie, le calage consiste donc à sélectionner le jeu de paramètres d'un modèle de façon à ce que celui-ci simule le comportement hydrologique du bassin versant de la meilleure façon possible [8].

Les critères utilisés sont le coefficient de détermination  $R^2$ , le critère de Nash-Sutcliffe, le RSR et le Pbias. L'opération de calage consiste à trouver des valeurs des paramètres du modèle qui minimisent l'erreur de modélisation sur la période considérée.

La validation porte sur l'application des modèles sur les données qui n'ont pas été utilisées lors du calage des modèles.

## 2.9 Modèle de régression

### 2.9.1 Introduction

Il y a un certain nombre de situations où on cherche à modéliser les valeurs d'une variable, notée classiquement  $Y$ , en fonction d'une ou plusieurs autres variables

notées  $X_i$ . Le modèle, soigneusement défini par des équations, peut servir soit à décrire les phénomènes, souvent dans une optique de causalité, soit à prédire de nouvelles valeurs, à condition de prendre certaines précautions.

Suivant la nature de  $Y$ , le nombre et la nature des  $X_i$ , cette modélisation porte différents noms dits de régression :

Tableau 2.1: Régression (statistiques)

Modélisation	Nature de la Régression
avec un seul $X$	régression simple
avec plus d'un seul $X$	régression multiple

## 2.9.2 Comment effectuer une régression ?

Pour réaliser une «bonne» régression linéaire, il faut effectuer plusieurs étapes. Tout d'abord il faut choisir un modèle parmi les modèles possibles. Si on a plusieurs  $X_i$ , la sélection de variables, en régression multiple avec ou sans interaction (variables supplémentaires définies comme produits des variables de départ), est une étape souvent délicate. Il faut ensuite déterminer les paramètres du modèle, c'est-à-dire trouver les coefficients dans la ou les équations de régression. Après, il faut tester la qualité générale du modèle, tester la nullité des coefficients, et analyser l'ajustement du modèle aux données par l'analyse des résidus.

## 2.9.3 Le modèle linéaire

Un modèle de régression linéaire est un modèle de régression d'une variable expliquée sur une ou plusieurs variables explicatives dans lequel on fait l'hypothèse que la fonction qui relie les variables explicatives à la variable expliquée est linéaire dans ses paramètres.

On parle aussi de modèle linéaire ou de modèle de régression linéaire.

Le modèle de régression linéaire est souvent estimé par la méthode des moindres carrés mais il existe aussi de nombreuses autres méthodes pour estimer ce modèle. On peut par exemple estimer le modèle par maximum de vraisemblance ou encore par inférence bayésienne.

Bien qu'ils soient souvent présentés ensemble, le modèle linéaire et la méthode des moindres carrés ne désignent pas la même chose. Le modèle linéaire désigne une classe de modèles qui peuvent être estimés par un grand nombre de méthodes, et la méthode des moindres carrés désigne une méthode d'estimation. Elle peut être utilisée pour estimer différents types de modèles.[3]

### 2.9.3.1 Applications

Comme les autres modèles de régression, le modèle de régression linéaire est aussi bien utilisé pour chercher à prédire un phénomène que pour chercher à l'expliquer.

Après avoir estimé un modèle de régression linéaire, on peut prédire quel serait le niveau de  $y$  pour des valeurs particulières de  $x$ .

Il permet également d'estimer l'effet d'une ou plusieurs variables sur une autre en contrôlant par un ensemble de facteurs. Par exemple, dans le domaine des sciences de l'éducation, on peut évaluer l'effet de la taille des classes sur les performances scolaires des enfants en contrôlant par la catégorie socio-professionnelle des parents



ou par l'emplacement géographique de l'établissement. Sous certaines hypothèses restrictives, cet effet peut être considéré comme un effet causal.

En apprentissage statistique, la méthode de régression linéaire est considérée comme une méthode d'apprentissage supervisé utilisée pour prédire une variable quantitative.

Dans cette perspective, on entraîne généralement le modèle sur un échantillon d'apprentissage et on valide ensuite les performances prédictives du modèle sur un échantillon de validation.

## 2.10 Les réseaux de neurones artificiels

### 2.10.1 Introduction

Les études des réseaux de neurones artificiels (RNA) datent depuis les années 1940. Grâce aux développements des recherches sur le cerveau et la disponibilité des outils de simulation, les chercheurs étudièrent des ensembles de neurones formels interconnectés. Ces réseaux, déjà développés à l'époque, permettaient d'effectuer quelques opérations logiques simples. Jusqu'aux années 1980, la recherche était freinée par la limitation théorique du perceptron. Peu après cette époque, Hopfield lança de nouveau en 1982 la recherche dans ce domaine après avoir montré l'analogie entre les RNA et les systèmes physiques.

Après les années 1990, quelques travaux scientifiques ont vu le jour dans le domaine de la robotique, parmi ces applications, on trouve la commande des systèmes d'entraînement et des systèmes de positionnement de haute performance.

Les réseaux de neurones sont des ensembles d'éléments de base appelés neurones. La philosophie derrière ces réseaux de neurones est d'imiter le cerveau humain, mais l'écart entre les réseaux de neurones et le cerveau est toujours grand, dû à la complexité de ce dernier. Cette complexité et une connaissance toujours améliorée du cerveau ont amené une multitude de solutions pour la conception des réseaux de neurones. L'absence de normalisation ajoute aussi à la difficulté de présenter clairement une théorie sur les réseaux de neurones. Les réseaux de neurones se modifient pour tenir compte de leur environnement. Cette capacité d'apprendre à partir d'exemples est d'un grand intérêt et elle s'apparente à celle du cerveau.

Les RNA sont une formulation mathématique simplifiée des neurones biologiques. Ils ont la capacité de mémorisation, de généralisation et surtout d'apprentissage qui est le phénomène le plus important.[10]

### 2.10.2 Avantages

Les principales qualités des réseaux de neurones sont leur capacité d'adaptabilité et d'auto-organisation et la possibilité de résoudre des problèmes non-linéaires avec une bonne approximation. Ils ont une bonne immunité aux bruits et se prêtent bien à une implantation parallèle. La rapidité d'exécution est une qualité importante et elle justifie souvent à elle seule le choix d'implanter un réseau de neurones. Ces qualités ont permis de réaliser avec succès, plusieurs applications : classification, filtrage, compression de données, contrôleur, etc ...[10]

### 2.10.3 Inconvénients

La difficulté d'interpréter le comportement d'un réseau de neurones est un inconvénient pour la mise au point d'une application. Il est souvent impossible d'utiliser les résultats obtenus pour améliorer ce comportement. Il est également hasardeux de généraliser à partir d'expériences antérieures et de conclure ou de créer des règles sur le fonctionnement et le comportement des réseaux de neurones.

Plusieurs paramètres doivent être ajustés et aucune méthode ne permet de choisir des valeurs optimales. Beaucoup d'heuristiques sont utilisées, mais elles se contredisent parfois et elles ne permettent pas toujours de trouver des valeurs optimales.[10]

### 2.10.4 Types et structures des réseaux de neurones artificiels (RNA)

#### 2.10.4.1 Types de RNA

Pour concevoir un réseau de neurones, nous devons établir des connexions entre les neurones. Nous avons quatre types principaux de connexion: directe, récurrente, latérale et à délais. Tous les réseaux de neurones utilisent la connexion directe pour acheminer l'information de l'entrée vers la sortie. La connexion récurrente permet d'acheminer l'information de la sortie des neurones des couches supérieures vers les entrées des neurones précédents. Les réseaux de neurones qui doivent choisir un neurone gagnant utilisent la connexion latérale pour établir une relation entre les neurones de sortie et la maintenir. Finalement, les problèmes temporels sont résolus par les modèles de réseaux dynamiques avec des connexions à délais. Les connexions entre les neurones peuvent être complètes ou partiellement complètes. Une connexion est complète lorsque les neurones d'une couche inférieure!! sont reliés à ceux de la supérieure et elle est locale lorsque les deux couches de neurones ne sont pas complètement reliées.

Une couche est définie comme un ensemble de neurones situé au niveau d'un réseau de neurones. Nous avons, par exemple, une couche de neurones de sortie avec des couches situées entre les entrées-sorties appelées couches cachées. Les réseaux de neurones possèdent une ou plusieurs couches de neurones et leur dimension dépend du nombre de couches et du nombre de neurones par couche.[10]

- **Perceptron**

Le perceptron est la forme la plus simple d'un réseau de neurones, il modélise la perception visuelle. Il comprend trois principaux éléments: la rétine, les cellules d'association et les cellules de décision. La fonction d'activation utilisée dans ce réseau est de type tout ou rien (0 ou 1). L'apprentissage du perceptron peut se faire avec plusieurs méthodes déjà utilisées, il n'y a qu'une seule couche de poids modifiables entre les cellules d'association et les cellules de décision. Le perceptron est limité dans ses applications. Premièrement, il ne peut être applicable que dans la classification dont les variables sont linéairement séparables et deuxièmement la sortie ne peut être que 0 ou 1.

- **Perceptron multicouche**

Cette classe est la plus importante des réseaux de neurones car elle représente la généralisation du perceptron monocouche avec une fonction d'activation de type sigmoïde et une ou plusieurs couches cachées. Le vecteur d'entrée se propage dans le réseau de couche en couche jusqu'à la sortie, l'entraînement de celui-ci se fait avec l'algorithme par la rétro-propagation de l'erreur. Ce réseau est caractérisé par son modèle du neurone traitant les non-linéarités. Il peut comporter une ou plusieurs couches cachées et un plus grand nombre de connexions permettant de résoudre la majorité des problèmes.

Même avec les avantages des couches cachées et la performance de l'algorithme d'apprentissage, il reste plusieurs problèmes non réglés comme le choix du nombre de couches, le nombre de neurones par couche et le problème des minimums locaux où le réseau peut converger.

- **Réseau de neurones linéaire**

Cette classe de réseaux diffère du perceptron car elle possède un neurone dont la fonction d'activation est linéaire. L'une des règles d'apprentissage permet d'effectuer une descente de gradient de l'erreur sur une mesure d'erreur quadratique. Les domaines d'application comprennent la commande, le contrôle, et le traitement du signal. L'avantage de ce réseau est qu'il converge sur un seul minimum si la solution existe, sinon l'ajout de couches n'a aucun effet. Parmi ses inconvénients, il est limité à une couche de sortie et ne peut résoudre que les problèmes dont la relation entrées/sorties est linéaire.

- **Réseau Hopfield**

Ce réseau est basé sur les principes de la physique statistique et il est fondamentalement une mémoire adressable par son contenu. Les neurones, basés sur le modèle étudié en , sont tous interconnectés. Plusieurs domaines d'application sont possibles, en particulier: les mémoires associatives et l'économie. La principale limitation est qu'il n'y a pas de couches cachées.

#### 2.10.4.2 Structure d'un RNA

##### Structure d'un neurone

Le neurone est la cellule fondamentale d'un réseau de neurones artificiels. Par analogie avec le neurone biologique, le neurone doit être apte à accomplir les tâches suivantes: collecter,traiter les données qui viennent des neurones émetteurs et transmettre les messages aux autres neurones. La relation entre l'entrée et la sortie du neurone peut être donnée par l'équation suivante:

$$S_i = F(a) \tag{2.1}$$

$$a = \sum W(i, j).X(j) \tag{2.2}$$

Les variables  $N$ ,  $S_i$ ,  $F$ ,  $x$  et  $W$  désignent respectivement le nombre d'entrées du réseau de neurones, le vecteur de sortie du réseau, la fonction d'activation, le vecteur des entrées du réseau de neurones et la matrice des poids. Nous présentons dans la Figure 2.1 la structure d'un neurone simple.




Figure 2.1: Structure d'un neurone simple

### Structure d' un réseau de neurones à couches simples

Le réseau à couches est un réseau dont les neurones sont organisés en couches, la forme la plus simple est le réseau à une seule couche. Tous les signaux d'entrées sont propagés des noeuds d'entrée vers la couche de neurones de sortie. Le nombre de neurones d'entrée (noeuds) et de sortie est en général lié au problème à résoudre. Les entrées seront propagées à travers la matrice des poids  $W$  pour ensuite obtenir la réponse de sortie (Figure 2.2). L'équation équivalente peut s'écrire sous la forme:

$$y(j) = \sum W(i, j).X(i) \quad (2.3)$$

où:

$x(i)$  : Vecteur d'entrée.

$y(j)$  : Vecteur de sortie.

$W(i,j)$  : Poids du réseau de neurones.

$W(0,j)$  représente le biais  $b(j)$ .




Figure 2.2: Réseau de neurones mono-couche

### Structure des réseaux de neurones multicouches

Cette structure est caractérisée par une ou plusieurs couches. À chaque couche correspond une matrice de poids  $W$  et un vecteur de seuils  $b$ , et on peut avoir aussi des fonctions d'activation différentes pour chaque couche. La fonction des couches cachées intervient entre les entrées  $x$  et la couche de sortie  $y$ . Elle permet de résoudre des problèmes plus complexes que le réseau à couche simple. Les réseaux de neurones utilisant un apprentissage par rétropropagation sont constitués de plusieurs couches (multicouches) qui comportent chacune plusieurs neurones. Ces derniers sont reliés entre eux par des matrices de poids qui caractérisent le réseau. Dans ce type de réseau de neurones, chaque neurone a d'abord le rôle de sommer les différentes entrées pondérées par leurs poids respectifs, puis de passer la somme obtenue dans une fonction  $F(\cdot)$  linéaire ou non-linéaire et finalement, de transmettre le résultat aux neurones de la couche suivante.




Figure 2.3: Réseau de neurones multicouches

La Figure 2.3 illustre un réseau de neurones multicouches avec une couche d'entrée et une de sortie. Les équations d'un tel réseau peuvent être données par la relation suivante:

$$S(z) = F_2(y_s(z)) \quad (2.4)$$

$$y_s(z) = \Sigma F_2(i, z).F_1(y(i)) \quad (2.5)$$

$$y(s) = \Sigma W_1(i, s).X(i) \quad (2.6)$$

où  $s$  est le vecteur de sortie du réseau de neurones de dimension  $(z \times 1)$ ,  $x$  est le vecteur d'entrée de dimension  $(n \times 1)$ ,  $y(1)$  est la sortie de la 1<sup>ère</sup> couche de dimension  $(j \times 1)$  et  $W_1$  est la matrice de poids de dimension  $(n \times j)$  associée à la 1<sup>ère</sup> couche. Enfin,  $F_1$  et  $F_1$  sont respectivement les fonctions d'activation appliquées à la 1<sup>ère</sup> et la 2<sup>ème</sup> couche.

### 2.10.5 Fonctions d'activation de RNA

Les fonctions d'activation utilisées dans les modèles connexionnistes d'aujourd'hui sont variées. On peut identifier trois principaux types de fonctions les plus connues: binaire à seuil, rampe avec saturation, et la sigmoïde.

#### 2.10.5.1 Fonction binaire à seuil

La Figure 2.4 présente la fonction d'activation qui a été utilisée. Le seuil introduit une non-linéarité dans le comportement du neurone, c'est le modèle tout ou rien.




Figure 2.4: Fonction d'activation binaire à seuil

### 2.10.5.2 Fonction à rampe avec saturation

Cette fonction représente un compromis entre la fonction linéaire et la fonction seuil: entre ses deux bornes, elle confère au neurone une combinaison linéaire de l'entrée. À la limite, la fonction linéaire est équivalente à la fonction seuil (Figure 2.5).




Figure 2.5: Fonction d'activation à rampe avec saturation

### 2.10.5.3 Fonction sigmoïde

La fonction sigmoïde est une fonction continue qui maintient la sortie dans l'intervalle  $[0,1]$  (Figure 2.6). Son avantage principal est l'existence de sa dérivée en tout point. Elle est employée en général dans le perceptron multicouches.




Figure 2.6: Fonction d'activation sigmoïde

### 2.10.6 Modes d'apprentissage des réseaux de neurones artificiels (RNA)

On peut définir l'apprentissage comme la capacité d'emmagasiner des informations qui peuvent être rappelées par la suite. Les connaissances d'un réseau connexionniste sont mémorisées dans les poids de connexions qui seront déterminés lors de l'apprentissage. Le but de l'apprentissage pour un réseau est de trouver un ensemble de poids synoptiques qui minimisent l'erreur entre la sortie du réseau et le résultat désiré. C'est la caractéristique principale des réseaux de neurones.

Les possibilités de reconnaissance des données dans le temps sont statiques ou temporelles. Un réseau de neurones est statique si l'ordre des données dans le temps ne change pas l'interprétation faite par celui-ci et il est temporel si cela change l'interprétation. Les possibilités de reconnaissance de données temporelles ajoutent la notion de mémoire aux réseaux de neurones. Cette mémoire est déterministe ou stochastique.

L'entraînement consiste à présenter, de façon répétitive, un ensemble de données pour permettre au réseau de neurones d'apprendre à résoudre ce problème en ajustant correctement ses poids. L'exécution est l'utilisation d'un réseau, avec tous ses paramètres et ses poids prédéterminés, pour la résolution d'un problème. Les caractéristiques qui vont constituer l'ensemble de données doivent être consistantes pour définir clairement les frontières des classes. Ces caractéristiques ont avantage à être limitées à celles qui sont vraiment nécessaires à la résolution du problème.

Les méthodes d'entraînement sont divisées en trois catégories: avec supervision, sans supervision et avec des poids prédéterminés. L'entraînement supervisé consiste à ajuster par interpolation, approximation ou optimisation les poids du réseau de neurones. Les réseaux de neurones supervisés dont l'ajustement des poids est obtenu par interpolation sont appelés à base de décision ("decision based neural network"). Avec l'entraînement non supervisé, le réseau de neurones s'ajuste uniquement en fonction de l'ensemble d'entrées. Il n'est pas nécessaire de connaître a priori les résultats et de constituer un ensemble de sorties désirées. Les réseaux de neurones à poids prédéterminés n'ont pas de phase d'apprentissage et la valeur des poids doit être déterminée par l'utilisateur. Une fonction d'énergie minimum est souvent utilisée pour calculer ces poids.

Pour l'apprentissage supervisé, on présente au réseau des entrées et on lui demande de modifier sa pondération de telle sorte que l'on retrouve la sortie correspondante. L'algorithme consiste, dans un premier temps à propager vers l'avant les entrées jusqu'à obtenir une sortie calculée par le réseau. La seconde étape compare la sortie calculée à la sortie réelle connue. On modifie alors les poids de telle sorte qu'à la prochaine itération, l'erreur commise entre la sortie calculée et connue soit minimisée. Malgré tout, il ne faut pas oublier que l'on a des couches cachées. On rétropropage alors l'erreur commise vers l'arrière jusqu'à la couche d'entrée tout en modifiant la pondération. On répète ce processus sur tous les exemples jusqu'à ce que l'on obtienne une erreur de sortie considérée comme négligeable. Les poids optimaux seront alors appliqués sur le test pour vérifier la justesse et la précision des calculs.

d'apprentissage plus grand. La stratégie discriminatoire utilise un ensemble d'entraînement comprenant des exemples couvrant le domaine complet du problème à résoudre. La stratégie mutuelle est toujours discriminatoire. La stratégie in-



dépendante utilise un ensemble d'entraînement comprenant des exemples couvrant seulement la classe à reconnaître par une sortie. L'avantage de cette stratégie d'entraînement est de réduire le temps d'apprentissage, alors que son inconvénient est d'obtenir des frontières moins bien définies entre les classes. Il est possible d'utiliser une stratégie d'entraînement à deux niveaux pour obtenir les avantages de chacun. L'entraînement est premièrement effectué de façon individuelle, puis les résultats sont raffinés avec la stratégie mutuelle. Ces stratégies d'entraînement peuvent être utilisées pour la classification des réseaux de neurones.[10]

## 2.11 Les systèmes Neuro-flous

### 2.11.1 Introduction

Les systèmes neuro-flous sont nés de l'association des réseaux de neurones et de la logique floue, de manière à tirer profit des avantages de chacune de ces deux techniques . Cependant, la logique floue permet une spécification rapide des tâches à accomplir à partir de la connaissance symbolique disponible. le réglage précis du système obtenu et l'optimisation de ses différents paramètres reste néanmoins beaucoup plus difficile dans de nombreux cas. Par contre les modèle les plus courant de RNA ,n'autorisent pas l'incorporation de connaissance a priori mais permet de régler par apprentissage le comportement précis du système.

Donc, la principale propriété des systèmes neuro-flous est leur capacité à traiter dans une même outil des connaissances numérique et symboliques d'un système. Il permettent donc d'exploiter les capacités d'apprentissage des réseaux de neurones d'un part et les capacités de raisonnement de la logique floue d'autres part.

L'intégration des réseaux de neurones et les systèmes d'inférence flous peut être formulée en trois principales catégories: coopérative , concurrentes et hybride. [10]

### 2.11.2 Définitions

Les systèmes neuro-flous sont des systèmes flous formés par un algorithme d'apprentissage inspiré de la théorie des réseaux de neurones. La technique d'apprentissage opère en fonction de l'information local et produit uniquement des changements locaux dans le système flou d'origine.

Les règles floues codées dans le système neuro-flou représentent les échantillons imprécis et peuvent être vues en tant que prototypes imprécis des données d'apprentissage.

Un système neuro-flou ne devrait par contre pas être vu comme un système expert (flou). Il n'a rien à voir avec la logique floue dans le sens stricte du terme. On peut aussi noter que les systèmes neuro-flous peuvent être utilisés comme des approximateurs universels.

Afin de résumer l'apport du neuro-flou, le Tableau 2.2 regroupe les avantages et les inconvénients des réseaux de neurones et de la logique floue.

Tableau 2.2: comparaison entre la logique floue et les réseaux de neurones

Réseaux de neurones	Logique floue
Avantages	
Le modèle mathématique non requis	Le modèle mathématique non requis
Aucune connaissance basé sur les règles	La connaissance antérieure sur les règles peut être utilisée
Plusieurs algorithmes d'apprentissagesont disponibles	Une interprétation et implémentation simple
Inconvénients	
Boite noire(manque de traçabilité)	Aucune méthode formelle pour l'ajustement
L'adaptation aux environnements différents est difficile et le réapprentissage est souvent obligatoire	Les règles doivent être disponibles
La connaissance antérieure ne peut pas être employée (apprentissage à partir de zéro)	Ne peut pas apprendre Adaptation difficile au changement de l'environnement
Aucune garantie sur la convergence de l'apprentissage.	

Diverses associations de ces deux approche ont été développées depuis 1988 et sont le plus souvent orientées vers la commande de systèmes complexe et les problèmes de classification. Il existe ainsi trois méthodes neuro-floues :

### 2.11.3 Le système neuro-flou coopératif

Il utilise des réseaux de neurones et des systèmes flous associés en série ou en parallèle. Plusieurs variantes d'utilisation sont ainsi possibles :

Le réseau de neurones fonctionne en amont du système flou (Figure 2.7).




Figure 2.7: Système Neuro-flou pour régler une fonction d'appartenance

Les variantes d'entrées du système flou sont déterminées à partir des sorties du réseau de neurones (dans le cas où elles ne sont pas mesurables directement) ou

encore un réseau de neurones effectue une tâche de classification ou de reconnaissance de formes, suivie d'un système flou d'aide à la décision. Un réseau de neurones qui fonctionne en aval du système flou, dans le but d'ajuster les sorties d'un système de commande floue à de nouvelles connaissances obtenues, les variables de sorties étant les erreurs sur les variables de sortie du système flou.

Deuxièmement le système en série, qui serait utilisé si la sortie n'est pas convenable pour une relation direct à l'entrée du système flou. Les systèmes post-traitement existent aussi et dans lesquels la sortie d'un système flou n'est pas convenable par rapport direct aux systèmes externes, et par conséquent un réseau neurone fournit une interface qui exécute une projection topographique qui ne pourrait pas être porté facilement (Figure 2.8).




Figure 2.8: Système neuro-flou en série avec prétraitement neuronal

On trouve aussi un système neuro-flou parallèle qui fait une coopération entre les réseaux de neurones et les systèmes flous en parallèle en même temps. (Figure 2.9).




Figure 2.9: Système neuro-flou en parallèle

Ces deux combinaisons des réseaux de neurones et de la logique floue sont des paradigmes qui ont besoin d'une plateforme mathématique très forte, et aussi ne peuvent être implémenté que d'une manière informatisée vu les gigantesques probabilités de calcul .

Le modèle du système neuro-flou coopératif peut être considéré comme un préprocesseur avec des mécanismes d'apprentissage des RNA détermine les fonctions d'appartenance du système d'inférence floue ou les règles floues quand les paramètres de SIF( système d'inférence floue) sont déterminées .

### 2.11.4 Le système de neuro-flou concurrent

Il utilise des réseaux de neurones et des systèmes flous associés en série ou en parallèle. Plusieurs variantes d'utilisation sont ainsi possibles :

Le réseau de neurones fonctionne en amont du système flou. Les variantes d'entrées du système flou sont déterminées à partir des sorties du réseau de neurones (dans le cas où elles ne sont pas mesurables directement) ou encore un réseau de neurones effectue une tâche de classification ou de reconnaissance de formes, suivie d'un système flou d'aide à la décision.

Un réseau de neurones qui fonctionne en aval du système flou, dans le but d'ajuster les sorties d'un système de commande floue à de nouvelles connaissances obtenues, les variables de sorties étant les erreurs sur les variables de sortie du système flou.

### 2.11.5 Le système neuro-flou hybride

Les approches neuro-floues modernes sont de cette forme . Un réseau neuronal et un système flou combinés dans une architecture homogène. Le système peut être interprété comme un réseau neuronal spécial avec des paramètres flous ou comme un système flou mis en application sous une forme distribuée parallèle (Figure 2.10).

Dans ce modèle, les algorithmes d'apprentissage des système de neurones sont utilisés pour déterminer les paramètres du système d'inférence floue. Le système neuro-flou partage la structure des données et la représentation de connaissance .Le SIF peut utiliser l'expertise humaine pour implémenter les composantes essentielles dans la base de connaissance et la base de données et exécute le raisonnement flou pour inférer la valeur de sortie totale.

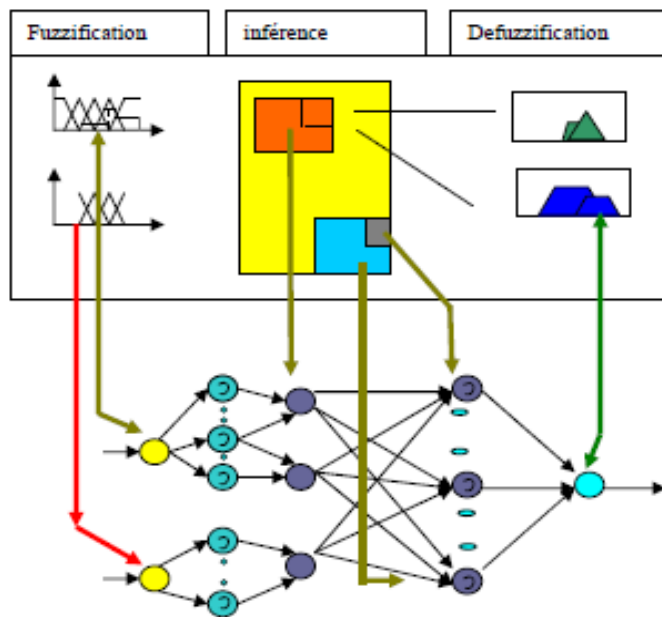


Figure 2.10: Principe de fonctionnement du neuro-flou hybride

### 2.11.6 ANFIS ( Adaptive-Network-based Fuzzy Inference System)

ANFIS représente un système à inférence flou mis en application dans le cadre des réseaux adaptatifs. Il utilise la procédure d'apprentissage Hybride.

Cette architecture (Figure 2.11) affine les règles floues obtenues par des experts humains pour décrire le comportement d'entrée-sortie d'un système complexe. Il est implémenté dans la boîte à outils « Neuro-Fuzzy » de MATLAB. Ce modèle donne de très bons résultats en poursuite de trajectoire, approximation non linéaire, commande dynamique et traitement du signal.

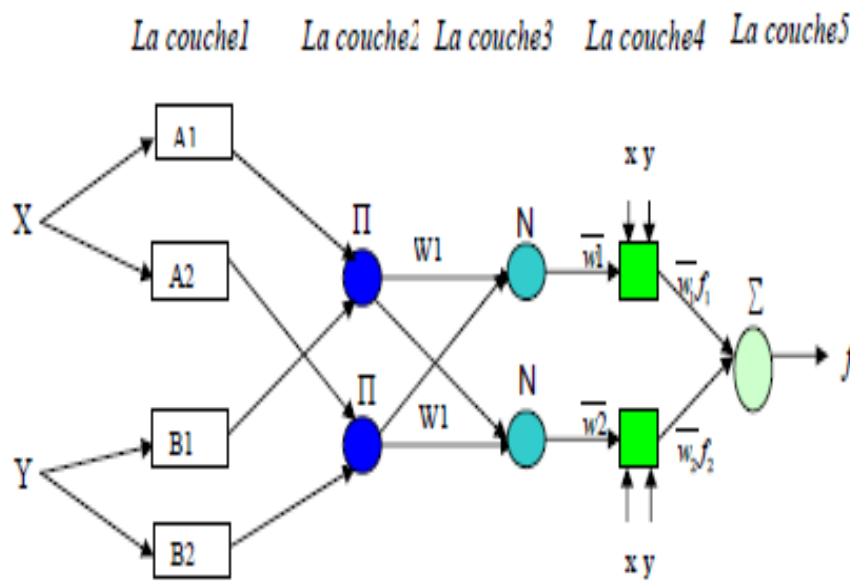


Figure 2.11: L'architecture de ANFIS

#### 2.11.6.1 Modélisation

Le problème de modélisation floue ou de construction de modèles flous peut être vu comme un processus d'identification de système. Ce processus est composé de trois phases :

- Phase d'identification de la structure du modèle Cette phase se base sur la détermination de la structure de la base des règles, du nombre de symboles et de la structure des conclusions des règles.
- Phase d'identification des paramètres du modèle L'identification des paramètres d'un modèle se fait à partir d'un ensemble de données appelé ensemble d'apprentissage. Cette phase permet l'identification des paramètres d'entrée, des paramètres de sortie et de la base des règles ou de la relation floue sous-jacente.
- Phase de validation du modèle Cette phase sert à tester la validité du modèle d'abord par rapport à l'ensemble d'apprentissage, puis sur de nouvelles données de test.

Sous Matlab l'identification de systèmes à l'aide d'ANFIS s'effectue en suivant l'organigramme présenté ci dessous:

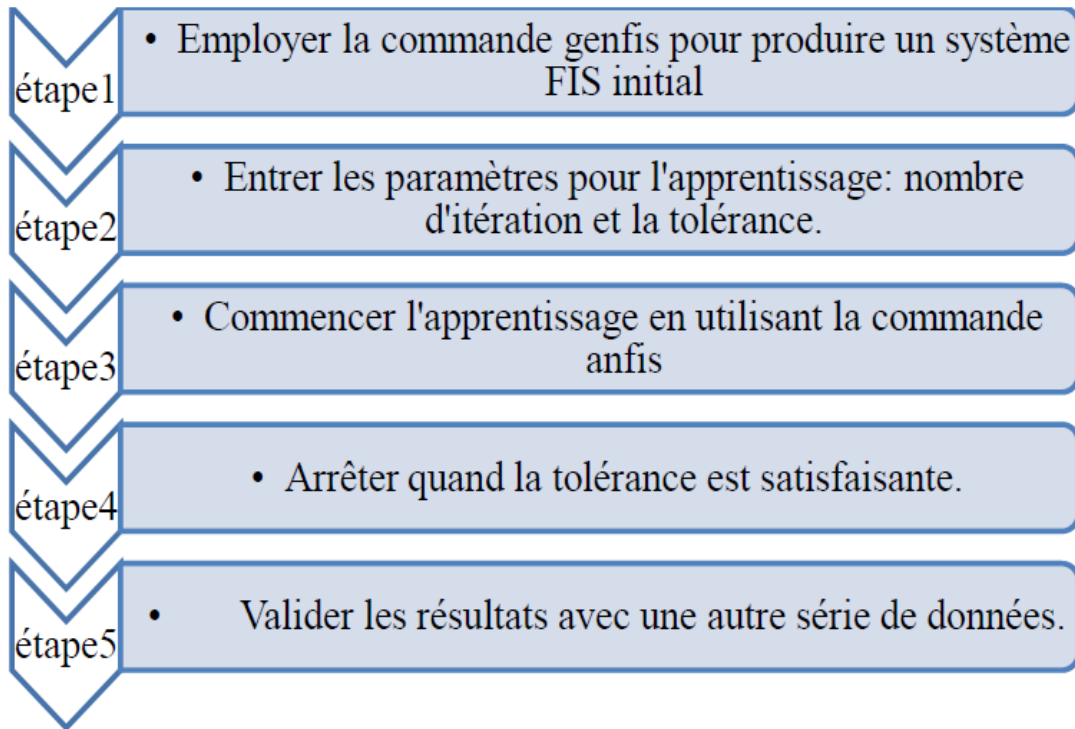


Figure 2.12: Etape de synthèse d'une identification floue sous ANFIS de Matlab

### 2.11.6.2 Améliorations potentielles d'un système ANFIS

Les réseaux neuro-flous sont connus pour leur rapidité et précision. Nous présentons ci-dessous un inventaire des leviers permettant d'améliorer les performances des réseaux de neuro-flou.

- **Base d'apprentissage :**

L'ensemble d'apprentissage disponible impacte bien entendu la qualité de généralisation du système ANFIS. Il est nécessaire de disposer d'une base d'apprentissage de taille 5 fois supérieure au nombre de paramètres à optimiser (prémises et conséquents). Cependant, au-delà de la taille de cet ensemble d'apprentissage, c'est également la pertinence des données qu'il contient qui se révèle critique.

Le numéro d'époques choisit doit être assigné pour surmonter le problème de paramétrisation ( *overfitting* et *underfitting*), elle comprend une propagation en avant et une rétro-propagation. Durant la propagation en avant, les variables d'entrée servent à déterminer les sorties des neurones couche par couche, permettant de déterminer les valeurs des paramètres des conséquents. Durant la phase de rétro-propagation, l'algorithme de rétro-propagation d'erreur est appliqué pour optimiser les poids des différentes couches. Les époques dans l'apprentissage dépendent également de l'erreur d'apprentissage.

Le processus d'apprentissage se termine lorsque l'erreur d'apprentissage est réduite à un niveau de tolérance indiqué.

- **Algorithme d'apprentissage :**

L'apprentissage consiste en la correction des paramètres (prémises et conséquents) du réseau afin de généraliser une fonction de transfert (inconnue a priori) entre les entrées et la sortie du réseau. A cette fin, une base d'apprentissage est nécessaire, elle sera constituée des entrées/sorties. Le déploiement des algorithmes d'apprentissage sur cette base de données permet de construire une fonction d'approximation (appelée aussi prédiction) de la sortie désirée à partir des nouveaux vecteurs d'entrée.

En général, des algorithmes hybrides sont utilisés. Une combinaison entre l'algorithme de descente du gradient qui permet l'estimation des poids du réseau et de l'algorithme d'estimation des moindres carrés qui permet d'estimer des paramètres des conséquents réduisent la complexité de l'apprentissage est réduite et l'efficacité se trouve améliorer (Riedmiller et al., 1993) proposent de modifier l'algorithme d'apprentissage afin d'en accélérer la convergence. (Yaam et al., 2000) proposent d'optimiser l'initialisation des poids d'apprentissage. La modification des pas d'apprentissage peut aussi être envisagée.

- **Structure du réseau :**

(Rui et al., 1995), a montré qu'il n'y a pas de structure du réseau idéal a priori. Celle-ci est à définir au cas par cas selon le problème. Concernant le réseau neuro-flou ANFIS, définir une architecture consiste à choisir le nombre de fonctions d'appartenance, leur type (gaussienne, sigmoïde...) et le nombre de règles floues utilisées. Aussi, un compromis simplicité/ généralisation doit être trouvé : il n'est pas concevable de construire un système ANFIS trop complexe, la base d'apprentissage étant, elle, limitée.

## 2.12 Critères d'évaluation d'un modèle

Pour analyser la performance et la fiabilité d'un modèle, plusieurs critères d'évaluation (validation) ont été développés. Ils peuvent être utilisés aussi bien pour la calibration qu'en validation.

Une simple visuelle des résultats d'une simulation ne représente pas une évaluation complète d'un modèle. En effet, l'oeil humain n'est pas capable de voir toutes les différences qui peuvent exister entre deux courbes d'allure similaire. Ainsi, nous avons besoin en plus de l'analyse graphique de nous doter de critères objectifs (dénommés aussi fonctions objectives) pour comparer les simulations aux observations et pour hiérarchiser des simulations qui ont l'air équivalentes. Plusieurs critères objectifs mathématiques existent pour quantifier la distance entre les observations et la simulation.

### 2.12.1 Principaux critères objectifs

Les principaux critères objectifs utilisés en hydrologie sont :

#### 2.12.1.1 Le critère de Nash Sutcliffe (Nash et Sutcliffe, 1970)

Utilisé surtout en hydrologie, il donne une indication sur la robustesse (pouvoir prédictif) des modèles utilisés. Ainsi, il est utilisé comme un outil d'aide à la décision.

Le critère est le suivant :

$$E = 1 - \frac{\sum(Q_0^t - Q_m^t)^2}{\sum(Q_0^t - \bar{Q}_0)^2} \quad (2.7)$$

Où

$Q_0$  représente les valeurs observées ;

$Q_m$  sont les valeurs simulées et  $Q_0^t$  est l'observé à l'instant t ;

$\bar{Q}_0$  est la moyenne des valeurs observées.

(E est aussi connu sous le symbole de NSE)

La valeur de E varie de «  $-\infty$  » à « 1 » et est généralement présenté en pourcentage.

- Une efficacité de  $E=1$  correspond à une modélisation parfaite où les simulées = les observées.
- Une efficacité de  $E=0$  indique que les prédictions du modèle sont aussi précises que la moyenne des données observées.
- Une efficacité de  $E<0$  indique que les valeurs simulées conduisent à de moins bons résultats et que la moyenne observée est meilleur prédicateur que le modèle.

Le critère de Nash a pour inconvénient de surestimer l'erreur des grandes valeurs (pics) contrairement aux petites valeurs qui sont négligées.

#### 2.12.1.2 Nash modifié

### Le logarithmique de Nash

Le Nash modifié est la version modifiée du critère E, par introduction du logarithme aux variables de la loi. Le Nash modifié a été établi afin de mettre fin au problème qu'on rencontre avec le critère de Nash à savoir l'importance qu'il donne aux extrêmes par rapport aux étiages. Ainsi, en introduisant le « ln » cette sensibilité aux extrêmes sera réduite.

### Le Nash modifié

Ce critère utilise la forme puissance 1 et absolue au lieu de la forme quadratique, le but est de mettre fin au problème de sensibilité aux extrêmes.

$$E = 1 - \frac{\sum |Q_0^t - Q_m^t|}{\sum |Q_0^t - \bar{Q}_0|} \quad (2.8)$$



### 2.12.1.3 L'erreur quadratique moyenne (RMSE: Root Mean Square Error)

La mesure de l'erreur quadratique moyenne est aussi un critère souvent utilisé pour mesurer l'écart entre la simulation et l'observation, en donnant notamment une idée de la dispersion entre les deux et cela dans l'unité des variables étudiées. Plus le RMSE sera faible et plus l'écart entre la simulation et les observations sera faible.

Le critère est le suivant :

$$RMSE = \sqrt{\frac{1}{n_0}(Q_m^t - Q_0^t)^2} \quad (2.9)$$

Le RMSE est couramment utilisé pour d'écrire l'erreur statistique. Bien que la performance du modèle est retenue selon une valeur minimale du RMSE, mais des études statistique (établies par SINGH et al, 2004) l'ont normalisé et ont développé le RSR (ratio of the root mean square error to the standard deviation of measured). Il est calculé comme le rapport entre l'erreur quadratique moyenne et l'écart type des données mesurées comme le montre l'équation :

$$RSR = \frac{RMSE}{STDEV_{obs}} = \frac{\sqrt{(Q_m^t - Q_0^t)^2}}{\sqrt{(Q_0^t - \bar{Q}_0)^2}} \quad (2.10)$$

Le RSR varie de la valeur optimale qui est de zero jusqu'à un nombre très grand.

### 2.12.1.4 Percent bias PBIAS

Le pourcentage du bias mesure la tendance moyenne des données simulées à être plus grandes ou plus petites que leurs homologues observées. Le PBIAS prend sa valeur optimale quand il est égal à zéro.

Si le PBIAS <0 il indique que les valeurs simulées sont plus élevés que ceux observés, ainsi on peut dire qu'il y'a une surestimation des valeurs.

Si le PBIAS >0 il indique que les valeurs simulées sont inférieurs à ceux observés, ainsi on peut dire qu'il y'a une sous-estimation des valeurs par le modèle.

$$PBIAS = \frac{\sum(Q_0^t - Q_m^t) * 100}{\sum Q_0^t} \quad (2.11)$$

### 2.12.1.5 Le coefficient de détermination

Il est défini comme étant la valeur élevée au carré du coefficient de corrélation de Pearson. Donc il estime la dispersion entre la série des observées et des simulées, plus il sera important plus l'accord entre les deux séries de valeurs le sera aussi.

Il nous informe également sur le degré de corrélation entre deux variables à étudier, si sa valeur est égale à « 0 » cela signifie qu'il n'y a aucune corrélation entre les deux variables.

La valeur maximale est de « 1 » et elle représente la valeur optimale.

Le  $R^2$  est donné par la relation :

$$R^2 = \left( \frac{\sum(Q_0^t - \bar{Q}) * (Q_m^t - \bar{Q}_m)}{\sqrt{\sum(Q_0^t - \bar{Q})^2} * \sqrt{\sum(Q_m^t - \bar{Q}_m)^2}} \right)^2 \quad (2.12)$$

L'inconvénient du  $R^2$  est qu'il quantifie la dispersion des points "observés-simulés" et ne donne aucune information sur la qualité du modèle, donc même si les valeurs simulées sont sous-estimées ou surestimées mais que leur dispersion est identique à celle des observées, on aura un  $R^2$  proche de « 1 ». Comme solution à ce problème on définit ci-dessous le coefficient de détermination pondéré.

### 2.12.1.6 Le taux de performance des critères

Selon une étude sur l'évaluation de modèles pour la quantification systématique de la précision dans les simulations de bassins versants (Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations) les critères définis ci-dessus sont les meilleurs critères pour juger de la performance d'un modèle. Ainsi, ils seront tous retenus pour valider les modèles utilisés dans notre travail.

Un modèle est jugé satisfaisant si :

$$\left\{ \begin{array}{l} RSR \leq 0,70 \\ NASH > 50 \\ PBIAS < \pm 55\% \\ R^2 > 50\% \end{array} \right.$$

sont réunis à la fois. Cela reste valide pour n'importe quel pas de temps . Le tableau suivant indique les valeurs des critères NASH, RSR et PBIAS correspondant à différents degrés de performance .

Tableau 2.3: Qualité des modèles en fonction des valeurs des différents critères pour un pas de temps journalier

	NASH(%)	RSR	PBIAS(%)
<b>Très bon</b>	$75 < NASH \leq 100$	$0,00 \leq RSR \leq 0,50$	$PBIAS < \pm 15$
<b>Bon</b>	$65 < NASH \leq 75$	$0,50 < RSR \leq 0,60$	$\pm 15 \leq PBIAS < \pm 30$
<b>Satisfaisant</b>	$50 < NASH \leq 65$	$0,60 < RSR \leq 0,70$	$\pm 30 \leq PBIAS < \pm 55$
<b>insatisfaisant</b>	$NASH \leq 50$	$RSR > 0,70$	$PBIAS \geq \pm 55$

# Chapitre 3

## Présentation du bassin versant de la Tafna

### 3.1 Dispositions physique, géomorphologique et géologique du bassin de la Tafna

Le bassin versant de la Tafna est un pourvoyeur important de ressources hydriques pour la région Ouest, il alimente non seulement les régions du bassin versant mais aussi d'autres régions par le biais d'aménagement comme le transport inter bassin.

Le bassin versant de la TAFNA se compose de huit sous bassins hydrologiques (ANRH, 1975) :

- Le sous bassin d'Oued Mouilah amont avec une superficie de  $747km^2$ .
- Le sous bassin d'Oued Mouilah aval avec une superficie de  $1235km^2$ .
- Le sous bassin d'Oued Mehaguene avec une superficie de  $665km^2$ .
- Le sous bassin d'Oued TAFNA amont avec une superficie de  $1294km^2$ .
- Le sous bassin d'Oued TAFNA Boukios avec une superficie de  $978km^2$ .
- Le sous bassin d'Oued Isser Cedera avec une superficie de  $1118km^2$ .
- Le sous bassin d'Oued Isser sikkak avec une superficie de  $820km^2$ .
- Le sous bassin d'Oued TAFNA Maritime avec une superficie de  $388km^2$ .

#### 3.1.1 Situation géographique

Le bassin versant de la Tafna couvre une grande partie du Nord Ouest Algérien (Figure 3.1). Selon la répartition hydrographique et la codification de l'agence nationale des ressources hydraulique ce bassin appartient au bassin hydrographique de l'Oranie-Chott Chergui (Figure 3.2) avec comme numéro le 16 parmi les 17 principaux bassins versants algériens.

Le bassin de la Tafna draine une superficie de  $7245km^2$ , près de 73% de la surface drainée se trouve dans le territoire algérien. Il est partagé entre les willayas de Tlemcen et Ain Témouchent, le reste (27%) se trouve au territoire marocain. Ce bassin hydrographique alimente cinq barrages qui sont, du plus ancien au plus récent, Béni-Bahdel ( $63Hm^3$ ), Mefouche ( $15Hm^3$ ), Sidi-Abdelli ( $115Hm^3$ ), Hammam Boughrara ( $177Hm^3$ ) et celui Sikkak ( $27Hm^3$ ). [3]

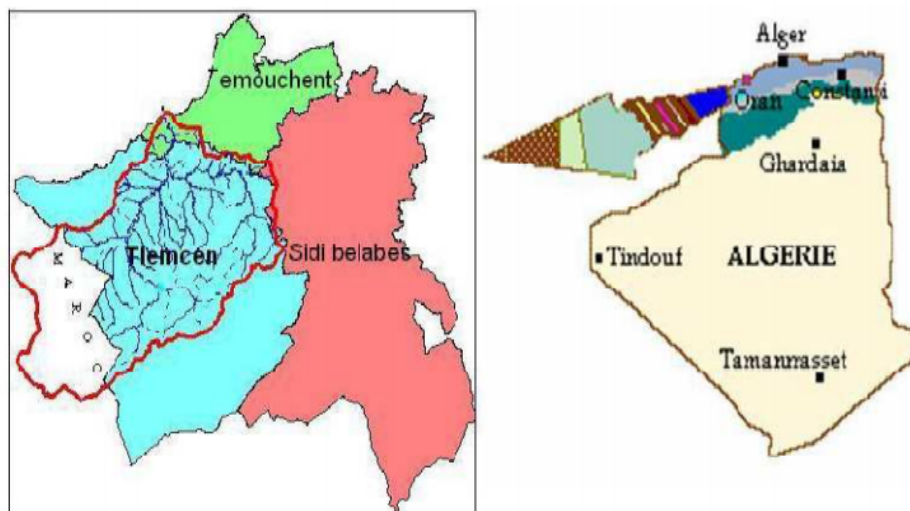
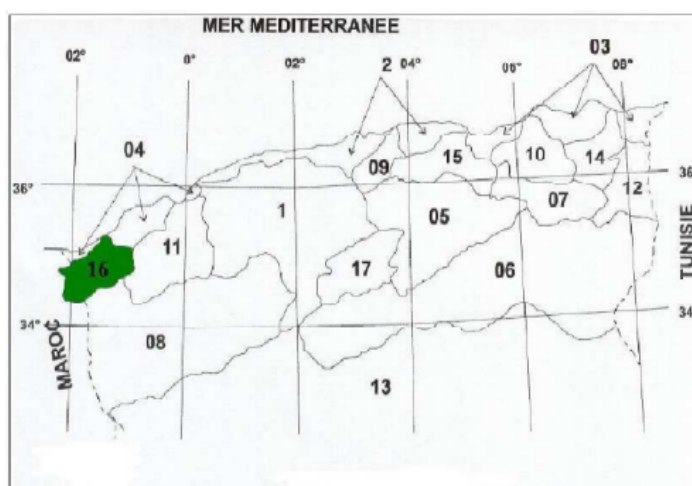


Figure 3.1: Situation géographique du bassin de la Tafna



- |                 |                                 |                           |                    |                    |
|-----------------|---------------------------------|---------------------------|--------------------|--------------------|
| 1- Cheliff      | 2- Côtiers algérois             | 3- Côtiers Constantinois  | 4- Côtiers Oranais | 5- Chott El- Hodna |
| 6- Chott Mclhir | 7- Hauts plateaux Constantinois | 8- Hauts plateaux oranais | 9- Isser           | 10- Kebir Rhumel   |
| 11- Macta       | 12- Medjerdah                   | 13- Sahara                | 14- Seybouse       | 15- Soummam        |
| 16- Tafna       | 17- Zahrez                      |                           |                    |                    |

Figure 3.2: Codes et noms des bassins versants de l'Algérie (Hamlet, 2005)

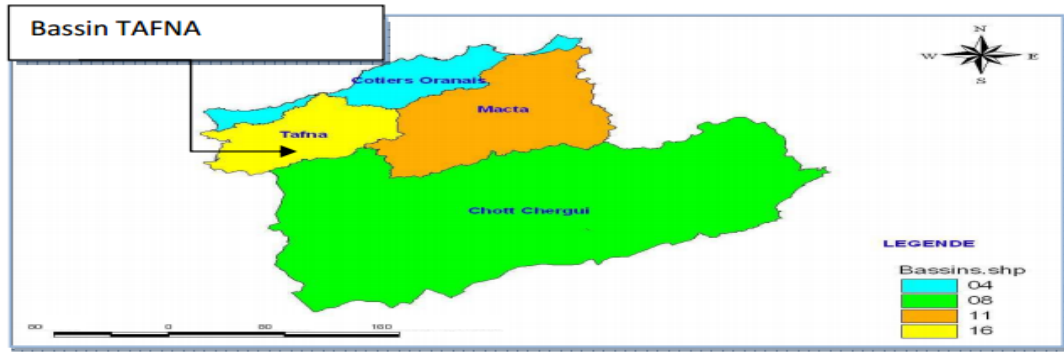


Figure 3.3: Situation géographique du bassin de la Tafna dans l'ensemble Oranie Chott Chergui

Il est délimité par les hautes plaines steppiques au Sud, entre la Méditerranée et les hautes plaines oranaises et relayé à l'Ouest par le moyen atlas marocain et à l'Est par les monts de Daïa (Figure 3.4).

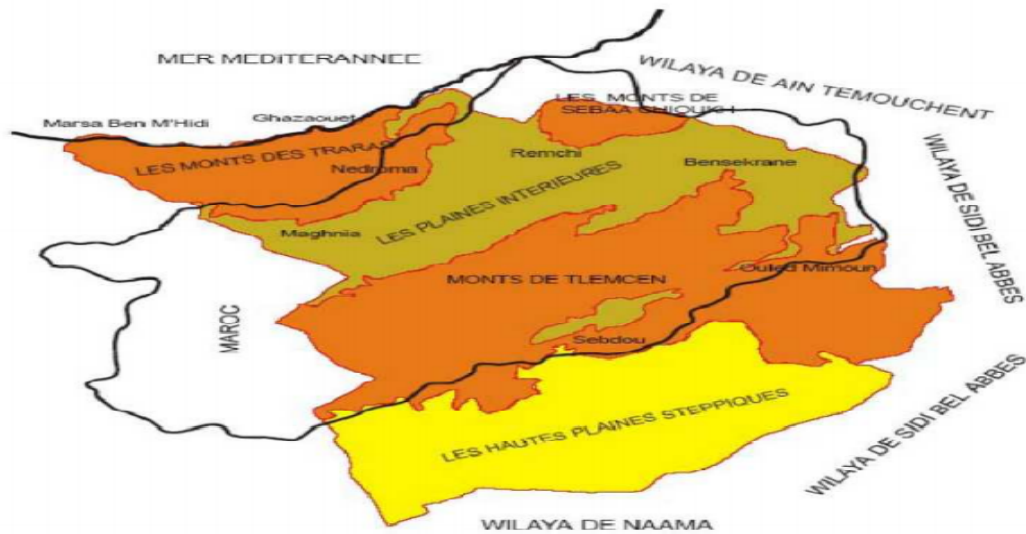


Figure 3.4: Contexte géographique du bassin de la Tafna (Hamlet, 2005)

Le bassin comporte au sud un relief assez abrupt avec des pentes supérieures à 25% incluant les monts de Tlemcen formant une chaîne montagneuse axes WSW-ENE dominant largement au nord les vallées de Maghnia, de Hennaya et de Sidi Abdelli. Cette configuration structurelle du relief engendre une transition climatique assez prononcée et perceptible de la région nord constituée des massif montagneux des monts de Traras et de Béni-Snassen.

### 3.1.2 Situation hydrographique

L'agencement des éléments du réseau dépend de la structure, de la géologie et du relief. Par conséquent, la formation du réseau hydrographique est fortement conditionnée par les facteurs caractéristiques des terrains traversés par les différents oueds. Ces facteurs sont tributaires de l'évolution des phénomènes structuraux qui ont affecté la région au cours des temps géologiques. Sans oublier l'activité humaine qui peut également modifier l'hydrographie d'une région suivant le degré d'implantation des aménagements comme le drainage des terres agricoles, la construction de barrages, l'endiguement, la protection des berges et la correction des cours d'eau. Le bassin de la Tafna ayant vu succéder un grand nombre d'aménagements hydrauliques au cours de ce dernier siècle ce qui rend non négligeable l'impact du facteur humain sur son hydrographie.

On note également que, la lithologie intervient sur le degré de ramification des oueds. C'est le cas de l'Oued Tafna qui traverse les calcaires des Monts de Tlemcen et suit la direction Sud-ouest, Nord-est du relief dominant représenté par la chaîne montagneuse des Traras et les Monts de Tlemcen (Bouanani, 2005).

Le Bassin de la Tafna présente un chevelu hydrographique atrophié caractéristique des zones semi-arides. Il est constitué d'une multitude d'oueds dont les débits en période d'étiage sont nuls.

Dans le cas de la Tafna, l'Oued Tafna représente le cours d'eau naturel le plus important à l'échelle du bassin. Environ 65% de la charge hydraulique, est drainé par cet Oued jusqu'à l'embouchure à Rachgoune. Ce cours d'eau permanent d'une longueur de 117 km prend naissance dans la grotte de Ghar-Boumazaa dans les monts de Tlemcen et peut être divisé en trois parties (Yebdri, 2007).

Dans sa partie haute, il se caractérise par des pentes assez marquées et des altitudes assez élevées favorisant l'écoulement superficiel et l'érosion hydrique. L'oued prend naissance à partir d'Oued Ouriach suite à la jonction de plusieurs ramifications et descend jusqu'au Oued Sebdou à une altitude d'environ 900 m. A partir de cette jonction le cours d'eau s'achemine à travers une vallée encaissée creusée dans les terrains jurassiques où il reçoit sur sa gauche l'Oued Khémis à Béni-Bahdel.

Dans sa partie moyenne, le cours d'eau est alimenté par de nombreux affluents de part et d'autres de sa rive, s'écoulant dans des terrains plus ou moins argileux. Il reçoit de sa rive gauche l'Oued Mouilah et Oued Ouardefou prenant naissance au Maroc et Oued Boukiou, moins important, et qui prend naissance dans les monts des Traras.

Il reçoit de sa droite un affluent très important l'Oued Isser, originaire des monts de Tlemcen. Ce dernier cours d'eau, est alimenté à son tour par l'oued Ouled Mimoun, Oued Lakhdar (ex Chouly) et Oued Ain Tellout. Dans sa partie orientale, l'Oued Isser recevra les oueds Boumessaoud et Zitoune ainsi que Oued Sikkak assez important et issue du plateau de Terny.

Sur la basse Tafna, l'oued s'écoule depuis les gorges de Tahouaret jusqu'à son exutoire situé à Rachgoune .

## 3.2 Caractéristiques morphométriques

Dans un bassin versant, les écoulements des eaux superficielles sont conditionnés par les paramètres morphométriques dont plusieurs indices caractérisent notre bassin versant :

- Caractéristiques de forme.
- Caractéristiques topographiques.

### 3.2.1 Caractéristiques de forme

La forme c'est la configuration géométrique du bassin dont plusieurs indices sont introduits servant à comparer un bassin avec d'autres bassins versants et son influence sur l'écoulement (Bouzera N. et al., 1997).

#### 3.2.1.1 Indice de compacité de Gravelius ( $K_c$ )

Il caractérise la forme de bassin versant, il peut rendre compte de la vitesse de la concentration des débits, de la puissance des crues et de l'érosion (Ould Etghana.W., 1998).

Cet indice est définie comme étant le rapport du périmètre du bassin versant avec sa surface (Bouzera N. et al., 1997).

avec :

$$K_c = \frac{P}{\sqrt{\pi * S}} = 0.28 * \frac{P}{\sqrt{S}} \quad (3.1)$$

D'ou :

kc: Indice de compacité de Gravelius (sans unité) ;

P : Périmètre du bassin-versant en (km) ;

S : Surface du bassin- versant en ( $km^2$ ).

Alors :

$$K_c = 1,35 \quad (3.2)$$

La valeur de kc montre que notre bassin est d'une forme allongée, donc une concentration des eaux superficielles très lente.

#### 3.2.1.2 Le rectangle équivalent

C'est une transformation purement géométrique en un rectangle équivalent (Benina T., 2004), ce paramètre sert à donner la forme d'un bassin, du point de vue longueur et largeur qui détermine le temps de ruissellement pour arriver à l'exutoire. Car un ruissellement dans un bassin versant ramassé est plus rapide pour arriver à l'exutoire qu'un bassin allongé.

Ce rectangle équivalent est caractérisé par la même surface et le même périmètre du bassin, ses dimensions sont (Bouzera N. et al., 1997).

La longueur :

$$L_R = \frac{K_c * \sqrt{S}}{1.128} [1 + \sqrt{1 - (\frac{1.128}{K_c})^2}] \quad (3.3)$$

Donc :

$$L_R = 157,83Km \quad (3.4)$$

La largeur :

$$l_R = \frac{K_c * \sqrt{S}}{1.128} [1 - \sqrt{1 - (\frac{1.128}{K_c})^2}] \quad (3.5)$$

Donc :

$$l_R = 45,90Km \quad (3.6)$$

Les dimensions du rectangle équivalent confirment la valeur de  $K_c$  ce qui montre que le temps de ruissellement est plus lent.

### 3.2.2 Caractéristiques topographiques

Le relief nous permet de constater l'aptitude des terrains au ruissellement, il est représenté par plusieurs paramètres.

#### 3.2.2.1 La courbe hypsométrique

C'est la répartition des surfaces en fonctions des altitudes et permet de préciser l'influence de l'altitude sur le volume d'eau précipité (Bouzera N. et al., 1997). Le planimétrage par tranche d'altitude nous a donné les résultats suivants

Tableau 3.1: Répartition des surfaces partielles en fonction des altitudes (Sources ANRH)

Altitudes (m)	Surfaces partielles $s_i$ ( $Km^2$ )	Surfaces partielles $\frac{s_i}{s_t}$ (%)	Surfaces cumulées $\Sigma s_i$ ( $Km^2$ )	Surfaces cumulées $\Sigma \frac{s_i}{s_t}$ (%)
1821-1600	130	1,79	130	1.79
1600-1400	259	3.58	389	5.37
1400-1200	324	4.47	713	9,84
1200-1000	1390	19.18	2103	29,02
1000-800	869	12	2972	41.02
800-600	955	13.18	3927	54,20
600-400	1824	25,18	5751	79.4
400-200	1146	15.81	6897	95,2
200-0	348	4.80	7245	100
$\Sigma$	7245	100		

Ce tableau ci-dessus, nous permet de tracer la courbe hypsométrique annexe C



### Les Altitudes :

A partir de la courbe hypsométrique, on peut déterminer les altitudes suivantes :

- **Altitude maximale**

C'est le point culminant du bassin versant.

$$H_{\max} = 1821m \quad (3.7)$$

- **Altitude minimale**

Elle représente le point le plus bas au niveau de l'exutoire.

$$H_{\min} = 0m \quad (3.8)$$

- **Altitude moyenne**

C'est le rapport de la somme des surfaces partielles par l'altitude moyenne correspondante sur la surface totale du bassin versant (Benina T., 2004).

$$H_{\text{moy}} = \frac{\sum(s_i \cdot e_i)}{S} \quad (3.9)$$

Avec :

S : Surface du bassin versant ( $Km^2$ ) ;

$s_i$  : Surfaces partielles entre deux courbes de niveau ;

$e_i$  : Altitude moyenne entre deux courbes de niveau voisines.

Donc :

$$H_{\text{moy}} = 731.85m \quad (3.10)$$

- **Altitude médiane**

Correspond à 50% de la surface du bassin versant.

$$H_{\text{med}} = 760m \quad (3.11)$$

### Les pentes :

La pente joue un rôle capital dans le ruissellement et la détermination de l'aptitude du relief à l'érosion, celle-ci peut être estimée par plusieurs indices.

• **Indice de pente de Roche ( $I_p$ )**

Démontre l'influence du facteur pente sur le régime hydrologique du bassin versant (Bouzera N. et al., 1997).

Il est déterminé à partir de la relation suivante :

$$I_p = \frac{1}{\sqrt{L_R}} \cdot \Sigma(\sqrt{B_i \cdot (e_i - e_{i-1})}) \quad (3.12)$$

Avec :

$L_R$  : Longueur de rectangle équivalent ;

$B_i$  : Fraction de surface totale du bassin comprise entre les côtés ( $e_i, e_{i-1}$ ).

Donc :

$$I_p = 0.10 \quad (3.13)$$

• **Indice de pente globale ( $I_g$ )**

Il se détermine à partir de la courbe hypsométrique, c'est le rapport de la différence des altitudes de fréquence 5 % et 95 % par la longueur de rectangle équivalent (Ould Etghana W., 1998).

$$I_g = \frac{D}{L_R} \quad (3.14)$$

Avec :

$L_R$  : Longueur de rectangle équivalent ;

$D$  : La différence entre l'altitude qui correspond à 5 % et celle de 95 % de surface.

Avec :

$$D = H_{5\%} - H_{95\%} \quad (3.15)$$

D'où:

$$D = 1220m \quad (3.16)$$

Alors :

$$I_g = 7.72 \quad (3.17)$$

• **La dénivelée spécifique ( $D_s$ )**

C'est un paramètre de comparaison entre le relief des différents bassins versants (Bouzera N. et al., 1997).

$$D_s = I_g \cdot \sqrt{\sqrt{S}} \quad (3.18)$$

Donc :

$$D_s = 657 \quad (3.19)$$

Ce qui nous permet de classer notre bassin versant d'après la classification de l'ORSTOM :

Tableau 3.2: Classification du bassin versant d'après l'ORSTOM

R1	Relief très faible	<	Dénivelle spécifique (Ds)	10 m
R2	Relief faible	10 m	Ds	25 m
R3	Relief assez faible	25 m	Ds	50 m
R4	Relief modère	50 m	Ds	100 m
R5	Relief assez fort	100 m	Ds	250 m
R6	Relief fort	250 m	Ds	500 m
R7	Relief très fort	500 m	Ds	>

D'après cette classification, notre bassin versant se situe dans la classe  $D_s > 500m$ , ce qui montre qu'il a un relief très fort.

### 3.2.3 Le réseau hydrographique

Le réseau hydrographique est un aperçu sur le mode de drainage du bassin versant et son aptitude au ruissellement.

On procéda à la classification des talwegs pour calculer les paramètres hydrographiques.

La méthode adoptée est celle de " SHUM " dont on suit le principe :

(X+1 est un cours d'eau recevant deux cours d'eau au plus d'ordre x) Ce principe sert à la numérisation des talwegs (Benina T., 2004).

#### 3.2.3.1 Densité du drainage ( $D_b$ )

Elle est définie comme étant le rapport de la longueur totale des cours d'eau à la surface du bassin versant et donne l'importance du chevelu hydrographique (Bouzera N. et al., 1997).

$$D_d = \frac{\sum L_x}{S} \quad (3.20)$$

Avec :

$\sum L_x$ : Longueur totale cumulée des cours d'eau d'ordre x (km) ;

S : Surface de bassin versant ( $km^2$ ).

Donc :

$$D_d = 2,6km/km^2(\text{source ANRH}) \quad (3.21)$$

#### 3.2.3.2 Coefficient de torrentialité

Ce coefficient est le paramètre le plus représentatif de la sensibilité d'un bassin à l'érosion (Bouzera N. et al., 1997).

$$C_t = D_d \cdot F \quad (3.22)$$

$$F = \frac{N_i}{S} \quad (3.23)$$

Avec :

$C_t$  : Coefficient de torrentialité ;

$D_d$  : Densité de drainage ;

$F$  : Densité des talwegs élémentaires ;

$S$  : Surface du bassin versant ;

$N_i$  : Longueur des talwegs élémentaires.

Donc :

$$C_t = 26km/km^2(\text{source ANRH}) \quad (3.24)$$

Le tableau ci-dessous récapitule toutes les caractéristiques morphométriques du bassin versant TAFNA

Tableau 3.3: Caractéristiques morphométriques du bassin versant

N	Caractéristiques	Symboles	Unités	Valeur
1	Superficie	S	$km^2$	7245
2	Périmètre	P	$km$	410
3	Indice de compacité	$K_c$	-	1.35
4	Rectangle équivalent (L / l)	L	$km$	157,83
		l	$km$	45.90
5	Les altitudes	Hmax	$m$	1821
		Hmoy		731.85
		Hmed		760
		Hmin		0
6	Indice de pente globale	$I_g$	-	7.72
7	Indice de pente de Roche	$I_p$	-	0,1
8	Densité de drainage	$D_d$	$km/km^2$	2.6
9	Coefficient de torrentialité	$C_t$	$km/km^2$	26

### 3.3 Caractéristiques climatiques

#### 3.3.1 Le climat

Le climat influe sur le comportement hydrographique des cours d'eau. Ce qui active le phénomène d'érosion et participe de près ou loin à la dissolution des formations lithologiques notamment en périodes sèches.

##### 3.3.1.1 Les précipitations

Le climat du bassin de la Tafna est de type semi-aride. Le système semblerait très influencé par l'irrégularité des précipitations et aussi par la forte évaporation pendant les périodes d'été. Les apports du bassin enregistrent leurs plus fortes quantités en printemps suivi d'un volume moins important en hiver (Bouanani 2004). En

période d'été (juin à septembre) les précipitations sont pratiquement nulles (Meddi et Hubert 2003). C'est la période la plus sévère en étiage. Les écoulements deviennent de moins en moins importants, puis disparaissent dans certains secteurs du bassin. Les précipitations du bassin de la Tafna sont inégalement réparties. Une carte d'isohyètes montre que les zones les plus arrosées sont celles en montagne avec 400–450 mm (Meddi et Hubert 2003). La partie en plaine du bassin est la partie la moins arrosée avec une moyenne inférieure à 300 mm. [5]

### 3.3.1.2 La température

Les températures contribuent à la diminution du niveau d'eau par le phénomène d'évaporation, donc augmentation de la concentration saline.

La température moyenne mensuelle est de  $16,35^{\circ}C$ , le minimum apparaît en Janvier avec  $9^{\circ}C$  pour un maximum de  $26^{\circ}C$  en Août, cette température descend rarement en dessous de zéro sauf dans le cas des hauts reliefs.

Tableau 3.4: Les températures mensuelles

Mois	J	F	M	A	M	J	J	A	S	O	N	D	Année
T( $^{\circ}C$ )	9	9.5	11.6	14.2	16.5	21.3	24.7	26	22.3	17.9	13	10	16.3

La durée de la saison sèche est de 4 mois, elle est caractérisée par une température de  $20^{\circ}C$  et plus.

Le bassin est tempéré en saison d'hiver et d'automne et très chaud en été, d'où l'importance de l'évapotranspiration surtout à l'intérieur de la région où l'amplitude thermique croît en raison de la continentalité du climat du bassin versant (Bouanani A., 2000).

Les résultats d'analyse climatiques affirment que le bassin versant de la TAFNA est soumis à un climat méditerranéen caractérisé par une période froide et pluvieuse en hiver et une autre chaude et relativement sèche en été.

## 3.4 Caractéristiques de L'écoulement superficiel

### 3.4.1 Variabilité mensuelle de l'écoulement

La répartition des débits mensuels du bassin versant à la station de pierre du chat (160801) à l'exutoire est obtenue par la moyenne arithmétique des débits liquides ( $QLm^3/s$ )

Les résultats sont résumés dans le tableau suivant :

Tableau 3.5: Variation mensuelle du débit (1977-1991)

Mois	Sept	Oct	Nov	Dec	Jan	Fev	Mars	Avr	Mai	Juin	Juill	Aou
Ql( $m^3/s$ )	0.63	2.93	2.52	2.53	3.16	6.34	9.15	2.46	1.56	1.55	0.37	0.2

### 3.5 Caractéristiques géologiques

La représentation des caractéristiques géologiques joue un rôle double, son influence se fait sentir sur le régime d'écoulement d'une part et d'autre part sur l'érosion et le transport solide (Benina T., 2004).

Le bassin de la TAFNA présente (03) formations géologiques bien distinctes :

- La région Nord, formée par les montagnes des Traras et de Beni Snassène, est constituée de formation du jurassique moyen et inférieur.
- La région sud, formée par le massif calcaire des monts de Tlemcen, est constituée par la plupart des dépôts carbonatés du jurassique supérieur sont recouverts par des marnes du miocène.
- La dépression inter-montagneuse formé par les plaines de Oujda et Maghnia, est occupée par des dépôts marins du miocène supérieur et inférieur surmonté par des alluvions, des sables, des graviers et galets du pléistocène et des formations argileuses sous-jacentes.

Des failles extrêmement nombreuses sont présentés au niveau du bassin de Mefrouche, traversant la cuvette d'Est en Ouest cette dernière se présente comme un grand synclinal allongé du Sud-Ouest au Nord-Est où elle se reforme en bordure de la grande faille qui fait apparaître les dolomies du jurassique inférieur (Houari K., 1999).

### 3.6 La végétation

La végétation est un facteur déterminant de la rapidité du ruissellement superficiel, du taux d'évaporation et de la capacité de rétention du bassin ; donc la présence de végétation va jouer le rôle régulateur dans le régime d'écoulement.

Le paysage végétal du bassin de la TAFNA a été largement dégradé et défriché en montagne par les incendies et par une petite agriculture extensive et un surpâturage endémique, ce qui à entraîné une perte d'eau par évaporation et une accélération de l'érosion.

Notre zone d'étude est caractérisée par un couvert végétal très pauvre au Nord vue l'irrégularité pluviométrique.

Les sommets des monts de Tlemcen sont occupés par un couvert forestier dégradé ; sont rassemblés sous ce thème les maquis et les forêts claires, les zones en cours de reboisement, les forêts et les maquis dégradés par l'utilisation excessive du sous sol forestier, le pâturage sauvage et irrationnel compromettant la rénovation, le déboisement intégral pour installer d'autres cultures et les effets des incendies. Les chaînes des montagnes de Traras sont essentiellement occupés par les arboricultures ; représentés principalement par les vignobles et l'olivier (Bouanani A., 2000).

L'intérieur du bassin ne présente pratiquement pas de végétations naturelles ; les plaines sont réservées à l'agriculture (Houari K., 1999).

La végétation est très pauvre dans le bassin versant de la TAFNA ce qui favorise l'érosion hydrique.

# Chapitre 4

## Modélisation de la salinité de l'oued Tafna

### Partie I

#### 4.1 Analyse et critique des données

Nous avons eu de la part de l'ANRH des données concernant le débit et la concentration saline pour la station hydrométrique pierre du chat 160801, un jeu de données de 543 couples ( $Q_l$ ,  $C_s$ ) allant de 1977 à 1991, les années 1980 et 1981 sont manquantes.

Evolutions du débit liquide et de la salinité dans le temps

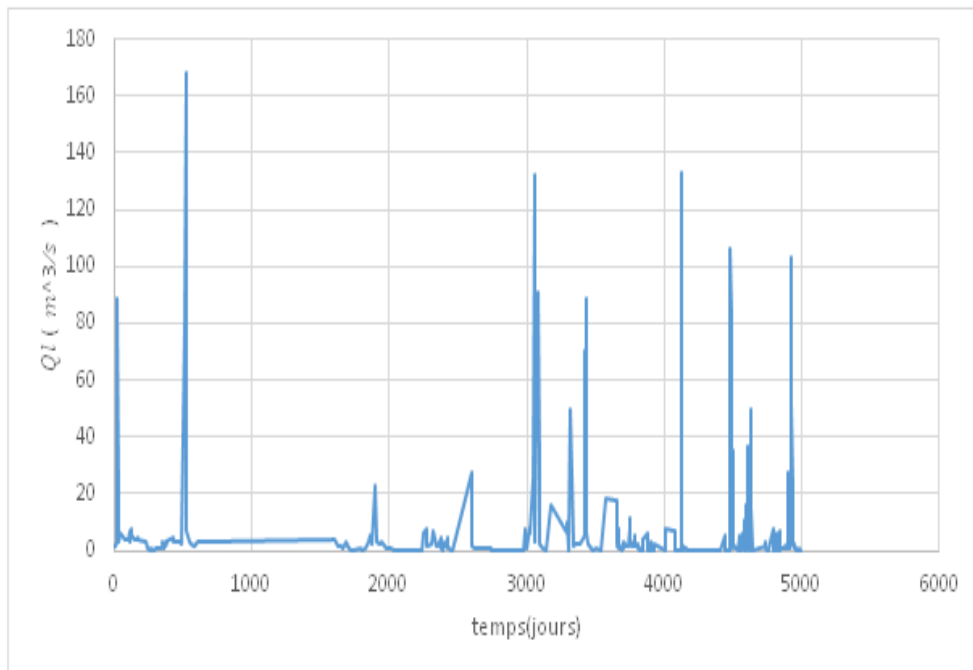


Figure 4.1: Evolution du débit liquide dans le temps

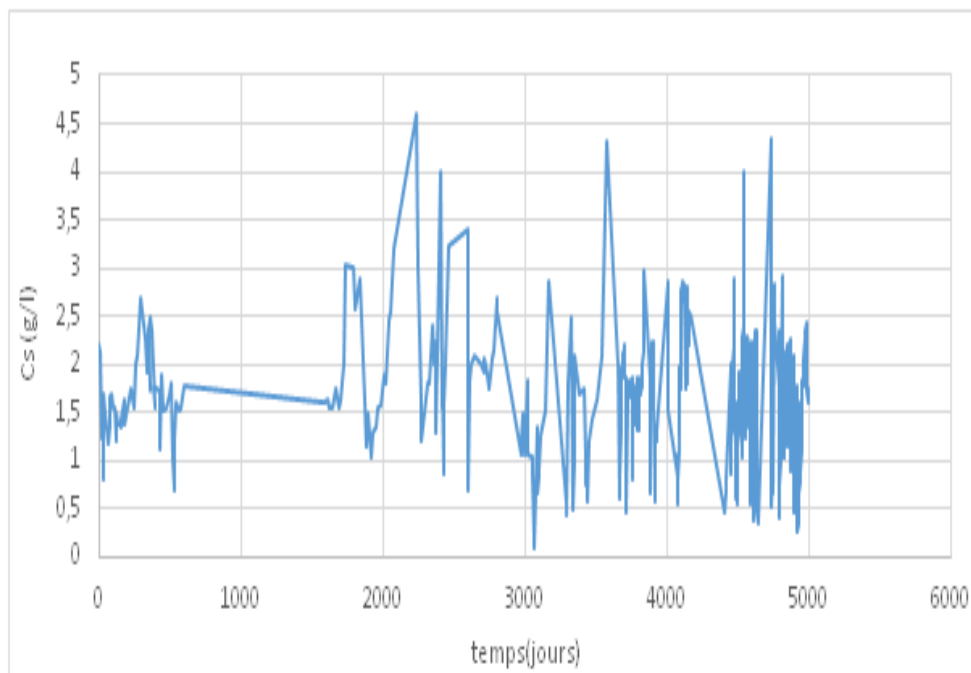


Figure 4.2: Evolution de la concentration saline dans le temps

Nous remarquons que le débit est faible dans la majeure partie du graphe, et il y a des jours où la salinité est élevée et le débit l'est aussi, ces valeurs sont à écarter.

Le total des solides dissous dans une eau potable ne devrait pas dépasser les 1g/l (selon l'OMS lennetech.fr).

Dans notre cas, la concentration saline dépasse les 1 g/l pour la majeure partie des données que nous avons, elle dépasse pour quelques observations les 4 g/l, ces dernières sont classées comme douteuses.

## 4.2 Traitement statistique des données

Lors de la phase de mesure ou de récupération de données, des erreurs peuvent être commises.

Ces erreurs (valeurs) sont appelées valeurs aberrantes. Pour ne pas perturber l'adéquation de notre modèle, il faut les éliminer.

Pour cela, plusieurs tests statistiques existent dans l'hydrologie, parmi eux le test de Grubbs et Beek.

### 4.2.1 Détection de valeurs singulières Test de Grubbs et Beck

Connue pour sa puissance ce test est utilisé pour la détection des valeurs aberrantes et est recommandé par le United States Water Resources Council (1981). A partir des données mesurées la statistique de Grubbs est calculée pour chaque valeur extrême (min, max).

$$X_{\min} = e^{(\bar{x} - K_n * s)} \quad (4.1)$$



$$X_{\max} = e^{(\bar{x} + K_n * s)} \quad (4.2)$$

Où :

$\bar{x}$  et  $s$  sont respectivement la moyenne et l'écart type des logarithmes naturels des éléments constituant l'échantillon.

$K_n$  représente une valeur statistique de Grubbs et Beck, tabulée pour différentes tailles d'échantillons et de niveaux de signification.

Au niveau de risque de 10 %, l'approximation polynomiale suivante a été proposée par Pilon et Harvey (1992) :

$$K_n = -3.62201 + 6.28446 * n^{\frac{1}{4}} - 2.49835 * n^{\frac{1}{2}} + 0.491436 * n^{\frac{3}{4}} - 0.037911 * n \quad (4.3)$$

Où  $n$  représente la taille de l'échantillon.

Ainsi, toutes les valeurs supérieures à  $X_{\max}$  et inférieures à  $X_{\min}$  seront considérées comme des valeurs aberrantes.

Pour  $5 \leq n \leq 150$ ,  $K_n$  peut être calculé à partir de l'équation suivante (Stedinger et al., 1993) :

$$K_n = -0.9043 + 3.345 * \sqrt{\log(n)} - 0.4046 * \log(n) \quad (4.4)$$

Les résultats du test sont les suivants :

Tableau 4.1: Add caption

Parmètres	n	kn	xbarre	s	Xmin	Xmax
Ql(m3/s)	543	3,19138397	0,04601724	1,89503342	0,00225682	404,140276
Cs(g/l)	543	3,19138397	0,40790724	0,48476207	0,32008949	7,06370097

Pour le débit il n'y a aucune valeur singulière, par contre, pour la salinité, les valeurs inférieures à 0,32 sont considérées comme singulières par le test, mais nous n'allons pas écarter ces dernières.

Après avoir filtré les données, nous les avons découpées en mois et saisons, nous avons eu 7 mois, qui sont : novembre, décembre, janvier, février, mars, avril, mai ; et trois saisons : (janvier - février - mars) , (novembre - décembre), (avril - mai), et la saison humide où tout le jeu de données est mis en œuvre. Nous avons décidé de supprimer les données de la saison sèche, vu que la variation du débit est infime.

Dans ce qui suit, nous allons procéder à l'application des modèles cités précédemment, à savoir : la régression linéaire, l'ajustement par réseaux de neurones et les systèmes neuro-flous

## Partie II

### 4.3 Application des modèles

Dans ce qui suit, nous allons procéder à l'application des modèles cités précédemment, à savoir : la régression linéaire, l'ajustement par réseau de neurones et par les systèmes neuro-flous.

Nous avons découpé les données en mois et saisons, nous avons eu 7 mois, qui sont : novembre, décembre, janvier, février, mars, avril, mai ; et trois saisons : (novembre - décembre), (janvier - février - mars), (avril - mai), et la saison humide où tout le jeu de données est mis en œuvre. Nous avons décidé de supprimer les données de la saison sèche, vu que la variation du débit est infime.

Ensuite, nous avons débuté la modélisation.

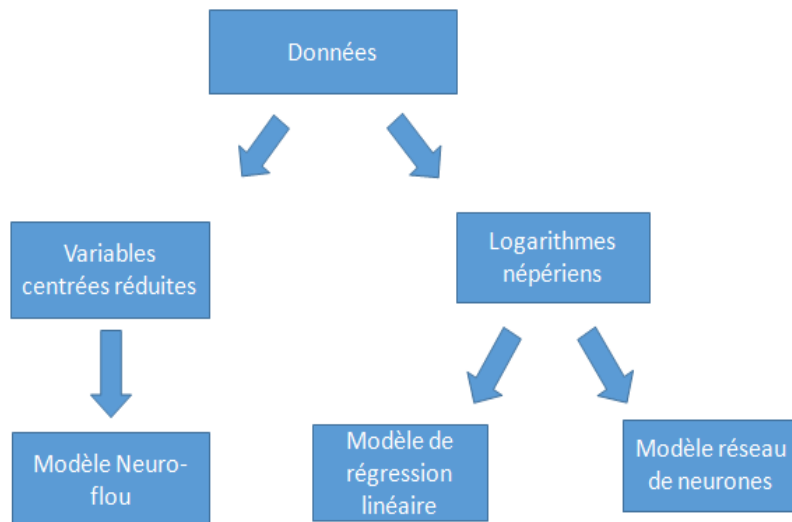


Figure 4.3: Organigramme résumant le travail effectué

#### 4.3.1 Le modèle de régression

Pour réduire la sensibilité aux extrêmes nous avons calculé les logarithmes népériens des données, nous avons ainsi obtenu une distribution homogène des points.

Pour cette méthode, nous avons utilisé l'outil d'ajustement de courbes « The Curve Fitting Tool » disponible dans le logiciel « Matlab » (Figure 7.2).

Cette interface nous donne directement l'équation de la droite de régression, on génère le code du modèle, et on l'adapte pour avoir les critères de qualité des modèles et les graphiques de comparaisons des résultats simulés avec les valeurs observées.

Pour reconstituer les valeurs de salinité simulées, nous allons calculer l'exponentielle des valeurs simulées avec le logarithme népérien.

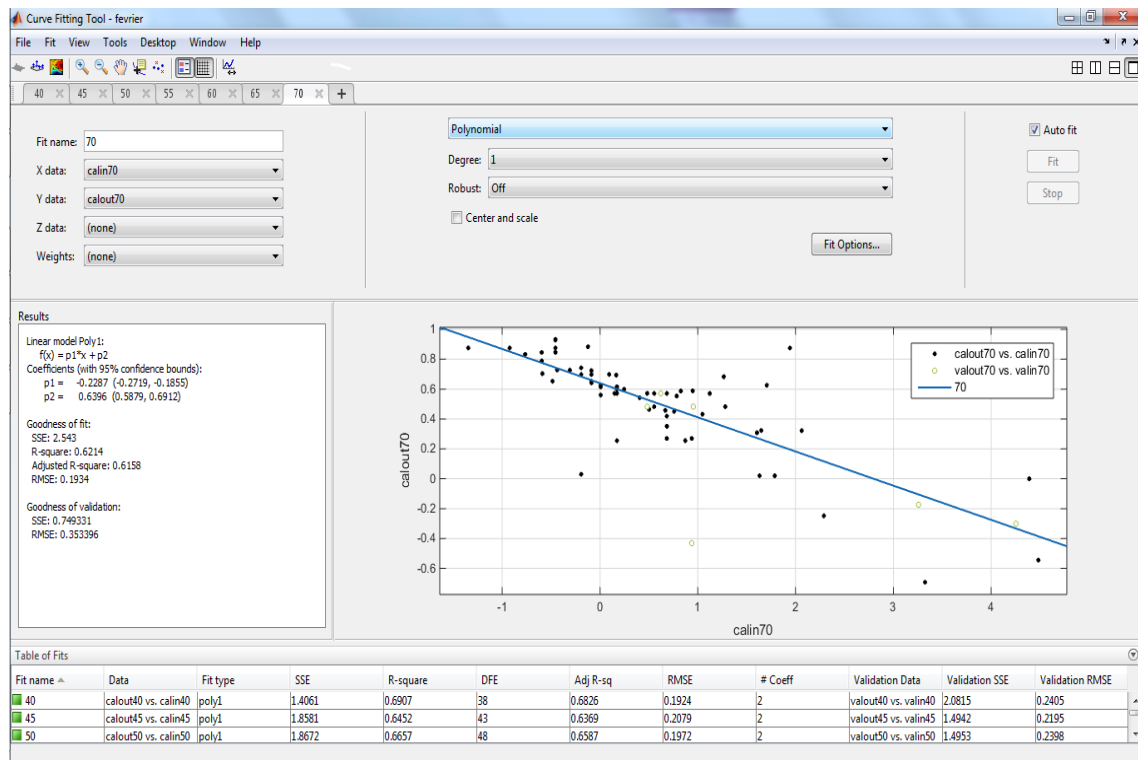


Figure 4.4: Interface de l'application Curve Fitting Tool

### 4.3.2 Les réseaux de neurones

Nous avons utilisé les mêmes données pour le modèle de réseau de neurones, et nous avons utilisé l'outil d'ajustement par réseau de neurones « Neural Network Fitting Tool » disponible dans le logiciel « Matlab ».

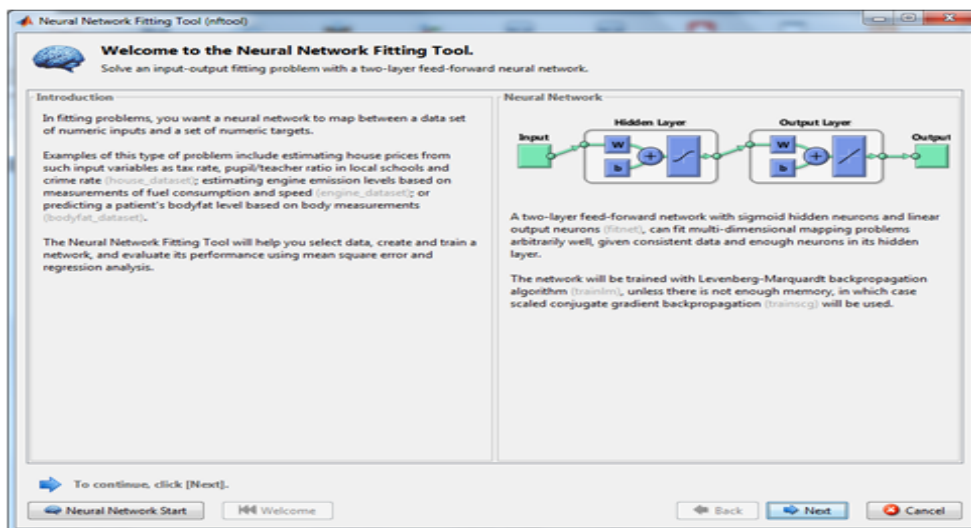


Figure 4.5: Interface d'entrée de l'application NNFT

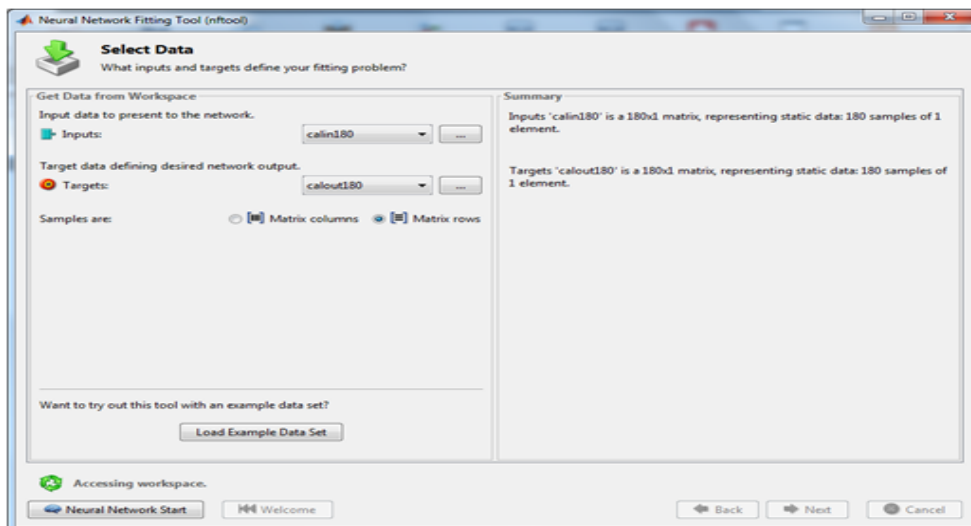


Figure 4.6: Interface de sélection des entrées et des sorties

La deuxième boîte de dialogue nous demande d'appeler les entrées et les sorties.




Figure 4.7: Interface de répartition des données

La troisième boîte de dialogue nous demande de répartir les données en calage, validation et test. Notons que l'application donne une répartition aléatoire des données.

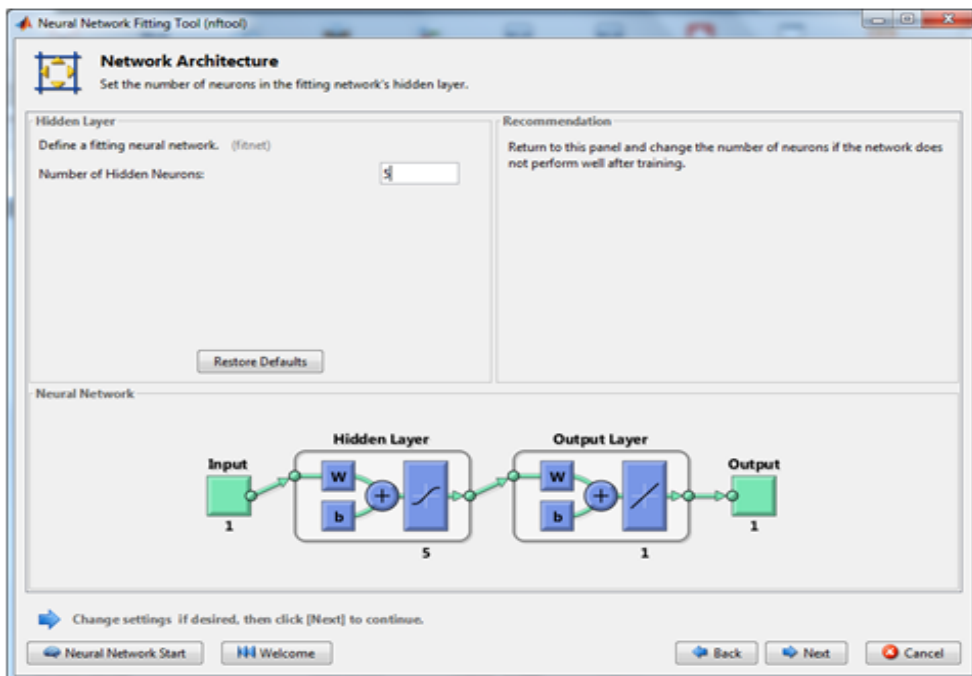


Figure 4.8: Architecture du réseau de neurones

Dans cette fenêtre, on demande de choisir le nombre de neurones cachés, donc

l'architecture de notre réseau.

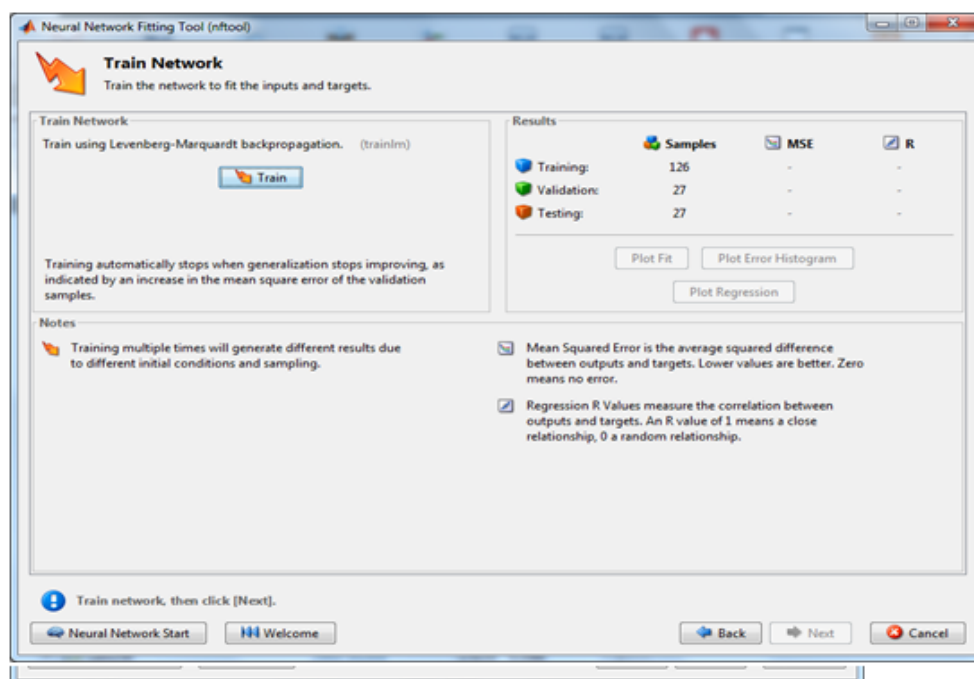


Figure 4.9: Lancement de l'apprentissage

Ensuite on lance la phase d'apprentissage du réseau.

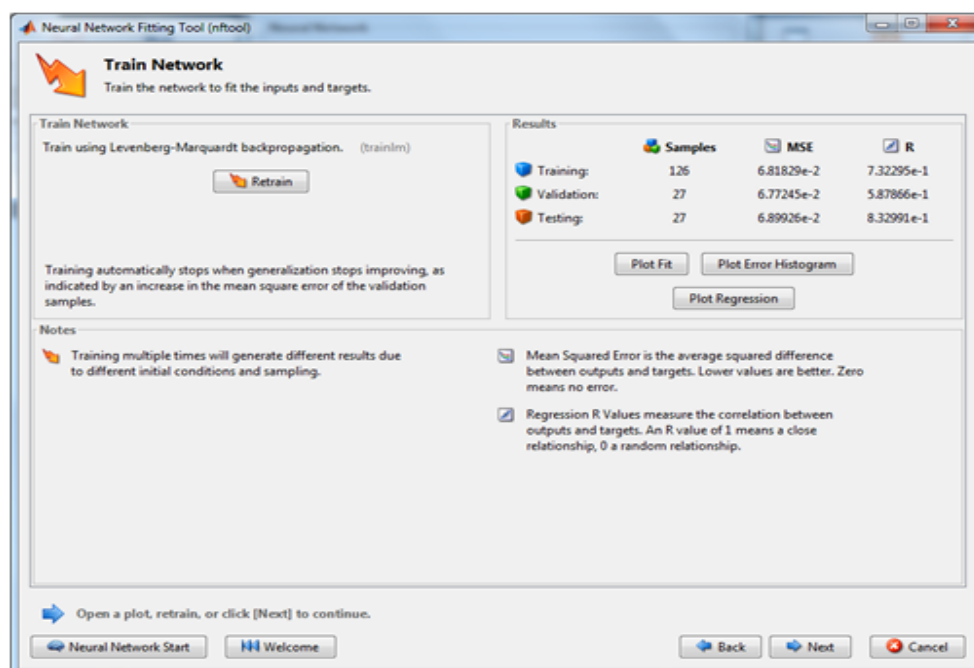


Figure 4.10: Performances du réseau de neurones

L'application donne les performances du modèle, et demande si on veut refaire

l'apprentissage du réseau.

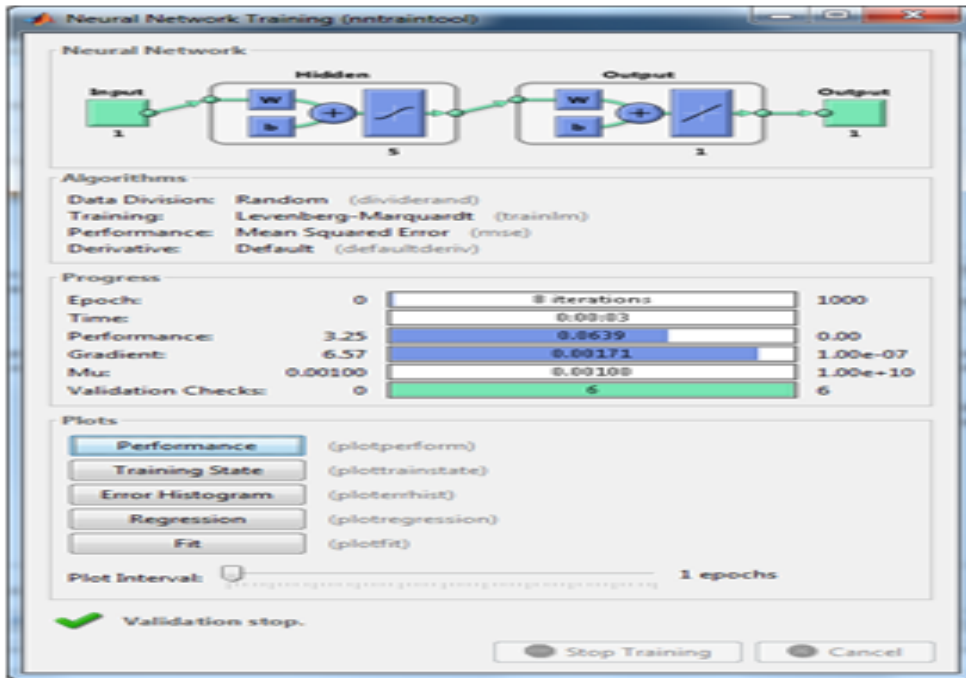


Figure 4.11: État d'avancement de l'apprentissage

Cette interface nous renseigne sur l'avancement du processus d'apprentissage et nous permet de visualiser les performances du modèle.

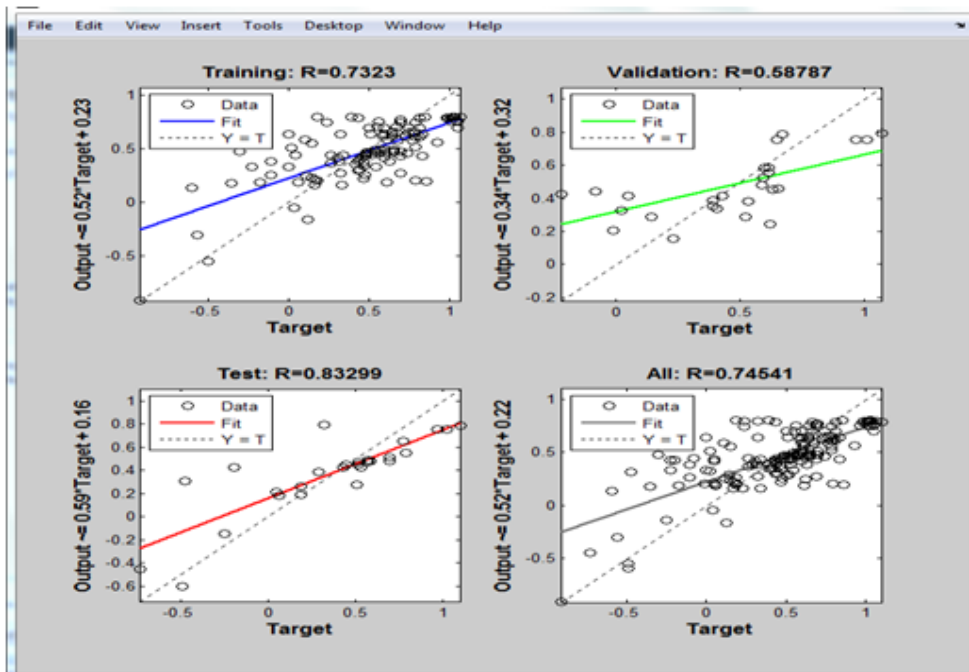


Figure 4.12: Coefficient de corrélation des phases de création du RN

Nous obtenons ensuite les valeurs du coefficient de corrélation pour chaque phase de création du modèle.

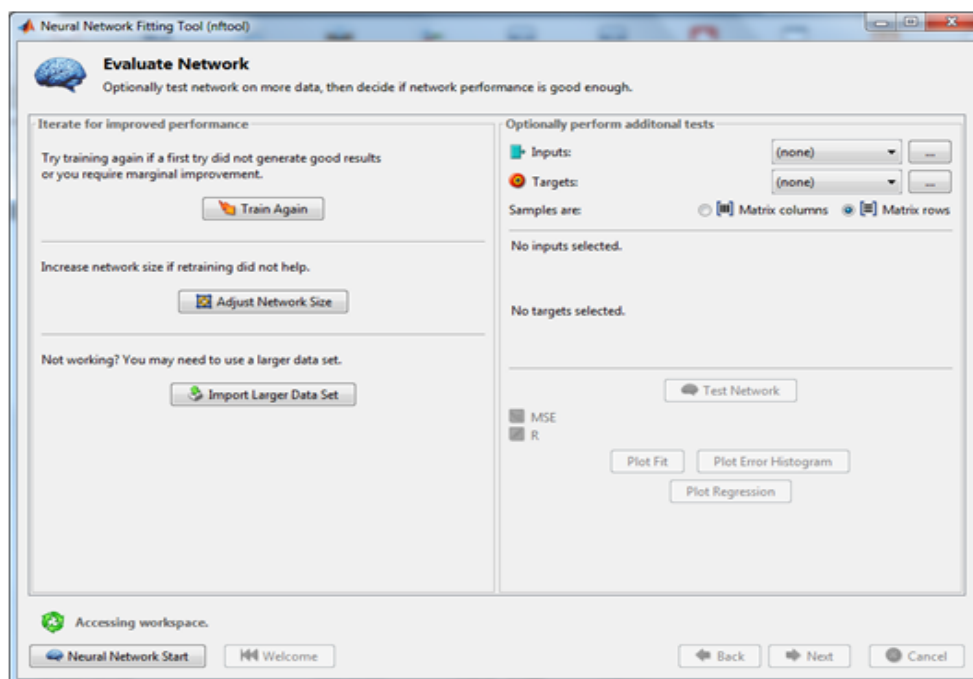


Figure 4.13: Évaluation du RN et extension du jeu de données

Cette interface nous offre la possibilité de refaire l'apprentissage du modèle, ou d'ajouter d'avantage de données.

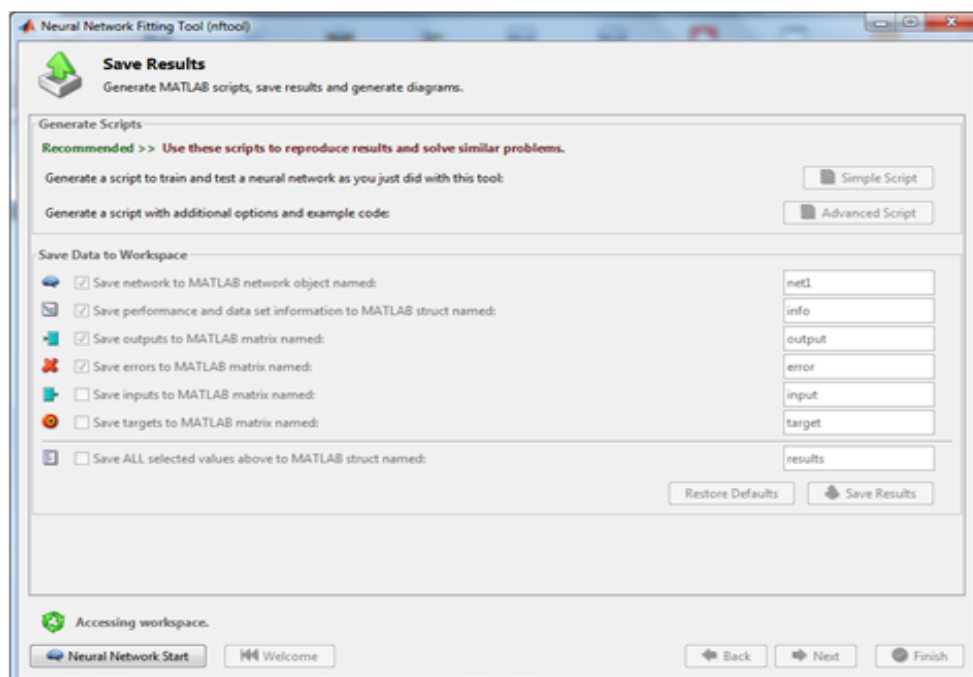


Figure 4.14: Génération du code Matlab du RN



Cette dernière interface nous permet de générer le code du modèle que nous allons adapter à notre cas, en changeant la fonction qui nous donne une répartition aléatoire des phases de création du modèle, et ne garder que la phase du calage et de la validation.

Pour tous les modèles RN présentés dans ce qui suit, nous avons utilisé 5 neurones cachés, car ça a donné de meilleurs résultats pour tous les jeux de données.

Pour reconstituer les valeurs de salinité simulées, nous avons calculé l'exponentielle des valeurs simulées avec le logarithme népérien.

### 4.3.3 Les systèmes Neuro-Flous

Pour ce modèle, nous avons préféré les valeurs centrées réduites aux logarithmes népériens, car nous avons eu de meilleurs résultats ainsi, pour reconstituer les valeurs de salinité, on multiplie les valeurs centrées réduites simulées par l'écart type de l'échantillon en question, et on ajoute la moyenne.

Pour générer un système d'inférence flou, c'est-à-dire notre modèle, nous avons fait usage de l'outil de génération de systèmes neuro-flou de Matlab « The Neuro-Fuzzy Design Toolbox ».

L'interface d'entrée de l'application nous permet d'appeler les jeux de données de calage et de validation enregistrées préalablement dans l'espace de travail de Matlab.

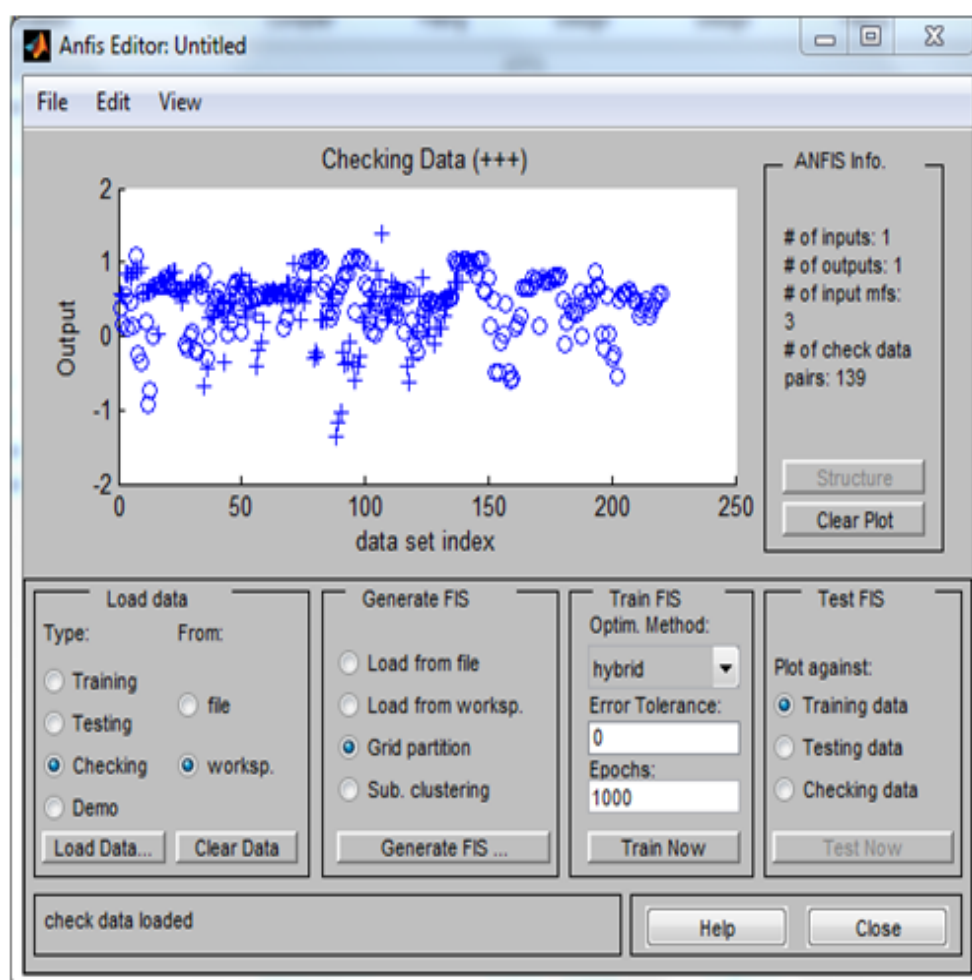


Figure 4.15: Interface de l'application ANFIS

On choisit aussi le nombre d'itérations pour que le système d'inférence floue généré arrive à un optimum.

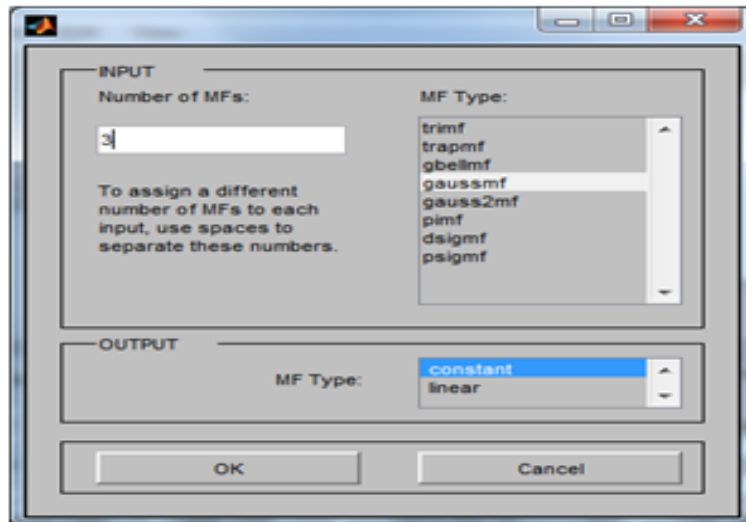


Figure 4.16: Choix de la fonction d'appartenance et du nombre de règles floues

Dans cette fenêtre, on choisit le nombre de règles floues et le type de fonction d'appartenance de l'entrée et de la sortie, nous avons choisi « gaussmf » pour les entrées, car c'est celle qui a donné les meilleurs résultats, et une fonction d'appartenance constante pour les sorties.

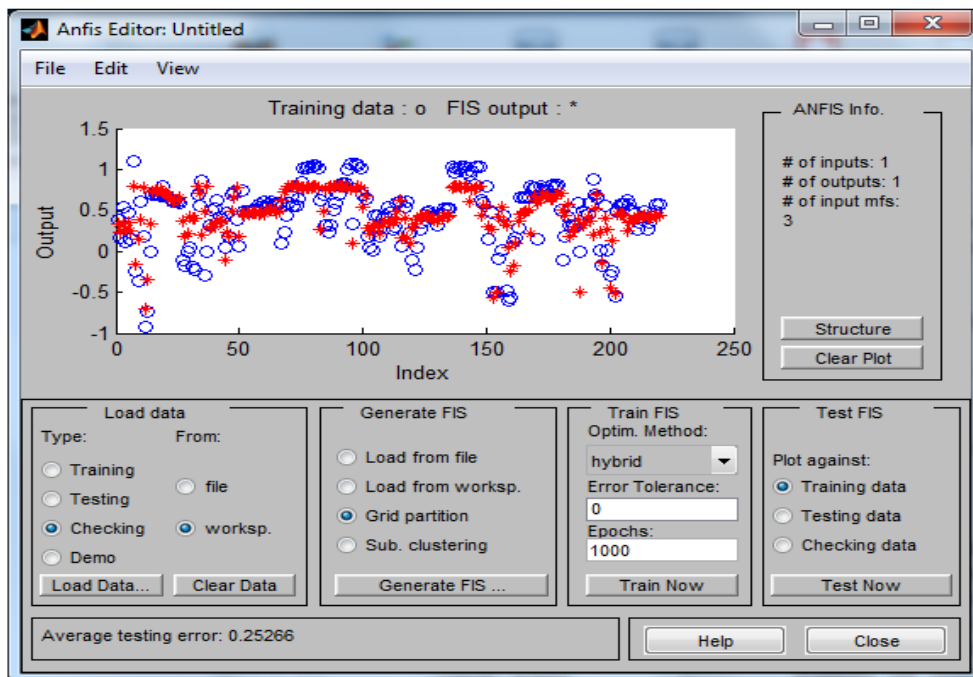


Figure 4.17: Comparaison observé-simulé

Cette interface nous permet de visualiser la capacité de notre modèle à reproduire le phénomène étudié, et nous renseigne aussi sur l'erreur qu'il y a entre l'observé et le simulé, on peut donc changer les paramètres du modèle qui sont le nombre de règles floues et les fonctions d'appartenance, jusqu'à avoir l'erreur la plus faible.

Après avoir réalisé l'apprentissage du modèle, on a procédé à son utilisation dans un programme Matlab qui a comme sorties les tableaux contenant les critères d'évaluation du modèle, et les graphes de comparaison des valeurs observées et simulées.

Dans ce qui suit, pour tous les modèles neuro-flous, nous avons utilisé 7 règles floues, la fonction d'appartenance de Gauss pour les entrées, et une fonction d'appartenance constante pour les sorties.

## 4.4 Approche mensuelle

### 4.4.1 Mois de mars

On a pour le mois de mars une série de 68 couples (Ql, Cs) .

#### 4.4.1.1 Modèle de régression

Tableau 4.2: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de mars

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,6895	0,6545	2,55	0,5878	0,3786
40	0,6854	0,646	2,2942	0,595	0,3592
45	0,6886	0,6498	2,1629	0,5918	0,3574
50	0,6789	0,6327	2,0034	0,606	0,3564
55	0,7069	0,6657	1,8257	0,5782	0,3454

Tableau 4.3: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de mars

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
33	0,7236	0,6905	3,8897	0,5564	0,2987
28	0,7385	0,7247	0,0184	0,5247	0,3052
23	0,7391	0,7235	-0,6085	0,5258	0,2985
18	0,7821	0,7219	-6,1057	0,5273	0,3119
13	0,6989	0,5392	-10,021	0,6788	0,3424

Le modèle donne des résultats satisfaisants en calage, nous avons des  $R^2$  et des  $Nash > 0,5$ , et des  $RSR < 0,70$ , des  $RMSE < 0,5$  .

Les critères sont encore plus forts en validation, on choisira la répartition 40 valeurs de calage et 28 valeurs de validation :




Figure 4.18: Comparaison observé-simulé phase de calage, modèle de régression, mois de mars




Figure 4.19: Comparaison observé-simulé phase de la validation, modèle de régression, mois de mars

La comparaison de l'observé et du simulé en calage montre que le modèle arrive plus ou moins à reproduire l'allure mais fluctue beaucoup, alors qu'en validation, le modèle reproduit mieux l'allure et les pics. Le modèle de régression linéaire est satisfaisant.

4.4.1.2 Modèle Réseau de neurones

Tableau 4.4: Résultats des critères numériques de la phase du calage, modèle RN, mois de mars

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,6895	0,6545	2,55	0,5878	0,3786
40	0,6854	0,646	2,2942	0,595	0,3592
45	0,6886	0,6498	2,1629	0,5918	0,3574
50	0,6789	0,6327	2,0034	0,606	0,3564
55	0,7069	0,6657	1,8257	0,5782	0,3454

Tableau 4.5: Résultats des critères numériques de la phase de la validation, modèle RN, mois de mars

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
33	0,7236	0,6905	3,8897	0,5564	0,2987
28	0,7385	0,7247	0,0184	0,5247	0,3052
23	0,7391	0,7235	-0,6085	0,5258	0,2985
18	0,7821	0,7219	-6,1057	0,5273	0,3119
13	0,6989	0,5392	-10,021	0,6788	0,3424

Pour quasiment toutes les répartitions calage et validation, le modèle donne de très bons résultats, des  $R^2$  et  $Nash > 0,75$  et des  $RSR$  et  $RMSE < 0,5$ , le  $Pbias$  n'est pas trop élevé.

Le modèle s'améliore en validation, pour toutes les variantes, ce qui signifie que l'apprentissage a été fructueux.

On choisira la répartition 40 calage 28 validation :




Figure 4.20: Comparaison observé-simulé phase du calage, modèle RN, mois de mars




Figure 4.21: Comparaison observé-simulé phase de la validation, modèle RN, mois de mars

On remarque qu'en calage, le modèle suit bien l'allure et reproduit moyennement les pics, vu qu'il y a des fluctuations.

En période de validation les fluctuations diminuent, le modèle reproduit mieux l'allure et les pics. Les graphes de comparaison confirment les valeurs des critères numériques obtenus par le modèle. Le modèle réseau de neurones est meilleur que celui de régression linéaire et confirme que la relation entre le débit et la concentration saline n'est pas linéaire.

#### 4.4.1.3 Modèle Neuro-Flou

Tableau 4.6: Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de mars

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,7536	0,7536	0,0007	0,4964	0,3106
40	0,756	0,756	0,0004	0,494	0,2897
45	0,7707	0,7707	0,0003	0,4789	0,2807
50	0,7757	0,7757	0,0007	0,4736	0,2705
55	0,767	0,767	0,0003	0,4827	0,28

Tableau 4.7: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de mars

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
33	0,84	0,84	0,0001	0,4	0,2087
28	0,8115	0,8115	0	0,4341	0,2453
23	0,8449	0,8449	-0,0001	0,3939	0,2177
18	0,8443	0,8443	-0,0002	0,3946	0,227
13	0,8501	0,8501	-0,0001	0,3161	0,1554

Les résultats des critères révèlent des  $R^2$  et  $Nash > 0,75$  et des  $RSR$  et  $RMSE < 0,5$  et des  $Pbias$  presque nuls, donc le modèle est satisfaisant, le modèle est très bon pour toutes les variantes calage, il est nettement meilleur en validation.

On choisira la variante qui présente les meilleurs critères numériques en validation, à savoir 55 valeur en calage et 13 pour la validation :




Figure 4.22: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de mars




Figure 4.23: Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de mars

Le modèle reproduit bien l'allure et les pics en calage et s'améliore en validation, il est meilleur que les modèles de régression et réseaux de neurones.

Notons que les modèles des mois de janvier et de février présentent des critères numériques similaires à ceux du mois de mars, les résultats obtenus pour ces deux mois peuvent être visualisés en annexe (A et B).



### 4.4.2 Mois de mai

Pour ce mois, nous avons 47 couples (Ql, Cs) .

#### 4.4.2.1 Modèle de régression linéaire

Tableau 4.8: Résultats des critères numériques de la phase du calage, modèle régression, mois de mai

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
25	0,3475	0,3261	5,1972	0,8209	0,494
30	0,3911	0,3702	4,9144	0,7936	0,4847
35	0,3929	0,3672	6,2978	0,7955	0,5063

Tableau 4.9: Résultats des critères numériques de la phase de la validation, modèle régression, mois de mai

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
22	0,7047	0,5937	-11,176	0,6374	0,4546
17	0,7142	0,6496	-5,68	0,5919	0,4437
12	0,8368	0,7323	2,2362	0,5174	0,3779

Les résultats du modèle en calage sont médiocres pour toutes les répartitions, des  $R^2$  et  $Nash < 0,5$  des  $RSR > 0,75$ , mais en validation, elles sont plutôt satisfaisantes  $R^2$  et  $Nash > 0,5$  et  $RSR < 0,5$ , on a choisi de visualiser les graphes de la variante 35 calage et 12 validation :




Figure 4.24: Comparaison observé-simulé phase du calage, modèle de régression, mois de mai




Figure 4.25: Comparaison observé-simulé phase de la validation, modèle de régression, mois de mai

On remarque qu'en calage le modèle ne reproduit pas bien l'allure et qu'il a tendance à surestimer ou sous-estimer les valeurs, par contre en validation, il arrive à reproduire l'allure, mais avec des écarts importants.

#### 4.4.2.2 Le modèle réseau de neurones

Tableau 4.10: Résultats des critères numériques phase du calage, modèle RN, mois de mai

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
25	0,4266	0,4015	5,5681	0,7736	0,4656
30	0,4103	0,3929	4,9245	0,7792	0,4759
35	0,4824	0,4664	4,251	0,7305	0,4649

Tableau 4.11: Résultats des critères numériques phase de la validation, modèle RN, mois de mai

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
22	0,7222	0,6773	-10,188	0,568	0,4051
17	0,769	0,6837	-6,759	0,5624	0,4216
12	0,8139	0,7726	1,3342	0,4768	0,3483

Les résultats des critères enregistrés en calage sont meilleurs que ceux du modèle de régression, mais ne sont toujours pas suffisants, alors qu'en validation nous avons pratiquement les mêmes résultats que la régression, qui sont satisfaisants.

On a choisi la variante 35 calage 12 validation pour visualiser les graphes de comparaison :




Figure 4.26: Comparaison observé-simulé phase du calage, modèle RN, mois de mai




Figure 4.27: Comparaison observé-simulé phase de la validation, modèle RN, mois de mai

En calage, le modèle arrive à suivre l'allure mais il y a un décalage entre l'observé et le simulé, alors qu'en validation, l'allure est suivie et il n'y a pas une grande différence entre les valeurs observées et simulées.

#### 4.4.2.3 Le modèle Neuro-flou

Tableau 4.12: Résultats des critères numériques phase du calage, modèle ANFIS, mois de mai

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
25	0,522	0,522	-0,0001	0,6914	0,4161
30	0,5681	0,5681	-0,0002	0,6572	0,4014
35	0,5708	0,5708	-0,0003	0,6551	0,4169

Tableau 4.13: Résultats des critères numériques phase de la validation, modèle ANFIS, mois de mai

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
22	0,8158	0,8158	0,0001	0,4292	0,3061
17	0,842	0,842	-0,0001	0,3975	0,298
12	0,8797	0,8797	0,0001	0,2243	0,1638

On remarque très bien d'après les critères obtenus, que le modèle neuro-flou est meilleur que les deux précédents, les résultats du calage sont moyens  $R^2$  et  $Nash > 0,5$  et  $RSR < 0,70$ .

En validation, les résultats sont très bons,  $R^2$  et  $Nash > 0,80$  et  $RSR < 0,5$ .

On a choisi la variante 35 valeurs de calage et 12 valeurs de validation :




Figure 4.28: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de mai




Figure 4.29: Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de mai

On remarque que le modèle suit un peu l'allure en calage, et reproduit quelques pics, mais présente des fluctuations, ce qui n'est pas bon.

Alors qu'en validation, le simulé suit très bien l'observé, retrace l'allure et reproduit les pics, pour ce mois aussi, le modèle neuro-flou est meilleur que les autres.

Les résultats d'évaluation des performances pour les autres mois peuvent être visualisés en annexe (A et B).

## 4.5 Approche saisonnière

On va maintenant passer aux saisons, pour décider si on peut généraliser le modèle, on va regrouper les mois successifs pour lesquels on a eu des modèles avec des critères de performance similaires, pour ne pas influencer négativement la qualité du modèle obtenu.

### 4.5.1 Saison janvier-février-mars

On a un échantillon de 223 couples (Ql, Cs) .

#### 4.5.1.1 Modèle de régression

Tableau 4.14: Résultats des critères numériques phase du calage, modèle régression, saison jan-fév-mar

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
120	0,558337	0,479995	1,676359	0,721113	0,408403
140	0,567211	0,507219	1,633782	0,701984	0,381355
160	0,567877	0,510657	1,776882	0,69953	0,390049
180	0,554839	0,50256	1,927958	0,705294	0,39271
200	0,560017	0,51176	1,909716	0,698742	0,383987

Tableau 4.15: Résultats des critères numériques phase de la validation, modèle régression, saison jan-fév-mar

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
103	0,603478	0,13061	-15,82	0,932411	0,500745
83	0,636208	0,092169	-19,6094	0,952802	0,536478
63	0,634877	0,115355	-19,1452	0,940556	0,480685
43	0,608298	0,177865	-16,5297	0,906717	0,439173
23	0,659297	0,051334	-23,4443	0,973995	0,558329

En calage, Les  $R^2$  et les  $Nash$  sont supérieurs à 0,50, ce qui entre dans le domaine du moyen, ce n'est pas le cas du  $RSR$  qui avoisine les 0,70, le  $Pbias$  stipule que le modèle sous-estime un peu les résultats.

Pour la validation, on a des  $R^2$  qui tournent autour de 0,60, mais les  $Nash$  sont trop faibles (0,1), et les  $RSR$  sont trop importants (dépassent les 0,90), le  $Pbias$  nous informe que le modèle surestime les résultats.

Afin de confirmer les résultats des critères, on choisira la variante 180 calage et 43 validation.




Figure 4.30: Comparaison observé-simulé phase du calage, modèle régression, saison jan-fév-mar




Figure 4.31: Comparaison observé-simulé phase de la validation, modèle régression, saison jan-fév-mar

Les graphes confirment bel et bien les résultats moyens des critères, on voit qu'en calage il y a un semblant de sous-estimation, alors qu'en validation le modèle surestime nettement les résultats.

Le modèle régression linéaire a donné des résultats médiocres.

#### 4.5.1.2 Modèle Réseau de neurones

Tableau 4.16: Résultats des critères numériques phase du calage, modèle RN, saison jan-fév-mar

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
120	0,7068	0,689	3,7142	0,5576	0,3158
140	0,7006	0,6918	2,1979	0,5552	0,3016
160	0,7319	0,7092	4,1488	0,5392	0,2929
180	0,6768	0,6664	2,9286	0,5776	0,3216
200	0,7075	0,7039	1,9265	0,5442	0,299

Tableau 4.17: Résultats des critères numériques phase de la validation, modèle RN, saison jan-fév-mar

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
103	0,663	0,5596	-10,2532	0,6636	0,3564
83	0,6579	0,5245	-13,3404	0,6895	0,3882
63	0,6259	0,5527	-10,1606	0,6688	0,3766
43	0,61	0,481	-12,0275	0,7204	0,3489
23	0,6219	0,4989	-14,2542	0,7079	0,4058



En comparant les deux tableaux à ceux obtenus en régression linéaire, les critères numériques se sont améliorés, on peut donc dire que la relation QI-Cs n'est pas linéaire.

En calage, Les  $R^2$  et les  $Nash$  sont dans l'ordre de 0,70, ce qui est bon, contrairement à la régression, le  $RSR$  pour le modèle réseau de neurones tourne autour de  $0,55 < 0,70$ , ce qui est satisfaisant, le  $Pbias$  montre que le modèle sous-estime un peu les résultats.

Pour la validation, on a des  $R^2$  qui tournent autour de 0,60, et des  $Nash$  supérieurs à 0,50 pour la plupart, et les  $RSR$  aussi inférieurs à 0,70 sont trop, le  $Pbias$  nous informe que le modèle surestime les résultats dans toutes les répartitions calage-validation.

Pour confirmer les résultats des critères, on choisit 160 valeurs pour le calage et 63 valeurs pour la validation.




Figure 4.32: Comparaison observé-simulé phase du calage, modèle RN, saison jan-fév-mar






Figure 4.33: Comparaison observé-simulé phase de la validation, modèle RN, saison jan-fév-mar

Les graphes confirment qu'il y a une surestimation, dans la partie apprentissage du modèle, et une sous-estimation dans la validation.

Il est clair, d'après les résultats obtenus, que le modèle réseau de neurones est meilleur que le modèle de régression.

#### 4.5.1.3 Modèle Neuro-Flou

Tableau 4.18: Résultats des critères numériques phase du calage, modèle AN-FIS, saison jan-fév-mar

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
120	0,7745	0,7745	-0,0004	0,4748	0,2689
140	0,7701	0,7701	0,0002	0,4795	0,2605
160	0,755	0,755	0,0004	0,4949	0,276
180	0,7117	0,7117	-0,0003	0,5369	0,2989
200	0,7079	0,7079	-0,0006	0,5404	0,297

Tableau 4.19: Résultats des critères numériques phase de la validation, modèle AN-FIS, saison jan-fév-mar

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
103	0,7107	0,7107	-0,0001	0,5378	0,2888
83	0,7226	0,7226	-0,0001	0,5267	0,2965
63	0,7284	0,7284	-0,0002	0,5211	0,2663
43	0,6733	0,6733	-0,0003	0,5716	0,2768
23	0,765	0,765	0,0001	0,4847	0,2779

En calage, Les  $R^2$  et les  $Nash$  sont en majorité satisfaisants (supérieurs à 0,75), le  $RSR$  pour trois répartitions est inférieur à 0,5, ce qui est bon.

Pour la validation, on a des  $R^2$  et  $Nash$  qui tournent autour de 0,70, et les  $RSR$  avoisinent les 0,50, ce qui est aussi satisfaisant.

Le  $Pbias$  est infime en calage comme en validation, ce qui stipule qu'il n'y a ni une surestimation ni une sous-estimation des résultats.

Pour confirmer les résultats des critères, on choisit la variante 160 valeurs en calage et 63 en validation.




Figure 4.34: Comparaison observé-simulé phase du calage, modèle ANFIS, saison jan-fév-mar




Figure 4.35: Comparaison observé-simulé phase de la validation, modèle ANFIS, saison jan-fév-mar

Le modèle reproduit l'allure en calage et en validation, et atteint quelques pics, il est nettement meilleur que les modèles de régression et réseau de neurones.

Puisque le modèle est bon, on peut donc préférer le modèle saisonnier pour les mois de janvier, février et mars. Les résultats des critères numériques et les graphes

de comparaison des saisons novembre-décembre et avril-mai peuvent être visualisés dans l'annexe (A et B).

### 4.5.2 Saison humide

Dans cette partie, on a utilisé tout le jeu de données à notre disposition, il est composé de 427 couples (Ql, Cs).

L'objectif de cette partie est de vérifier si on peut faire un modèle global pour la simulation de la concentration saline à partir du débit liquide du cours d'eau.

#### 4.5.2.1 Modèle de régression

Tableau 4.20: Résultats des critères numériques phase du calage, modèle régression, saison humide

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
220	0,3832	0,3347	4,3653	0,8157	0,4933
240	0,3807	0,3392	4,3158	0,8129	0,4807
260	0,3878	0,3539	4,2433	0,8038	0,4671
280	0,3751	0,3387	4,1815	0,8132	0,4682
300	0,3677	0,3317	4,0021	0,8175	0,4549
320	0,3863	0,3509	3,9815	0,8056	0,4719
340	0,3833	0,3477	3,8143	0,8077	0,4661
360	0,3826	0,3497	3,7448	0,8064	0,4591
380	0,3895	0,3568	3,6249	0,802	0,4509
400	0,3893	0,3554	3,8383	0,8028	0,4624

Tableau 4.21: Résultats des critères numériques phase de la validation, modèle régression, saison humide

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
207	0,4237	0,3368	10,4201	0,8144	0,466
187	0,4459	0,3457	11,258	0,8089	0,4751
167	0,4516	0,3405	11,7679	0,8121	0,4882
147	0,4647	0,4104	8,3726	0,7678	0,4722
127	0,4916	0,4522	6,6048	0,7401	0,4894
107	0,4152	0,4105	1,7072	0,7678	0,4553
87	0,4054	0,3864	-4,1874	0,7833	0,4625
67	0,4349	0,421	-4,6809	0,7609	0,4934
47	0,4518	0,4113	-10,0242	0,7672	0,5667
27	0,4471	0,4357	-5,1198	0,7512	0,5447

Selon les résultats des critères numériques, le modèle est médiocre, on a des  $R^2$  et  $Nash$  inférieurs à 0,5, et des  $RSR$  supérieurs à 0,70, en calage comme en validation.




Figure 4.36: Comparaison observé-simulé phase du calage, modèle régression, saison humide




Figure 4.37: Comparaison observé-simulé phase de la validation, modèle régression, saison humide

Le modèle semble reproduire l'allure en calage et en validation, mais soit il surestime soit il sous-estime les pics.

D'après les critères numériques, et les graphiques de comparaison, le modèle de régression linéaire ne sera pas pris en considération.

#### 4.5.2.2 Modèle Réseau de neurones

Tableau 4.22: Résultats des critères numériques phase du calage, modèle RN, saison humide

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
220	0,4852	0,4851	0,2813	0,7175	0,4339
240	0,4549	0,4432	3,8963	0,7462	0,4413
260	0,4609	0,4477	4,0926	0,7431	0,4318
280	0,454	0,4412	3,974	0,7475	0,4304
300	0,4459	0,4323	3,9589	0,7535	0,4193
320	0,4722	0,4621	3,5005	0,7334	0,4296
340	0,4633	0,4445	4,5879	0,7453	0,4301
360	0,4578	0,435	5,113	0,7517	0,428
380	0,4591	0,422	6,4897	0,7602	0,4274
400	0,4793	0,4665	3,9009	0,7304	0,4207

Tableau 4.23: Résultats des critères numériques phase de la validation, modèle RN, saison humide

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
207	0,4278	0,415	3,2351	0,7648	0,4376
187	0,4894	0,4187	9,4092	0,7624	0,4478
167	0,4992	0,419	9,5905	0,7622	0,4582
147	0,4915	0,4513	6,5807	0,7408	0,4556
127	0,509	0,4704	5,8697	0,7278	0,4812
107	0,4655	0,4646	0,3492	0,7317	0,4339
87	0,4286	0,4225	-3,1465	0,7599	0,4487
67	0,4493	0,4471	-2,0984	0,7436	0,4822
47	0,4651	0,4533	-4,3413	0,7394	0,5461
27	0,4404	0,4327	-2,4464	0,7532	0,5462

On remarque que les résultats des  $R^2$  et  $Nash$  avoisinent les 0,50 en calage et en validation pour la majorité des variantes calage-validation, le  $RSR$  est supérieur à 0,70 pour toutes les répartitions, que ça soit en calage ou en validation, le modèle est donc médiocre aussi.

On visualisera les graphes de la répartition 300 calage et 127 validation.




Figure 4.38: Comparaison observé-simulé phase du calage, modèle RN, saison humide




Figure 4.39: Comparaison observé-simulé phase de la validation, modèle RN, saison humide

L'allure est mieux suivie que dans le modèle de régression, mais il y'a un décalage important entre l'observé et le simulé, que ça soit en calage ou en validation.

Le modèle réseau de neurones ne donne pas lui non plus des résultats satisfaisants, il n'est pas à prendre en considération.

#### 4.5.2.3 Modèle Neuro-Flou

Tableau 4.24: Résultats des critères numériques phase du calage, modèle ANFIS, saison humide

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
220	0,4919	0,4919	-0,0008	0,7128	0,3975
240	0,4769	0,4769	0,0007	0,7233	0,3944
260	0,4731	0,4731	0,0002	0,7259	0,389
280	0,4598	0,4598	0,0004	0,735	0,3902
300	0,4498	0,4498	0,0002	0,7418	0,3806
320	0,4811	0,4811	0,0006	0,7204	0,3891
340	0,4854	0,4854	0,0006	0,7174	0,3831
360	0,4805	0,4805	0,0003	0,7208	0,3797
380	0,4847	0,4847	0,0002	0,7178	0,3734
400	0,4815	0,4815	-0,0002	0,7201	0,3836

Tableau 4.25: Résultats des critères numériques phase de la validation, modèle ANFIS, saison humide

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
207	0,4906	0,4906	0,0002	0,7138	0,3766
187	0,5215	0,5215	0,0001	0,6917	0,3746
167	0,5496	0,5496	0,0003	0,6711	0,372
147	0,5515	0,5515	0,0004	0,6697	0,3798
127	0,5868	0,5867	0,0001	0,6428	0,3919
107	0,5034	0,5034	0,0001	0,7047	0,3853
87	0,4615	0,4615	0,0001	0,7338	0,3996
67	0,4834	0,4834	0,0001	0,7188	0,4298
47	0,6033	0,6033	-0,0004	0,6298	0,429
27	0,55	0,55	0,0002	0,6708	0,4486

On remarque une légère amélioration dans les critères numériques en comparant avec les deux méthodes précédentes, surtout en validation où les critères entrent dans le domaine moyen, avec des  $R^2$  et  $Nash > 0,5$  et des  $RSR < 0,70$ .

On va visualiser les graphes de comparaison pour confirmer ces remarques, on a choisi la répartition 380 valeurs en calage et 47 en validation :






Figure 4.40: Comparaison observé-simulé phase du calage, modèle ANFIS, saison humide




Figure 4.41: Comparaison observé-simulé phase de la validation, modèle ANFIS, saison humide

On remarque qu'en calage, le modèle reproduit quelques pics, mais pas les plus extrêmes.



En validation, l'allure est reproduite, avec un décalage dans certaines parties. Les trois modèles obtenus avec les trois méthodes sont médiocres à moyens dans ce cas, les données des mois où l'on a eu des résultats médiocres ont influencé les performances des modèles.

## 4.6 Conclusion

On a eu les meilleurs résultats pour les mois de janvier, février et mars et pour la saison les englobant, le modèle qui a été le plus performant est le modèle neuro-flou, vu que c'est un couplage entre deux méthodes de l'intelligence artificielle, la logique floue assure la classification de données, pour que le réseau de neurones ait un apprentissage optimal.

# Conclusion générale

Les eaux de l'Oued Tafna présentent un taux de salinité très élevé, cela est confirmé par les données que nous avons eu de la part de l'ANRH, la concentration saline de ces eaux stipule que nous sommes en présence d'une eau saumâtre.

Pour modéliser la relation débit liquide-concentration saline, nous avons utilisé trois méthodes, la régression simple, l'ajustement par réseau de neurones et les systèmes neuro-flou, le modèle qui aura les meilleurs critères d'évaluation numériques et graphiques sera retenu.

Nous sommes arrivés aux conclusions suivantes :

- Le débit liquide de l'Oued Tafna est faible sur la majeure partie de l'année et la salinité a une variation aléatoire, non cyclique, c'est donc un phénomène complexe.
- L'approche mensuelle a donné de meilleurs résultats que l'approche saisonnière, ce qui signifie que chaque mois est caractérisé par un climat pour tous les modèles utilisés, à savoir le modèle heuristique et les deux modèles métaheuristiques.
- On a eu les meilleurs résultats pour les mois de janvier, février et mars et pour la saison les englobant, le modèle qui a été le plus performant est le modèle neuroflou, vu que c'est un couplage entre deux méthodes de l'intelligence artificielle, la logique floue assure la classification de données, pour que le réseau de neurones ait un apprentissage optimal.
- Nos résultats ont révélé qu'il y a une forte corrélation entre le débit liquide et la concentration saline du cours d'eau étudié, mais on voit bien qu'il y a d'autres paramètres qui ont leur part d'influence dans le taux de salinité, on peut citer à titre d'exemple l'évapotranspiration, la température, l'ensoleillement, la végétation. Concernant les méthodes de modélisation, les modèles relevant de l'intelligence artificielle ont montré de meilleurs résultats que le modèle empirique, ils sont donc mieux adaptés à la modélisation hydrologique.
- L'établissement de modèles avec les méthodes de l'intelligence artificielle nécessite des jeux de données importants, pour que le modèle puisse apprendre la majorité des cas possibles, ce qui le rendra plus performant.

# Bibliographie

- [1] Aubert., 1983
- [2] BACHA Fella *Thèse : Modélisation du transport solide par les modèles empirique et neuro-flou à différents pas de temps, Juin 2012.*
- [3] BOUSSAIDI Saliha et MOKRANI Sakina. *Thèse :Analyse physico-chimique des eaux d'un cours d'eau et la quantification de la salinité (cas de l'Oued TAFNA), Juin 2006.*
- [4] CAPTEURS ET INSTRUMENTATION UTILISES EN OCEANOGRAPHIE PHYSIQUE,LABORATOIRE DE PHYSIQUE DES OCEANS , 2013
- [5] Citation Bakreti, A., Braud, I., Leblois, E., et Benali, A. Analyse conjointe des régimes pluviométriques et hydrologiques dans le bassin de la Tafna (Algérie Occidentale).Hydrological Sciences Journal, 58 (1), 1–19. 2013
- [6] F.Ghassemi, A.J.Jakeman, et H.A. Nix, *salinisation of Land and Water Resources (Sydney: University of New South Wales Press, 1995)*
- [7] J.P.Villeneuve. La modélisation hydrologique et la gestion de l'eau. Revue Scientifique Eau. 1998.
- [8] Madsen, 2000
- [9] Mimoune., 1995
- [10] Modèles et modélisation. Diplôme Universitaire de Pharmacocinétique de Toulouse. 2007
- [11] Reguig et Larroussi., 2007
- [12] W. Kloppmann, A. Bourhane *Article :Salinisation des masses d'eaux en France,Décembre 2010*

# Annexes

# Annexe A

## Tableaux des résultats des critères numériques

Tableau A.1: Résultats des critères numériques de la phase du calage, modèle AN-FIS, mois de Novembre

<b>Calage</b>	<b><math>R^2</math></b>	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
25	0,5270	0,5270	-0,0002	0,6878	0,4441
30	0,5398	0,5398	0,0008	0,6784	0,4181
35	0,5647	0,5646	-0,0007	0,6598	0,3878

Tableau A.2: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Novembre

<b>Calage</b>	<b><math>R^2</math></b>	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
25	0,3828	0,3582	8,1269	0,8011	0,6138
30	0,2930	0,2614	8,4000	0,8594	0,6283
35	0,3108	0,2825	7,3981	0,8470	0,5906

Tableau A.3: Résultats des critères numériques de la phase du calage, modèle RN, mois de Novembre

<b>Calage</b>	<b><math>R^2</math></b>	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
25	0,5324	0,5131	6,1985	0,6978	0,5346
30	0,4357	0,3872	9,5230	0,7828	0,5723
35	0,4571	0,2870	16,0943	0,8444	0,5887

Tableau A.4: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Novembre

<b>VALIDATION</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
22	0,3465	0,3465	-0,0003	0,8084	0,4057
17	0,4787	0,4787	0,0006	0,7220	0,3464
12	0,3696	0,3696	-0,0008	0,7940	0,3592

Tableau A.5: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Novembre

<b>VALIDATION</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
22	0,1153	-0,0141	8,9872	1,0070	0,5995
17	0,2793	0,1812	-13,7627	0,9049	0,5150
12	0,3230	-0,2257	-36,0265	1,1071	0,5942

Tableau A.6: Résultats des critères numériques de la phase de la validation, modèle RN, mois de Novembre

<b>VALIDATION</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
22	0,2241	0,1787	-5,1570	0,9063	0,5395
17	0,3217	0,1924	-14,1219	0,8987	0,5114
12	0,3293	-0,0266	-27,9745	1,0132	0,5438

Tableau A.7: Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Décembre

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
35	0,4105	0,4105	-0,0002	0,7678	0,3762
40	0,4673	0,4673	-0,0001	0,7299	0,3849
45	0,5072	0,5072	0,0001	0,7020	0,3726
50	0,5262	0,5262	0,0001	0,6883	0,3540

Tableau A.8: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Décembre

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,1659	0,1534	2,8938	0,9201	0,4509
40	0,2104	0,1981	2,9751	0,8955	0,4723
45	0,2592	0,2482	2,8373	0,8670	0,4602
50	0,2861	0,2764	2,5904	0,8506	0,4374

Tableau A.9: Résultats des critères numériques de la phase du calage, modèle RN, mois de Décembre

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,4936	0,4866	2,0250	0,7165	0,3511
40	0,4981	0,4345	4,8231	0,7520	0,3966
45	0,4540	0,3924	4,8692	0,7795	0,4137
50	0,4683	0,3783	7,2584	0,7885	0,4055

Tableau A.10: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Décembre

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,5329	0,5329	0,0002	0,6835	0,3908
30	0,4702	0,4702	0,0002	0,7279	0,3754
25	0,4185	0,4185	0,0001	0,7626	0,3881
20	0,4074	0,4074	0,0001	0,7698	0,4216

Tableau A.11: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Décembre

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
35	0,3139	0,2631	3,6382	0,8584	0,4909
30	0,2398	0,2145	-4,8975	0,8863	0,4715
25	0,2030	0,1302	-8,2227	0,9327	0,4922
20	0,1794	0,0664	-11,2957	0,9662	0,5492

Tableau A.12: Résultats des critères numériques de la phase de la validation, modèle RN, mois de Décembre

<b>VALIDATION</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
35	0,3853	0,3808	-1,1270	0,7869	0,4499
30	0,3078	0,2280	-8,6011	0,8787	0,4674
25	0,2752	0,2019	-8,3817	0,8934	0,4715
20	0,2735	0,1936	-9,4870	0,8980	0,5104

Tableau A.13: Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Janvier

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
40	0,8903	0,8903	0,0001	0,3312	0,1803
45	0,8216	0,8216	0,0002	0,4224	0,2349
50	0,6986	0,6986	0,0003	0,5490	0,3158
55	0,7684	0,7684	0,0001	0,4812	0,2798
60	0,8053	0,8053	0,0003	0,4412	0,2702
65	0,7409	0,7409	0,0004	0,5090	0,3074

Tableau A.14: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Janvier

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
40	0,7539	0,7499	1,2427	0,5001	0,2722
45	0,6785	0,6743	1,9945	0,5707	0,3173
50	0,6484	0,6416	2,6757	0,5987	0,3443
55	0,6759	0,6692	2,5583	0,5752	0,3345
60	0,7125	0,7075	2,3459	0,5408	0,3311
65	0,7127	0,7079	2,2661	0,5404	0,3264



Tableau A.15: Résultats des critères numériques de la phase du calage, modèle RN, mois de Janvier

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
40	0,7725	0,7702	1,4163	0,4794	0,2610
45	0,7542	0,7498	1,9335	0,5002	0,2781
50	0,6780	0,6691	3,0056	0,5752	0,3308
55	0,7363	0,7327	1,9450	0,5171	0,3007
60	0,7550	0,7516	1,8812	0,4984	0,3052
65	0,7631	0,7582	2,3257	0,4918	0,2970

Tableau A.16: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Janvier

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
39	0,7436	0,7436	0,0000	0,5063	0,3153
34	0,8217	0,8217	0,0000	0,4222	0,2710
29	0,8271	0,8271	0,0000	0,4159	0,2629
24	0,8257	0,8257	0,0001	0,4175	0,2624
19	0,7427	0,7427	0,0001	0,5072	0,2551
14	0,6438	0,6438	-0,0003	0,5968	0,2523

Tableau A.17: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Janvier

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
39	0,6818	0,6412	-7,6949	0,5990	0,3730
34	0,7502	0,7211	-1,6425	0,5281	0,3391
29	0,7990	0,7797	3,2370	0,4694	0,2967
24	0,7734	0,7598	2,6521	0,4901	0,3080
19	0,6511	0,6416	-0,0365	0,5987	0,3011
14	0,4643	0,4622	-1,1350	0,7333	0,3100

Tableau A.18: Résultats des critères numériques de la phase de la validation, modèle RN, mois de Janvier

<b>VALIDATION</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
39	0,6819	0,6365	-7,7510	0,6029	0,3754
34	0,7125	0,6974	-2,5919	0,5501	0,3531
29	0,8039	0,7969	2,8261	0,4507	0,2849
24	0,7583	0,7542	2,1670	0,4958	0,3116
19	0,6770	0,6630	1,8955	0,5805	0,2920
14	0,4933	0,4689	3,2900	0,7288	0,3081

Tableau A.19: Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Février

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
40	0,8164	0,8164	-0,0009	0,4285	0,1917
45	0,7613	0,7613	0,0003	0,4886	0,2268
50	0,7712	0,7712	-0,0004	0,4783	0,2205
55	0,7638	0,7638	-0,0008	0,4860	0,2138
60	0,7586	0,7586	-0,0009	0,4913	0,2094

Tableau A.20: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Février

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
40	0,6268	0,5939	1,0106	0,6373	0,2851
45	0,6132	0,6037	1,5061	0,6295	0,2922
50	0,6431	0,6346	1,3343	0,6045	0,2786
55	0,6406	0,6316	1,2146	0,6069	0,2671
60	0,6340	0,6265	1,1776	0,6111	0,2604

Tableau A.21: Résultats des critères numériques de la phase du calage, modèle RN, mois de Février

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
40	0,7217	0,7150	2,0524	0,5339	0,2388
45	0,6802	0,6764	1,5223	0,5689	0,2641
50	0,7121	0,7051	1,9513	0,5430	0,2503
55	0,6956	0,6944	0,8616	0,5528	0,2432
60	0,6812	0,6800	0,8464	0,5657	0,2410

Tableau A.22: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Février

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
36	0,7044	0,7044	0,0002	0,5437	0,2596
31	0,7154	0,7153	0,0003	0,5335	0,2535
26	0,6574	0,6573	0,0005	0,5854	0,2735
21	0,6832	0,6831	0,0005	0,5629	0,2853
16	0,6587	0,6587	0,0006	0,5842	0,3342

Tableau A.23: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Février

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
36	0,6614	0,5626	-9,1535	0,6614	0,3158
31	0,6774	0,6375	-4,9511	0,6020	0,2861
26	0,6187	0,5563	-7,0906	0,6661	0,3112
21	0,6327	0,5385	-9,8183	0,6793	0,3443
16	0,6250	0,5618	-9,0464	0,6620	0,3787

Tableau A.24: Résultats des critères numériques de la phase de la validation, modèle RN, mois de Février

VALIDATION	$R^2$	Nash	PBIAS	RSR	RMSE
36	0,6008	0,5584	-5,9876	0,6645	0,3173
31	0,6193	0,6089	-2,8671	0,6254	0,2971
26	0,5563	0,5326	-4,2144	0,6836	0,3194
21	0,5855	0,5144	-8,5919	0,6968	0,3531
16	0,5913	0,5355	-8,6355	0,6815	0,3899

Tableau A.25: Résultats des critères numériques de la phase du calage, modèle ANFIS, mois de Avril

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
20	0,3797	0,3797	-0,0002	0,7876	0,3139
25	0,4788	0,4788	-0,0013	0,7220	0,2984

Tableau A.26: Résultats des critères numériques de la phase du calage, modèle régression linéaire, mois de Avril

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
20	0,2549	0,2449	2,4889	0,8690	0,3548
25	0,3177	0,2965	2,4213	0,8388	0,3552

Tableau A.27: Résultats des critères numériques de la phase du calage, modèle RN,mois de Avril

<b>Calage</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
20	0,4066	0,3891	7,4461	0,8104	0,5759
25	0,4555	0,3874	5,6175	0,7827	0,3315

Tableau A.28: Résultats des critères numériques de la phase de la validation, modèle ANFIS, mois de Avril

<b>Validation</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
17	0,5146	0,5146	-0,0004	0,6967	0,3334
12	0,4644	0,4644	-0,0006	0,7319	0,3460

Tableau A.29: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, mois de Avril

<b>Validation</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
17	0,4904	0,3605	-4,0209	0,7997	0,3921
12	0,4419	0,3212	-5,7657	0,8239	0,3991

Tableau A.30: Résultats des critères numériques de la phase de la validation, modèle RN, mois de Avril

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
17	0,5038	0,4628	8,3790	0,6150	0,3486
12	0,4546	0,4078	-6,4035	0,7696	0,3727

Tableau A.31: Résultats des critères numériques de la phase du calage, modèle ANFIS, Saison Novembre Décembre

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
60	0,4464	0,4464	0,0003	0,7441	0,4521
70	0,4338	0,4338	0,0002	0,7525	0,4621
80	0,3968	0,3968	-0,0002	0,7766	0,4626
90	0,4664	0,4664	0,0005	0,7305	0,4499
100	0,3896	0,3896	0,0001	0,7813	0,5103

Tableau A.32: Résultats des critères numériques de la phase du calage, modèle régression linéaire, Saison Novembre Décembre

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
60	0,3170	0,2931	5,1184	0,8408	0,5109
70	0,2999	0,2761	4,9081	0,8508	0,5225
80	0,3125	0,2912	4,5328	0,8419	0,5015
90	0,3318	0,3072	4,8876	0,8323	0,5126
100	0,2934	0,2668	6,1536	0,8563	0,5593

Tableau A.33: Résultats des critères numériques de la phase du calage, modèle RN, Saison Novembre Décembre

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
60	0,3850	0,3699	4,4875	0,7938	0,4823
70	0,3732	0,3727	0,8019	0,7920	0,4864
80	0,3860	0,3617	5,2113	0,7989	0,4759
90	0,3731	0,2318	14,0180	0,8765	0,5397
100	0,3242	0,2862	4,3497	0,8449	0,5518

Tableau A.34: Résultats des critères numériques de la phase de la validation, modèle ANFIS, Saison Novembre Décembre

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
57	0,3427	0,3427	-0,0004	0,8107	0,5465
47	0,3265	0,3265	-0,0008	0,8207	0,5558
37	0,3365	0,3365	-0,0001	0,8145	0,5879
27	0,1603	0,1603	-0,0003	0,9164	0,6528
17	0,2733	0,2733	-0,0001	0,8525	0,4764

Tableau A.35: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, Saison Novembre Décembre

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
57	0,2244	0,1984	5,3569	0,8953	0,6036
47	0,2293	0,2235	1,8287	0,8812	0,5968
37	0,2267	0,2086	-5,9438	0,8896	0,6421
27	0,0967	0,0739	1,4545	0,9623	0,6855
17	0,1007	-0,0067	2,9811	1,0033	0,5607

Tableau A.36: Résultats des critères numériques de la phase de la validation, modèle RN, Saison Novembre Décembre

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
57	0,2595	0,2480	1,6920	0,8672	0,5846
47	0,2618	0,2472	-4,1067	0,8676	0,5876
37	0,2501	0,2296	-6,3316	0,8777	0,6335
27	0,1206	0,0704	8,3313	0,9642	0,6868
17	0,1368	0,1273	3,0815	0,9342	0,5221

Tableau A.37: Résultats des critères numériques de la phase du calage, modèle ANFIS, Saison Avril MAI

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
45	0,5413	0,5413	0,0003	0,6773	0,3543
55	0,5210	0,5210	0,0002	0,6921	0,3582
65	0,5058	0,5058	0,0001	0,7030	0,3824

Tableau A.38: Résultats des critères numériques de la phase du calage, modèle régression linéaire, Saison Avril MAI

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
45	0,4111	0,3881	4,0198	0,7822	0,4093
55	0,4020	0,3745	4,0149	0,7909	0,4093
65	0,3975	0,3742	4,2926	0,7911	0,4302

Tableau A.39: Résultats des critères numériques de la phase du calage, modèle RN, Saison Avril MAI

Calage	$R^2$	Nash	PBIAS	RSR	RMSE
45	0,4652	0,4468	4,5370	0,7438	0,3891
55	0,4702	0,4548	4,1892	0,7384	0,3822
65	0,4471	0,4367	3,5451	0,7505	0,4082

Tableau A.40: Résultats des critères numériques de la phase de la validation, modèle ANFIS, Saison Avril MAI

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
39	0,5314	0,5314	0,0004	0,6845	0,4413
29	0,5954	0,5954	-0,0001	0,6361	0,4381
19	0,6814	0,6814	-0,0002	0,5645	0,3950

Tableau A.41: Résultats des critères numériques de la phase de la validation, modèle régression linéaire, Saison Avril MAI

Validation	$R^2$	Nash	PBIAS	RSR	RMSE
39	0,4743	0,4599	1,3601	0,7349	0,4738
29	0,5002	0,4869	-2,5607	0,7163	0,4934
19	0,6299	0,5358	-12,7124	0,6813	0,4767

Tableau A.42: Résultats des critères numériques de la phase de la validation, modèle RN,Saison Avril MAI

<b>Validation</b>	$R^2$	<b>Nash</b>	<b>PBIAS</b>	<b>RSR</b>	<b>RMSE</b>
39	0,5036	0,4615	1,4347	0,7338	0,4731
29	0,5059	0,4794	0,5522	0,7215	0,4969
19	0,6028	0,5123	-11,4389	0,6983	0,4887



## Annexe B

### Graphiques de comparaison de l'observé et du simulé




Figure B.1: Comparaison observé-simulé phase de calage, modèle de régression, mois de Janvier




Figure B.2: Comparaison observé-simulé phase de la validation, modèle de régression, mois de Janvier




Figure B.3: omparaison observé-simulé phase du calage, modèle RN, mois de Janvier




Figure B.4: Comparaison observé-simulé phase de la validation, modèle RN, mois de Janvier




Figure B.5: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Janvier




Figure B.6: Comparaison observé-simulé phase de la validation, modèle ANFIS, mois de Janvier




Figure B.7: Comparaison observé-simulé phase de calage, modèle de régression, mois de Février




Figure B.8: Comparaison observé-simulé phase de la validation, modèle de régression, mois de Février




Figure B.9: Comparaison observé-simulé phase du calage, modèle RN, mois de Février




Figure B.10: Comparaison observé-simulé phase de la validation, modèle RN, mois de Février




Figure B.11: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Février




Figure B.12: Comparaison observé-simulé phase de la validation, modèle AN-FIS, mois de Février




Figure B.13: Comparaison observé-simulé phase de calage, modèle de régression, mois de Avril






Figure B.14: Comparaison observé-simulé phase de la validation, modèle de régression, mois de Avril




Figure B.15: Comparaison observé-simulé phase du calage, modèle RN, mois de Avril






Figure B.16: Comparaison observé-simulé phase de la validation, modèle RN, mois de Avril




Figure B.17: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Avril




Figure B.18: Comparaison observé-simulé phase de la validation, modèle AN-FIS, mois de Avril

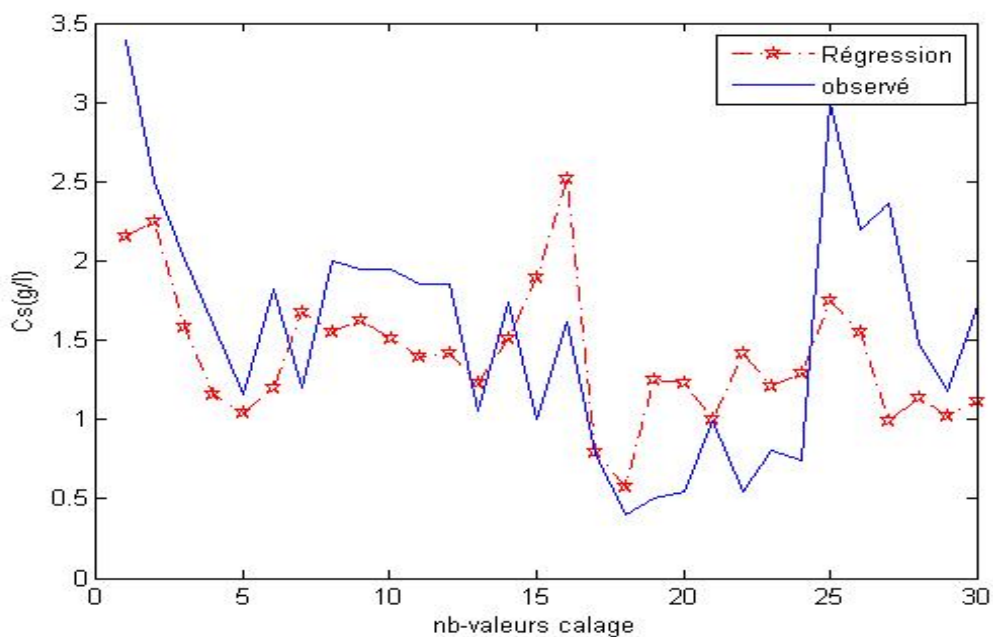


Figure B.19: Comparaison observé-simulé phase de calage, modèle de régression, mois de Novembre




Figure B.20: Comparaison observé-simulé phase de la validation, modèle de régression, mois de Novembre




Figure B.21: Comparaison observé-simulé phase du calage, modèle RN, mois de Novembre




Figure B.22: Comparaison observé-simulé phase de la validation, modèle RN, mois de Novembre




Figure B.23: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Novembre




Figure B.24: Comparaison observé-simulé phase de la validation, modèle AN-FIS, mois de Novembre




Figure B.25: Comparaison observé-simulé phase de calage, modèle de régression, mois de Décembre




Figure B.26: Comparaison observé-simulé phase de la validation, modèle de régression, mois de Décembre




Figure B.27: Comparaison observé-simulé phase du calage, modèle RN, mois de Décembre






Figure B.28: Comparaison observé-simulé phase de la validation, modèle RN, mois de Décembre




Figure B.29: Comparaison observé-simulé phase du calage, modèle ANFIS, mois de Décembre




Figure B.30: Comparaison observé-simulé phase de la validation, modèle AN-FIS, mois de Décembre




Figure B.31: Comparaison observé-simulé phase de calage, modèle de régression, Saison Avril Mai






Figure B.32: Comparaison observé-simulé phase de la validation, modèle de régression, Saison Avril Mai




Figure B.33: Comparaison observé-simulé phase du calage, modèle RN, Saison Avril Mai




Figure B.34: Comparaison observé-simulé phase de la validation, modèle RN, Saison Avril Mai




Figure B.35: Comparaison observé-simulé phase du calage, modèle ANFIS, Saison Avril Mai




Figure B.36: Comparaison observé-simulé phase de la validation, modèle ANFIS, Saison Avril Mai




Figure B.37: Comparaison observé-simulé phase de calage, modèle de régression, Saison Novembre Décembre




Figure B.38: Comparaison observé-simulé phase de la validation, modèle de régression, Saison Novembre Décembre




Figure B.39: Comparaison observé-simulé phase du calage, modèle RN, Saison Novembre Décembre




Figure B.40: Comparaison observé-simulé phase de la validation, modèle RN, Saison Novembre Décembre




Figure B.41: Comparaison observé-simulé phase du calage, modèle ANFIS, Saison Novembre Décembre




Figure B.42: Comparaison observé-simulé phase de la validation, modèle ANFIS, Saison Novembre Décembre

# Annexe C

## Courbe hypsométrique




Figure C.1: Courbe hypsométrique du bassin versant de la TAFNA