

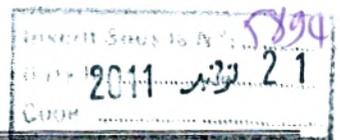
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

UNIVERSITE ABOU BEKR BELKAID TLEMCEM

FACULTE DES SCIENCES DE LA NATURE ET DE LA VIE ET SCIENCES  
DE LA TERRE ET DE L'UNIVERS

MEMOIRE DE MAGISTER

Option :  
Hydrogéologie



---

MODELISATION HYDROLOGIQUE PAR L'APPROCHE  
CONNEXIONNISTE : CAS DU BASSIN DE L'OUED SEBDOU  
(TAFNA- NORD OUEST ALGERIEN )

---

Présenté par :

Mourad CHIKH



Devant les membres du jury :

<i>Président</i>	Mme A.AZZOUNI	Professeur	Université de Tlemcen
<i>Promoteur</i>	Mr A.BOUANANI	Maitre de conférences	Université de Tlemcen
<i>Examineur</i>	Mme F.ADJIM	Maitre de conférences	Université de Tlemcen
<i>Examineur</i>	Mr S. MERIAH	Professeur	Université de Tlemcen
<i>Invité</i>	Mr A.CHIKH	Maitre de conférences	Université de Tlemcen

# Remerciements

## **Remerciements :**

*"Mes remerciements les plus sincères à toutes les personnes qui auront contribué de près ou de loin à l'élaboration de ce mémoire "*

*Je remercie tout particulièrement monsieur Bouanani Abderezak qui m'a encadré et apporté une aide précieuse, pour avoir dirigé les travaux, pour ses remarques qui ont permis d'améliorer la qualité de ce mémoire. Mon co-encadreur monsieur Chikh Mohamed Amine qui m'a accueilli au sein de son équipe ,de sa disponibilité et ses conseils qui ont été indispensables à la concrétisation de ce mémoire.*

*Je tiens à remercier aussi madame Azzouni d'avoir bien voulu accepter de présider le jury de ce mémoire.*

*Je tiens à remercier très sincèrement l'ensemble des membres du jury qui me font le grand honneur d'avoir accepté de juger et d'examiner mon travail Madame Adjime fouzia et monsieur Meriah sidi mohamed.*

*Je témoigne toute ma reconnaissance amicale à monsieur Dekkiche le directeur de L'ANRH d'Oran qui a accepté de nous fournir les données concernant les précipitations et les débits pour la période 1995-2005 .*

*Je tiens à adresser mes plus vifs remerciements à la direction de la briqueterie de la Tafna , le gérant monsieur Bendimered Djamel et le Directeur monsieur Chikh Nouredine pour leurs soutiens tout au long de mon travail .*

*Je remercie tout particulièrement mes parents qui m'ont toujours soutenu et qui m'ont permis de mener à bien mes études*

*Je dédie ce travail à mes chers  
parents, mes sœurs  
et à mon frère.*

# Table des matières

## Tables Des Matières

1- Introduction générale .....	02
<b>Chapitre I</b>	<b>Principes Des Réseaux De Neurones</b>
1- Principes du neurone Biologique:.....	05
2- Historique des réseaux de neurones .....	06
3- Principe du neurone formel .....	07
3-1. Structure des réseaux de neurones .....	07
3-2. Modèle de neurone formel .....	08
3-3. Equation mathématique du neurone formel:.....	09
3-4. Modèle neuronal de Mc culloch et Pitts .....	09
4- L'apprentissage des réseaux de neurones .....	10
4- 1. L'apprentissage supervisé ( l'apprentissage associatif) .....	11
4- 2. L'apprentissage non-supervisé ( auto organisation) .....	11
4- 3. L'apprentissage semi-supervisé .....	11
4- 4. Les principaux algorithmes d'apprentissage .....	11
a- La règle de Hebb .....	11
b- La règle delta .....	11
c- Règle d'apprentissage compétitive .....	11
d- La règle de corrélation en cascade .....	11
e- La règle de correction d'erreurs .....	12
f- La règle de rétro-propagation .....	12
5- La topologie des réseaux de neurones .....	12
5-1. Les réseaux à couches .....	13
5-1-1. Introduction .....	13
5-1-2. Le perceptron Monocouche .....	13
5-1-3. Le Perceptron multicouche .....	16
5-1-4. Le réseau à fonction radiale (RBF) .....	17
5-2. Les réseaux récurrents .....	18
5-2-1. Le réseau d'Elman .....	19
5-2-2. Les réseaux à compétition .....	20
5-2-3. Les réseaux ART .....	20
a- ART-1 .....	20
b- ART-2 .....	20
5-2-4. Les réseaux de Kohonen .....	20
6- Dimensionnement d'un réseau de neurone .....	21
7- Les limitations d'un réseau de neurone .....	24
7- 1. Les avantages d'utilisation des réseaux de neurones sont .....	25
7- 2. Les inconvénients des réseaux de neurones sont .....	25
8- Domaines d'application des réseaux de neurones .....	26

**Chapitre II Environnement et implémentation du modèle de prédiction**

1- Introduction :	28
2- Les outils neuronaux :	28
2-1. Outil Pythia :	28
2-2. Outil Stuttgart Neural Network Simulator :	29
2-3. Outil NeuroXL Classifier et NeuroXL Predictor :	29
2-4. Outil Neuroshed :	30
3- Environnement du Matlab pour les réseaux de neurone :	31
4- Cas d'utilisation du logiciel Matlab :	33
5- Conclusion :	37

**Chapitre III Présentation du bassin versant de l'oued Sebdou**

1- Situation Géographique :	39
2- Caractéristiques De Forme :	40
3- Etude Du Réseau Hydrographique :	41
4- Etude Du Relief :	42
4-1. Etude du relief oued Sebdou :	42
4-2. Altitude Du Sous Bassins :	44
4-3. Etude De Profil En Long :	44
4-4. Indices De Pente Et Relief :	44
4-4-1. Indices de pente :	44
4-4-2. Coefficient de torrencialité :	45
4-4-3. Temps de concentration :	45
5- Sols et Végétations :	46
6- Cadre Géologique :	48
6-1. La série litho stratigraphique :	49
6.1-1. Le Jurassique :	49
6.1-2. Crétacé :	51
6.1-3. Plio-Quaternaire :	52
7- Hydrologie :	52
7-1- Etude des précipitations :	52
7-2- Etude hydropluviométrique :	52
7-2-1. Ajustement des précipitations annuelles à une loi de probabilité :	53
7-2-2. Les débits moyens annuels :	54
7-2-3. Variations des débits annuels moyens bruts (m3/s) :	54
7-2-4. Débits moyens mensuels et saisonniers :	56
7-2-5. Coefficient mensuel de Débits :	56
7-2-6. Coefficient de variation :	57
7-2-7. Modifications inter annuelles du régime saisonnier :	57
7-2-8. Variations journalières des débits de l'Oued Sebdou à Béni Bahdel :	58

**Chapitre IV Modélisation neuronale des données pluviométriques**

1- Introduction :	61
2- Modèles neuronaux :	62
2-1. Choix de la base d'exemples :	62
2-2. Choix des descripteurs :	62

# INTRODUCTION GENERALE

Sur le bassin versant de l'oued Sebdou, il est nécessaire de mieux gérer l'eau, d'un point de vue quantitatif. Or la prise de décisions peut être aidée par la modélisation hydrologique.

La production du ruissèlement superficiel représente un flux important sachant que Le bassin-versant de l'oued Sebdou est situé au nord-ouest de l'Algérie. De forme assez ramassée (coefficient de compacité : 1,37), il s'étend sur une superficie de 256 km<sup>2</sup>, pour un périmètre de 78 km. Il est caractérisé par un relief accidenté où 49 % de sa superficie est à une pente supérieure à 25 %, d'où une densité de drainage de 2,88 km/km<sup>2</sup>. Le bassin est occupé par un couvert végétal maigre et discontinu dominé sur 44 % de son étendue par un couvert forestier dégradé, protégeant mal le sol vis-à-vis de l'érosion hydrique. Le cours d'eau principal, d'une longueur de 29,7 km, prend naissance à Ouled Ouriach à 1 300 m d'altitude, mais ne s'individualise nettement qu'aux environs de la ville de Sebdou. L'entaille du cours d'eau est creusée dans des formations essentiellement gréseuses sur lesquelles reposent des formations carbonatées bien karstifiées.

Le climat de la région est semi-aride, de type méditerranéen. L'essentiel des précipitations se répartit entre l'hiver et l'automne, la saison sèche est l'été. Les précipitations annuelles sont irrégulières au cours de l'année pour notre période d'étude (1995-2005).

Notre travail a pour objectif la mise en place d'un modèle basé sur l'approche connexionniste par les réseaux neuronaux sur ce bassin afin d'évaluer sa capacité à simuler les débits liquides observés.

Ce bassin représente par ailleurs de réelles difficultés pour ce type de modélisation, liées essentiellement au manque de données : une absence d'information spatiale sur les précipitations et absence d'étude détaillée pour certains paramètres.

Or l'optimisation de la gestion de l'eau nécessite la mise en place de modèles, pour étudier différents scénarios.

Le but de ce mémoire est d'étudier une méthode pour prédire le débit de l'oued Sebdou, un phénomène naturel qui dépend de manière non-triviale des conditions météorologiques et géographiques.

Ici, prédire c'est utiliser de l'information, disponible à l'instant présent, pour calculer une estimation d'une certaine grandeur pour un ou plusieurs instants dans le futur.

Pourquoi est-il utile d'avoir des estimations du débit pour des instants futurs d'un cours d'eau à un endroit donné ? Pour répondre à cette question, il ne faut que penser à deux des phénomènes les plus catastrophiques dans le monde : les inondations et les périodes de sécheresse.

La prévision du débit d'un cours d'eau est une motivation primordiale pour tenter de décrire le comportement d'un bassin versant et les modèles Pluie-Débit sont des modèles hydrologiques particuliers qui permettent de simuler le débit des cours d'eau à partir de l'observation des pluies tombées sur le bassin versant. Les objectifs de cette modélisation sont variés et on peut notamment citer :

1. **La simulation des débits** : (dans le cas de lacunes de débits, cela permet d'étendre les chroniques à partir de celles de pluie).

2. **La prévision en temps réel** : des débits des cours d'eau (notamment pour la prévision des crues ou des étiages).

3. **La pré-détermination des débits de crue ou d'étiage** : (par exemple les valeurs de débits d'une crue de période de retour de 100 ans) notamment dans la perspective de dimensionner des ouvrages et des aménagements dans le lit des cours d'eau.

4. **La détermination des conséquences d'aménagements anthropiques** : (barrages, occupation des sols...) sur l'hydrologie des cours d'eau.

# Chapitre **1**

## Principes des réseaux de neurones

### 1-Principes du neurone Biologique:

Le neurone biologique est une cellule vivante spécialisée dans le traitement des signaux électriques. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux électriques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone.

Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu vont fournir un courant en sortie (figure 1).

La structure d'un neurone se compose de trois parties :

- La somma (corps cellulaire): ou cellule d'activité nerveuse, au centre du neurone.
- L'axone : attaché au somma qui est électriquement actif, ce dernier conduit l'impulsion conduite par le neurone.
- Dendrites : électriquement passives, elles reçoivent les impulsions d'autres neurones.

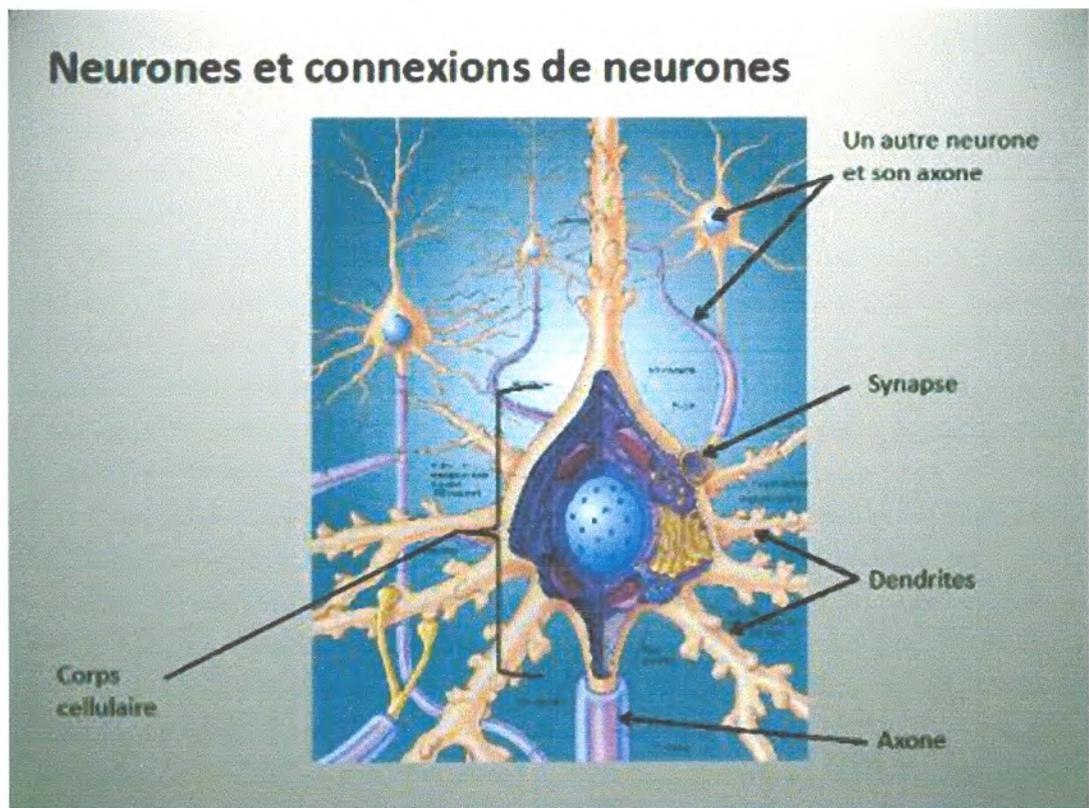


Fig.1. Un Neurone Biologique

La figure 02 présentent deux modèles de neurones ,un neurone biologique et un neurone artificiel.

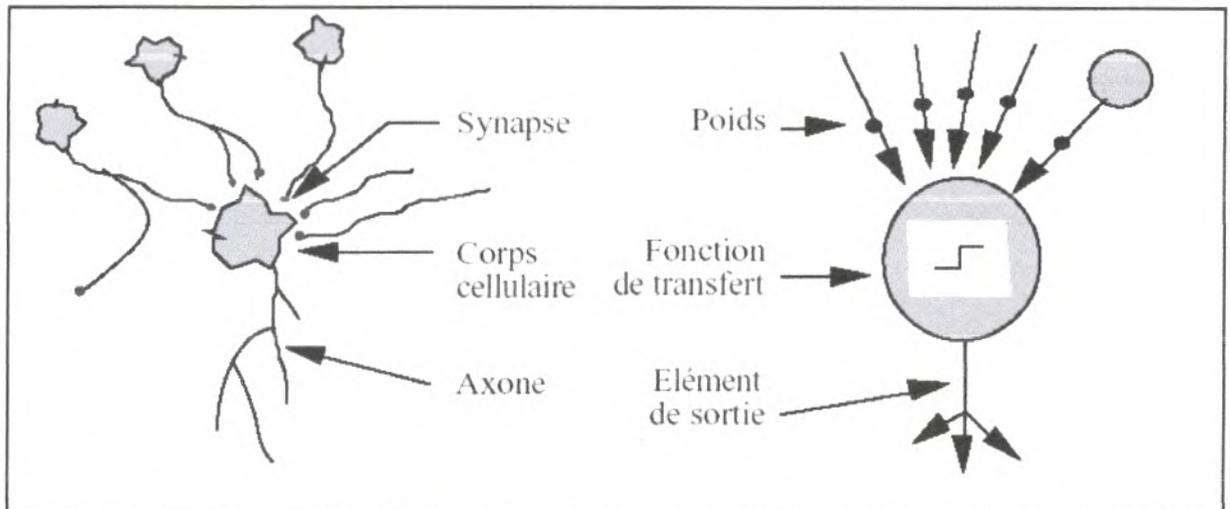


Fig.02. La Comparaison Entre Un Neurone Biologique Et Un Neurone Artificiel

## 2- Historique des réseaux de neurones :

Les réseaux de neurones artificiels sont construits sur ce paradigme biologique. Ainsi les neurologues Warren Sturgis McCulloch et Walter Pitts menèrent les premiers travaux sur les réseaux de neurones à la suite de leur article fondateur « What the frog's eye tells to the frog's brain » [McCulloch et Pitts, 1943].

Ils constituèrent un modèle simplifié de neurone biologique appelé neurone formel. Ils montrèrent théoriquement que les neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes.

Le premier succès apparut en 1957 quand Frank Rosenblatt [Rosenblatt, 1958] inventa le premier modèle artificiel nommé le Perceptron. C'était le premier système qui pouvait apprendre par expérience, y compris lorsque son instructeur commettait des erreurs.

Puis en 1960 Widrow et Hoff proposèrent un autre modèle, aussi basé sur les travaux de McCulloch et Pitts, nommé l'Adaline (ADaptive LInear NEuron).

Au contraire de l'orientation psycho-physiologique du Perceptron, l'Adalin est développé dans le contexte de traitement du signal.

En 1969 Marvin Lee Minsky et Seymour Papert publièrent un ouvrage nommé *Perceptrons* [Minsky et Papert, 1969] et montrèrent les limitations théoriques des modèles de Perceptron et plus particulièrement de l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils étendirent implicitement ces limitations à tous modèles de réseaux de neurones artificiels.

Seulement quelques chercheurs continuèrent alors leurs efforts. Les plus célèbres furent Teuvo Kohonen, Stephan Grossberg, James Anderson, et Kunihiko Fukushima. Une révolution survient alors dans les années 80 quand on a découvert d'importants résultats théoriques. Les plus célèbres sont la rétro-propagation d'erreur inventée en 1986 et la nouvelle génération de réseau de neurone: le perceptron multicouche proposé par Werbos. Dans la section suivante une définition formelle des réseaux de neurones est présentée.

### 3- Principe du neurone formel :

Dans ce paragraphe nous présentons d'abord la structure des réseaux de neurones, puis leur fonctionnement en termes d'apprentissage.

#### 3-1-Structure des réseaux de neurones :

En général on peut dire que les réseaux de neurones peuvent être caractérisés comme des modèles de calculs apprenant, généralisant et organisant des données.

Un réseau de neurone artificiel contient un grand nombre d'unités, les neurones, qui communiquent entre eux en s'envoyant des signaux à travers de liens, appelées connexions synaptiques. En général le système de neurone possède trois types de neurones ( figure 03) :

- les neurones d'entrée qui reçoivent les données ;
- les neurones de sortie qui envoient les données par la sortie du système ;
- les neurones cachés, dont les signaux d'entrée et de sortie demeurent dans le système.

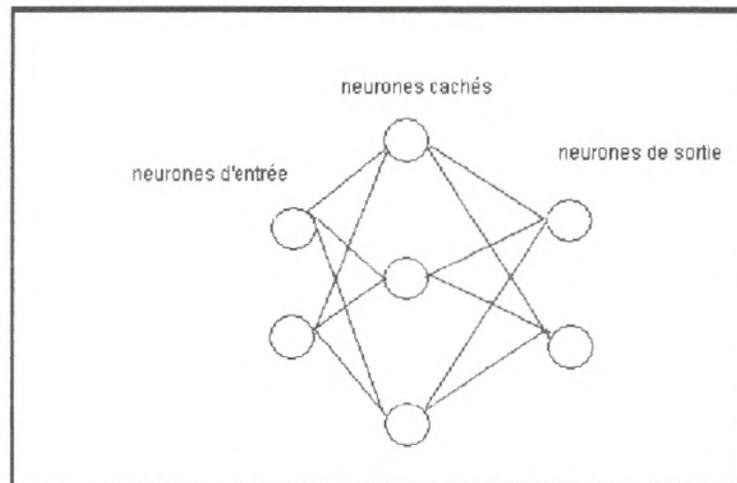


Fig.03. Un schéma simple d'un réseau de neurone

Dans les réseaux de neurones artificiels on utilise une modélisation mathématique du neurone biologique, appelé neurone formel. Chaque neurone reçoit des valeurs d'entrées (ou des signaux d'entrée) par son neurone voisin et les utilise pour calculer le signal de sortie qui se propage par les autres neurones. En concordance avec ce processus on doit ajuster les poids des connexions synaptiques.

Sur la figure (04) on peut voir la structure d'un neurone artificiel. Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie.

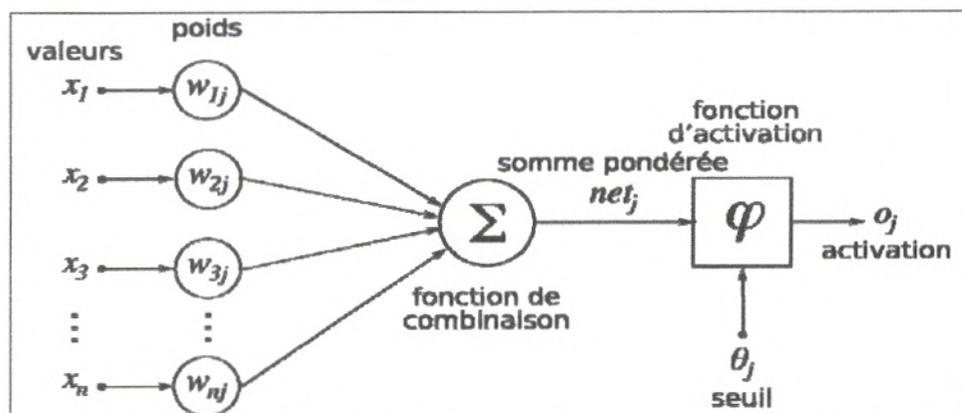


Fig.04. La structure d'un neurone artificiel

(Structure d'un neurone artificiel. Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie) Un neurone formel est une représentation mathématique et informatique d'un neurone biologique.

**3-2-Modèle de neurone formel :**

L'unité de traitement élémentaire dans un réseau connexionniste est appelée neurone formel C'est un model mathématique très simple. Ils sont appelés neurones formels pour leur similitude grossière avec les neurones biologiques.

Donc nous caractérisons un neurone par trois concepts son état, ses connexions avec d'autres neurones et sa fonction de transfert.

- ❖ Un neurone artificiel est un élément qui possède un état interne. il reçoit des signaux qui lui permettent éventuellement de changer d'état .cet état peut être par exemple 0 ou 1 où 0 sera interprété comme l'état inactif et 1 état actif .

Un neurone possède une fonction qui lui permet de changer d'état en fonction des signaux qu'il reçoit c'est sa fonction de transfert, le tableau (01) présente les fonctions les plus utilisées par les neurones formels.

**Tableau -1- Les différentes fonctions d'activation pour les neurones**

Nom de la fonction	Relation entrée/sortie	Forme
seuil	$a = \begin{cases} 0 & \text{si } n < 0 \\ 1 & \text{si } n \geq 0 \end{cases}$	
seuil symétrique	$a = \begin{cases} -1 & \text{si } n < 0 \\ 1 & \text{si } n \geq 0 \end{cases}$	
linéaire	$a = n$	
linéaire saturée	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } 0 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$	
linéaire saturée symétrique	$a = \begin{cases} -1 & \text{si } n < -1 \\ n & \text{si } -1 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$	
linéaire positive	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } n \geq 0 \end{cases}$	
sigmoïde	$a = \frac{1}{1 + e^{-n}}$	
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
compétitive	$a = \begin{cases} 1 & \text{si } n \text{ maximum} \\ 0 & \text{autrement} \end{cases}$	

L'état d'un neurone est fonction des états des neurones auxquels il est relié. Pour calculer l'état d'un neurone il faut donc considérer les connexions entre ce neurone et d'autres neurones et leur poids.

- ❖ Une connexion est un lien établi explicitement entre deux neurones .les connexions sont aussi appelées synapse en analogie avec les neurones biologiques.

Une connexion entre deux neurones a une valeur numérique associée appelée poids de connexion.

- ❖ Le poids de connexion **w<sub>ij</sub>** entre deux neurones **j** et **i** peut prendre des valeurs discrètes l'information qui traverse la connexion sera affectée par la valeur du poids correspondant.

#### 4-L'apprentissage des réseaux de neurones :

L'apprentissage d'un réseau de neurone peut être considéré comme une action de la mise à jour de ses poids des connexions synaptiques, afin de résoudre le problème demandé. L'apprentissage est la caractéristique principale des réseaux de neurones et il peut se faire de différentes manières et selon différentes règles. On peut distinguer trois types d'apprentissage : **l'apprentissage supervisé et l'apprentissage non-supervisé et l'apprentissage semi supervisé (par renforcement)**.

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux neuronaux.

Elle ne concerne cependant pas tous les modèles, mais les plus utilisés.

« *L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement* ».

Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage.

Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience. Il est souvent impossible de décider a priori des valeurs des poids des connexions d'un réseau pour une application donnée. A l'issue de l'apprentissage, les poids sont fixés : c'est alors la phase de test.

Certains modèles de réseaux sont improprement dénommés à apprentissage permanent. Dans ce cas il est vrai que l'apprentissage ne s'arrête jamais, cependant on peut toujours distinguer une phase d'apprentissage (en fait de remise à jour du comportement) et une phase de test. Cette technique permet de conserver au réseau un comportement adapté malgré les fluctuations et les erreurs dans les données d'entrées.

Au niveau des algorithmes d'apprentissage, il a été défini trois grandes classes selon que l'apprentissage est dit supervisé, non supervisé ou supervisé. Cette distinction repose sur la forme des exemples d'apprentissage.

Dans le cas de l'apprentissage supervisé, les exemples sont des couples (Entrée, Sortie associée) alors que l'on ne dispose que des valeurs (Entrée) pour l'apprentissage non supervisé (fig-05-).

Remarquons cependant que les modèles à apprentissage non supervisé nécessitent avant la phase d'utilisation une étape de labellisation effectuée l'opérateur, qui n'est pas autre chose qu'une part de supervision.

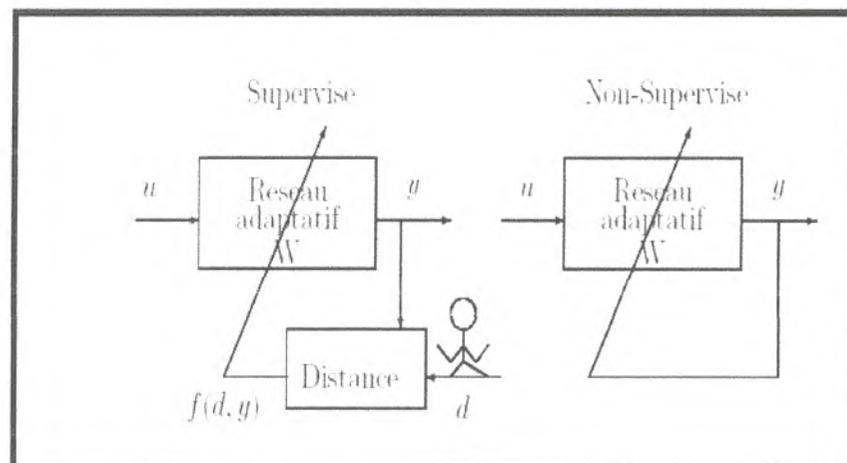


Fig.05. Apprentissage supervisé et Non-supervisé  
(V.Andronova 2006)

2. On entraîne maintenant un petit groupe des neurones supplémentaires qui doit diminuer l'erreur résiduelle du réseau. La règle d'apprentissage utilisée modifie les poids de ces neurones. Le neurone qui réussit le mieux est ensuite retenu, et intégré au réseau. Puis l'étape 1 est relancée, pour permettre au réseau de s'adapter à la nouvelle ressource.

#### e- La règle de correction d'erreurs :

Peut se caractériser par les étapes suivantes :

1. On commence avec des valeurs des poids de connexions qui sont pris au hasard.
2. On introduit un vecteur d'entrée de l'ensemble des échantillons pour l'apprentissage.
3. Si la sortie ou la réponse n'est pas correcte, on modifie toutes les connexions pour atteindre la bonne réponse ;

#### f- La règle de rétro-propagation :

Inventée par Rumelhart, Hinton et Williams en 1986 [Rumelhart, Hinton, et Williams, 1986]. Elle s'utilise pour ajuster les poids de la couche d'entrée à la couche cachée. Cette règle peut aussi être considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire et pour des réseaux multicouches. Les poids dans le réseau de neurones sont au préalable initialisés avec des valeurs aléatoires.

On considère ensuite un ensemble de données qui vont servir à l'apprentissage. Chaque échantillon possède ses valeurs cibles qui sont celles que le réseau de neurones doit à terme prédire lorsqu'on lui présente le même échantillon.

Dans la section suivante on présente les différentes topologies des réseaux de neurones, plus particulièrement les réseaux à couches et les réseaux récurrents.

### 5-La topologie des réseaux de neurones :

On appelle topologie des réseaux la façon dont les neurones sont connectés entre eux à travers les différentes couches. En général on peut distinguer deux grands groupes de réseaux de neurones selon leur topologie : **les réseaux à couches et les réseaux récurrents (fig-06)**.

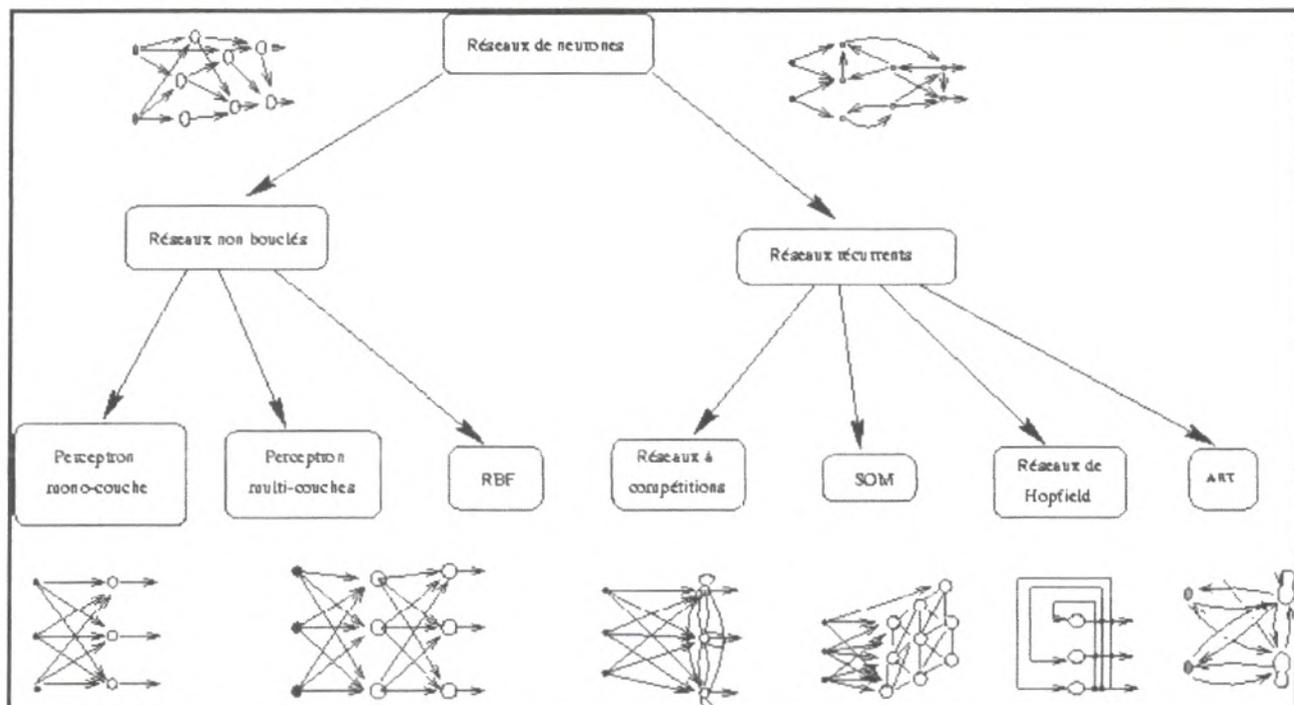


Fig.06. La topologie des réseaux de neurones

1. **les réseaux à couches (ou réseaux non récurrents) feed forward** : sont des réseaux de neurones dans lesquels l'information se propage couche par couche sans retour en arrière possible .

2. **les réseaux récurrents ou bien les réseaux feed back** sont des réseaux de neurones dans lesquels il y a une liaison vers l'arrière. Les connexions de ces réseaux forment des boucles.

Ainsi la fonction d'activation peut circuler le long de ces boucles et affecter le réseau pendant une période arbitrairement longue. Pour cette raison les comportements des réseaux récurrents sont potentiellement plus complexes que ceux des réseaux à couches.

## 5-1 Les réseaux à couches :

### 5-1-1 Introduction :

Les réseaux à couches peuvent se diviser en réseaux sans couches cachées et en réseaux avec une ou plusieurs couches cachées. Les réseaux sans couches cachées, sont les réseaux les plus simples.

Ils sont utilisables pour des problèmes de classification et d'approximation. Leur avantage est que l'apprentissage du réseau converge vers une solution optimale. Cela est dû au fait que c'est un système linéaire. Leur inconvénient est qu'ils peuvent seulement classifier ou approximer les problèmes linéaires et ne peuvent résoudre un problème non linéaire. La figure 07 décrit un exemple d'une classification en utilisant une fonction linéaire. On voit que dans le cas non linéairement séparable (figure de droite), on doit utiliser une fonction non linéaire, qui est dessinée sous la forme d'une courbe .

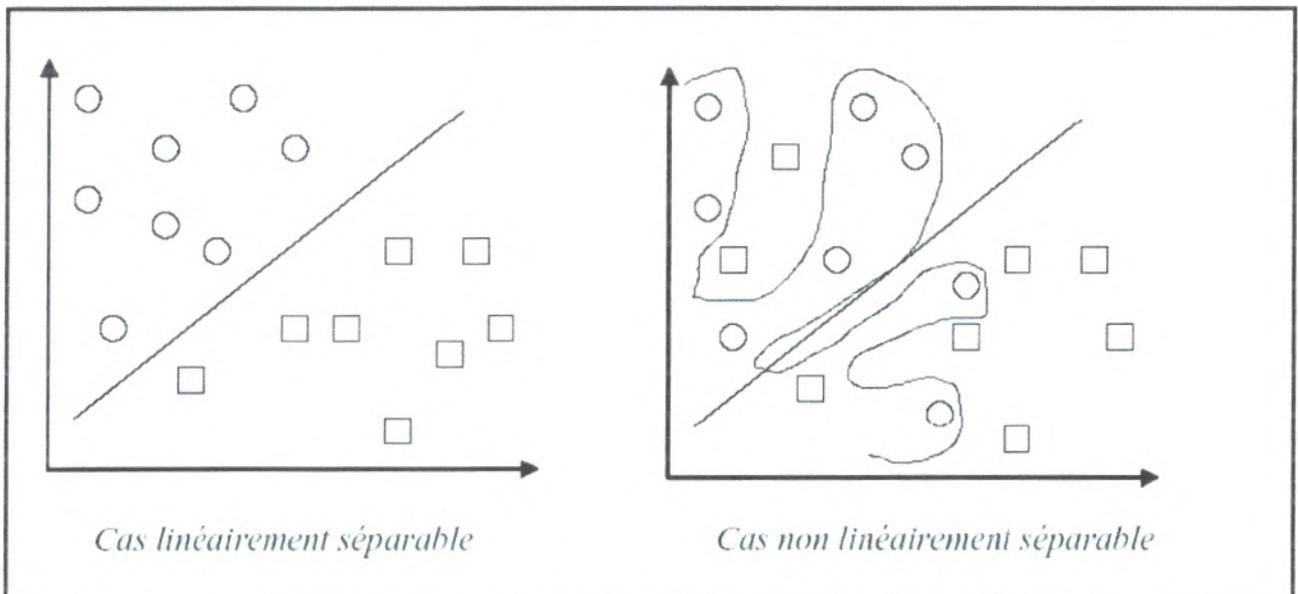


Fig.07. Une classification par une fonction linéaire

### 5-1-2 Le perceptron Monocouche :

L'exemple classique pour un système de neurones monocouches est le Perceptron monocouche, inventé par Rosenblatt [Rosenblatt, 1958]. C'est un modèle très simple, basé sur l'orientation psychophysique. Il ne dispose que deux couches :

- ❖ Une couche d'entrée qui s'appelle la rétine et qui est une aire sensorielle .
- ❖ Une couche de sortie qui donne la réponse correspondante à la simulation présentée à l'entrée.

Le fonctionnement est le suivant : une donnée est présentée au réseau en activant la rétine. L'activation se propage vers la couche de sortie où on peut noter la réponse du système. Cette réponse suit la formule suivante ou est la fonction d'activation utilisée :

$$y = \varphi \left( \sum_{j=1}^2 w_j x_j + \Theta \right)$$

La figure 08 montre la structure de Perceptron monocouche, avec une sortie  $y$  et deux entrées  $x_1$  et  $x_2$  qui forme la rétine du réseau.

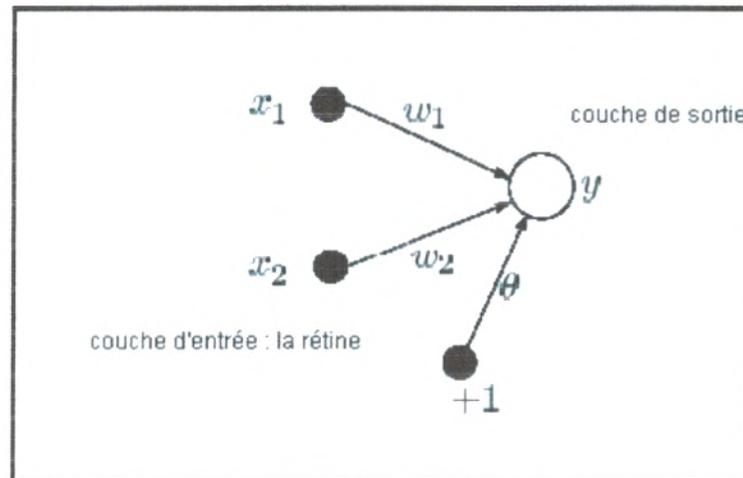


Fig.08. Un Perceptron monocouche

Ces réseaux suivent un apprentissage supervisé selon la règle d'apprentissage delta et la règle de correction d'erreurs. Les deux règles ajustent les poids et les seuils de la même manière. Pour chaque poids la valeur nouvelle est calculée par l'addition d'une correction de valeur ancienne :

$$w_j(\text{nouveau}) = w_j(\text{ancien}) + \Delta w_j$$

$$\Theta(\text{nouveau}) = \Theta(\text{ancien}) + \Delta \Theta$$

Pour illustrer le fonctionnement de ce type de réseau, nous allons utiliser l'exemple classique du problème de classification. Soit trois points A, B et C, positionnés sur une surface à deux dimensions, le réseau de neurone est chargé alors de classer les trois points suivant deux classes : la classe des '+' et la classe des 'o' (voir figure suivante). Le réseau de neurone fait office de fonction discriminante linéaire : c'est-à-dire qu'il calcule une fonction linéaire qui va séparer l'espace à deux dimensions en deux classes.

Supposons que le Perceptron est initialisé avec les poids suivants :  $w_1 = 1$ ,  $w_2 = 2$  et

$\theta = -2$ , et que l'on dispose aussi de deux échantillons :

- ❖ A, avec des valeurs  $x = (0.5, 1.5)$  et la cible  $d(x) = +1$  signifiant que le point A appartient à la classe des '+'.  
❖ B, avec des valeurs  $x = (-0.5, 0.5)$  et une cible  $d(x) = +1$  signifiant que le point A appartient à la classe des 'o'.

Si l'on effectue le calcul avec l'équation :  $\gamma = \varphi\left(\sum_{j=1}^2 w_j x_j + \Theta\right)$  on voit qu'il n'y a pas besoin de changer les poids : on obtient la valeur +1 comme pour la cible.

Maintenant si on représente au système un point C avec des valeurs  $x = (0.5, 0.5)$  avec une valeur de cible  $d(x) = +1$ , la sortie du réseau sera -1. On utilise la règle de correction d'erreurs, pour calculer les poids :  $\Delta w_1 = 0.5$  ,  $\Delta w_2 = 0.5$  et  $\Delta \Theta = 1$ . Les nouveaux poids sont alors :  $w_1 = 1.5$ ,  $w_2 = 2.5$ ,  $\Theta = -1$ . Ainsi le nouvel échantillon C est classifié correctement. La figure (09) illustre cette mise à jour des poids .

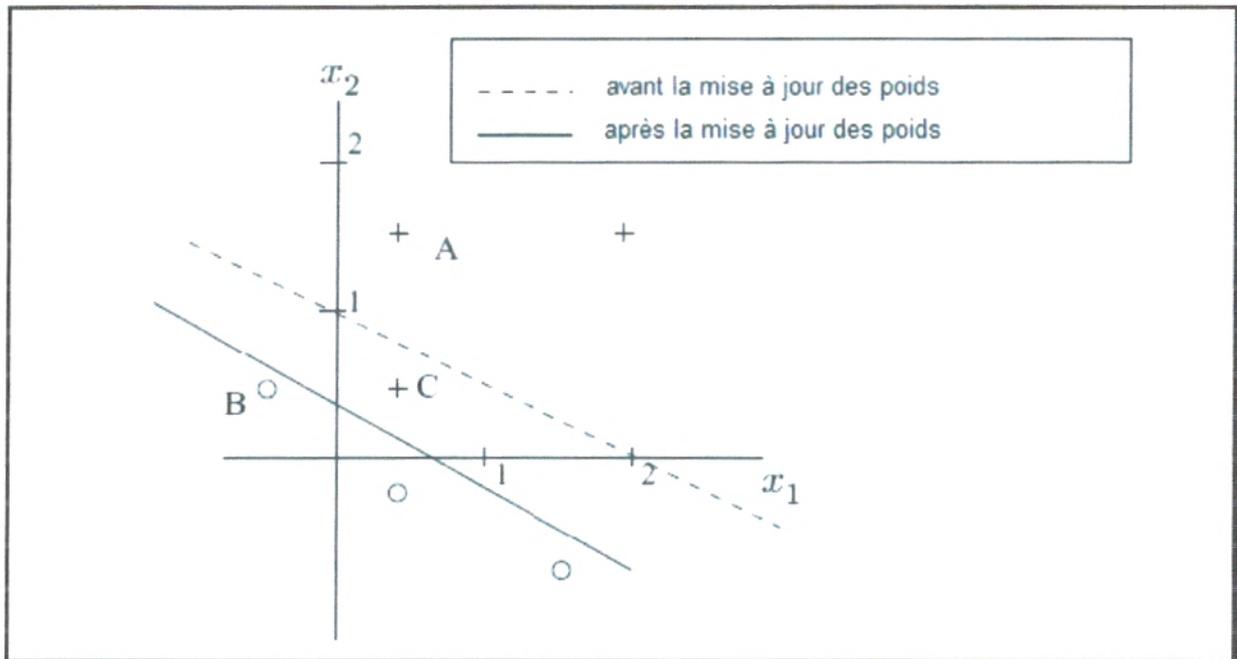


Fig.09. La Mise à jour des poids

Un réseau monocouche ne permettant pas de résoudre des problèmes non linéaires, les réseaux multicouches qui sont des systèmes non linéaires ont été inventés. Les réseaux de ce type possèdent trois sortes de couches :

- des couches d'entrée avec  $N_i$  des unités d'entrée .
- des couches cachées avec  $N_{h,1}$  unités. Les couches cachées démultiplient la puissance de calcul et permettent d'aborder des problèmes plus difficiles ;
- des couches de sortie avec  $N_o$  unités de sortie.

On peut voir la structure d'un tel réseau sur la figure suivante :

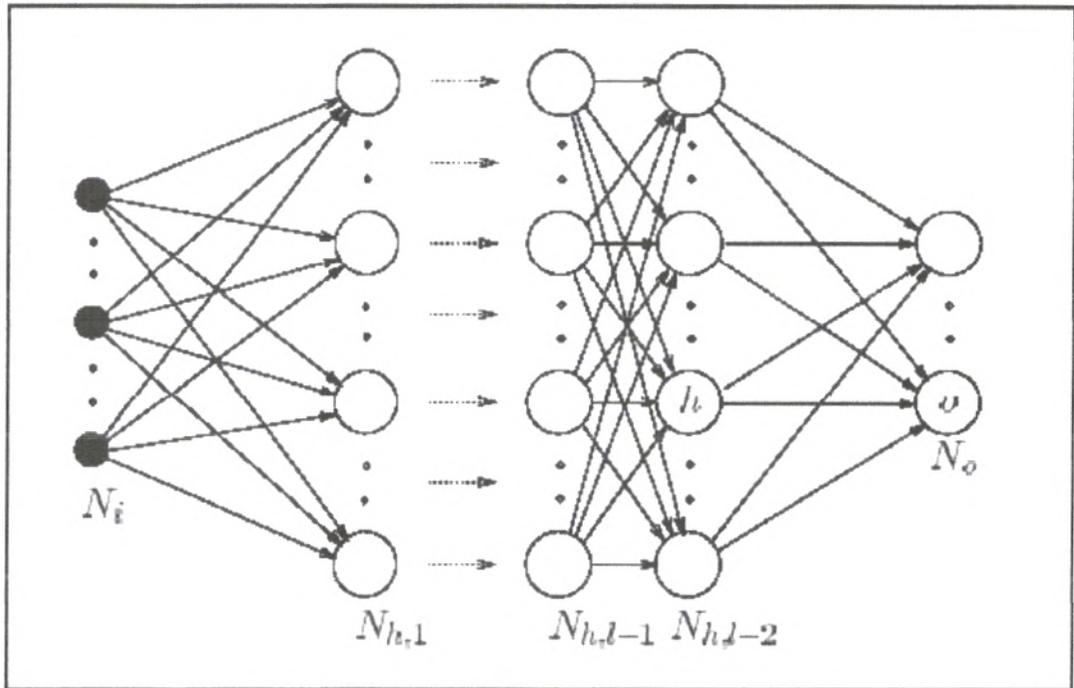


Fig.10. Un réseau multicouche avec  $l$  couches d'unité

Comme exemple de tel système, nous allons détailler le Perceptron multicouche et le réseau à fonction radiale (RBF).

### 5-1-3 -Le Perceptron multicouche :

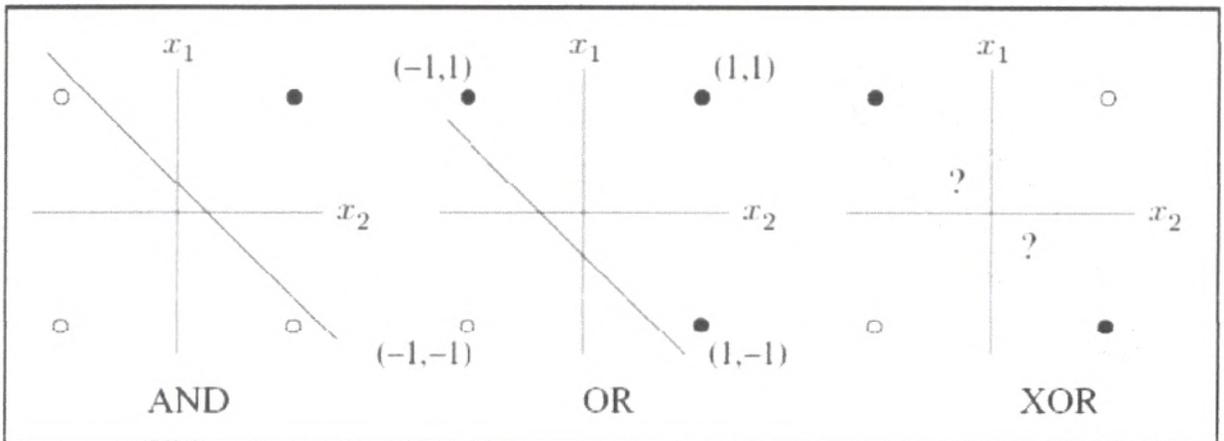
Est un modèle d'une plus grande capacité de calcul. Sa structure est composée d'une couche d'entrée, une couche de sortie, interprétée comme la réponse du réseau et d'une ou plusieurs couches intermédiaires dites « couches cachées ».

Un neurone d'une couche inférieure ne peut être relié qu'à des neurones des couches suivantes. Il suit un apprentissage supervisé et utilise une règle d'apprentissage par rétro propagation. En général, les neurones du Perceptron multicouche sont animés par une fonction d'activation non linéaire (au moins dans une des couches). Les choix classiques pour cette fonction sont :

- La fonction tangente hyperbolique :  $\varphi(x) = \tanh(x)$  (c'est le choix standard) .
- La fonction sigmoïde :  $\varphi(x) = \frac{1}{1 + e^{-x}}$

Pour illustrer le fonctionnement de ce type de réseau, nous allons utiliser l'exemple classique du problème de l'approximation de la fonction XOR (OU exclusif).

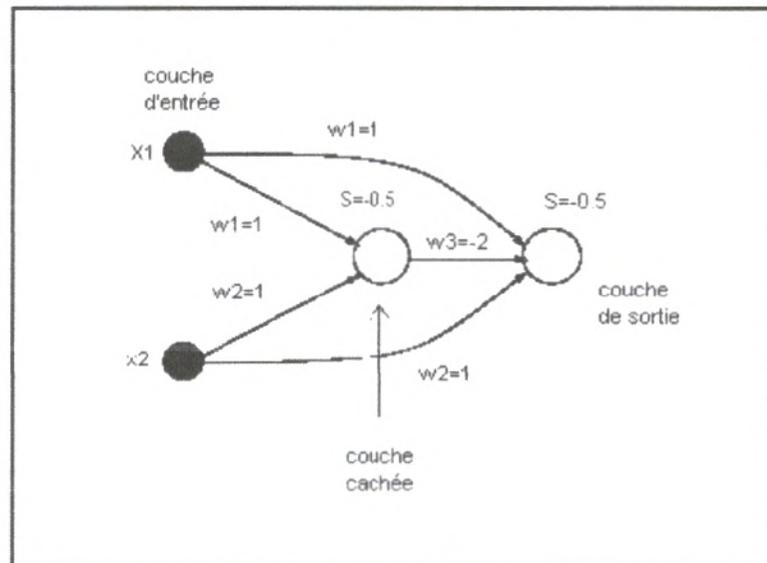
La figure 10 illustre le fait que l'on ne peut séparer linéairement l'espace des solutions de la fonction XOR. Au lieu d'un perceptron monocouche, on doit utiliser un perceptron multicouche.



**Fig.11. La Fonction logique AND,OR : Séparation linéaire.  
La Fonction logique XOR : Séparation non linéaire.**

On peut utiliser un Perceptron multicouche avec trois couches : une couche d'entrée avec deux neurones  $x_1$  et  $x_2$ , une couche cachée possédant un seul neurone et une couche de sortie possédant aussi un seul neurone. Si l'on respecte la table de vérité de fonction **XOR**, on peut déduire les valeurs des deux entrées et de la cible qui sont respectivement :  $x_1 = [0011]$ ,  $x_2 = [0101]$  et  $d(x) = [0110]$ .

La figure suivante montre une solution géométrique où la lettre **S** indique le seuil utilisé et **w** indique le poids des différentes couches :



**Fig.12. Le perceptron Multicouche**

#### 5-1-4 Le réseau à fonction radiale (RBF) :

Est à la même structure que le Perceptron multicouches, mais la fonction d'activation est une fonction de type Gaussienne. Ce réseau, à cause de son architecture, utilise le plus souvent la règle d'apprentissage de correction d'erreur et la règle par apprentissage compétitif.

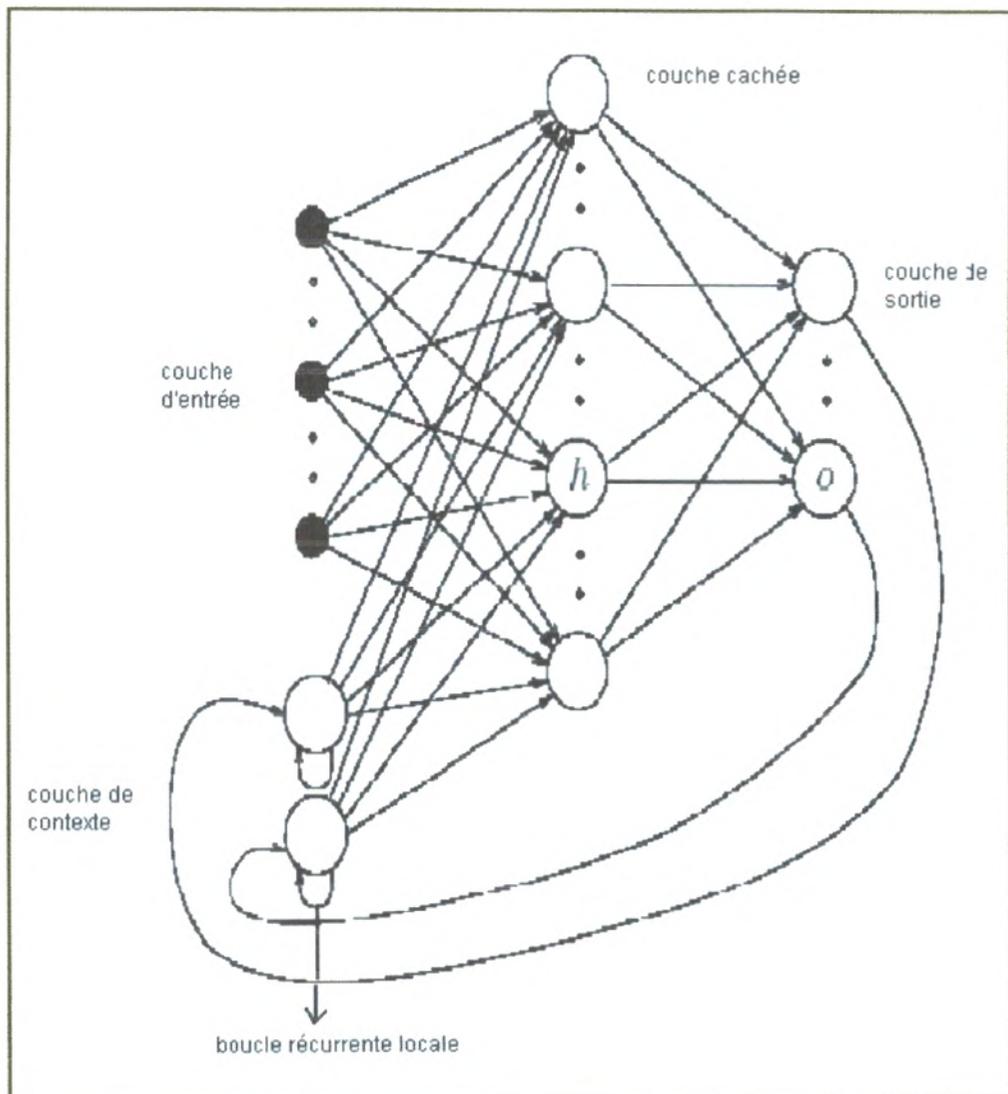
Il peut avoir un apprentissage qui combine en même temps l'apprentissage supervisé et l'apprentissage non supervisé. Ce réseau obtient des performances comparables ou supérieures à ceux du Perceptron multicouches. De plus leur apprentissage plus rapide et plus simple en font des outils de choix pour plusieurs types d'applications, dont la classification et l'approximation des fonctions.

Cependant, ce réseau n'a pas si grandes recherches que le Perceptron multicouches.

### 5-2-Les réseaux récurrents :

Les réseaux récurrents constituent la deuxième grande catégorie de réseaux de neurones, avec les réseaux type perceptron. Trois classes importantes de réseaux récurrents sont présentées dans ce paragraphe : **les réseaux récurrents à couches** (le réseau de Elman et le réseau de Jordan), **les réseaux à compétition** (réseaux ART et réseaux de Kohonen, « Self-organisation mapping ») et **les réseaux à connexions symétriques** (réseau de Hopfield).

**Le réseau de Jordan** [Jordan, 1986a, 1986b] est le réseau récurrent le plus ancien. On présente la structure de ce réseau sur la figure (13) :



**Fig.13. Le réseau de Jordan**

Ce réseau a pour but d'effectuer une séquence d'actions par rapport à une tâche donnée par l'utilisateur.

La tâche est constante durant l'exécution de la séquence ; le réseau doit toutefois retenir sa position dans la séquence. Pour mener sa tâche à bien, il lui faut donc une mémoire du contexte représentée par une couche nommée « couche de contexte ». Les neurones de sorties sont reliés vers cette couche. Le nombre de neurone de cette couche dépend du nombre des couches de sortie. Elle retient l'état du réseau au temps précédent et sa propre activation par une boucle récurrente locale. Il en résulte que la couche de contexte retient une trace des événements passés.

L'apprentissage a lieu aussi bien au niveau des connexions entre les couches d'entrée et les couches cachées qu'entre les couches cachées et les couches de sortie. Ainsi on peut utiliser toutes les règles d'apprentissage décrit par un Perceptron multicouche pour entraîner ce réseau.

**5-2-1 Le réseau d'Elman :** a été introduit par Elman à 1990 [Elman, 1990] et est présenté sur la figure (14).

Ce réseau est très semblable au réseau de Jordan, mais son architecture est plus adaptée au traitement de séquence structurée. Là où le réseau de Jordan bouclait ses sorties sur ses entrées, le réseau d'Elman fait boucler sa couche cachée sur elle-même. L'effet de cette boucle est de recopier sans autre traitement la valeur de la couche cachée dans la couche de contexte, de telle sorte que l'état de la couche de contexte à un temps  $t$  est égal à l'état de la couche cachée au temps  $(t - 1)$ . Dans le réseau d'Elman, comme dans le réseau de Jordan, cette boucle récurrente permet de retenir une trace d'événements passés. Pour l'apprentissage du réseau on applique une rétro propagation classique pour corriger les poids, sans tenir compte de la recopie de l'activation de la couche cachée vers la couche de contexte.

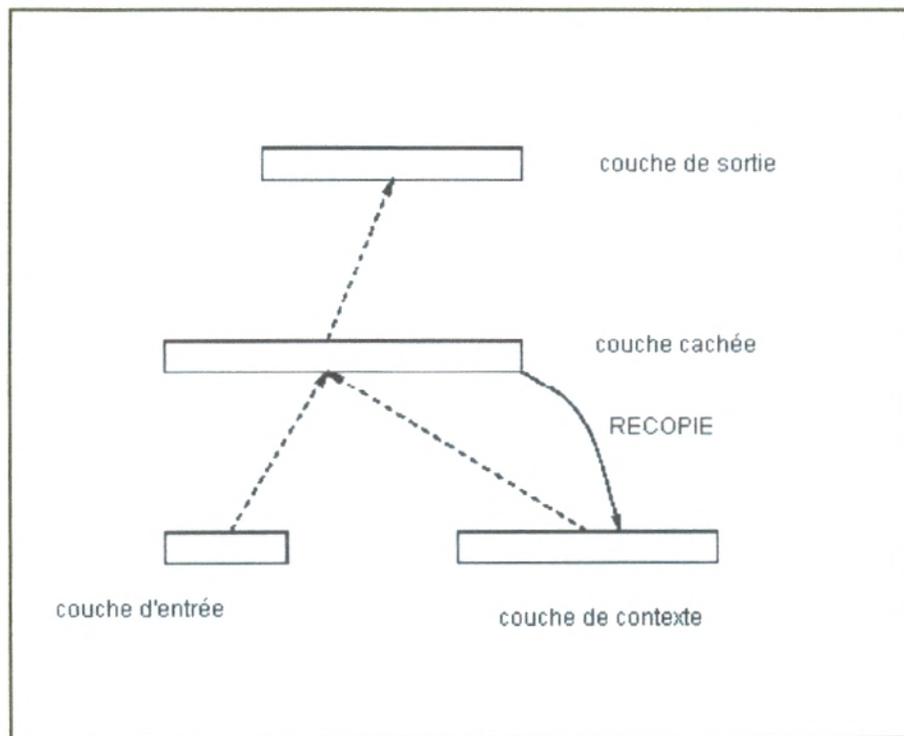


Fig.14. Le réseau de ELMAN

**5-2-2 Les réseaux à compétition :**

Sont composés d'une couche de neurones qui reflète passivement les données d'entrée présentées au réseau, et une couche de neurones de sortie en compétition.

On utilise le réseau de la façon suivante : une donnée d'entrée est présentée au réseau, provoquant des réponses variées de la part des neurones de sortie.

La compétition s'installe alors entre ces derniers, et prend la forme d'un combat d'influence qui doit éventuellement se stabiliser, grâce à la force des liens inhibiteurs. A la fin de la compétition, le ou les neurones de sortie les plus activés sont déclarés "vainqueurs". Des exemples de réseaux ART (Adaptive Resonance Theory) et de réseaux de Kohonen (Self-organisation mapping) sont présentés ci-après.

**5-2-3 Les réseaux ART :**

Sont des réseaux à compétition. Le problème majeur qui se pose dans ce type de réseaux est le dilemme stabilité/plasticité. En effet dans un apprentissage par compétition, rien ne garantit que les catégories formées vont rester stable. La seule possibilité pour assurer une stabilité, serait que le taux d'apprentissage tende vers zéro, mais alors le réseau perd sa plasticité. C'est pour résoudre ce problème, qu'on utilise les réseaux ART. Les valeurs de poids ne sont adaptées que s'il y a une approximation suffisante entre l'entrée du réseau et le prototype déjà connu par le réseau. Alors il existe une résonance. Sinon, l'entrée du système est très éloignée du prototype, on fonde alors une nouvelle classe. Le mode d'apprentissage peut être supervisé ou non. On va présenter deux types de ces réseaux :

**a- ART-1 :**

Est un système binaire dont la fonction est d'associer à une donnée d'entrée binaire un seul neurone de sortie. Les autres membres de cette famille ne sont pas si limités. Le but le plus connu de ce réseau est de modéliser la reconnaissance d'un objet perçu, ainsi que de stocker une information.

Mais ces réseaux sont très sensibles aux bruits qui apparaissent sur les données.

Pour y échapper, on doit mettre en place une couche de filtrage.

**b- ART-2 :**

Traite des valeurs continues, mais il a le même but que le réseau précédent. Cependant les calculs utilisés sont beaucoup plus difficiles à comprendre.

**5-2-4 : Les réseaux de Kohonen :(Self organisation mapping) utilisent la carte de Kohonen.**

Cette carte est composée de deux couches dont la première constitue l'entrée du réseau et la seconde la sortie. On peut voir la structure de cette carte sur la figure ci-après. Les neurones de cette carte sont disposés en une topologie déterminée. Plusieurs topologies sont possibles, par exemple une carte carrée ou une carte rectangulaire.

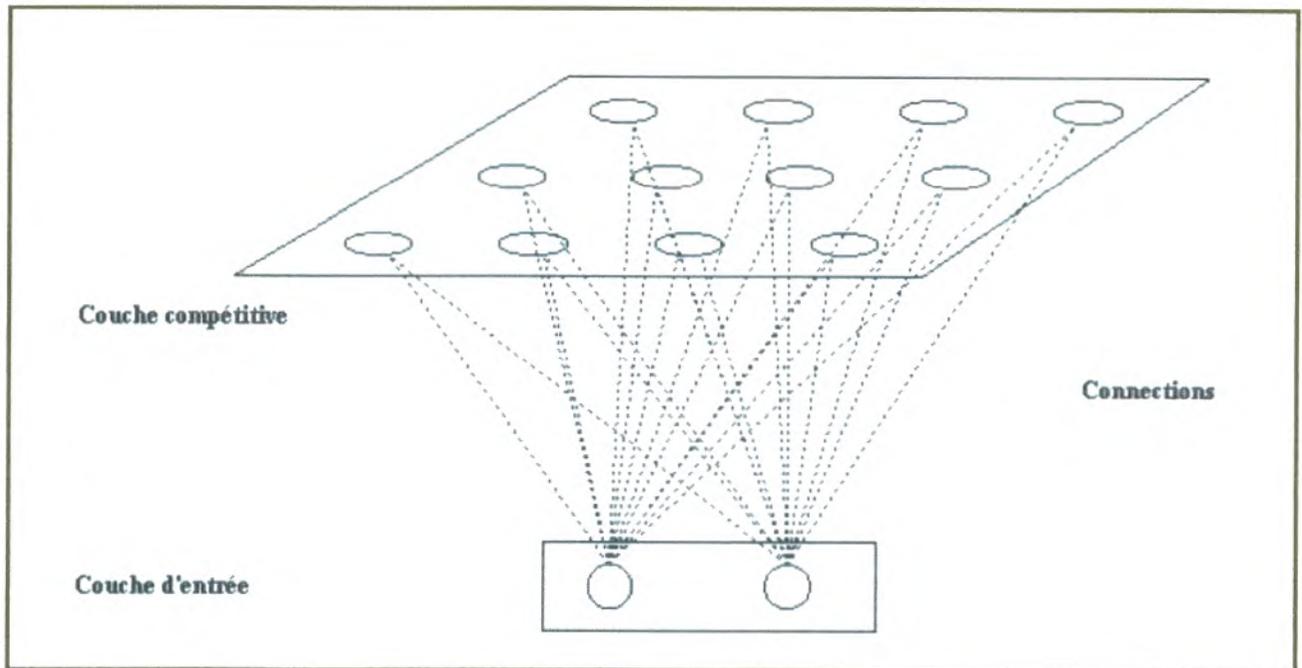


Fig.15. La structure de la carte de kohonen

Enfin dans les réseaux à **connexions symétriques**, il est possible de comprendre un système complexe, non pas en s'attardant sur le comportement individuel de ses composants, mais en étudiant le comportement collectif du système dans son ensemble. Comme exemple, on peut indiquer le **réseau de Hopfield**. Ce réseau est potentiellement utile en pratique, dès qu'il est possible de dicter par apprentissage les états stables du réseau. Dans une application, l'état d'activation initial du réseau est fixé de façon à exprimer le problème à résoudre. Le réseau évolue ensuite par une succession de propagations synchrones, jusqu'à un point fixe.

Cet état stable est alors interprété comme le résultat du calcul (et donc la solution du problème).

On remarque qu'en général, tous les neurones du réseau participent à la description du problème et à sa résolution. Ainsi, le réseau de Hopfield ne contient pas de neurones cachés [Jodouin, 1994].

Nous venons de décrire les différentes topologies des réseaux de neurones. On a montré aussi quelle est la différence entre les réseaux à couches et les réseaux récurrents. Les réseaux récurrents s'utilisent quand on introduit un cycle, c'est-à-dire il existe une liaison rétroactive entre les différentes couches. Il y a aussi une propagation d'information jusqu'à l'obtention d'une valeur stable. Les réseaux à couches ne présentent pas de cycle. Ils ont une structure simple. Cependant ils peuvent résoudre la plupart des problèmes complexes.

## 6- Dimensionnement d'un réseau de neurone :

Pour paramétrer un réseau des neurones on doit déterminer les variables suivantes :

- le nombre de neurones d'entrée .
- le nombre de couches cachées et le nombre de neurones cachés .
- le nombre d'échantillons d'apprentissage.

Le nombre des neurones d'entrée correspond au nombre des variables du vecteur d'entrée utilisée pour résoudre le problème donné. Cependant il n'y a pas une suggestion systématique pour déterminer ce nombre. La sélection de ce paramètre doit être incluse dans le modèle de construction du processus.

Idéalement on choisit un petit nombre pour les neurones d'entrée.

La couche cachée et les neurones cachés ont un rôle important pour l'application correcte des réseaux de neurones. Ce sont les neurones de la couche cachée qui prennent le modèle des données, effectuent une mise en correspondance non linéaire complexe entre les variables d'entrée et les variables de sortie.

La plupart des scientifiques utilisent dans leurs réseaux de neurones seulement une couche cachée. Cependant une couche cachée nécessite un nombre très grand des neurones cachés qui n'est pas désirable. Cela provoque un temps d'apprentissage et une capacité de généralisation du réseau très mauvais.

En général pour déterminer le nombre des neurones cachés, on réalise des expériences et des essais et parmi eux on choisit le nombre qui provoque la plus petite erreur.

Cette erreur peut être mesurée et est appelée **erreur moyenne**. Elle est causée par les échantillons d'apprentissage. C'est l'erreur mesurée durant le processus d'apprentissage. Elle

est calculée par l'expression suivante :  $E_{\text{apprentissage}} = \frac{1}{P_{\text{apprentissage}}} \sum_{p=1}^{P_{\text{apprentissage}}} E^p$

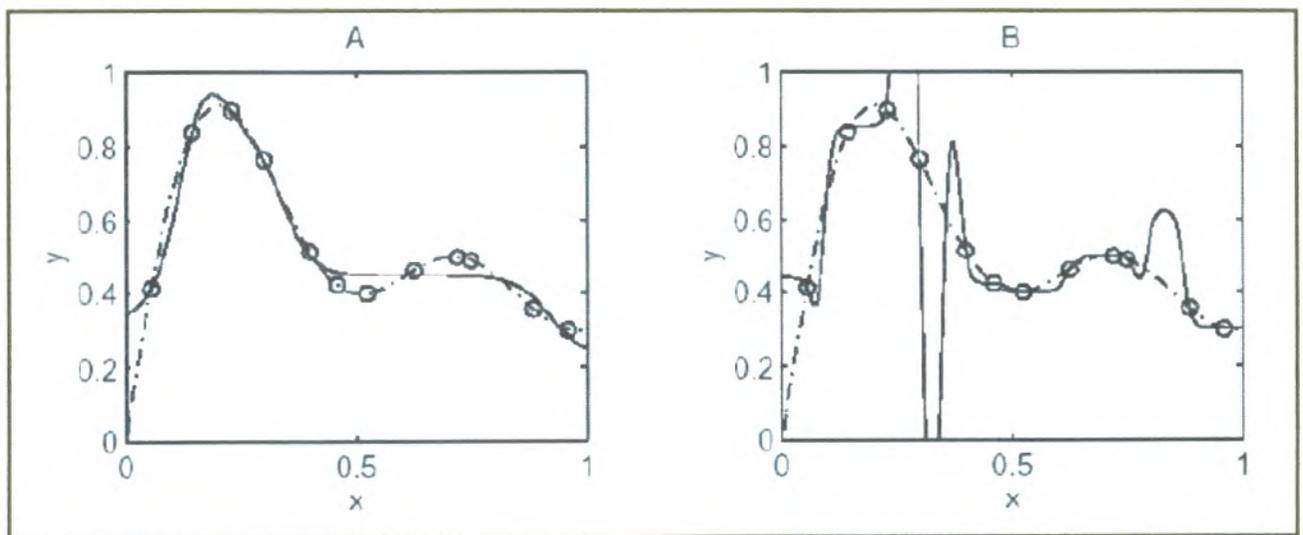
Où ( $P_{\text{apprentissage}}$ ) est l'ensemble des échantillons d'apprentissage et  $E^p$  est la différence entre la sortie désirée et la sortie obtenue par des échantillons d'apprentissage :

$$E^p = \frac{1}{2} \sum_{0=1}^{N_0} (d_0^p - y_0^p)^2$$

La différence entre la sortie désirée et la sortie obtenue peut être minimisée si l'on a un grand nombre d'échantillons. On peut définir l'erreur moyenne d'essai par l'expression suivante :

$$E_{\text{essai}} = \frac{1}{P_{\text{essai}}} \sum_{p=1}^{P_{\text{essai}}} E^p$$

Prenons maintenant l'exemple de la fonction  $y = f(x)$  devant être approximée par un réseau non récurrent. Pour cet exemple Le réseau de neurone possède une entrée, 5 neurones cachés avec une fonction d'activation sigmoïde, et un neurone de sortie avec une fonction linéaire. Si on change le nombre de neurones cachés (de 5 à 20 neurones), on peut voir quel sera l'effet sur la Figure (16) :



**Fig.16. L'effet de nombre de neurone caché sur la performance du réseau**

La ligne pointillée donne la fonction désirée et la ligne continue, l'approximation faite par le réseau. Les cercles sont les échantillons d'apprentissage. La partie A de la Figure décrit le comportement du réseau avec 5 neurones cachés et la partie B de la même figure décrit le comportement du réseau avec 20 neurones cachés.

Cet exemple montre qu'un grand nombre de neurones cachés mène vers une erreur d'apprentissage ( $E_{\text{apprentissage}}$ ) faible, mais pas nécessairement vers une erreur d'essai ( $E_{\text{essai}}$ )

faible. Sur la figure suivante on peut voir les taux moyens d'erreur d'apprentissage et d'essai comme une fonction de nombre des neurones cachés :

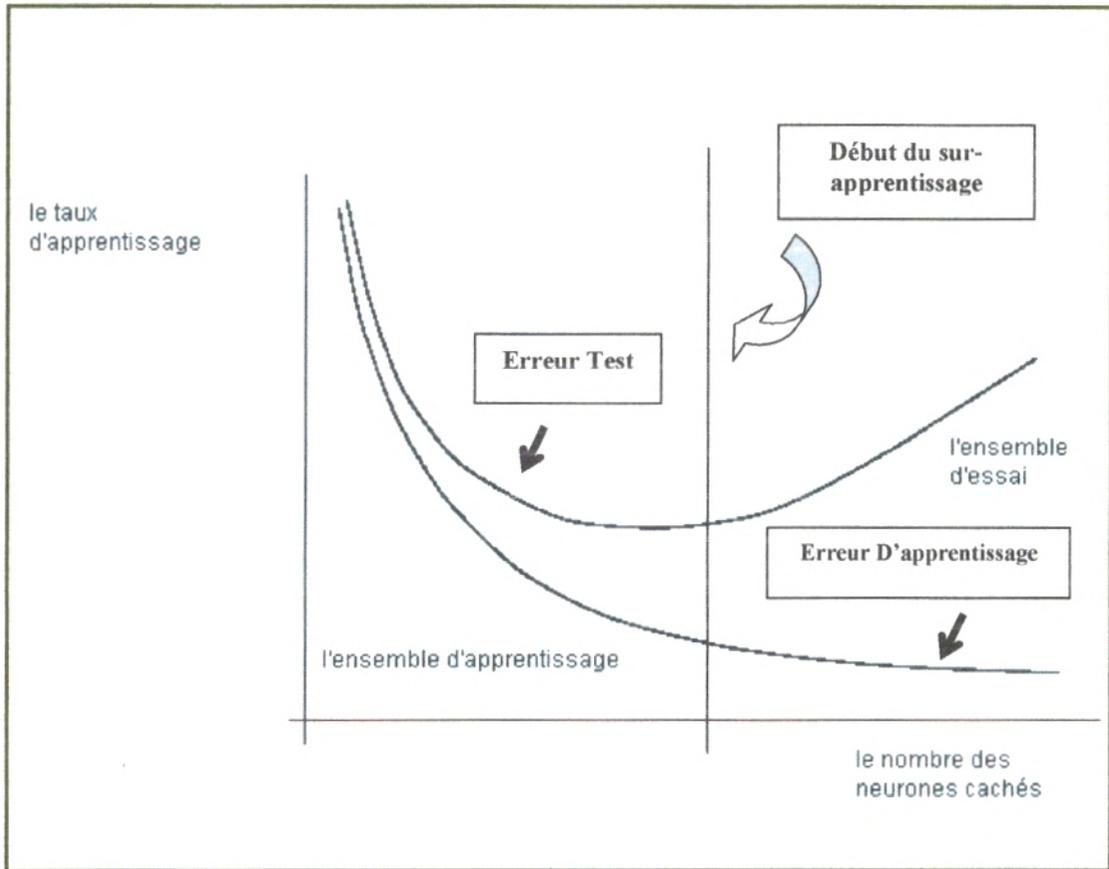


Fig -17- Evolution de l'erreur d'apprentissage et de test

Nous allons maintenant aborder la problématique du nombre d'échantillons d'apprentissage. Nous reprenons le même exemple en modifiant cette fois le nombre d'échantillons. On fait varier le nombre des échantillons d'apprentissage de 4 à 20.

Le réseau est entraîné avec ces échantillons. L'apprentissage se termine lorsque l'erreur cesse de diminuer. On peut voir sur cette figure l'effet de ce changement.

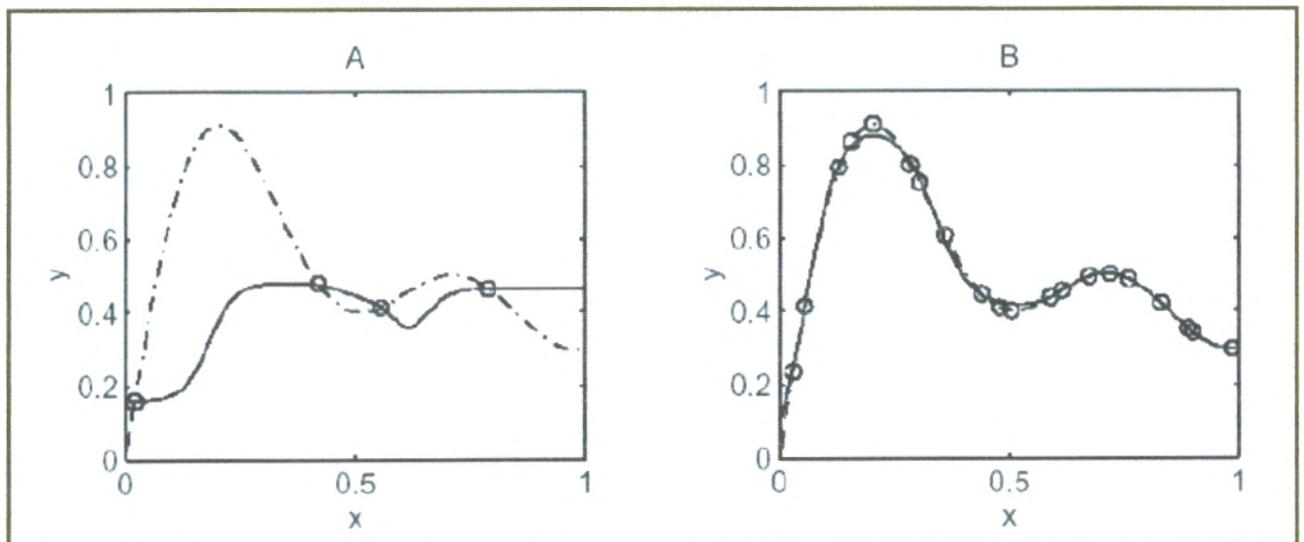
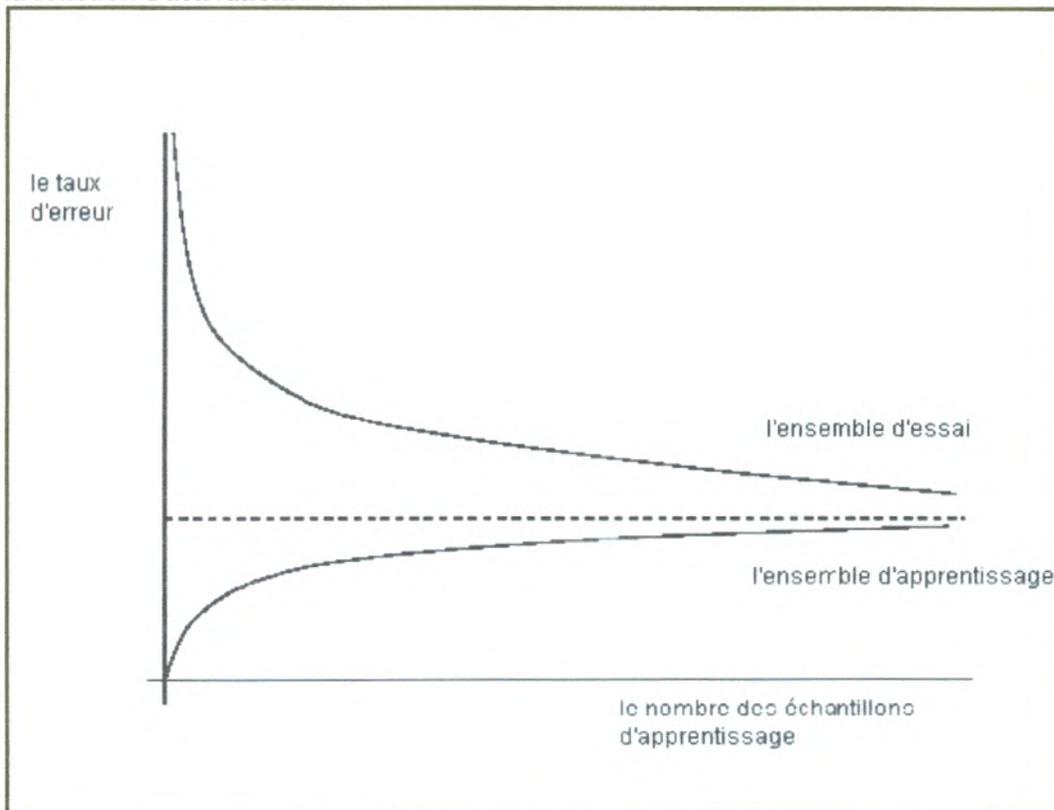


Fig -18- La diminution de l'erreur pour le Réseau

La ligne pointillée donne la fonction désirée, la ligne continue donne l'approximation faite par le réseau et les cercles sont les échantillons d'apprentissage. La partie A de cette figure décrit le réseau avec 4 échantillons d'apprentissage et la partie B de la même figure décrit le réseau qui utilise 20 échantillons d'apprentissage. Avec 4 échantillons d'apprentissage, l'erreur d'apprentissage ( $E_{\text{apprentissage}}$ ) est faible (les sorties de réseau coïncident idéalement avec les échantillonnages d'apprentissage), mais l'erreur d'essai ( $E_{\text{essai}}$ ) est importante. L'approximation obtenue avec un nombre d'échantillons égale à 20 est plus efficace. En effet l'erreur d'apprentissage ( $E_{\text{apprentissage}}$ ) est plus grande, alors que l'erreur d'essai  $E_{\text{essai}}$  est plus petite.

La figure (19) montre le taux moyen d'erreur d'apprentissage et d'essai. L'erreur d'apprentissage augmente avec la grandeur des échantillons d'apprentissage et au contraire l'erreur d'essai diminue avec cette augmentation d'erreur d'apprentissage. Mais une erreur d'apprentissage faible ne garantit pas la bonne performance du réseau. Le taux d'erreur dépend du nombre de neurones cachés et de la fonction d'activation.



**Fig -19- L'effet de la grandeur des échantillons d'apprentissage sur le taux d'erreur**

Pour qu'un réseau de neurone soit performant et réalise des calculs corrects, on doit bien organiser sa structure et bien le paramétrer. Ce paramétrage est empirique : à partir d'essais on choisit quel doit être le nombre exact des paramètres décrivant ce réseau : le nombre des couches d'entrée, des couches cachées et des neurones cachés, ainsi que le nombre des échantillons d'apprentissage.

## 7- Les limitations d'un réseau de neurone :

Les réseaux de neurones peuvent implémenter n'importe quelle fonction non linéaire jusqu'à un certain degré de fiabilité. Ils peuvent implémenter des fonctions dynamiques et posséder n'importe quel nombre d'entrée et de sortie. Nous allons lister quels sont les avantages et les inconvénients des réseaux de neurones artificiels.

**7- 1- Les avantages d'utilisation des réseaux de neurones sont :**

- Une tolérance à l'incertitude très élevée ;
- Etant une multiple copie d'unité simple (les neurones), ils sont donc facilement extensibles.
- Une facilité d'application car ne nécessitant pas une compréhension approfondie.
- Un choix de types, d'architecture et de fonction d'activation de réseaux diverses.
- Ils possèdent une capacité de généraliser.

**7- 2- Les inconvénients des réseaux de neurones sont :**

- Une facilité d'application donnant lieu à de nombreuses implémentations et des choix pas toujours justifiés.
- Malgré une solide base théorique, le choix du réseau appartient souvent à l'utilisateur car il n'existe pas de guide approprié et reconnu.
- la surface d'erreur des réseaux complexes possède beaucoup de sommets (des maximums locaux) et des vallées (des minimums locaux). A cause de leur nature non linéaire ils peuvent être piégé dans un minimum local où les performances des réseaux sont nettement sous optimales. Pour éviter les minima locaux on doit envisager les solutions suivantes :

- 1- Modifier le pas d'apprentissage du réseau pour pousser le réseau hors des minima locaux. C'est un paramètre qui règle la taille de la surface d'erreur ;
- 2- Entraîner un même réseau à partir de plusieurs choix initiaux de poids, pour ensuite ne garder que le meilleur d'entre eux.

Les réseaux de neurones artificiels ont besoin de cas réels servant d'exemples pour leur apprentissage. Ces cas doivent être d'autant plus nombreux que le problème est complexe et que sa topologie est peu structurée. Par exemple, on peut optimiser un système neuronal de lecture de caractères en utilisant le découpage manuel d'un grand nombre de mots écrits à la main par de nombreuses personnes. Chaque caractère peut alors être présenté sous la forme d'une image brute, disposant d'une topologie spatiale à deux dimensions, où d'une suite de segments presque tous liés. La topologie retenue, la complexité du phénomène modélisé, et le nombre d'exemples doivent être en rapport. Sur un plan pratique, cela n'est pas toujours facile car les exemples peuvent être soit en quantité absolument limitée ou trop onéreux à collecter en nombre suffisant.

Les performances du réseau de neurones sont très souvent liées à son architecture. Le choix de l'architecture est aussi un problème difficile à résoudre. On ne peut pas choisir au hasard le nombre de neurones dans la couche cachée ou de la couche intermédiaire. Seule l'expérience permet de répondre à cette question car il n'y a pas une théorie dans ce domaine. Avec un nombre limité de neurones, le réseau ne sera pas performant sur l'apprentissage tandis qu'avec un nombre important de neurones il sera difficile à entraîner. On juge la performance du réseau sur sa capacité à généraliser les résultats et non pas sur sa capacité à mémoriser les résultats. C'est pour cela qu'il n'est pas toujours profitable d'utiliser un réseau avec un nombre élevé des neurones.

Mais le choix de l'architecture n'est pas le seul problème qui se pose. La méthode d'apprentissage doit également être choisie de façon judicieuse. On parle alors de pédagogie d'apprentissage et c'est bien un facteur de bon fonctionnement du réseau.

Enfin, il ne faut pas non plus que le réseau apprenne trop d'exemples si l'on ne veut pas aboutir au phénomène de "sur apprentissage". En effet, si l'on propose trop d'exemples à apprendre au réseau, ses performances commencent à baisser et le réseau devient de moins en moins efficace.

## 8- Domaines d'application des réseaux de neurones :

Les réseaux de neurones sont des systèmes artificiels modernes qui sont des outils d'analyse et d'interprétation de données. Leur création exige la connaissance approfondie de plusieurs domaines scientifiques.

- Des spécialistes au niveau médical, principalement en neurophysiologie pour donner une information concrète de la structure de cerveau humain.
- Des notions de mathématiques et en plus de la physique pour créer les formules permettant la modélisation du cerveau.
- Une expertise informatique afin d'utiliser le système. Cependant, ces réseaux ne sont pas encore si intelligents et on ne peut pas les appliquer pour la création d'une machine intelligente telle que celle de l'être humain. Mais ils s'appliquent sur une grande variété de domaines, de la médecine à la gestion, de la consommation d'eau et d'électricité ou encore en physique des particules, dans le domaine de la classification et de la reconnaissance des formes.

Comme chaque méthodologie, ils ont leurs limites et leurs profils d'application privilégiés. Les réseaux de neurones sont plus efficaces pour les problèmes suivants :

- Quand la résolution peut se faire par un petit nombre d'étape de calcul. Le système répartit les calculs parmi les neurones, celui-ci lui permet d'effectuer des calculs puissants en une seule étape.

Cependant pour un tel réseau, il est difficile d'apprendre à réaliser un enchaînement structuré de calculs. Par exemple la planification, qui nécessite de choisir par avance une séquence d'actions, est un problème difficile pour un réseau de neurones seul .

Quand la structure interne des données est simple. Le codage de données complexe (par exemples arbres, graphes et etc.) sous forme des vecteurs d'entrée et de sortie demeure aujourd'hui un problème ouvert [Jodouin, 1994] .

- Le système doit posséder de suffisamment d'exemples d'apprentissage. Un corpus d'apprentissage trop petit peut provoquer la généralisation du réseau par sa couverture insuffisante du domaine d'application. En revanche, il n'est pas nécessaire de disposer d'un modèle précis du domaine d'application .
- Il n'est pas nécessaire d'expliquer le cheminement du calcul en termes intelligibles. En effet le système est le résultat d'un grand nombre de calculs, dont les particularités en général se déterminent automatiquement pendant l'apprentissage.

On peut aussi utiliser les réseaux de neurones dans divers domaines de l'industrie (par exemple le diagnostic de panne ou le contrôle de qualité), de la télécommunication (par exemple l'élimination du bruit ou l'analyse du signal), de l'environnement (par exemple **la prévision et la modélisation hydrologique** ou l'analyse chimique). Le marketing est aussi un domaine où les réseaux sont utilisables. Les hommes se servent d'eux pour diminuer les tâches d'administration d'énormes bases de données. On appelle cette méthode, le data mining .

# Chapitre 2

Environnement et implémentation du modèle de prédiction

## 1- Introduction :

Dans ce chapitre, nous dressons d'abord un comparatif de quelques outils informatiques utilisables pour modéliser et simuler un réseau de neurone. Nous présentons ensuite l'outil MatLab que nous avons utilisé pour mener à bien nos expériences. Enfin nous proposons d'illustrer l'utilisation de l'outil MatLab à travers deux exemples simples.

## 2- les outils neuronaux :

Il existe de nombreux outils informatiques utilisables pour modéliser et simuler un réseau de neurone. Nous allons présenter une petite partie de ces outils et plus précisément les outils «Pythia», « Stuttgart Neural Network Simulator » et « NeuroXL Classifier » « NeuroXL Predictor », « Neuroshed ».

### 2- 1- Outil Pythia :

Pythia est un outil informatique qui permet de modéliser les réseaux de neurones. Ce programme s'utilise beaucoup pour une simulation de la règle d'apprentissage par rétro-propagation. Les poids des réseaux sont initialisés par des valeurs au hasard. Pendant le processus d'apprentissage la sortie obtenue est comparée avec la sortie désirée et l'erreur obtenue est renvoyée en arrière vers l'entrée de réseau.

Pythia permet d'importer des données de différents formats ou utilisant les programmes comme Microsoft Excel. Les réseaux et les données obtenus peuvent être facilement emmagasinés sur un disque dur. Une caractéristique spécifique de Pythia est l'optimisation évolutionnaire qui automatiquement génère les réseaux appropriés pour les ensembles des données d'apprentissage. Elle utilise les algorithmes évolutionnaires pour sélectionner et générer les réseaux de neurones. Ce programme exige un Pentium processeur, 32 MB Ram et Windows 95, 98, ME, NT, 2000 ou XP. Ce n'est pas un produit libre. On peut voir dans la figure suivante un aperçu de l'interface du logiciel :

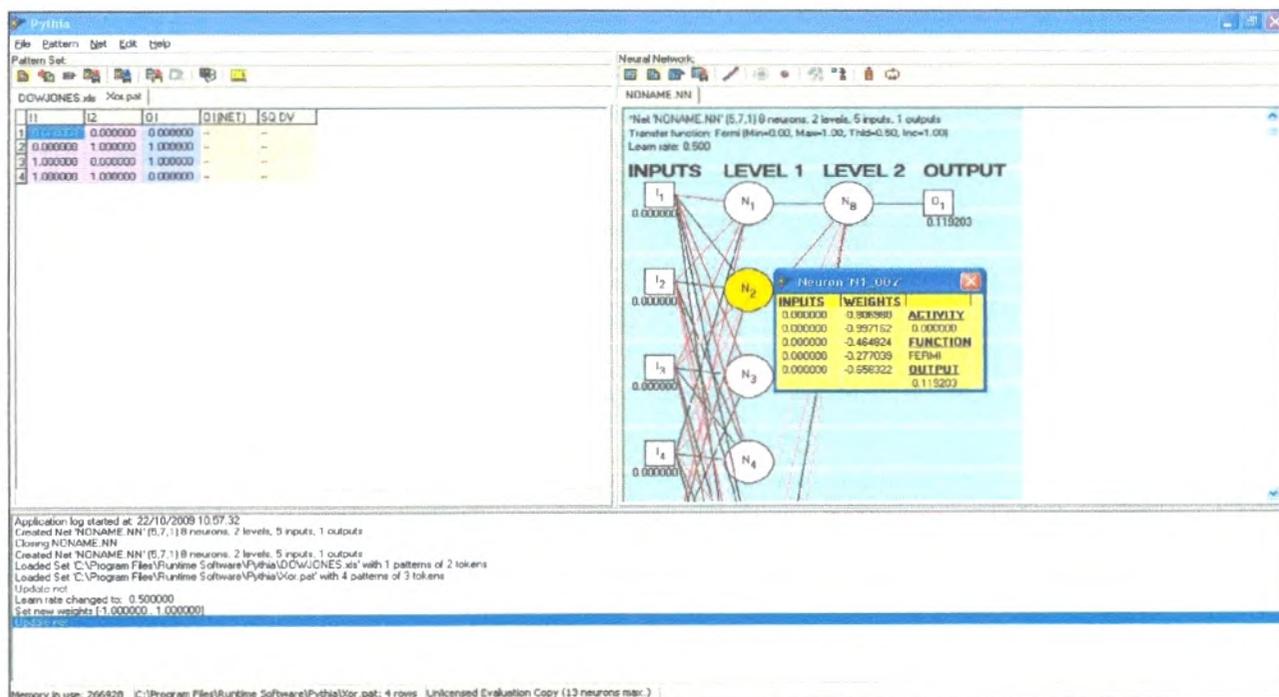


Fig -20- La fenêtre principale du logiciel Pythia

### 2-2- Outil Stuttgart Neural Network Simulator :

(SNNS) est un outil informatique pour simuler les réseaux de neurones. Ce programme est développé à l'IPVR (« Institute for Parallel and Distributed High Performance Systems ») de l'université de Stuttgart.

Le but de SNNS est de créer une simulation efficace et flexible pour une bonne application des réseaux de neurones. Le simulateur SNNS est composé de deux parties :

1. un simulateur crée en programme C .
2. un GUI (Graphical User Interface) ;

Il y a aussi un XGUI (X Graphical User Interface) qui donne une représentation graphique en 2D et 3D des réseaux de neurones. Le « 2D user interface » peut être utilisé pour directement créer, manipuler et visualiser un réseau de neurone de différentes manières. Les réseaux complexes peuvent être créés rapidement et facilement.

Ce produit est disponible sous licence libre dans un but de recherche. Le programme s'exécute sous Linux et MS-Windows. La figure suivante montre une représentation simple de l'interface de cet outil :

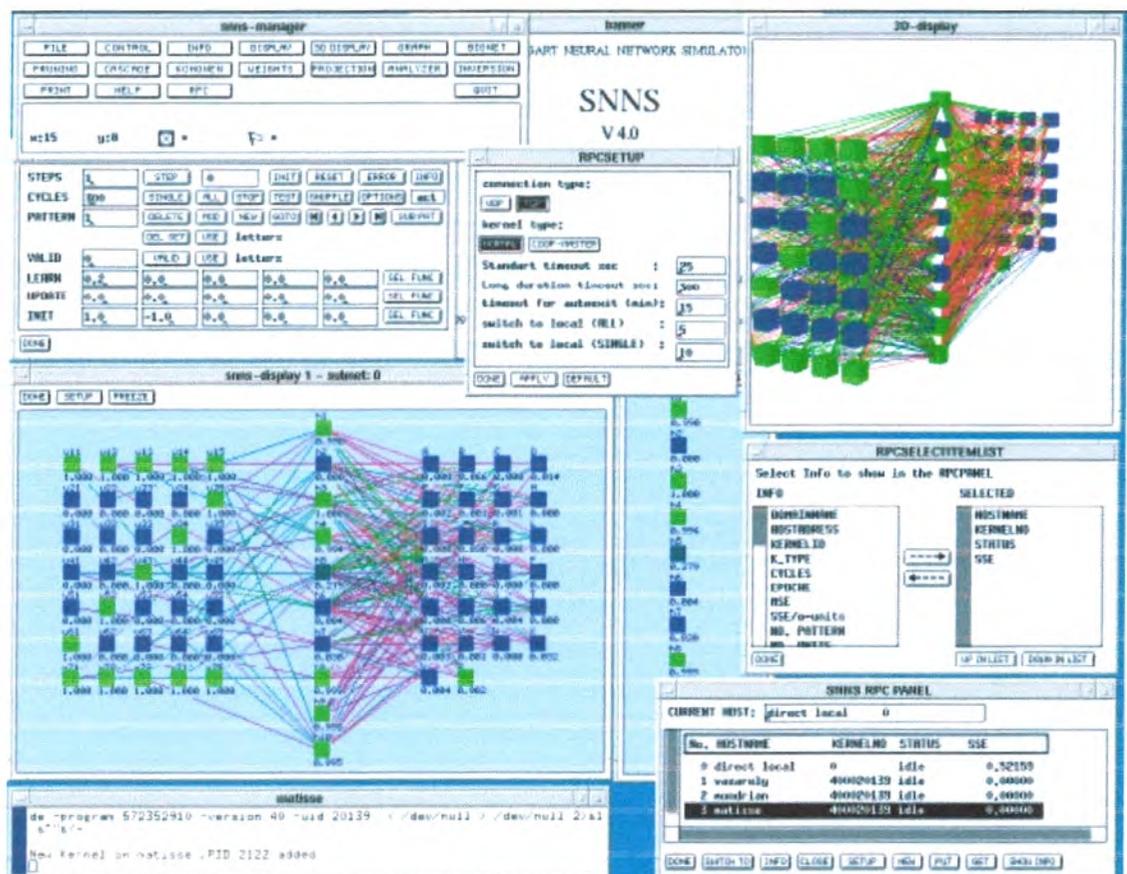


Fig- 21- Image SNNS (Stuttgart Neural Network Simulator )

### 2-3-Outil NeuroXL Classifier et NeuroXL Predictor :

Sont des outils de réseaux de neurones pour classifier les données de Microsoft Excel. Les avantages de cet outil sont :

1. un apprentissage et une utilisation faciles .
2. pas besoin de connaître les réseaux de neurones à priori .
3. une intégration facile de l'outil avec Microsoft Excel .
4. une modélisation efficace des réseaux de neurone pour une tâche de classification .
5. le prix de ce produit est le moins cher par comparaison à d'autres outils informatiques.

On peut conclure que c'est un outil très efficace pour classifier des données simples ou complexes. Il se décrit comme un additionneur de Microsoft Excel et on n'a pas besoin d'importer ou d'exporter les données. NeuroXL Classifier peut être utilisé pour résoudre des problèmes d'industrie dans la discipline du numérique, de la finance, de la médecine et de la recherche.



Fig -22 –NeuroXL Predictor et NeuroXL Classifier

#### 2-4- Outil Neuroshed :

Le NeuroShed, comme étant un outil de prédiction de débit de rivière par réseau de neurones. Ce logiciel utilise un réseau de neurones de type perceptron multicouches pour expérimenter plusieurs configurations de données afin de prédire le débit d'une rivière.

Une grande attention fut portée à définir une interface graphique aussi claire et agréable que possible, cet outil n'étant pas destiné uniquement aux informaticiens mais aussi aux hydrologues et physiciens.

Ainsi l'aspect général du logiciel se veut facile et ergonomique au possible pour les néophytes voulant juste réaliser des expériences.

La lecture des résultats n'est pas obligatoirement réalisée à la fin de l'expérience, elle peut intervenir à tout moment de l'apprentissage.

Des fonctions plus évoluées de suivi des différents graphes et valeurs ont aussi été implémentées mais elles ne sont toutefois pas exposées ici, une animation étant difficile à intégrer dans un rapport papier.

Elles permettent de relever les graphes et cartes à intervalles réguliers pour obtenir leur évolution dans le temps.

La sortie du réseau (prédiction) est automatiquement sauvegardée dans la sortie définie dans les paramètres, à savoir soit dans un fichier texte, soit dans une base de données.

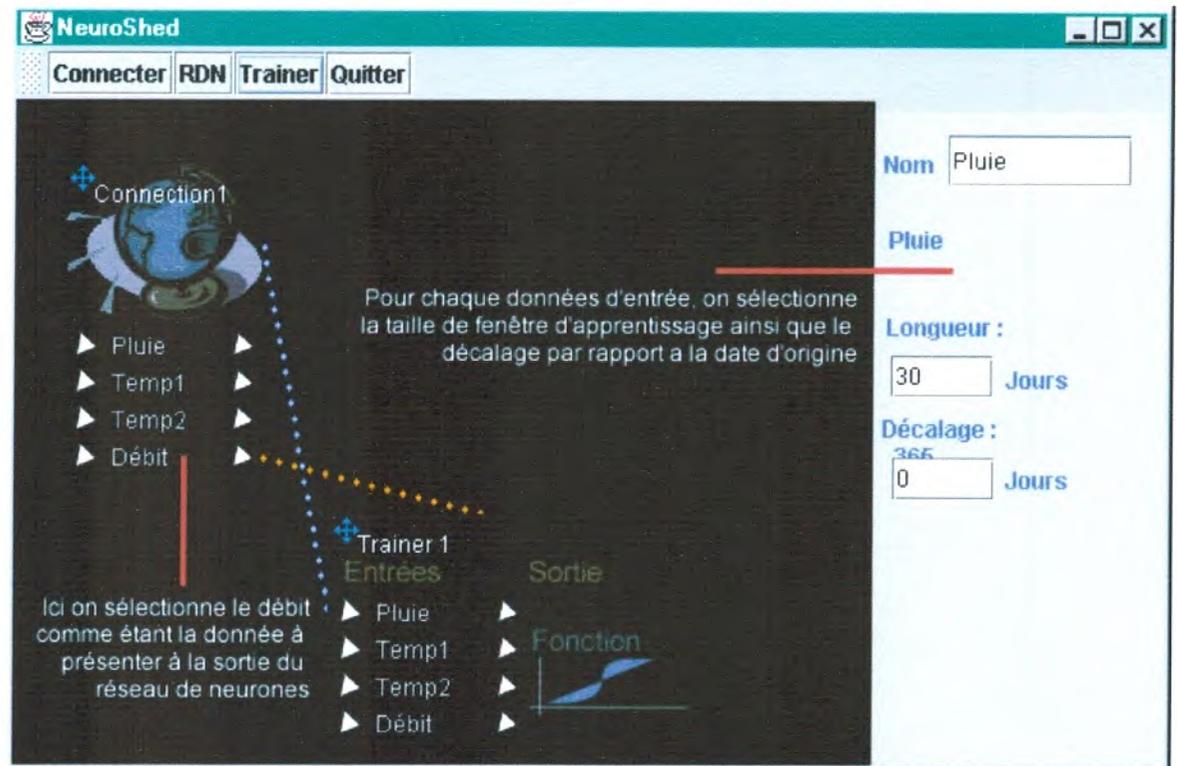


Fig -23 - La vue Général de Neuroshed

### 3-Environnement du Matlab pour les réseaux de neurone :

Le MatLab est un logiciel de calcul matriciel à syntaxe simple. Avec ses fonctions spécialisées, MatLab peut être aussi considéré comme un langage de programmation adapté pour les problèmes scientifiques. C'est un interpréteur : les instructions sont interprétées et exécutées ligne par ligne. Il fonctionne dans plusieurs environnements tels que X-Windows, Windows, Macintosh. Il existe deux modes de fonctionnement :

- **Mode interactif** : MatLab exécute les instructions au fur et à mesure qu'elles sont données par MatLab.
- **Mode exécutif** : MatLab exécute ligne par ligne un "fichier M" (programme en langage MatLab).

Matlab est organisé en boîte à outils (toolbox) spécialisés . Les toolboxes sont réellement des boîtes à outils comportant une collection de fonctions relatives à plusieurs domaines scientifiques et techniques. On peut trouver une boîte à outil spéciale pour manipuler, visualiser et modéliser les réseaux de neurones. Les entités appartenant à cette boîte à outil de MatLab sont :

- Une GUI (graphical user interface), utilisé pour créer, entraîner et simuler les réseaux de neurones .
- Un support pour les architectures de réseaux supervisés ou non supervisés les plus courants.
- Une maquette détaillée des fonctions pour l'apprentissage et le traitement des réseaux .
- Des réseaux de neurones dynamiques qui incluent les temps de retard .
- « Simulink » qui est l'extension graphique de MatLab permettant de présenter les fonctions mathématiques et les réseaux de neurones sous forme de diagramme de blocs ; des sous programmes pour l'amélioration générale .
- Des fonctions de visualisation pour visualiser la performance du réseau .

La boîte à outil GUI permet une utilisation facile des réseaux de neurones. Il y a un assistant, appelé le « Fitting Tool » qui donne la possibilité d'importer des données complexes et larges, de créer et entraîner rapidement le réseau et d'évaluer sa performance. Un affichage graphique simple visualise l'architecture du réseau. En général cette boîte à outil permet de choisir une donnée, de créer un réseau, de l'entraîner et évaluer sa performance.

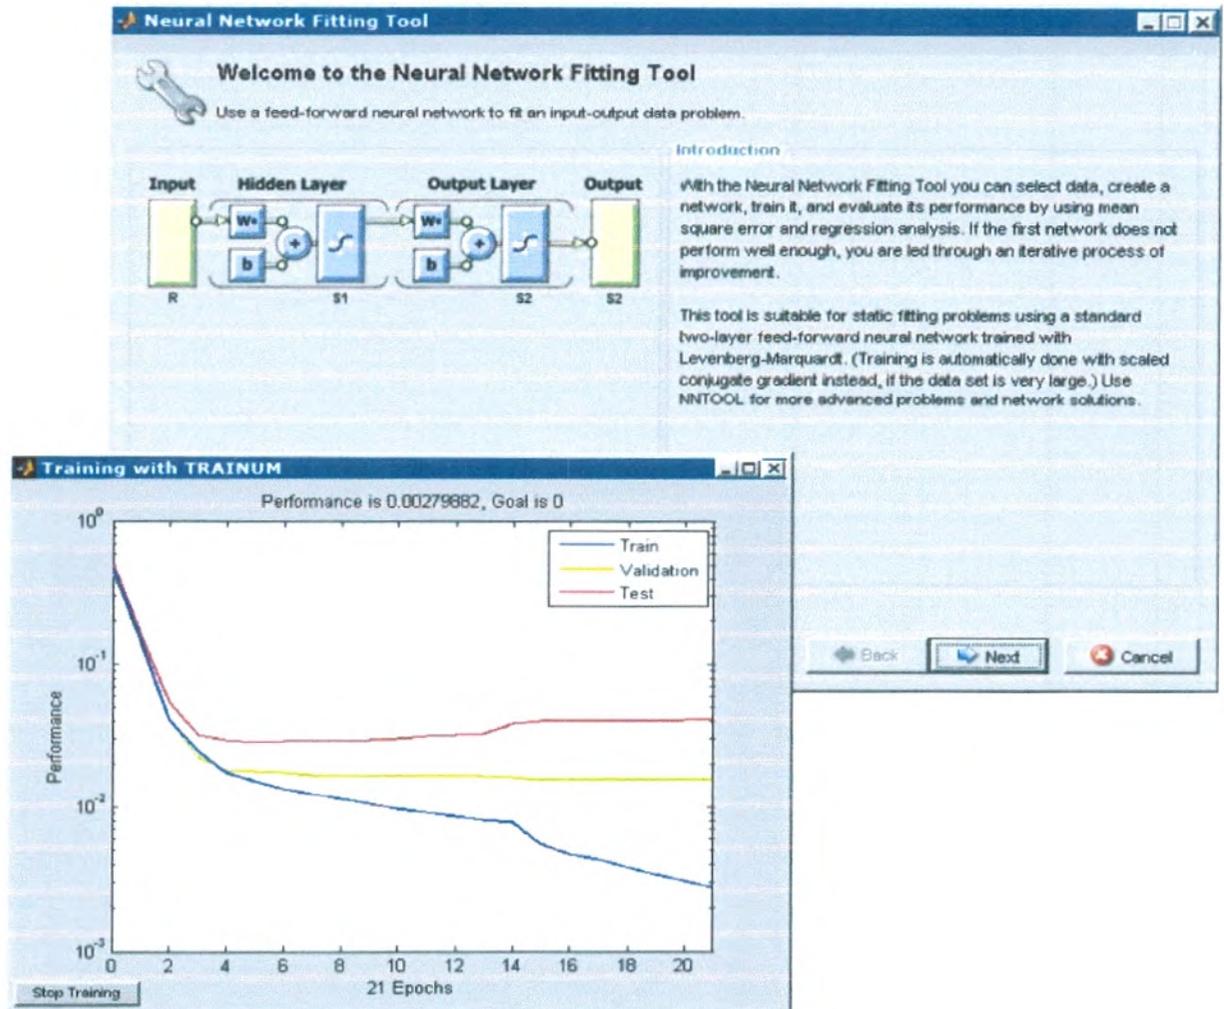


Fig -24- Fitting tool de réseau de neurone

En général on peut créer, entraîner et valider un réseau de neurone dans MatLab. Pour voir la vue graphique de réseau, on utilise Simulink Pendant des manipulations on peut indiquer que le réseau effectue une petite erreur au cours du processus d'apprentissage et une grande erreur quand une donnée nouvelle est présentée à l'entrée du réseau.

MatLab possède des boîtes à outil qui permettent d'éviter ce genre de problème. Ils portent les noms respectivement de régulation et de « early stopping ».

La **régulation** modifie la performance de la fonction d'activation de réseau (c'est la minimisation d'erreur au cours de l'apprentissage effectué). On inclut dans le réseau les poids et les seuils des données d'apprentissage, qui ont une bonne performance sur le réseau et avec les nouvelles données le réseau présente un changement de comportement.

Le « **Early stopping** » utilise deux ensembles de données différents :

- L'ensemble d'apprentissage pour la mise à jour des poids et des seuils .
- L'ensemble de validation pour stopper l'apprentissage quand le réseau commence à effectuer un apprentissage par cœur des données (sur - apprentissage).

Dans le paragraphe suivant on va illustrer à l'aide d'exemples quelques cas d'utilisation de l'outil MatLab.

#### 4 - Cas d'utilisation du logiciel matlab :

Pour illustrer l'utilisation du programme MatLab dans la modélisation et la simulation des réseaux de neurones, on va montrer deux exemples simples. Ces exemples montrent l'approximation par un réseau de neurone des fonctions logiques "OU" et OU Exclusif".

Premièrement on commence avec la fonction logique "OU". On montre ici la table de vérité de cette fonction

**Tableau -02- La fonction logique « OU » pour un réseau monocouche**

X1	X2	Y
0	0	0
0	1	1
1	0	1
1	1	1

Ce cas peut être modélisé par un réseau de neurone simple : un Perceptron monocouche. Deux couches seulement sont nécessaires : une couche d'entrée avec deux neurones  $x_1$ ,  $x_2$  et une couche de sortie avec un seul neurone  $y$ . La fonction de transfert utilisée est une fonction linéaire.

L'encadré suivant représente le programme MatLab qu'il faut créer. Le texte situé après le caractère spécifique « % » fait office de commentaire.

```
net = newp([0 1; -2 2],1); % ici on crée un perceptron d'un vecteur avec deux éléments dans un
intervalle choisie entre [0 1] et [-2 2] et un neurone de sortie; la fonction de transfert est
hardlim(une fonction linéaire) et l'apprentissage utilise une fonction LEARNP (la règle de
correction d'erreur)
P = [0 0 1 1; 0 1 0 1]; % ici on crée un vecteur avec deux éléments de quatre valeurs qui illustre la
fonction logique "OU"
T = [0 1 1 1]; % c'est la cible de sortie correspondante d'un vecteur avec un élément de quatre
valeurs
Y = sim (net, P) % ici on simule la sortie de réseau en faisant une initialisation du réseau de
neurone
```

```
Y =
    1    1    1    1
net.trainParam.epochs = 20; % ici on entraîne le
réseau
net = train(net,P,T);
Y = sim (net, P) % on simule de nouveau la sortie du
réseau
TRAINC, Epoch 0/20
TRAINC, Epoch 4/20
TRAINC, Performance goal met.
Y =
    0    1    1    1
```

La figure 25 visualise le réseau utilisé :

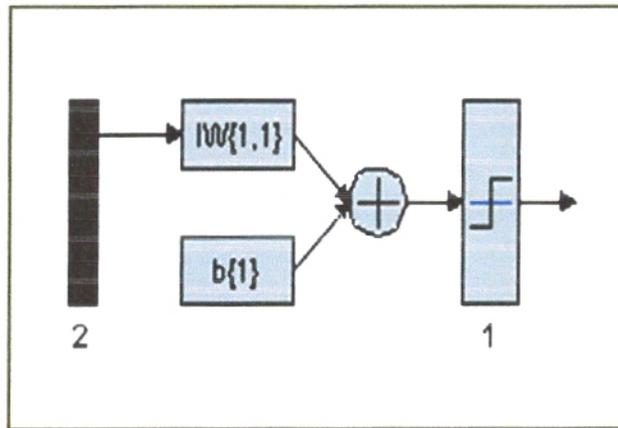


Fig -25- L'architecture du réseau de neurone pour le monocouche

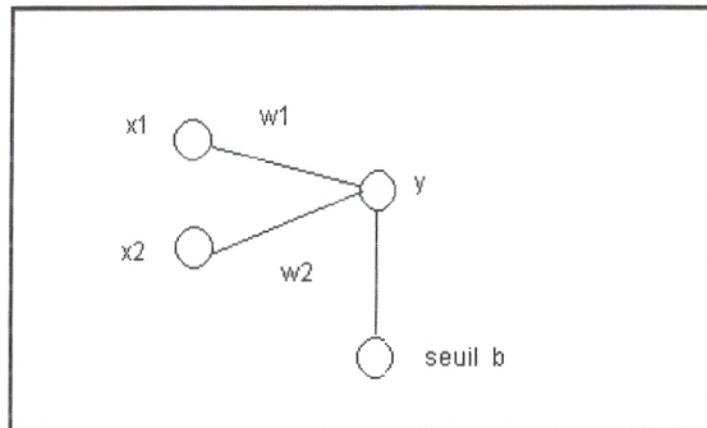


Fig -26-La vue du réseau de neurone utilisé (monocouche)

La figure (27) décrit l'entraînement du réseau. La ligne bleue est l'entraînement et la ligne noire est le but à atteindre. Au bout de la quatrième itération, le résultat désiré est atteint.

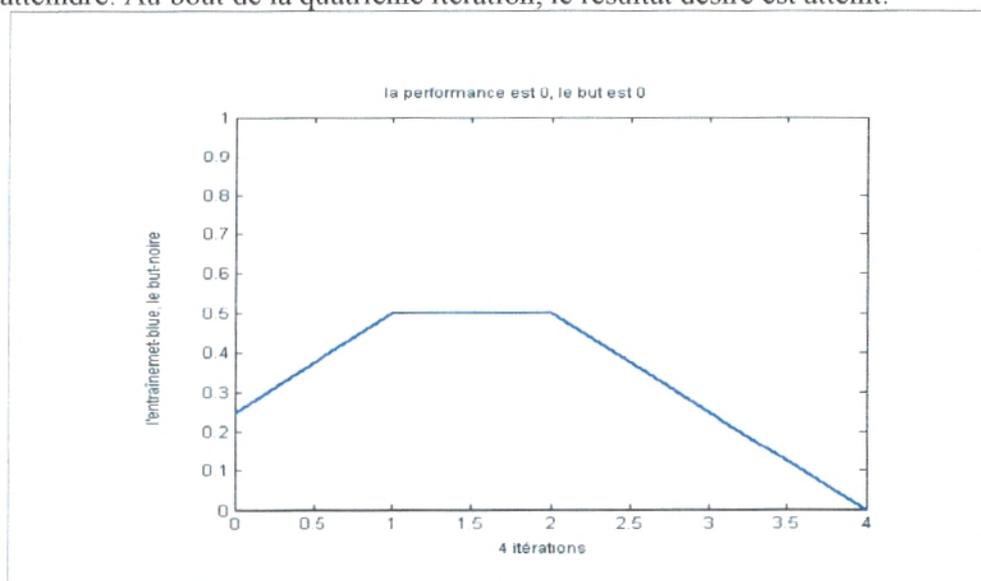


Fig -27-L'entraînement de réseau (monocouche)

L'autre exemple illustre la fonction logique "OU Exclusif". Ici on montre la table de vérité de cette fonction que l'on doit modéliser avec un Perceptron multicouches.

**Tableau -03- La fonction logique « OU » pour un réseau multicouches**

X1	X2	Y
0	0	0
0	1	1
1	0	1
1	1	1

Notre réseau possède trois couches : une couche d'entrée avec deux neurones d'entrée  $x_1$ ,  $x_2$ , une couche cachée avec trois neurones cachés et une couche de sortie avec un seul neurone  $y$ . On utilise une fonction de transfert sigmoïde dans la couche cachée et une fonction de transfert linéaire dans la couche de sortie.

L'encadré suivant représente le programme MatLab qu'il faut créer. Le texte situé après le caractère spécifique « % » fait office de commentaire.

```
P= [-1 -1 1 1; -1 1 -1 1]; % c'est l'initialisation de la fonction logique "OU Exclusif". On utilise des
valeurs -1 et 1, car la fonction tansig exige de telles valeurs

T= [-1 1 1 -1]; % c'est la cible de sortie

net = newff([-1 1;-1 1], [3 1], {'tansig'purelin'}); % ici on crée le réseau de neurone.
L'intervalle des données utilisées est indiqué par [-1 1;-1 1]. C'est un réseau qui utilise la règle
d'apprentissage par rétro-propagation. On dispose deux couches. Une couche cachée avec 3 neurones
qui ont une fonction de transfert tansig et une couche de sortie avec un neurone qui a une fonction
de transfert purelin

Y = sim (net, P) % ici on simule la sortie de réseau en faisant une initialisation du réseau

Y =
-0.0324 -0.7166 0.5704 1.0474
net.trainParam.epochs = 50; % ici on entraîne le réseau en utilisant 50 itérations

net = train(net,P,T);
TRAINLM, Epoch 0/50, MSE 2.06479/0, Gradient 5.07659/1e-010
TRAINLM, Epoch 4/50, MSE 7.89021e-024/0, Gradient 7.36623e-012/1e-010
TRAINLM, Minimum gradient reached, performance goal was not met.

Y = sim (net, P) % ici on simule de nouveau la sortie de réseau et on obtient le résultat désiré
Y =
-1.0000 1.0000 1.0000 -1.0000
```

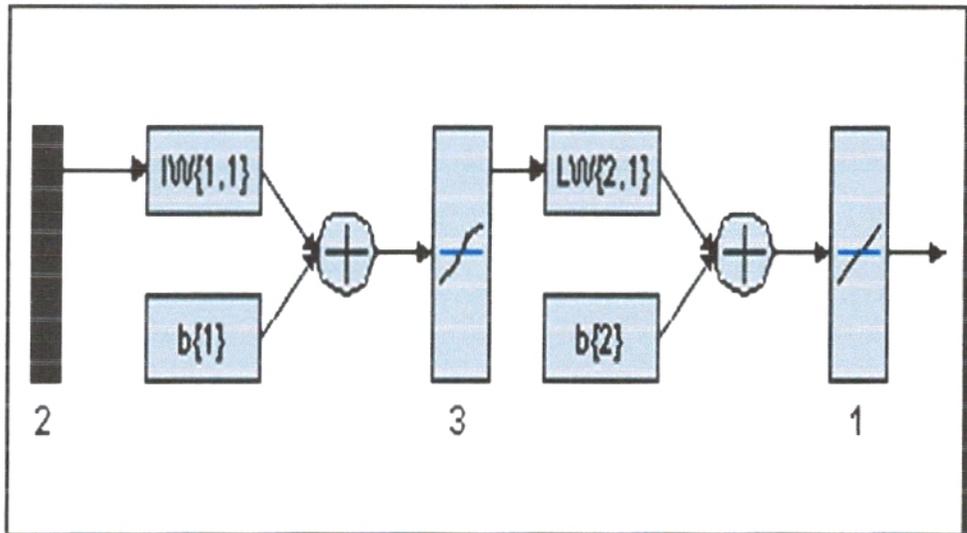


Fig -28- L'architecture du réseau de neurone pour le monocouche

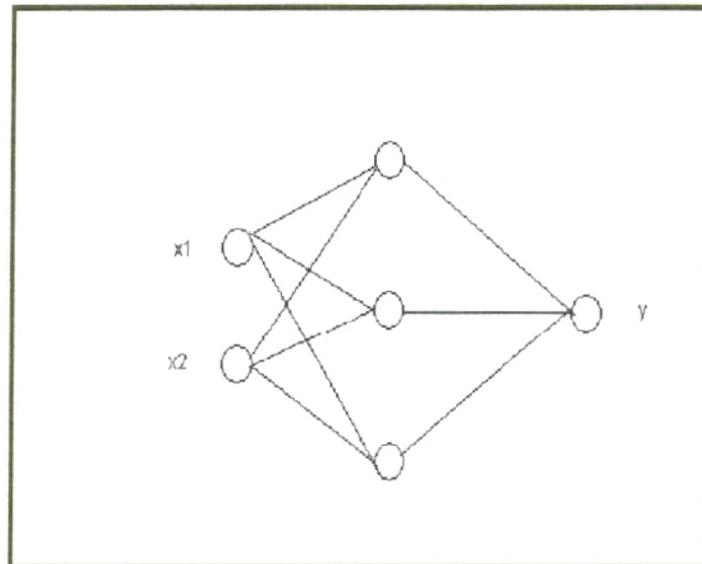


Fig -29-La vue du réseau de neurone utilisé (multicouche)

La figure (30) montre l'entraînement du réseau. La ligne bleue montre l'entraînement du réseau. On atteint le résultat désiré au bout de la cinquième itération.

## 1-Situation Géographique :

Le bassin versant de la Tafna, situé au Nord Ouest du territoire algérien (fig-31-), s'étend sur la totalité de la wilaya de Tlemcen sur une superficie de 7245 km<sup>2</sup>. Selon la nouvelle structuration des unités Hydrologiques en Algérie, le bassin versant de la Tafna appartient à l'ensemble de l'Oranie –Chott Cherguie (fig-32-).

Globalement, le bassin versant peut être subdivisé en trois grandes parties :

- partie orientale avec comme principaux affluents l'oued Isser et l'oued Sikkak).
- partie occidentale comprenant la Haute Tafna (oued Sebdo et oued Khemis) et l'oued Mouilah.
- partie septentrionale : qui débute pratiquement du village Tafna et s'étend jusqu'à la plage de Rachgoune, embouchure de la Tafna sur la mer. Les oueds Boukiou, Boumessaoud et Zitoun sont les principaux affluents de cette partie.

Les plaines du bassin de la Tafna s'étendent aux pieds des monts de Tlemcen en avant des massifs des Traras et du Tessala, elles sont entourées de massifs aux reliefs élevés dessinant un édifice régulier formé essentiellement de terrains mésozoïques et cénozoïques.

Les monts des Traras au Nord Ouest dressent une barrière entre le bassin et la mer, ils correspondent à une série de crêtes de direction NE – SW culminant à 1136 m au djebel Fillaoucène.

L'oued Tafna est un cours d'eau de 170 Km de long, il prend sa source dans les Monts de Tlemcen. Le cours de cet oued peut se subdiviser en trois parties : la haute Tafna, la moyenne Tafna et la basse Tafna.

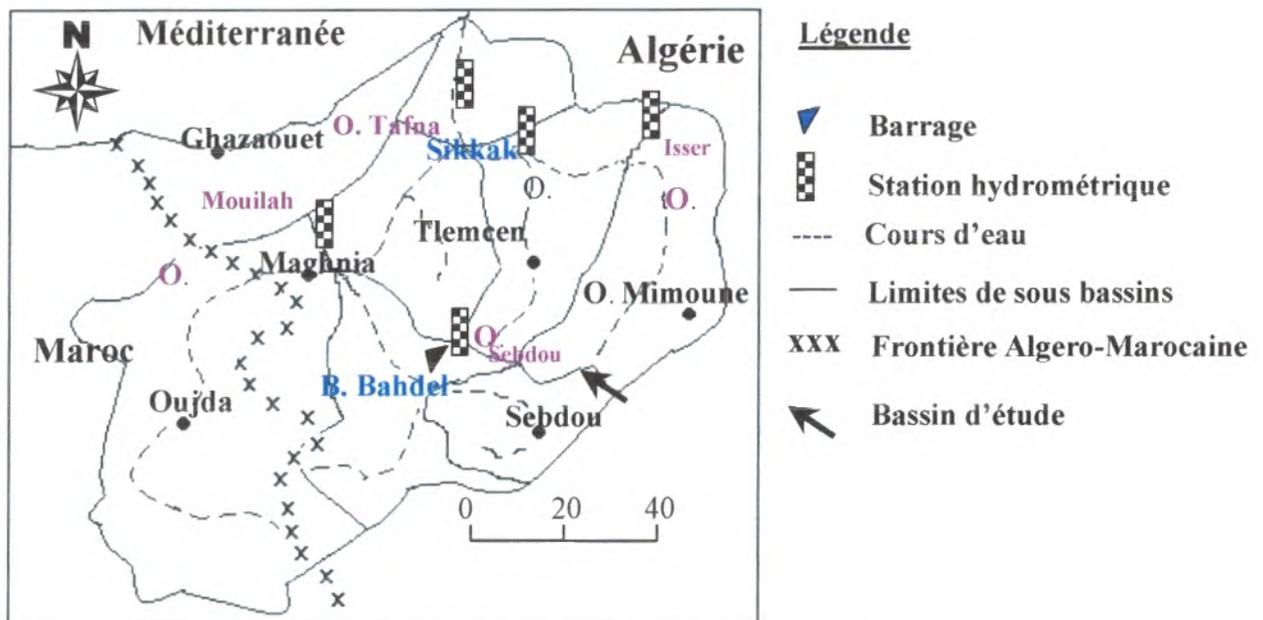


Fig-31- Le bassin versant de la Tafna

L'oued Sebdo, l'objet du présent mémoire fait partie de la haute tafna . Au niveau de cette unité hydrologique, l'oued prend naissance dans les Ouled Ouriach et s'affirme après la Jonction d'un grand nombre de ramifications creusées dans les terrains jurassiques et descendent de crêtes atteignant 1500m. Ces ramifications se réunissent aux environs de Sebdo à une altitude d'environ 900m. A partir de cet endroit et jusqu'à Sidi Medjahed, l'oued suit un cours dans une vallée encaissée creusée dans les terrains jurassiques. Dans cette région montagneuse, l'oued Tafna reçoit l'oued Khemis (rive droite) et l'oued Sebdo (rive gauche).

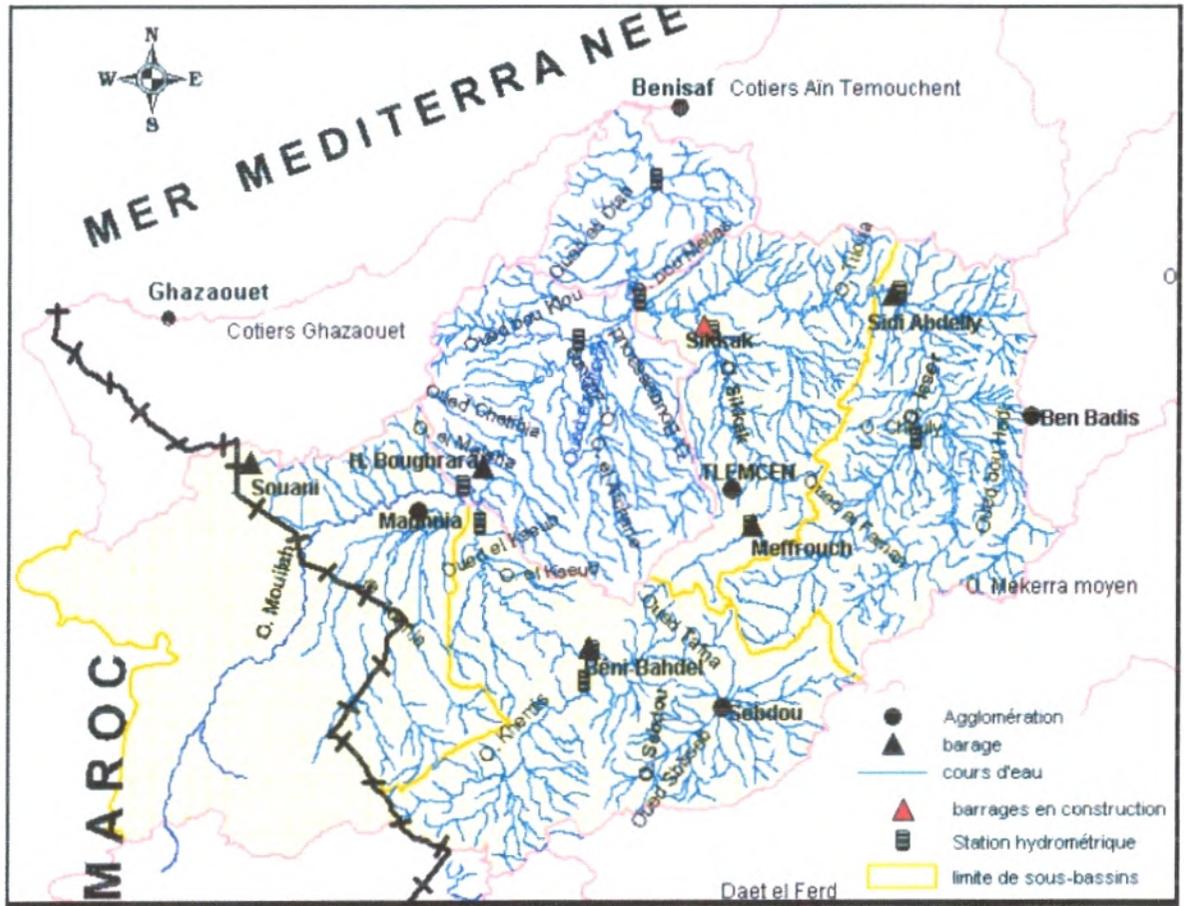


Fig-32- le Réseau hydrographique de Tafna

## 2- Caractéristiques De Forme :

Notre secteur d'étude se situe au niveau d'oued sebdu c'est pour cela que nous nous intéressons à des valeur comme l'indice de compacité qui montre que le bassin de l'oued sebdu est moyennement allongé avec un Kc de 1.37.

Tableau -4-Caractéristiques de forme pour le sous bassin de oued sebdu

bassin	Superficie (km <sup>2</sup> )	Périmètre (km)	Kc	Rectangle équivalent	
				Longueur (km)	Largeur (km)
Oued sebdu	255.5	78	1.37	30.70	8.32

Favorisant a priori, le temps de concentration des eaux de ruissellement. Mais l'influence du relief est encore plus déterminante.

### 3- Etude Du Réseau Hydrographique :

La disposition du réseau hydrographique est liée en grande partie à l'évolution des phénomènes structuraux qui ont affecté la région au cours des temps géologiques.

Le chevelu hydrographique suit pratiquement les accidents importants qui ont affecté les formations carbonatées du Jurassique et se modifie avec l'évolution de la tectonique (Baba Hamed 2001 -Bouanani 2004) .

Le réseau hydrographique du bassin d'oued Sebdou a été réalisé sur la base des cartes au 1/50000.

Les paramètres importants qui régissent le régime hydrologique d'un cours d'eau sont :

La densité de drainage (Dd), le rapport de confluence (Rc) et le rapport des longueurs (Rl).

**Tableau -5- Paramètres morphométriques du sous bassin oued sebdou**

Bassins	Dd	Rc	Rl
Oued Sebdou	2.88	3.43	2.38

#### 3-1-Densité de drainage :

La densité de drainage est définie par :

$$Dd = \Sigma L / A$$

Où,

**Dd** : densité de drainage en km/km<sup>2</sup>.

**L** : longueur cumulée de tous les thalwegs du bassin en km.

**A** : aire du bassin en km<sup>2</sup>.

Il faut signaler que la reproduction du chevelu hydrographique est d'autant plus fidèle que l'échelle de la carte est grande.

La valeurs de densité de drainage obtenue est de 2.88 km/km<sup>2</sup> .

L'importance du drainage est due principalement à la nature des formations qui forment le bassin ainsi qu'aux pentes assez fortes des versants d'une part et d'autre part au régime climatique, caractérisé par des pluies irrégulières et violentes.

La valeur de la densité de drainage est élevée dans le bassin de l'oued Sebdou où se conjuguent un très fort relief, une abondance pluviométrique relative et une faible perméabilité des affleurements carbonatés.

#### 3-2- Rapport de confluence :

Il est défini par :

$$Rc = N_n / N_{n+1}$$

Où,

**Rc** : rapport de confluence.

**N<sub>n</sub>** : nombre de cours d'eau d'ordre n.

Si l'on admet que, pour un bassin parfaitement organisé **Rc = 2**; les sous bassins de la Tafna sont mal hiérarchisés y compris le bassin de oued sebdou.

### 3-3- Rapport des longueurs :

La définition est la suivante :

$$R_L = L_{(N+1)} / L_N$$

$L_N$  : longueur de cours d'eau d'ordre n.

Les valeurs sont comprises entre 1.82 et 3.16, elles sont pour la plupart approximatives.

### 4 - Etude Du Relief :

Le relief est un facteur essentiel, il détermine en grande partie l'aptitude au ruissellement des terrains, l'infiltration et l'évaporation. C'est un élément capital dans le comportement hydrologique d'un bassin.

Partant de la répartition par tranches d'altitudes du bassin nous avons établi la courbe hypsométrique et le diagramme des fréquences altimétriques.

#### 4-1- Etude du relief oued Sebdou :

Le bassin versant occupe une superficie de 255,5 Km<sup>2</sup> avec une altitude maximale de 1465 m. La longueur du thalweg principal est de 78 km. Le bassin est caractérisé par deux ensembles distincts :

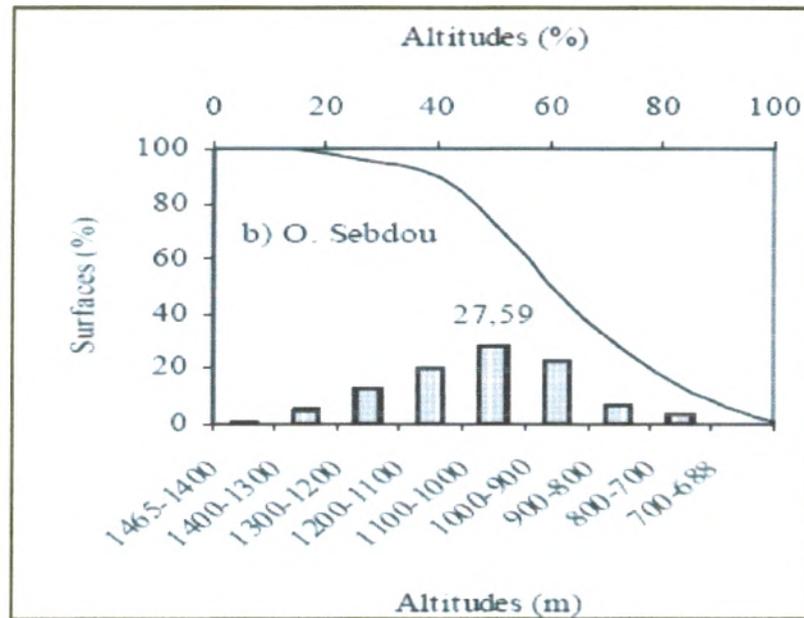
- au Nord et au Nord Ouest par un Horst.
- au Sud et à l'Est par un graben rempli de sédiments plio - quaternaires correspondant au Fossé de Sebdou.

La courbe hypsométrique (fig-33-), montre une concavité vers le bas, avec une pente faible vers les hautes altitudes. Elle indique la présence de pentes très fortes représentées par les Horsts qui délimitent le fossé. Vers les basses altitudes, la pente accentuée de la courbe hypsométrique indique que l'oued Sebdou se termine dans la vallée encaissée de Béni Bahdel.

La forme de la courbe est caractéristique d'un bassin à l'état de jeunesse allant vers l'équilibre, d'où un potentiel érosif assez important.

**Tableau -6- Répartition hypsométrique du sous bassin oued sebdou**

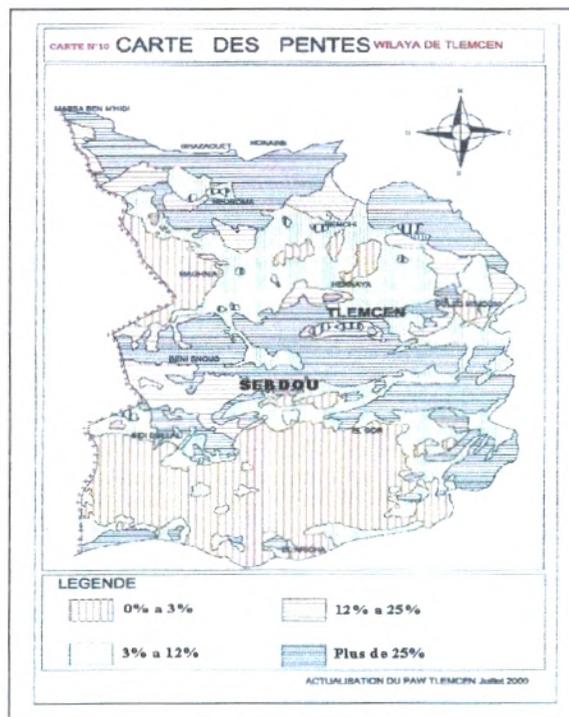
Tranches d'altitudes	Ai (Km <sup>2</sup> )	Ai cumulées (Km <sup>2</sup> )	Ai %	% Ai cumulés	% altitudes cumulés
1465-1400	1.40	1.40	0.55	0.55	100
1400-1300	13.975	15.375	5.47	6.02	91.63
1300-1200	31.725	47.1	12.42	18.44	78.76
1200-1100	52.50	99.6	20.55	38.99	65.89
1100-1000	70.50	170.1	27.59	66.58	53.02
1000-900	59.30	229.4	23.21	89.79	40.15
900-800	16.30	245.7	6.38	96.17	27.28
800-700	9.60	255.3	3.76	99.93	14.41
700-688	0.20	255.5	0.08	100	1.54



**Fig-33- Courbe Hypsométrique et histogramme de fréquence altimétrique du sous Bassin oued Sebdu de la Tafna (NW Algérie)**

Les pentes au niveau du bassin sont en majorité très fortes , 49.0% de la Superficie est à pente supérieure à 25%. Cette classe de pente est localisée principalement au Nord et au Sud du bassin correspondant à la zone montagneuse.

Au niveau du fossé de Sebdu, les pentes s'adoucissent et oscillent entre 0 et 3% occupant 10.50% de la superficie du bassin. A partir de cette zone, les pentes augmentent pour atteindre des valeurs de 3 à 12% s'étalant sur une superficie de 31.20% du bassin et de 12 à 25% sur une superficie de 9.30% de la surface totale du bassin.



**Fig-34- carte des pentes de la wilaya de Tlemcen y compris la zone d'étude (sous-bassin de l'oued sebdu)-PAW Tlemcen 2000.**

#### 4-2- Altitudes Du Sous Bassin de l'oued Sebdou :

A partir de la courbe hypsométrique du sous bassin de l'oued Sebdou et son histogramme des fréquences altimétriques, nous avons tiré les altitudes caractéristiques et l'état du bassin.

Tableau-7- caractéristique du sous bassin d'oued Sebdou

Bassins	Altitude la plus fréquente (m)	Altitude de fréquence ½ (m)	Observation
Oued Sebdou	1100-1000	1060	Equilibre

#### 4-3-Etude De Profil En Long :

Les profils en long relatifs aux principaux affluents de la Tafna permettent d'apporter des éléments complémentaires à ceux de la densité de drainage, au vu du rôle déterminant des pentes des thalwegs sur le ruissellement superficiels et surtout sur les vitesses d'écoulement lors des crues.

Le profil en long de l'oued Sebdou fait apparaître l'existence d'une pente forte en amont du bassin allant de 3.57% à 6.66 % dans le secteur correspondant au sud du fossé de Sebdou cette pente s'atténue au fur et à mesure que l'on se dirige vers l'aval pour n'être plus que 1.25%.

Le grand trait qui ressort de ce profil c'est la rupture de pente nettement marquée de la tafna vers sa sortie à oued Sebdou, témoignant de l'existence d'accidents récents ou de changement de faciès (Baba Hamed 2001).

La pente du profil en long est variable liée semble-t-il à la taille des bassins : la pente étant d'autant plus faible que le bassin est plus grand ( P.Dubreuil,1974).

#### 4-4-Indices De Pente Et Relief :

##### 4-4-1- Indices de pente :

Le relief joue un rôle important, car il commande en grande partie l'aptitude au ruissellement des terrains.

Son appréhension peut être faite à l'aide de l'indice de pente global  $I_g$  donné par la relation :

$$I_g = D / L$$

Où,

$I_g$  : indice globale de Roche.

$D$  : dénivelée (m).

$L$  : longueur du rectangle équivalent (Km).

Sur la courbe hypsométrique déjà tracée, on prend les points tels que la surface supérieure ou inférieure soit égale à 5% de la surface totale.

$H_5$  et  $H_{95}$  sont les altitudes entre lesquelles s'inscrivent 90% de la surface du bassin. La dénivelée  $D$  est donc égale à  $H_5 - H_{95}$ .

L'indice de pente  $I_p$  également défini par Roche à partir du rectangle équivalent est égal à :

$$I_p = (1 / \sqrt{L}) \cdot \sum x_i \cdot \sqrt{(\beta_i \cdot [a_i - a_{i-1}])}$$

$\beta_i$  : fraction de la surface totale du bassin comprise entre les côtes  $a_i$  et  $a_{i-1}$ ; fonction donnée par le tableau hypsométrique.

$x_1$  : distance séparant deux courbes de niveau sur le rectangle équivalent.  
 $L$  : longueur du rectangle équivalent.

**Tableau -8-Indice de pente et relief du sous bassin de oued sebdu**

Sous bassins	$I_p$	$I_g$	Relief selon " $I_g$ "
Oued Sebdu	1.46	0.016	Modéré

Les résultats du tableau , montrent d'après la classification de l'Orstom que le bassin de sebdu fait partie relief modéré à cause vraisemblablement de l'influence de la surface.

**Tableau -9-Classification du relief selon  $I_g$  par l'ORSTOM**

Type de relief	$I_g$
Relief très faible	$I_g < 0.002$ m/km
Relief faible	$0.002 < I_g < 0.005$
Relief assez faible	$0.005 < I_g < 0.01$
Relief modéré	<b><math>0.01 &lt; I_g &lt; 0.02</math></b>
Relief assez fort	$0.02 < I_g < 0.05$
Relief fort	$0.05 < I_g < 0.5$
Relief très fort	$0.5$ m/km $< I_g$

#### 4-4-2 Coefficient de torrentialité :

C'est un coefficient qui tient compte à la fois de la densité des thalwegs élémentaires et de la densité de drainage (V .Chow and D.Maidment,1988):

$$C_T = D_d \cdot F_1$$

avec :

$D_d$  : densité de drainage

$F_1$  : fréquence des thalwegs élémentaires  $F_1 = N_1 / A$  avec  $N_1$  : nombre de cours d'eau d'ordre 1.

#### 4-4-3-Temps de concentration :

C'est le temps que met une particule d'eau provenant de la partie du bassin la plus éloignée pour parvenir à l'exutoire, pour son calcul, nous faisons appel à la formule de Giandotti.

$$T_c = 4 (A + 1.5 L)^{1/2} / 0.8 (H_{\text{moy}} - H_{\text{min}})^{1/2}$$

Où,

$T_c$  : temps de concentration (heures)

$A$  : superficie du bassin (km<sup>2</sup>)

$L$  : longueur du thalweg principal (km)

$H_{\text{moy}}$  : altitude moyenne (m)

$H_{\text{min}}$  : altitude minimale (m)

**Tableau-10-Valeurs des coefficients de torrencialité et les temps de concentrations de l'oued sebdou**

Bassins	Coefficient de torrencialité CT	Temps de concentration TC
Oued Sebdou	15.2	07 h 00

Le coefficient de la torrencialité est du à plusieurs paramètres en particulier la pente et le chevelu hydrographique : au niveau bassin versant de Sebdou la valeur élevée du CT est expliquée par son caractère montagneux et sa densité de drainage élevée.

Le temps de concentration des eaux est non seulement fonction de la surface mais aussi d'autres paramètres tels que la lithologie, la pluviométrie et le relief ainsi l'occupation du sol . En effet, deux bassins ayant la même superficie ne se comportent pas forcément de la même façon.

## 5- SOLS ET VEGETATIONS :

Les sols dans cette zone peuvent être subdivisés en trois classes :

- les sols calcaires couvrant une grande partie du bassin où se développe une arboriculture non irriguée et un élevage de montagne.
- les sols alluvionnaires constituant la cuvette de Sebdou où émergent de nombreuses sources,
- Les sols constitués par des croûtes calcaréo-gréseuses ou marno-gréseuses ainsi que des argiles de calcification où l'on retrouve un couvert forestier bien développé.

Pour la distribution du couvert végétal pour ce bassin, nous avons rassemblé et classé les diverses formes de culture de la façon suivante :

### 1. Cultures extensives :

elles rassemblent toutes les cultures annuelles telles que les céréalicultures, les cultures maraîchères et l'association entre l'arboriculture et le maraîchage.

### 2. Couvert forestier dégradé :

sont rassemblés sous ce thème les maquis et les forêts clairs, 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.

### 3. Couvert forestier normal :

Représenté essentiellement par les forêts et les maquis denses n'ayant subi aucune dégradation que ce soit par l'action de l'homme (pâturage sauvage, déboisement) ou par l'effet des incendies.

### 4. Arboriculture :

représentée principalement par les vignobles et l'olivieraie, et les agrumes, vergers et murs en quantité inférieure.

### 5. Couvert mort :

Sont désignés par ce terme tous les terrains sur lesquels n'est présente aucune forme de végétation ou de culture utilisable, rendu nu par l'érosion ou par d'autres formes de dégradation.

### 6. Prairies et terrains de pacage :

Représentés par les surfaces qui sont utilisées pour la plupart en pâturage direct des animaux, les terres occupées par l'alfa et la lavande.

La distribution du couvert végétal dans le bassin de Sebdou donnée dans le tableau et la répartition de la couverture végétale font ressortir des nuances régionales importantes.

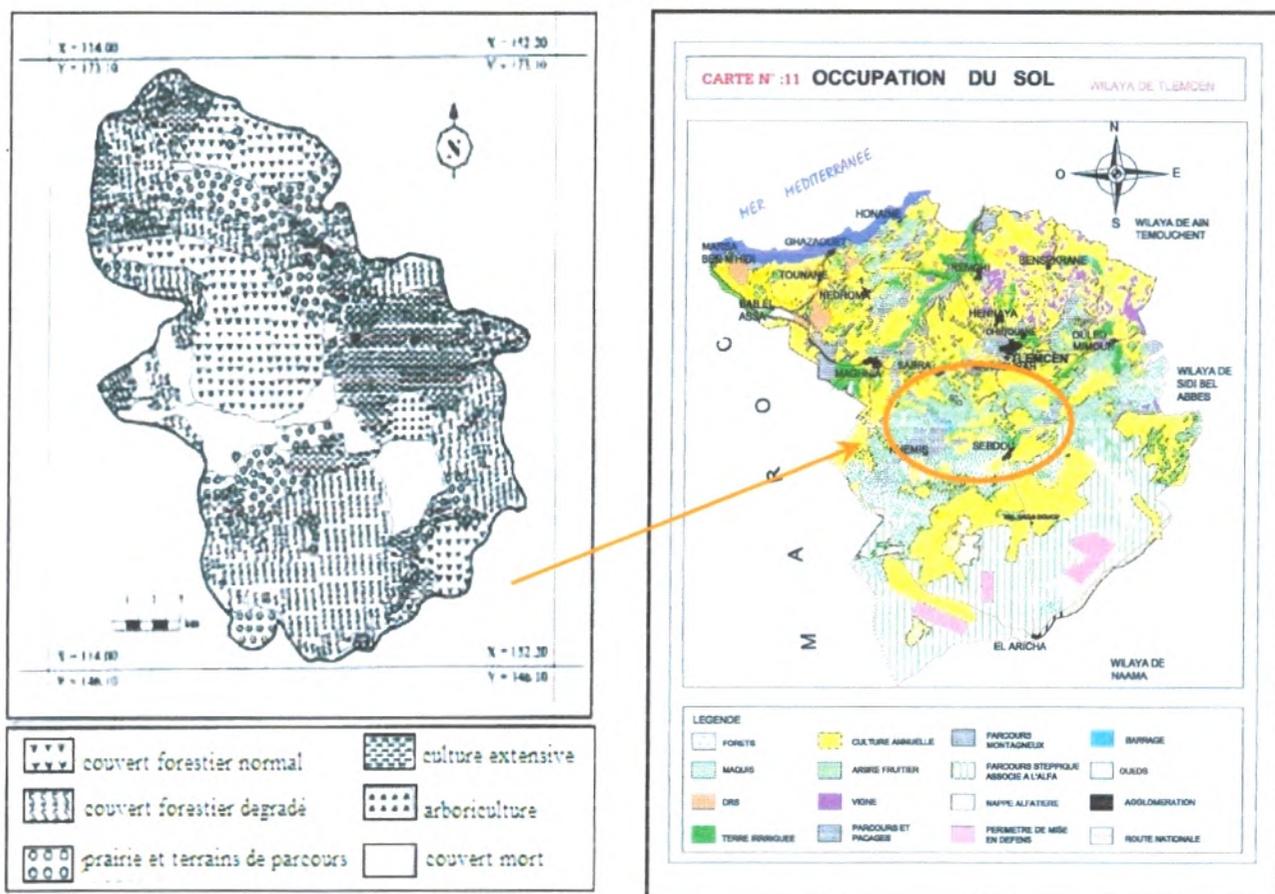


Fig-35-cartes d'occupation du sol du sous-bassin de l' oued Sebdo

Tableau -11-Distribution du couvert végétal dans le bassin d'oued Sebdo (BNEDER, 1993)

Occupation des sols	Surfaces (ha)	% des surfaces
Cultures extensives	4123	16.14
Couvert forestier dégradé	8645	33.84
Couvert forestier normal	5564	21.78
Arboriculture	497	01.94
Couvert mort	2459	09.62
Prairies et terrains de pacage	4261	16.68

La végétation dans le bassin reste étroitement liée à la pluviométrie. En effet, dans le secteur Sud, les zones en cours de reboisement et les forêts claires ainsi que le couvert mort dominant. Ce type de couvert végétal qui protège mal la texture du sol contre les agents de l'érosion, correspond à la partie du bassin où la pente dépasse 25%. Celle-ci constituerait une zone où l'activité érosive serait très importante (Bouanani 2004).

**Conclusion :****Tableau -12-principaux paramètres physique du sous bassin oued Tafna**

<b>Paramètres</b>	<b>Bassin oued sebdu</b>
Superficie (Km <sup>2</sup> )	255.5
Périmètre (Km)	78
Indice de compacité Kc	1.37
Largeur du Re (L) (Km)	8.32
Longueur du Re (L) (Km)	30.70
Densité de drainage Dd(Km /km <sup>2</sup> )	2.88
Rapport de confluence Rc	3.43
Rapport des longueurs R <sub>L</sub>	2.38
Altitude maximale (m)	1465
Altitude minimale(m)	688
Altitude moyenne(m)	1120
Surface érodé(%)	38.88
Indice de pente Ip	0.146
Indice de pente global Ig	0.016
Coefficient de torrentialité C <sub>T</sub>	15.2
Temps de concentration des eaux Tc	07H00
Cultures extensives (% de la superficie)	16.14
Couvert forestier dégradé (%)	33.84
Couvert forestier normal (%)	21.78
Arboriculture (%)	1.94
Couvert mort (%)	9.62
Prairies et terrain de parcours (%)	16.68
Couvert forestier dégradé ou mort (%)	43.46

La valeur de l'indice de compacité permet d'affirmer que l'oued Sebdu présente dans l'ensemble une forme plus ramassée ce qui lui confère un temps de concentration des eaux de ruissellement plus court et il faut noter que l'influence du relief est encore plus déterminante.

Les valeurs de **Ig** et **Ip** traduisent un relief modéré a une tendance forte qui présente bien sur un volume montagneux plus important par rapport d'autres sous bassins de la Tafna (Bouanani 2004).

La valeur de densité de drainage confirme les résultats précédents quant aux valeurs de **Ig** et **Ip**, la valeur élevée de la densité de drainage de l'oued sebdu peut être attribuée aux pente plus forts, aux formations lithologiques et relativement a l'abondance des précipitations.

La végétation qui a une influence mécanique certaine sur l'écoulement fluvial est faible à très faible respectivement dans le bassin de Sebdu.

Le paysage végétal du bassin a été largement dégradé et défriché en montagne par les incendies, par l'agriculture extensive et le surpâturage.

Le couvert végétal agit directement sur le débit solide et liquide ainsi que sur les eaux souterraines car les plantes favorisent l'infiltration, donc jouent un rôle dans la recharge des nappes, il intervient dans l'apport moyen annuel et saisonnier.

**6- CADRE GEOLOGIQUE :**

La structure actuelle de l'Algérie du Nord est liée aux mouvements hercyniens et alpins qui ont permis l'individualisation de plusieurs domaines (fig.36). En Oranie, du Nord au Sud :

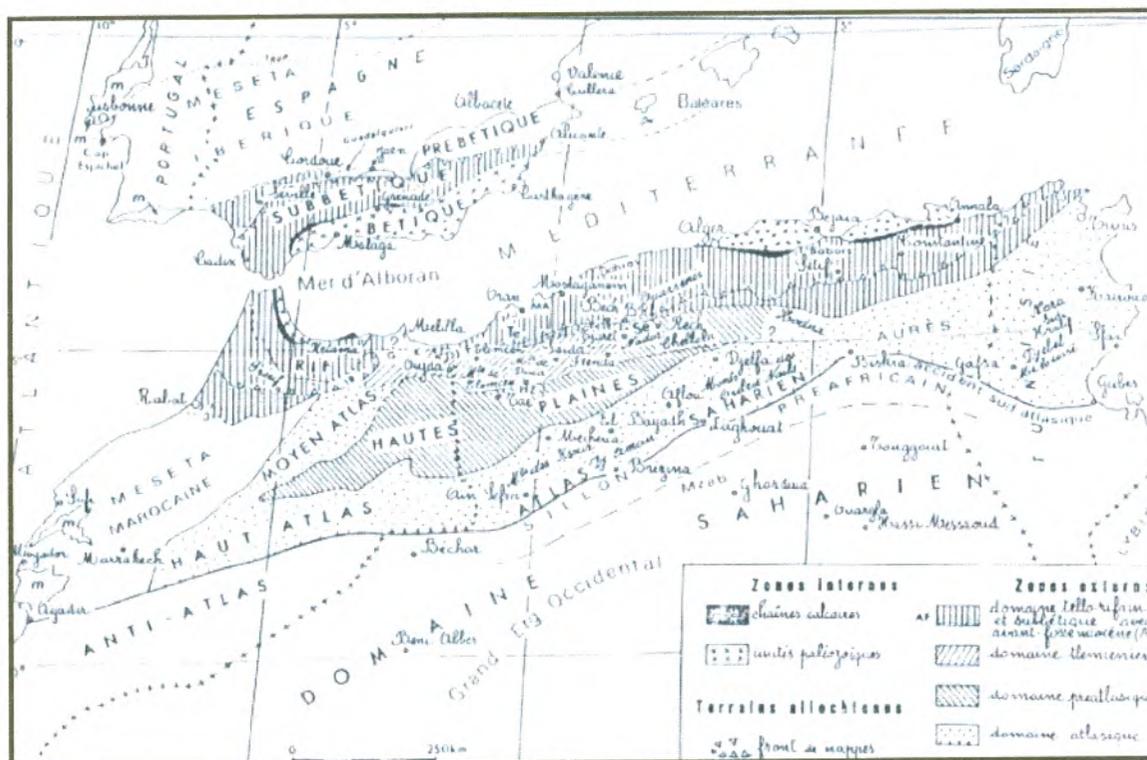
- Le domaine tellien représenté dans la zone d'étude par les monts des Traras et des Sebâa Chioukh,
- Le domaine tlemcenien dominé essentiellement par les monts de Tlemcen,
- Les hautes plaines oranaises,
- Le domaine atlasique,
- Et le domaine saharien.

Le bassin de la Tafna comprend de grandes plaines, dont les deux principales sont celle de Maghnia à l'Ouest et celle des Ghossels à l'Est entourées de massifs élevés :

- Le massif des Traras comprenant la chaîne des Fillaoucène qui s'étend vers l'Ouest par le massif des Béni-Snassen.
- Les monts de Tlemcen dessinant la bordure sud du bassin et s'interposent entre deux Domaines bien définis :

- le domaine des nappes du Tell au Nord,
- le domaine stable des hautes plaines oranaises au Sud.

La terminaison occidentale des monts de Tlemcen qui s'élève graduellement du Nord vers le Sud est occupée par un massif montagneux représenté par les monts de Rhar-Roubane.



**Fig -36- Schéma structural de la chaîne alpine de la Méditerranée occidentale**  
 Source BENEST.M, BENSALAH.M, BOUABDELLAH.H, OUARDAS.T (1999)

### 6-1-La série lithostratigraphique :

Le grand bassin de la Tafna est caractérisé par une géologie très complexe et qualifiée de grande tectonique. Sachant que l'évolution des terrains rencontrés dans le bassin de l'oued Sebdou va du Jurassique moyen jusqu' au Plio-Quaternaire.

#### 6.1.1 - Le Jurassique :

##### a- Les calcaires de Zarifet :

Il s'agit de bancs calcaires séparés par de minces intercalations de calcaires marneux écailleux, parfois quelque peu fossilifères, marquant presque partout la base très nette du Kimméridgien et reposent directement en concordance sur les grès de Boumediene formant les falaises des environs de Tlemcen. L'épaisseur de cette formation peut atteindre 25 m au col de Zarifet.

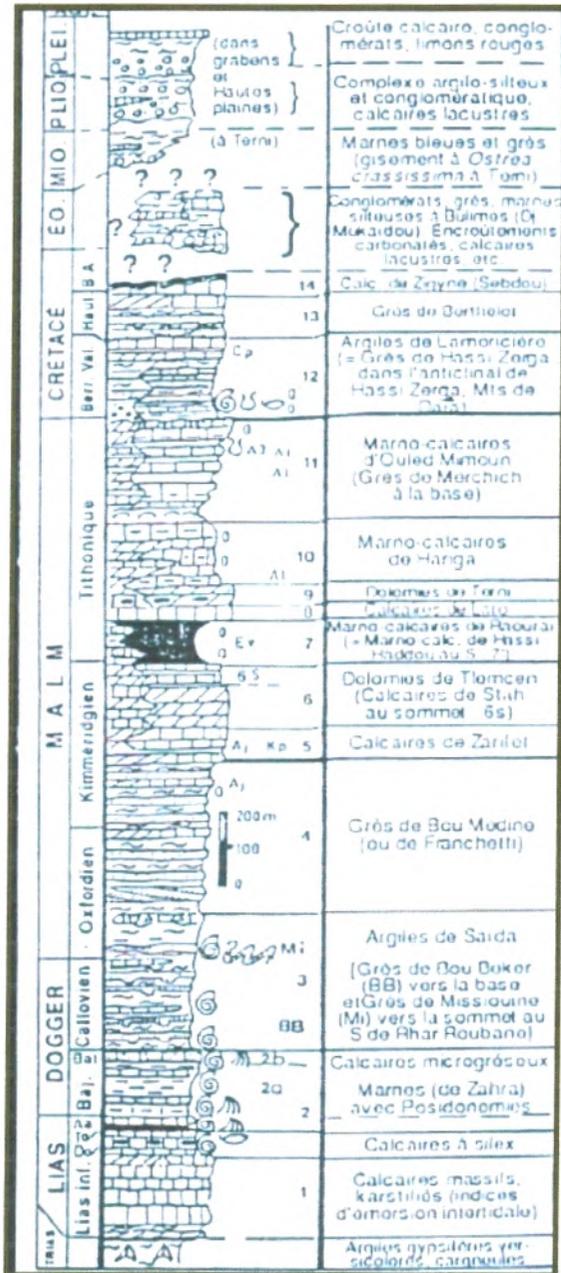
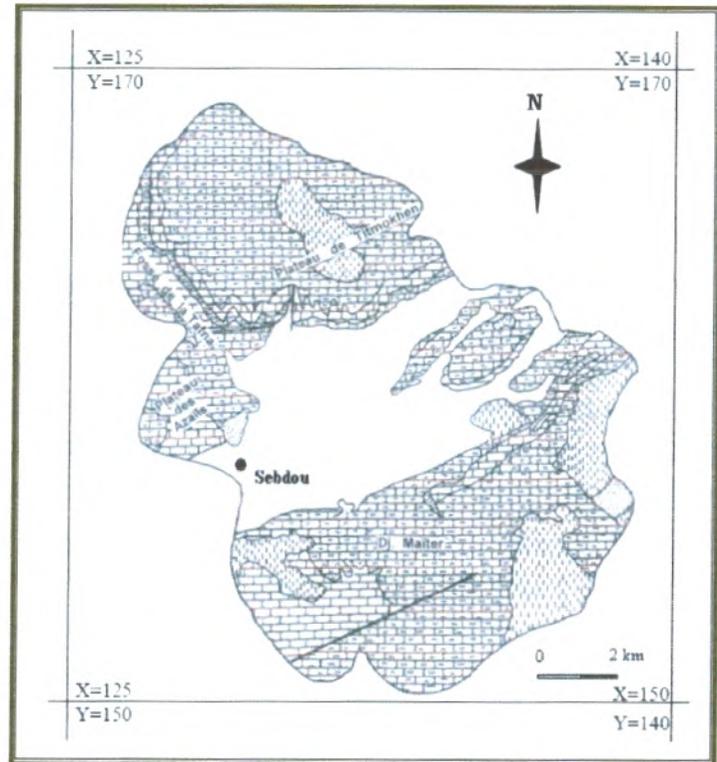


Fig-37 -Colonne stratigraphique des monts de Tlemcen jusqu'aux hautes plaines (Benest & Bensalah 1999)



Légende :

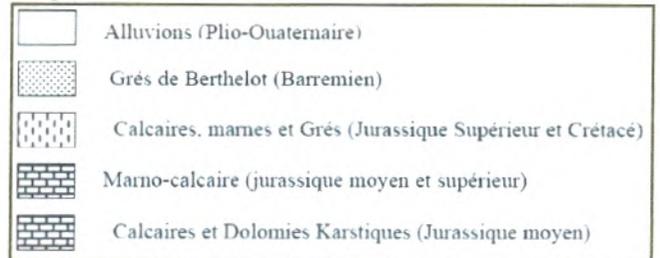


Fig -38- Carte lithologique du bassin versant de l'oued Sebdu (Bouanani 2004)

**b- Dolomies de Tlemcen :**

D'âge Kimméridgien moyen-Kimméridgien supérieur, il s'agit de dolomies cristallines grises, avec de nombreuses cavités remplies de calcite. Elles affleurent autours de Aïn Fezza, dans la forêt de Zarifet, au Nord de Tlemcen, dans les djebels Teffatisset, Aïn El Hout et sur le plateau de Terny; Elles peuvent être surmontées par les calcaires de Stah épargnés par la dolomitisation. Cette formation peut atteindre 200 m aux environs de Tlemcen à El Ourit .

**c- Marno-calcaires de Raouraï :**

Ce sont des marnes grises, blanchâtres en surface, intercalées de nombreux lits et bancs de calcaires marneux durs; cette formation est limitée à sa base par les lits calcaires de Stah et au sommet par les calcaires de Lato, ou les premières assises des dolomies de Terny. Elle affleure particulièrement sur le plateau de Terny, dans le djebel Lato et à l'Est de Aïn Fezza.

**d- Calaires de Lato :**

Ce sont des calcaires massifs en bancs épais, leur épaisseur est d'environ 50 m au djebel Lato.

**e- Dolomies de Terny :**

Elles correspondent à des dolomies parfois vacuolaires avec de nombreuses stratifications obliques et un aspect très massif, qui permet de bien les distinguer des dolomies de Tlemcen.

Elles sont développées au niveau du plateau des Azails, de Terny et près du barrage Meffrouch , leur épaisseur est de l'ordre de 100 m dans le plateau de Terny. Elles sont bien représentées au niveau des bassins de l'oued Sebdou (fig-38-) Ces trois formations précédentes sont attribuées au Tithonique inférieur.

**f- Marno-calcaires de Hariga :**

D'âge Tithonique moyen, il s'agit d'une alternance de marnes et de Calcaires,. Elles sont bien exposées au djebel Hariga avec une épaisseur de 165 m dans le bassin du Sebdou, ainsi qu'au Bled El Gliia à 270 m.

**g- Marno-calcaires d'Ouled Mimoun :**

"Tithonique supérieur ", cette formation renferme les couches de passage du Jurassique au Crétacé, elle est limitée à sa base par les "grès de Merchich", dans le secteur de Merchich, sur le rebord sud du plateau de Terny. Elle affleure nettement dans le secteur d'Ouled Mimoun, ainsi qu'au niveau de la bordure nord du fossé de Sebdou.

**6.1.2 - Crétacé :****a - Grès de Berthelot (Hauterivien) :**

Caractérisés par une récurrence de la smectite et surtout par l'application de la chlorite (10 à 15 m). La base est riche en stratifications obliques, marquée par des bancs de dolomies pulvérulentes. ils sont bien représentés au sud ouest du fossé de sebdou. marnes rouges ou verdâtres très ferrugineux à la base: c'est le terrain rouge de la basse Tafna, attribué à l'Oligocène par L.Gentil, 1902 pouvant correspondre à une émerision momentanée du bassin.

### 6.1.3 - Plio-Quaternaire :

Représenté par des sédiments continentaux d'âges comparables, bien que de natures variables. Il s'agit d'une série complexe de dépôts discontinus formés d'éléments hétérométriques et hétérogènes. On y rencontre les faciès suivants :

- Les travertins villafranchiens situés en bordure des monts de Tlemcen , qui sont représentés par des travertins fortement consolidés et des calcaires lacustres.
- Le complexe de sédiments plio-villafranchiens : la bordure des massifs secondaires est soulignée par des éboulis de piémont plus ou moins encroûtés et remaniés, d'épaisseur très variable mais toujours assez faible.
- Des marnes avec peu ou pas de galets, plus ou moins tufeuses, parfois très épaisses surtout au niveau du bassin de l'oued Mouilah.
- Des anciennes alluvions allant des marnes alluvionnaires verdâtres aux galets en passant par les limons et les graviers.
- Les limons, sables et graviers récents qui s'étendent entre oued Mehaguène et Chaâbet El Arneb au Nord Est de la frontière algéro-marocaine. Les limons sont jaunes en général avec des couches rougeâtres et à leur base se trouvent les galets en lits.
- Quelques lambeaux de basaltes interstratifiés, témoins d'une activité volcanique. Ils sont situés au Nord-ouest de la plaine de Maghnia .

## 7-HYDROLOGIE :

Selon Seltzer (1946), le climat de l'Algérie est de type méditerranéen caractérisé par une période pluvieuse allant en moyenne de Septembre à Mai et un été sec et ensoleillé.

L'Atlas tellien joue le rôle d'un rempart qui provoque la condensation et les précipitations d'une partie de la vapeur d'eau amenée par les vents soufflant de la mer. L'altitude entraîne une diminution générale de la température, l'éloignement de la mer, une augmentation des amplitudes diurnes et annuelles.

Le climat de l'Atlas tellien présentera donc tous les degrés intermédiaires entre un climat de montagne pluvieux, froid à amplitude thermique relativement faible avec chutes de neige et un climat de plaines plus sec relativement chaud et à forts écarts thermiques.

La région de Tlemcen se trouve entre deux domaines géographiques contrastés : les monts de Tlemcen au Sud et la zone des plaines qui s'étendent vers le Nord.

### 7-1-Etude des précipitations :

La Pluviométrie en Algérie a été étudié par plusieurs auteurs, (P.Seltzer, 1913-1938, H.Gaussen, 1918-1947, G.Medinger, 1913-1953, M.Chaumont et C.Paquin, 1913-1963). La plupart des stations du bassin ont été arrêtées pendant la guerre d'Algérie, d'autres ont subi des modifications après 1962.

Ceci se traduit par des résultats entachés d'erreurs et le nombre élevé de lacunes à l'échelle mensuelle et annuelle.

D'autre part bon nombre de stations ont été installées lors de la restructuration du réseau pluviométrique algérien et leurs données sont très utiles pour l'établissement d'une série pluviométrique récente (1970-1998). L'intérêt et le but de cette série et de permettre la confrontation avec l'écoulement correspondant afin de dégager une étude hydro pluviométrique et d'estimer la lame d'eau moyenne tombée sur le bassin.

Pour le nombre de stations pluviométrique existant à travers le bassin versant de la Tafna est de 29 dont 22 sont implantés dans les monts de Tlemcen ou leurs piémonts nord.

Ces stations appartiennent en grande partie à l'ANRH.

Tous les auteurs qui ont travaillé sur la pluviométrie de l'ouest Algérien sont arrivés à dire que la pluviométrie a nettement baissé. Cette baisse est d'environ 30% (Benfares et benabderahmane2002) .il faut remarquer la tendance déficitaire des précipitations lors des 20 dernières années a partir de 1976 ou plusieurs valeurs annuelles se trouvent en dessous de la moyenne (Bouanani2004, Megnounif 2007, Ghenim 2007).

### 7-2-Etude hydropluviométrique :

Par ailleurs nous allons voir les différents caractéristiques de précipitations et de débits pour une période plus longue (1970-1998) car le but est de permettre de voir et d'analyser l'étude hydro pluviométrique.

**Tableau -13- caractéristiques des précipitations annuelles pour les deux stations pluviométriques du bassin versant de l'oued sebdou.**

Stations	Moyenne (mm)	Max (année)	Min (année)	Nbre d'années > moy	PM/Pm
Sebdu	419.78	699.2 (95-96)	225.1 (91-92)	13	3.11
Beni Bahdel	435	729.1 (75-76)	187.7 (87-88)	15	3.88

Afin de caractériser la pluviosité propre à chaque année, il convient de tenir compte de "l'écart à la moyenne" correspondant à l'excédent ou au déficit des précipitations de l'année considérée rapporté à la moyenne de 28 ans. Cet écart est calculé par :

$$E_i (\%) = (P_i - P_n / P_n) \cdot 100 \quad \text{Avec:}$$

$E_i$  : écart à la moyenne

$P_n$  : module pluviométrique moyen

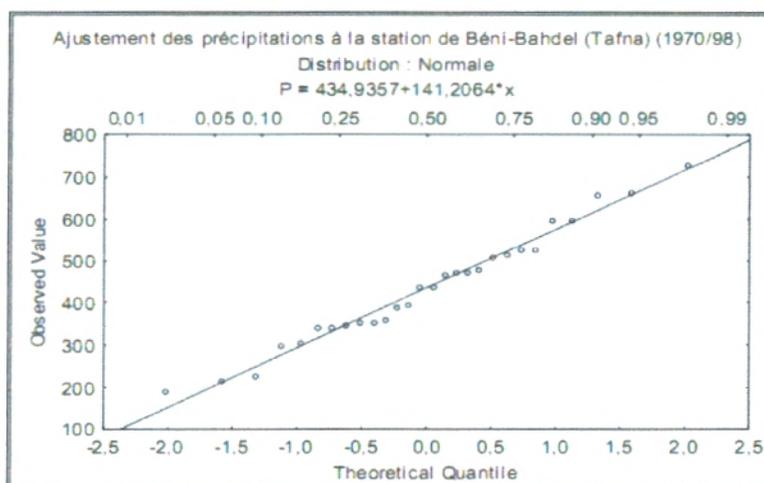
$P_i$  : total de l'année considérée.

Le coefficient d'irrégularité du régime des précipitations annuelles : rapport du module de l'année la plus humide  $P_M$  à celui de l'année la plus sèche  $P_m$  est en moyenne de 3.11 pour Sebdu et 3.88 pour Beni Bahdel Ceci traduit une irrégularité aussi bien spatiale que temporelle du régime pluviométrique dans le bassin de la Tafna..(Megnounif et al, 1999, Bouanani et al 2003)

#### 7-2-1- Ajustement des précipitations annuelles à une loi de probabilité

L'irrégularité interannuel des précipitations joue un rôle très important sur l'écoulement fluviale et afin de caractériser le régime des précipitations annuelles, nous allons essayer de trouver une loi d'ajustement de la distribution des pluies annuelles dans le but d'aboutir à une estimation des paramètres d'ajustement .

L'ajustement graphique de la série pluviométrique de la station de Beni bahdel pour la période (1970/98), montre que la pluie s'ajuste en général suivant une loi normale de Gauss ou une loi log normale.



**Fig- 39- Ajustements des précipitations annuelles de la station de Beni bahdel du bassin versant de l'oued Sebdou Tafna à la loi normale (Bouanani 2004) .**

### 7-2-3- Les débits moyens annuels :

L'écoulement moyen annuel ou l'abondance annuelle est une notion fondamentale en hydrologie. C'est le volume d'eau écoulé en 365 jours à la sortie d'un bassin. Le module brut ou absolu est généralement exprimé en  $m^3/s$ . Nous disposons de séries de données hydrométriques représentant 28 ans d'observation (1970/98).

**Tableau -14- Caractéristiques de station hydrométrique de Beni bahdel**

Bassins	Stations	Code	X	Y	Z	Période
Oued Sebdou (Haute Tafna)	Béni Bahdel	16-04-02	118,80	163,40	665,0	1970/1998

### 7-2-4- Variations des débits annuels moyens bruts ( $m^3/s$ ) :

La variation annuelles des débits annuels moyens bruts au niveau de la station de beni badel montre que l'oued Sebdou à Béni Bahdel, qui est un petit bassin de montagne (255  $km^2$ ) affiche un débit de  $1,465 m^3/s$ .

Tableau -15- Débits moyens annuels de l'oued Seb Dou à Béni bahdel

<b>Bassin</b>	<b>Oued Seb Dou</b>
<b>Station</b>	<b>Beni Bahdel</b>
<b>Année</b>	<b>Q (m<sup>3</sup>/s)</b>
1970/71	2,053
1971/72	2,9
1972/73	3,595
1973/74	5,476
1974/75	4,266
1975/76	1,527
1976/77	2,141
1977/78	1,099
1978/79	0,766
1979/80	1,922
1980/81	2,446
1981/82	0,736
1981/82	0,736
1982/83	0,678
1983/84	0,412
1984/85	0,403
1985/86	1,148
1986/87	1,707
1987/88	0,351
1988/89	0,565
1989/90	0,257
1990/91	1,464
1991/92	1,085
1992/93	0,465
1993/94	0,709
1994/95	1,136
1995/96	1,097
1996/97	0,189
1997/98	0,436
<b>Moyenne</b>	<b>1,465</b>
<b>Ecart type</b>	<b>1,265</b>

Tableau 16 Valeurs caractéristiques des modules au niveau du bassin versant de l'oued Seb Dou

<b>Stations</b>	<b>Moyenne (m<sup>3</sup>/s)</b>	<b>Max (m /s) (année)</b>	<b>Min (m /s) (année)</b>	<b>Nbre d'années &gt; moyenne</b>	<b>Coeff. Immodération R = QM/Qm</b>	<b>Coefficient Variation</b>
Beni Bahdel	1,465	5,476 (73-74)	0,189 (96-97)	10 sur 28	28,97	0,88

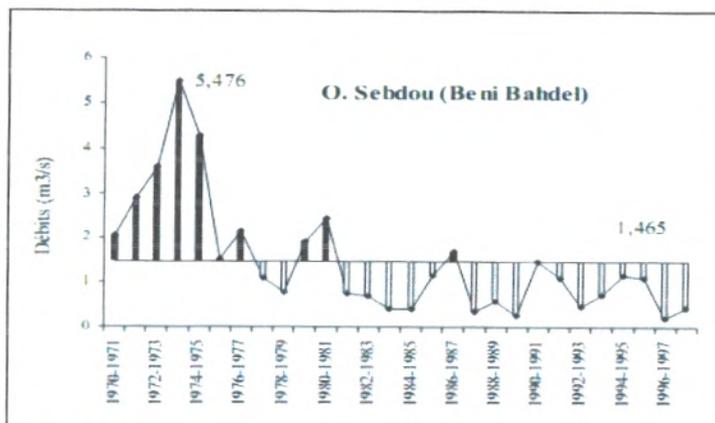


Fig - 40 - Variations interannuelles des modules de l'oued Sebdou à Béni Bahdel

### 7-2-5- Débits moyens mensuels et saisonniers :

L'analyse des débits moyens mensuels permet de mettre en évidence les régimes des cours d'eau et leurs variations inter annuelles ou inter saisonnières. Ces régimes peuvent être traduits par divers critères numériques et graphiques parmi lesquels on retiendra, principalement les coefficients mensuels de débits (C.M.D).

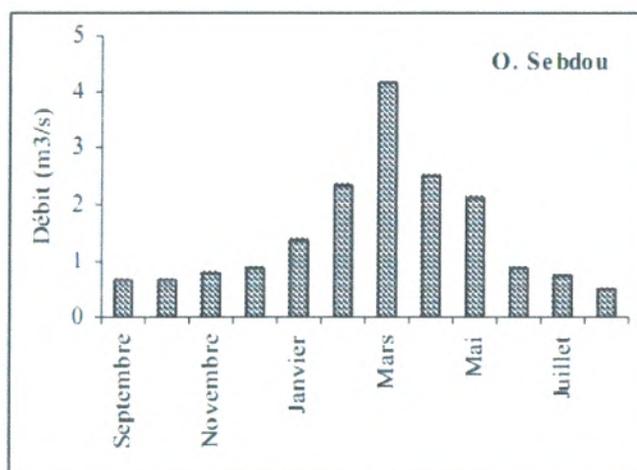
### 7-2-6- Coefficient mensuel de Débits :

Les coefficients mensuels ou rapports des débits moyens mensuels au module de la période considérée, pris pour l'unité, ont l'avantage de permettre la comparaison des variations saisonnières du régime des cours d'eau de débits très différents. Les CMD inférieures à l'unité correspondent aux mois de basses eaux et les CMD supérieures à l'unité représentent les mois de hautes eaux (tableau 17).

L'examen des histogrammes de figure (41), montrent que les maxima mensuels sont observés au mois de mars pour la station de beni bahdel, alors que les minima mensuels sont enregistrés en juillet-août.

Tableau 17 : Répartition des débits mensuels de l'oued Sebdou à Béni bahdel

	S	O	N	D	J	F	M	A	M	J	Jt	A	An
<b>M</b>	0.655	0.674	0.774	0.869	1.384	2.327	4.160	2.514	2.131	0.867	0.734	0.494	1.465
<b>CMD</b>	0.45	0.46	0.53	0.59	0.94	1.59	2.84	1.72	1.45	0.59	0.50	0.34	-
<b>Max</b>	2.209	2.178	1.976	2.915	8.894	9.628	2.609	2.085	1.252	3.036	4.677	2.354	5.476
<b>Min</b>	0.016	0.105	0.066	0.160	0.253	0.248	0.048	0.079	0.074	0.017	0.000	0.019	0.189
<b><math>\sigma</math></b>	0.531	0.562	0.568	0.647	1.686	2.410	6.235	4.592	3.156	0.849	0.976	0.570	1.289
<b>Cv</b>	0.81	0.83	0.73	0.74	1.22	1.04	1.50	1.83	1.48	0.89	1.33	1.16	0.88



**Fig -41- Variations des débits moyens mensuels de l'oued Sebdou à Beni bahdel**

Pour le bassin de l'oued Sebdou, la période des hautes eaux commence en janvier, en raison vraisemblablement de l'énorme capacité d'infiltration qu'offre son bassin concomitant à une évaporation élevée, les pluies du début de l'année climatique n'interviennent donc pas efficacement au soutien de l'écoulement superficiel.

Par ailleurs, la période des basses eaux est assez décalée dans le temps, elle ne commence qu'au mois de juin du fait de l'importance relative des précipitations de printemps. La moyenne mensuelle minimale est également retardée, elle se situe en août. Nous pensons que ceci est lié à l'alimentation de l'oued par des circulations d'eaux souterraines (Aïn Taga : l'exutoire principal de la Tafna) qui soutiennent l'écoulement (Bouanani 2004).

#### **7-2-8- Coefficient de variation :**

Il apparaît en effet que l'écoulement mensuel est extrêmement variable, pour certains mois le coefficient de variation dépasse largement l'unité et est compris entre 0.73 et 1.83 pour Sebdou (Bouanani 2004).

#### **7-2-9- Modifications inter annuelles du régime saisonnier :**

Les valeurs moyennes des fluctuations mensuelles figure (42) ne s'observent pas toujours de la même façon d'une année sur l'autre.

À Béni Bahdel, pendant 28 ans, le maximum s'est trouvé 8 fois en mars (29%) et 6 fois en février (21,5%), 5 fois en janvier (17.9%), 3 fois en mai (10.7%), 2 fois en avril et décembre et 1 fois en septembre et octobre. Ce maximum dans ces deux derniers mois s'explique par les orages et les pluies violentes d'été et du début d'automne.

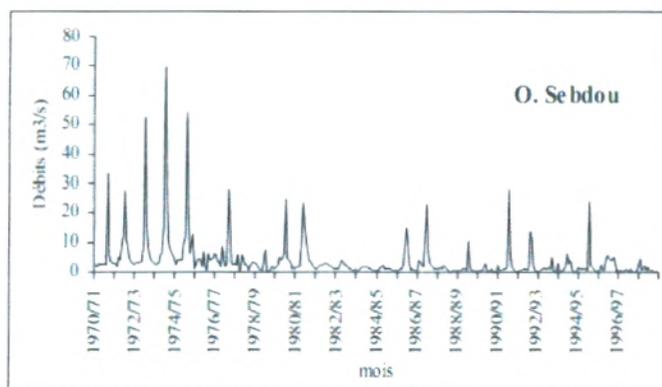


Fig –42- Variations interannuelles des débits mensuels de l'oued Seb dou à Beni Bahdel

#### 7-2-10- Variations journalières des débits de l' Oued Seb dou à Béni Bahdel :

Pour l'année humide (1971/72), la courbe des débits journaliers (fig.43) fait ressortir deux périodes :

Une saison pluvieuse qui a débuté de décembre à juin (hiver – printemps) au cours de laquelle les crues ont été brutales, et une saison chaude de tarissement pour le reste de l'année.

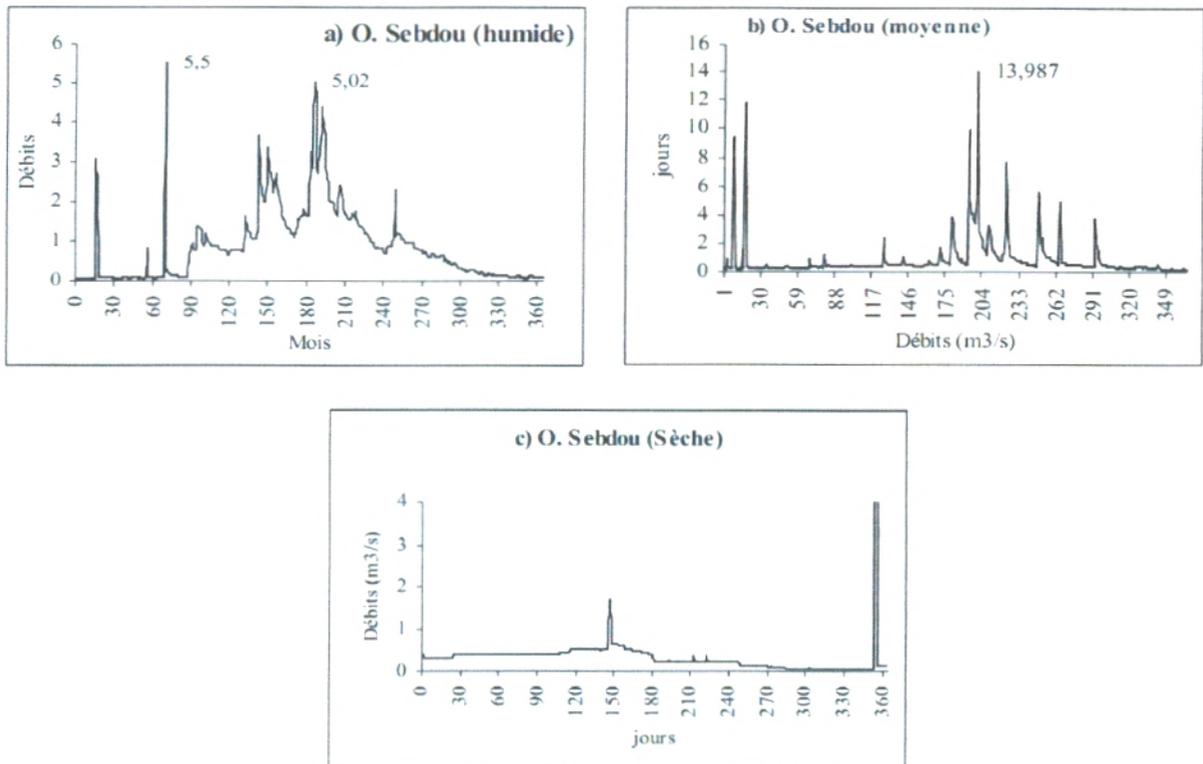
La décroissance des débits est moins brusque que les montées des eaux, ceci s'explique par le fait que l'oued est soutenu par de nombreuses sources en particulier la source de la Tafna.

Les débits moyens journaliers (Fig.43) varient selon une fréquence propre à chaque mois.

Au début de l'automne, une grande partie de la lame d'eau précipitée ruisselle étant donné que le sol est complètement sec et étanche à cause d'une longue période estivale sèche.

Par la suite, il y a un gonflement rapide du cours d'eau et l'apparition des premières montées des eaux en hiver qui interviennent brusquement, elles durent un temps faible puis décroissent. A ce moment le sol est suffisamment gorgé d'eau, les débits grossissent sous l'effet des maxima de crue. A partir du mois d'Avril les débits commencent à décroître lentement et presque régulièrement jusqu'au minimum. Pour l'année sèche (1996/97) (fig.43), le débit journalier minimal atteint 0,029 m<sup>3</sup>/s.

Cette faiblesse du débit est aggravée par de nombreux prélèvements le long de l'oued, la capacité de rétention du bassin est relativement faible, à ajouter à cela la forte évaporation en cette saison (Bouanani 2004).



**Fig -43- Variations des débits moyens journaliers de l'oued Sebdou à Beni Bahdel.**

L'interprétation statistique et graphique des données nous a permis de saisir les variations spatiales de l'écoulement superficiel en liaison avec les données climatiques et de même sa forte variabilité temporelle, annuelle et surtout saisonnières et journalières.

Pour notre prochain chapitre nous allons retenir les deux stations qui appartiennent à notre secteur d'étude, le sous bassin de l'oued Sebdou pour une série pluviométrique récente (1995-2005), ces stations se trouvent à l'aval de l'oued Sebdou et à l'amont de Beni bahdel a fin qu'on puisse modéliser la relation (pluie / Débit) par l'approche connexionniste réseau neurone, cette partie sera détaillée dans le chapitre quatre de ce mémoire .

# 4

Chapitre

## Modélisation neuronale des données pluviométriques

## 1. Introduction :

Comme tout modèle d'analyse des données, un système neuronal de traitement des données pluviométrique (pluie/débit) est amené à effectuer des tâches complexes et difficiles (notamment lors de l'apprentissage) à partir d'une base de données réelles.

Pour que le modèle neuronal soit opérationnel dans la phase d'exploitation, il est primordial que la nature des données et notamment leurs variations soient correctement prises en compte.

Le problème se profile à plusieurs niveaux, comportant chacun des difficultés théorique et pratique.

Il faut disposer premièrement d'un dispositif de collectes des données efficace qui nous fournira des données de qualité (avec un minimum d'erreur).

Il faut ensuite pouvoir représenter ces données de manière efficace et compatible avec les étapes de traitement ultérieures.

Cette représentation et ces modalités constituent le système avec lequel le mécanisme de modélisation (pluie/débit) devra travailler à fin de produire le résultat désiré.

Dans certains domaines tel que le domaine de l'hydrogéologie ainsi l'hydrologie, le principal obstacle auquel est confronté, le concepteur lors de la mise en œuvre d'un système de modélisation ou de prédiction est la caractérisation des données par des paramètres fiables et pertinents.

Dans ce chapitre nous abordons le problème de la prédiction du débit liquide à partir de la précipitation pluviale.

La caractérisation de la précipitation par des descripteurs représentatifs, et donc absolument indispensable lors de la conception d'un modèle neuronal pour la modélisation (pluie/débit).

Il convient de remarquer que de nombreuses approches citées dans la littérature ont porté sur la difficulté que représente le lien entre la précipitation pluviale et le débit liquide ; on peut citer les travaux menés par plusieurs chercheurs pour accomplir cette tâche, pour la prévision du débit (karunanthi et al., 1994, Dimopoulos et al., 1996, Lek et al 1996, Coulibaly et al 2000, Imrie et al, 2000, Sivakumar et al 2002) et pour la prévision des précipitations (French et al 1992, Luk Kin et al 2001). En outre, les réseaux de neurones sont utilisés pour modéliser la relation pluie-débit (Hsu et al., 1995, Smith et Eli 1995, Minns, 1996, Shamseldin 1997, Dawson et Wilby, 1998 et al 2000, Sajikumar et Thandaveswara ; 1999, Tokar et Johnson, 1999).

En ce qui concerne nous avons testé et comparé plusieurs modèles neuronaux à partir de la base de données de l'ANRH.

## 2 - Modèles neuronaux :

L'analyse suscitée de la littérature montre que lorsque une approche de modélisation ou prédiction est adoptée, les réseaux de neurones artificiels sont une bonne technique à choisir et à exploiter.

Pour notre étude comme décrit auparavant, le réseau de neurones utilisés sera optimisé par des algorithmes d'apprentissages de type supervisé.

La stratégie que nous envisageons de mettre en oeuvre est représentée dans la figure (44).

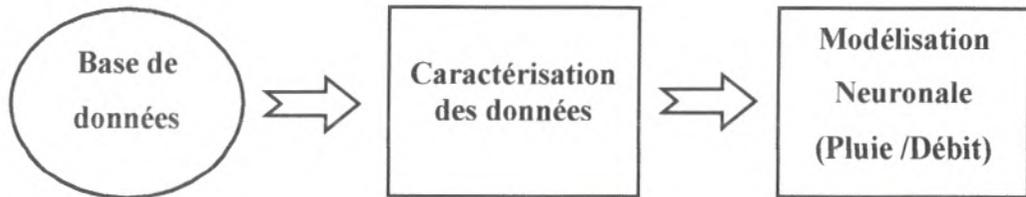


Fig-44 : Schéma globale de notre approche

### 2-1 choix de la base d'exemples :

Nous avons utilisé dans le cadre de ce mémoire de magister, une base de données collectées au niveau de l'ANRH, cette base représente des données d'une décennie (Septembre 1995-Septembre 2005).

La base de l'apprentissage affecte les performances des modèles neuronaux. Le critère général à respecter pour élaborer l'apprentissage est de sélectionner des exemples représentatifs de toutes les années choisis dans la base.

Dans notre cas, nous avons sélectionné 3623 jours de la période entre 1995-2005, dont les  $\frac{3}{4}$  de la base (2718) sont réservés pour l'apprentissage et le reste (905) est réservé pour le test.

### 2-2 choix des descripteurs :

Des descripteurs permettant de caractériser la précipitation sont retenus. Ils sont comparables aux paramètres sur lesquels sont construits les connaissances dans le domaine de l'hydrologie.

- a- Précipitation quotidienne.
- b- Précipitation mensuelle.
- c- Précipitation saisonnière.
- d- Précipitation annuelle.

### 2-3- Architecture des modèles neuronaux :

#### 2-3-1- Algorithme d'apprentissage :

L'architecture que nous avons retenue est le perceptron multicouche. Pour l'apprentissage, il existe généralement trois protocoles utilisés par les réseaux multicouches :

- Apprentissage stochastique, hors-ligne.
- Apprentissage par lot.
- Apprentissage en ligne.

L'apprentissage en ligne est utile lorsque l'ensemble d'apprentissage est très grand ou que la mémoire devient prohibitive, pour la sauvegarde des données.

Aujourd'hui, les ordinateurs ne présentent plus de problème de limitation en mémoire et en coût. Dans l'apprentissage en ligne, chacune des formes est présentée une seule fois, ce qui peut sembler donner un apprentissage rapide mais nécessite plus de données d'apprentissage.

L'apprentissage par lot est très utilisé de nos jours. Dans Matlab, on retrouve les trois protocoles d'apprentissage, mais nous utiliserons seulement le protocole d'apprentissage par lot. Au cours de ce travail nous avons utilisé principalement trois algorithmes très classiques en optimisation non linéaire.

**2-3-1-1- Quasi-Newton :** les algorithmes basés sur la méthode de Newton sont une alternative aux méthodes du gradient conjugué pour atteindre rapidement l'optimisation des paramètres de poids et de biais. La méthode de Newton se base sur le calcul suivant :

$$\mathbf{X}_{k+1} = \mathbf{X}_k - \mathbf{A}_k^{-1} \mathbf{g}_k$$

Où  $\mathbf{A}$  est la matrice Hessienne (matrice des dérivées secondes de l'indices de performance des valeurs de poids et de biais). Les algorithmes provenant de la méthode de Newton convergent plus rapidement que les méthodes du gradient conjugués.

Malheureusement, la matrice Hessienne consomme un temps appréciable en calcul. Il existe des méthodes que l'on appelle Quasi-Newton où le calcul de la matrice Hessienne est évalué approximativement à chaque pas d'itération de l'algorithme. Dans matlab, on retrouve ces algorithmes dans la fonction « trainbfg ».

**2-3-1-2- Levenberg-Marquardt :** cette méthode permet de palier les inconvénients du choix du pas et du nombre d'itérations, car elle choisit automatiquement un compromis entre la direction du gradient et la direction de Newton. Nous choisissons une valeur initiale de  $(\lambda)$  qui est modifiée durant l'optimisation.

À chaque itération, on calcule la fonction de coût  $\mathbf{J}(\boldsymbol{\theta})$  avec la valeur de  $(\lambda)$  précédente ; si la fonction de coût diminue, on effectue la modification des paramètres et on diminue  $(\lambda)$  ; si la fonction de coût croît, on cherche à se rapprocher du gradient et on augmente  $(\lambda)$  jusqu'à ce que le coût diminue. Dans Matlab, on retrouve cet algorithme dans la fonction « trainlm ».

**2-3-1-3. Méthode Du Gradient :** à pas constant c'est la méthode la plus simple à mettre en œuvre ; elle ne repose que sur le calcul du gradient qui donne la direction de descente. Le pas  $(\mu)$  est constant. Ainsi à l'itération  $(k)$ , la modification des paramètres est donnée par :

$$\boldsymbol{\theta}_k = \boldsymbol{\theta}_{k-1} - \mu \cdot \Delta J_{k-1}$$

Cette méthode est très simple d'utilisation et elle est efficace loin d'un minimum, le gradient tend vers 0 et la vitesse de convergence diminue très fortement. Le programme (**dp**) que nous avons utilisé est basé sur la méthode de la descente de gradient stochastique.

En les confrontant sur plusieurs problèmes, il apparaît qu'aucune de ces trois méthodes ne prend un avantage considérable sur l'autre. Chaque méthode d'optimisation possède des avantages et des inconvénients. La méthode de Levenberg-Marquardt présente un intérêt pratique car elle peut être utilisée sans avoir à choisir le pas.

Bien étendu, aucune méthode ne conduit à coup sûr au minimum global. Il convient donc de se parler dans des conditions où les minimas locaux sont aussi peu nombreux que possible ou correspondant à une erreur suffisamment faible.

### 2-3-2 – Dimensionnement du modèle neuronal :

Dans cette étude, la structure neuronale est déterminée par le nombre de neurones de la couche d'entrée  $N_e$  et celui de la couche cachée  $N_c$ , tous sont des variables.

#### 1- Couche d'entrée :

Nous avons quatre descripteurs cités auparavant, en effet le nombre de neurones de la couche d'entrée est liée directement au vecteur de caractéristique.

#### 2- Couche cachée :

Le choix de la taille de la couche cachée est réalisé souvent de façon heuristique et expérimentale, car aucune formulation théorique ne peut aider à l'optimiser.

Nous avons mené plusieurs essais pour arrêter le nombre  $N_c$  à mettre sur la couche cachée et choisir le coefficient d'apprentissage ( $\lambda$ ) pour chaque expérimentation.

Plusieurs essais nous ont permis d'arrêter le nombre de neurones,  $N_{c1}$  pour la première couche cachée et  $N_{c2}$  pour la deuxième couche cachée, et d'autres essais nous ont permis de choisir le coefficient d'apprentissage ( $\lambda$ ) le plus adéquat.

Les fonctions d'activations des neurones cachés sont des sigmoïdes, les tableaux (23,24,25) reportent respectivement les valeurs des paramètres pour chaque modèle neuronale pour toutes les expérimentations.

Notons que dans les réseaux multicouches, le grand problème est de déterminer le nombre de couches cachées et le nombre de neurones pour chacune de ces couches, afin d'obtenir le meilleur rapport précision/rapidité. En effet, un grand nombre de neurones augmente exagérément le temps de calcul, mais donne généralement (pas toujours !) de meilleurs résultats. Il n'existe actuellement pas de méthodes pour trouver la configuration optimale. Nous avons donc essayé plusieurs réseaux et gardé le meilleur.

#### 3- Couche de Sortie :

La sortie est composée d'un unique neurone correspondant au débit liquide, la fonction d'activation est linéaire.

Le nombre d'itérations, fixé selon les essais a permis de réaliser un apprentissage satisfaisant. Par ailleurs, il est clair que ce dernier paramètre est important : s'il est grand, le réseau risque de réaliser un sur-apprentissage ; au contraire, s'il est trop petit, l'apprentissage ne sera pas conduit à son terme.

Tableau-18- Paramètres choisis pour chaque expérimentation réalisé ( $Nc1=20, Nc2=20$ )

Le Réseau	Neurones cachés ( $Nc1, Nc2$ )	( $\lambda$ ) le pas d'apprentissage
Réseau 9	(20,20)	0,8
Réseau 9	(20,20)	0,8
Réseau 10	(20,20)	0,8
Réseau 10	(20,20)	0,8
Réseau 11	(20,20)	0,8
Réseau 12	(20,20)	0,5
Réseau 13	(20,20)	0,8
Réseau 13	(20,20)	0,8
Réseau 14	(20,20)	0,8
Réseau 15	(20,20)	0,8
Réseau 16	(20,20)	0,8
Réseau 17	(20,20)	0,8
Réseau 18	(20,20)	0,8
Réseau 19	(20,20)	0,8
Réseau 19	(20,20)	0,8
Réseau 20	(20,20)	0,8
Réseau 21	(20,20)	0,8
Réseau 22	(20,20)	0,5
Réseau 23	(20,20)	0,8
Réseau 24	(20,20)	0,8

Tableau -19- Paramètres choisis pour chaque expérimentation réalisé ( $Nc1=25, Nc2=25$ )

Le Réseau	Neurones cachés ( $Nc1, Nc2$ )	( $\lambda$ ) le pas d'apprentissage
Réseau 27	(25,25)	0,8
Réseau 28	(25,25)	0,8
Réseau 29	(25,25)	0,5
Réseau 30	(25,25)	0,8
Réseau 39	(25,25)	0,8
Réseau 40	(25,25)	0,8
Réseau 51	(25,25)	0,8
Réseau 51	(25,25)	0,8
Réseau 52	(25,25)	0,8
Réseau 53	(25,25)	0,5
Réseau 54	(25,25)	0,8
Réseau 55	(25,25)	0,8
Réseau 56	(25,25)	0,8
Réseau 57	(25,25)	0,8
Réseau 58	(25,25)	0,8
Réseau 59	(25,25)	0,8
Réseau 60	(25,25)	0,8
Réseau 61	(25,25)	0,8
Réseau 62	(25,25)	0,8
Réseau 63	(25,25)	0,8
Réseau 64	(25,25)	0,8
Réseau 65	(25,25)	0,5

Tableau -20- Paramètres choisis pour chaque expérimentation réalisé ( $Nc1=10, Nc2=10$ )

Le Réseau	Neurones cachés ( $Nc1, Nc2$ )	( $\lambda$ ) le pas d'apprentissage
Réseau 66	(10,10)	0,8
Réseau 67	(10,10)	0,8
Réseau 68	(10,10)	0,8
Réseau 69	(10,10)	0,8
Réseau 70	(10,10)	0,8
Réseau 70	(10,10)	0,8
Réseau 71	(10,10)	0,8
Réseau 72	(10,10)	0,8
Réseau 73	(10,10)	0,8
Réseau 74	(10,10)	0,8
Réseau 75	(10,10)	0,8
Réseau 80	(10,10)	0,8
Réseau 81	(10,10)	0,8
Réseau 82	(10,10)	0,8
Réseau 83	(10,10)	0,8

Tableau -21- Paramètres choisis pour chaque expérimentation réalisé ( $Nc1=30, Nc2=30$ )

Le Réseau	Neurones cachés ( $Nc1, Nc2$ )	( $\lambda$ ) le pas d'apprentissage
Réseau 46	(30,30)	0,8
Réseau 47	(30,30)	0,8
Réseau 48	(30,30)	0,5
Réseau 49	(30,30)	0,8
Réseau 88	(30,30)	0,8
Réseau 89	(30,30)	0,5
Réseau 90	(30,30)	0,8
Réseau 91	(30,30)	0,8

Tableau -22- Paramètres choisis pour chaque expérimentation réalisé ( $Nc1=40, Nc2=40$ )

Le Réseau	Neurones cachés ( $Nc1, Nc2$ )	( $\lambda$ ) le pas d'apprentissage
Réseau 49	(40,40)	0,8
Réseau 50	(40,40)	0,8
Réseau 50	(40,40)	0,8

### 3-Résultats expérimentaux et interprétations :

Dans ce qui suit, on présente de façon résumée les résultats des modèles neuronaux obtenus à partir des essais expérimentaux cités auparavant.

#### 3-1 Algorithmes d'apprentissage :

Nous avons choisis trois algorithmes d'apprentissage qui tournent autour de la technique de la descente de gradient (quelques paramètres qui changent pour accélérer la convergence) ; les tableaux suivants présentent les modèles neuronaux obtenus.

**Tableau -23- Algorithme d'apprentissage des modèles neuronaux LM**

<b>Le Réseau</b>	<b>Algorithme d'apprentissage</b>	<b>Epochs</b>	<b>Temps d'apprentissage</b>
Réseau 9	Levenberg-Marquardt	500	600 seconds
Réseau 9	Levenberg-Marquardt	284	540 seconds
Réseau 9	Levenberg-Marquardt	180	240 seconds
Réseau 10	Levenberg-Marquardt	500	366 seconds
Réseau 10	Levenberg-Marquardt	252	370 seconds
Réseau 11	Levenberg-Marquardt	223	422 seconds
Réseau 12	Levenberg-Marquardt	223	485 seconds
Réseau 13	Levenberg-Marquardt	500	733 seconds
Réseau 13	Levenberg-Marquardt	500	785 seconds
Réseau 14	Levenberg-Marquardt	500	487 seconds
Réseau 15	Levenberg-Marquardt	500	933 seconds
Réseau 16	Levenberg-Marquardt	500	955 seconds
Réseau 17	Levenberg-Marquardt	500	789 seconds
Réseau 18	Levenberg-Marquardt	500	723 seconds
Réseau 19	Levenberg-Marquardt	1000	2155 seconds
Réseau 19	Levenberg-Marquardt	1000	1560 seconds
Réseau 20	Levenberg-Marquardt	1000	1576 seconds
Réseau 21	Levenberg-Marquardt	1000	895.58 seconds
Réseau 22	Levenberg-Marquardt	1000	3111 seconds
Réseau 23	Levenberg-Marquardt	1000	1505 seconds
Réseau 24	Levenberg-Marquardt	1000	1455 seconds
Réseau 25	Levenberg-Marquardt	2000	2908 seconds
Réseau 26	Levenberg-Marquardt	2000	2923 seconds
Réseau 27	Levenberg-Marquardt	3000	4411 seconds
Réseau 28	Levenberg-Marquardt	3000	4461 seconds
Réseau 42	Levenberg-Marquardt	3000	767 seconds
Réseau 43	Levenberg-Marquardt	500	3482 seconds
Réseau 44	Levenberg-Marquardt	1000	2715 seconds
Réseau 45	Levenberg-Marquardt	1000	3127 seconds
Réseau 84	Levenberg-Marquardt	1500	4682 seconds
Réseau 85	Levenberg-Marquardt	1000	6109 seconds
Réseau 86	Levenberg-Marquardt	1500	12701 seconds
Réseau 87	Levenberg-Marquardt	500	4522 seconds
Réseau 88	Levenberg-Marquardt	1000	3127 seconds
Réseau 90	Levenberg-Marquardt	10 000	6109 seconds
Réseau 91	Levenberg-Marquardt	3000	13701 seconds
Réseau 92	Levenberg-Marquardt	1000	7102 seconds
Réseau 93	Levenberg-Marquardt	1000	9753.45 seconds
Réseau 84	Levenberg-Marquardt	1500	10340 seconds
Réseau 85	Levenberg-Marquardt	1000	11504 seconds
Réseau 86	Levenberg-Marquardt	1000	4623 seconds

Le Réseau	Algorithme d'apprentissage	Epochs	Temps d'apprentissage
Réseau 9	Levenberg-Marquardt	500	645 seconds
Réseau 9	Levenberg-Marquardt	284	523 seconds
Réseau 9	Levenberg-Marquardt	180	281 seconds
Réseau 10	Levenberg-Marquardt	500	12701 seconds
Réseau 10	Levenberg-Marquardt	252	4522 seconds
Réseau 11	Levenberg-Marquardt	223	3127 seconds
Réseau 12	Levenberg-Marquardt	223	4682 seconds
Réseau 13	Levenberg-Marquardt	500	6109 seconds
Réseau 13	Levenberg-Marquardt	500	13701 seconds
Réseau 14	Levenberg-Marquardt	500	12701 seconds
Réseau 15	Levenberg-Marquardt	500	944 seconds
Réseau 16	Levenberg-Marquardt	500	933 seconds
Réseau 17	Levenberg-Marquardt	500	782 seconds
Réseau 18	Levenberg-Marquardt	500	723 seconds
Réseau 19	Levenberg-Marquardt	1000	2115 seconds
Réseau 19	Levenberg-Marquardt	1000	1086 seconds
Réseau 20	Levenberg-Marquardt	1000	1533 seconds
Réseau 21	Levenberg-Marquardt	1000	895.58 seconds
Réseau 22	Levenberg-Marquardt	1000	3111 seconds
Réseau 23	Levenberg-Marquardt	1000	1505 seconds
Réseau 24	Levenberg-Marquardt	1000	1455 seconds
Réseau 25	Levenberg-Marquardt	2000	2908 seconds
Réseau 26	Levenberg-Marquardt	2000	2923 seconds
Réseau 27	Levenberg-Marquardt	3000	4421 seconds
Réseau 28	Levenberg-Marquardt	3000	4461 seconds
Réseau 42	Levenberg-Marquardt	3000	767 seconds
Réseau 43	Levenberg-Marquardt	500	3482 seconds
Réseau 44	Levenberg-Marquardt	1000	2733minutes
Réseau 45	Levenberg-Marquardt	1000	3127 seconds
Réseau 84	Levenberg-Marquardt	1500	4682 seconds
Réseau 85	Levenberg-Marquardt	1000	6109 seconds
Réseau 86	Levenberg-Marquardt	1500	2045 seconds
Réseau 87	Levenberg-Marquardt	500	735 seconds
Réseau 88	Levenberg-Marquardt	1000	2145 seconds
Réseau 89	Levenberg-Marquardt	500	7320 seconds
Réseau 90	Levenberg-Marquardt	10 000	14405 seconds
Réseau 91	Levenberg-Marquardt	3000	933 seconds
Réseau 92	Levenberg-Marquardt	1000	7102 seconds
Réseau 93	Levenberg-Marquardt	1000	9753.45 seconds
Réseau 84	Levenberg-Marquardt	1500	10340 seconds
Réseau 85	Levenberg-Marquardt	1000	11504 seconds
Réseau 86	Levenberg-Marquardt	1000	4623 seconds

Tableau -24- Algorithme d'apprentissage des modèles neuronaux Gd

Le Réseau	Algorithme d'apprentissage	Epochs	Temps d'apprentissage
Réseau 29	Gradient descent	500	664 seconds
Réseau 30	Gradient descent	500	432 seconds
Réseau 31	Gradient descent	500	277 seconds
Réseau 32	Gradient descent	500	834 seconds
Réseau 33	Gradient descent	500	244 seconds
Réseau 34	Gradient descent	500	1267 seconds
Réseau 35	Gradient descent	500	633 seconds
Réseau 71	Gradient descent	500	248 seconds
Réseau 72	Gradient descent	500	256 seconds
Réseau 73	Gradient descent	500	1020 seconds
Réseau 74	Gradient descent	500	933 seconds
Réseau 75	Gradient descent	500	923 seconds
Réseau 76	Gradient descent	500	784 seconds
Réseau 77	Gradient descent	500	733 seconds
Réseau 78	Gradient descent	1000	21 433 seconds
Réseau 79	Gradient descent	1000	1085 seconds
Réseau 80	Gradient descent	1000	1655 seconds
Réseau 81	Gradient descent	1000	895.58 seconds
Réseau 83	Gradient descent	1000	3111 seconds
Réseau 83	Gradient descent	1000	1505 seconds
Réseau 84	Gradient descent	1000	1455 seconds
Réseau 84	Gradient descent	2000	2908 seconds
Réseau 85	Gradient descent	2000	2923 seconds

Tableau -25- Algorithme d'apprentissage des modèles neuronaux gdx

Le Réseau	Algorithme d'apprentissage	Epochs	Temps d'apprentissage
Réseau 29	gdx	500	664 seconds
Réseau 30	gdx	500	433 seconds
Réseau 31	gdx	500	466 seconds
Réseau 32	gdx	500	732 seconds
Réseau 33	gdx	500	266 seconds
Réseau 34	gdx	500	198 seconds
Réseau 35	gdx	1000	144 seconds
Réseau 71	gdx	1000	298 seconds
Réseau 72	gdx	1000	254 seconds
Réseau 73	gdx	500	1055 seconds
Réseau 74	gdx	500	950 seconds
Réseau 75	gdx	500	963 seconds
Réseau 76	gdx	500	785 seconds
Réseau 77	gdx	500	733 seconds
Réseau 78	gdx	1000	2176 seconds
Réseau 79	gdx	1000	1083 seconds
Réseau 80	gdx	1000	1532 seconds

Nous remarquons clairement dans ces tableaux que chaque modèle neuronale présente un temps d'apprentissage bien spécifique qui varie avec l'algorithme d'apprentissage choisis :

- Algorithme Levenberg-Marquardt : **LM**
- Algorithme gradient descent : **GD**
- Algorithme gradient descent (variable learning rate backpropagation) : **GDX**

### 3-2- les critères de convergences :

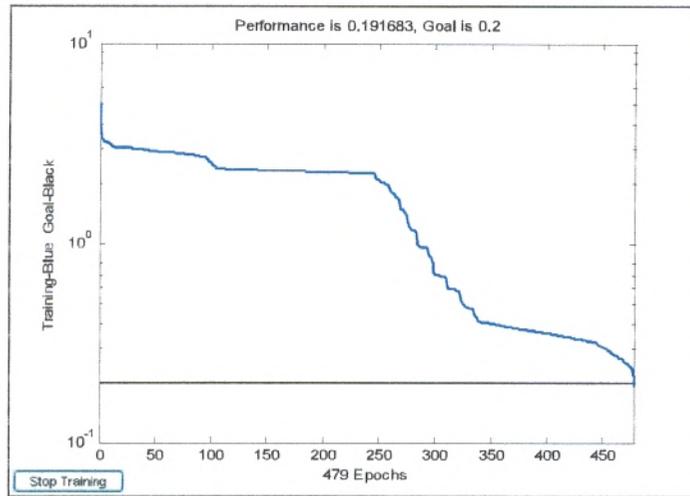
Notons que chaque modèle neuronale présente une initialisation aléatoire de ses poids synaptiques (  $w_i$  ) et la convergence du modèle dépend énormément de l'état initial.

Le tableau (26) présente des modèles neuronaux ou l'algorithme d'apprentissage a convergé avec succès.

**Tableau-26 - Les modèles neuronaux avec un bon apprentissage (convergence atteinte)**

<b>Le Réseau</b>	<b>Seuil d'apprentissage (Epochs)</b>
Réseau 9	500
Réseau 9	284
Réseau 9	180
Réseau 10	500
Réseau 10	252
Réseau 11	223
Réseau 12	223
Réseau 13	500
Réseau 13	500
Réseau 14	500
Réseau 15	500
Réseau 16	500
Réseau 17	500
Réseau 18	500
Réseau 19	1000
Réseau 19	1000
Réseau 20	1000
Réseau 21	1000

La figure (45) présente l'évolution de la convergence de l'erreur quadratique en fonction des itérations. Notons que l'erreur quadratique représente le carré de l'erreur entre la sortie désirée et la sortie réelle du modèle.



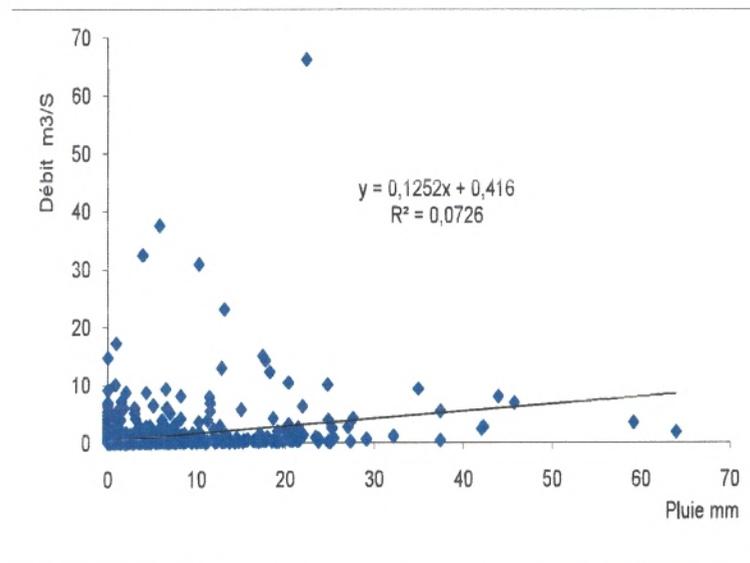
**Fig -45- La Convergence du modèle**

Nous remarquons que pour le même modèle neuronale, une fois l'algorithme d'apprentissage converge et d'autres fois il diverge, ce qui montre l'intérêt du choix des poids synaptiques initiaux.

### 3-3- Les performances du modèle neuronale choisis :

#### 3-3-1 Corrélation entre le Débit et la pluie de la série :

La base de donnée de l'ANRH est incomplète pour certaines périodes ce qui nous donne une mauvaise corrélation entre le débit et la pluie dans la globalité de la figure (46) dont les erreurs sur l'ensemble des données sont très élevées et ce qui montre aussi le coefficient de corrélation de pearson qui est de 0,2.



**Fig - 46- Corrélation de Pearson entre débit et pluie (1995-2005)**

### 3-3-2- Le débit simulé par le modèle neuronal choisi :

Nous avons gardé le meilleur modèle neuronal, celui qui a obtenu les meilleures performances lors des expérimentations précédentes il s'agit du réseau 21.

Les figures présentent (47,49,51) les sorties simulées avec les sorties mesurées pour les trois saisons : Saison d'automne 1996 ; Saison d'hiver 2000 ; Saison d'été 2002.

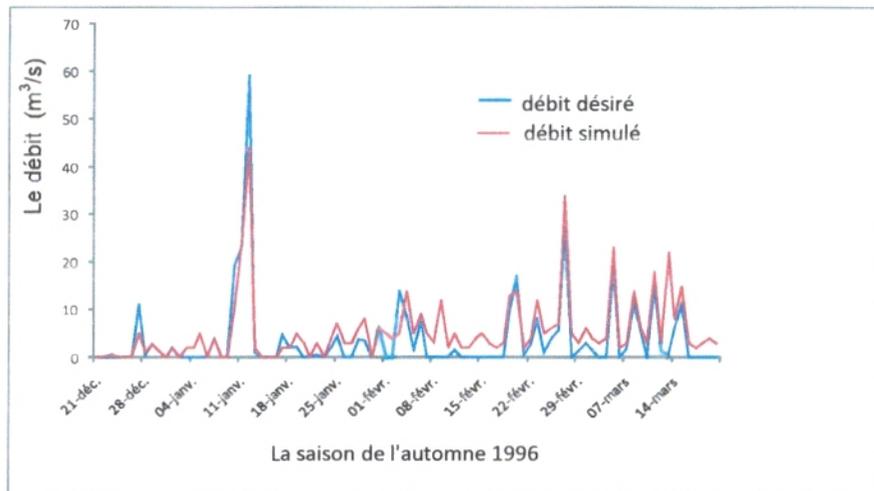


Fig-47- Hydrogramme de simulation entre le Débit mesuré et le débit Simulé pour la saison de l'automne 1996

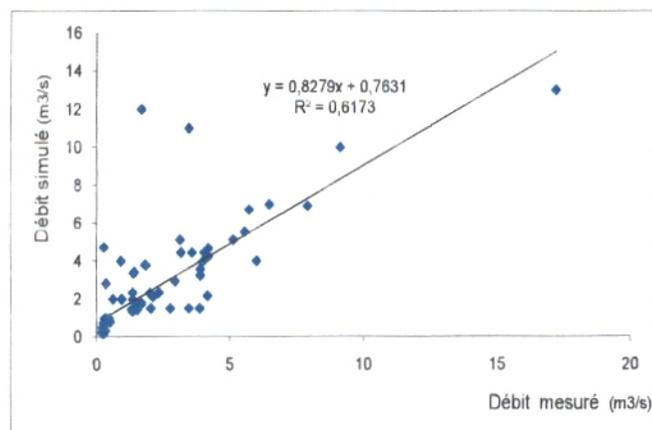


Fig -48- Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'automne 1996

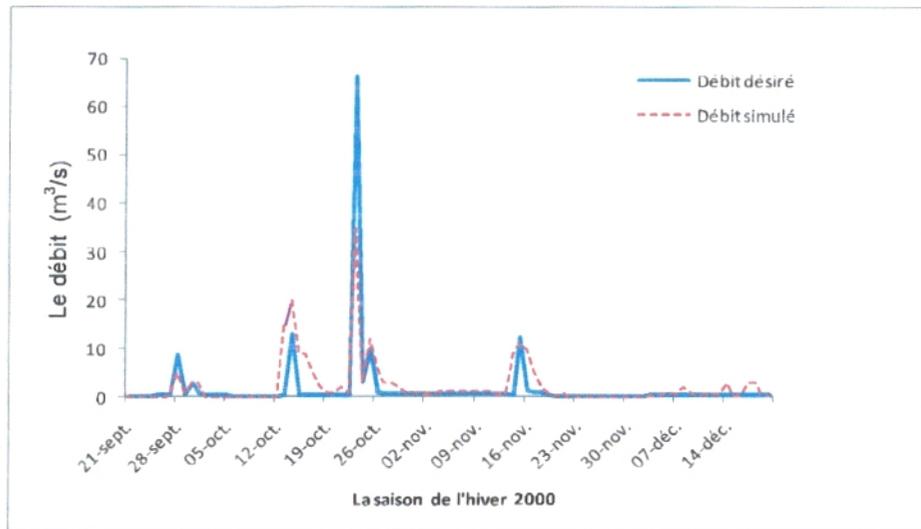


Fig-49- Hydrogramme de simulation entre le Débit mesuré et le débit Simulé pour la saison de l'hiver 2000

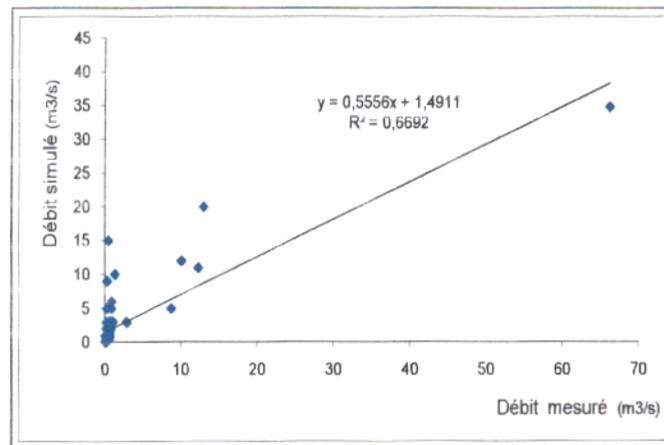


Fig -50- Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'hiver 2000

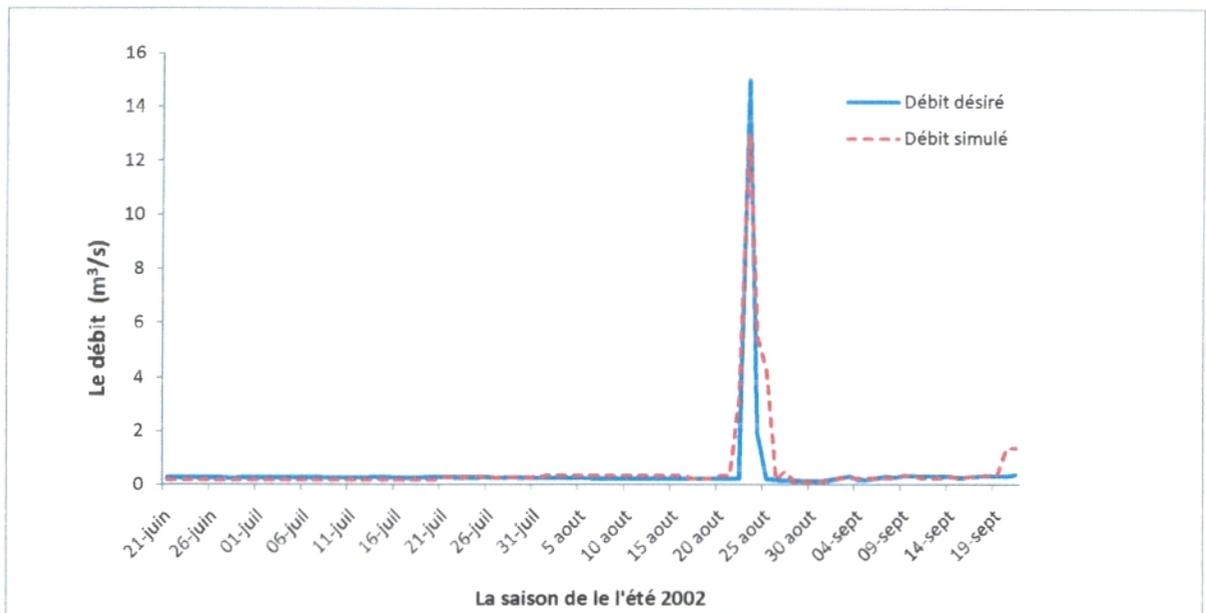


Fig-51- Hydrogramme de simulation entre le Débit mesuré et le débit Simulé pour la saison de l'été 2002

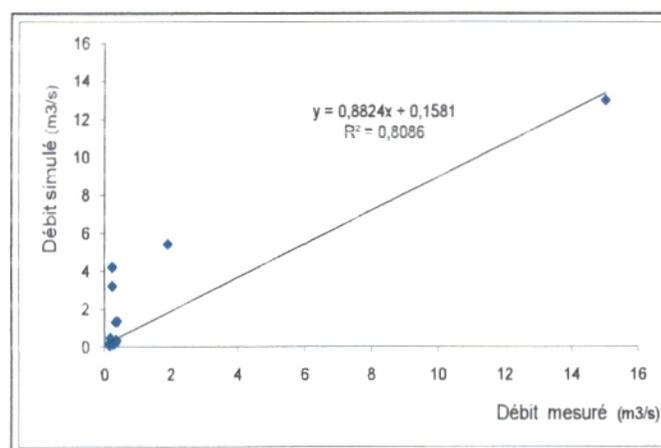


Fig -52-Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'été 2002

#### 4- Interprétation et Analyse

Les figures (47,49,51) nous montre la comparaison des données simulées et observées qui forme un nuage de points situé autour de la droite linéaire pour la phase du test du modèle .

Les résultats obtenus montrent une concordance expliquée par un coefficient de corrélation élevé ,une meilleure performance sachant que la taille réduite des données pluviométriques et hydrométriques constitue un obstacle pour la réalisation de ce travail .

Les résultats obtenus par les différents modèles neuronaux réalisés, ont montré que les réseaux neuronaux ont un pouvoir de simulation fort même si les données sont incomplètes.

Les capacités des réseaux de neurones sont telles qu'il suffit de spécifier une structure neuronale bien adaptée pour chaque type d'application.

Le modèle (Fig 51 ) qui représente la période de l'étiage est mieux représenté malgré que la capacité à simuler pour les faibles débit pourrait probablement être améliorée notamment si on utilise d'autres paramètres pour affiner les résultats mais cela ne sera pas sans doute un impact sur les forts débit , en général, les approches utilisant le RN donnent ici des résultats assez proches.

Les modèles (Fig 47 ) et (Fig 51) qui représentent la période des crues sont une grande performance malgré que cette dernière est limité par plusieurs causes , tout d'abord le manque de données de la pluviométrie et le débit liquide sont des limitations les plus évidentes qui se manifestent par des crues non simulé (4 janvier 1996 , 12 octobre 2000 , 14 mars 1996 , 19 septembre 2002 ...) ce qui réduit la capacité de simulation .

Le nombre réduit et la disposition des pluviomètres dans le sous bassin de l'oued Sebdou , ceci réduit la confiance de la série de précipitation et qui empêche la description réaliste de l'hétérogénéité spatiale de la pluie .

Les lacunes dans la description des 4 entrées du modèle (précipitations journalières, précipitations mensuelles, précipitations saisonnières et annuelles) viennent fort probablement limiter sa capacité à simuler, sachant que les paramètres physiques comme la pédologie et les débits observés à l'exutoire de l'oued Sebdou à la station de Beni bahdel augmentent certainement la robustesse de la prédiction des RNA (vecteur d'entrée sera plus informatif).

Par contre Le modèle neuronale a donné des bonnes performances malgré les lacunes dans les données, Autrement dit, un grand nombre de jeux de paramètres différents en entrée peut conduire à une amélioration de la partie simulée. Or, chaque paramètre correspond à des processus hydrologiques simulés différents.

# CONCLUSION GENERALE

La capacité prévisionnelle des réseaux connexionnistes a pu être démontrée, Plusieurs méthodes non linéaires ont été testées pour la modélisation et la prédiction de différents types de séries chronologiques.

Les modèles connexionnistes ont montré les meilleures performances. Leur utilisation pour la modélisation de la relation pluie-débit a été étudiée ici et les résultats paraissent prometteurs. Malgré le nombre limité de variables utilisées, la capacité prévisionnelle de modèles paraît bonne et leur stabilité, pour les prévisions à des horizons variés, satisfaisante.

Pour cela , on peut conclure que les Réseaux de Neurones Artificiels représentent des outils très exploitables pour les modèles globaux de pluies-débites dans le but de combler les déficits en termes de données de relevés. Néanmoins il est toujours affirmé que plus les données sont nombreuses plus les prédictions approchent les valeurs réelles. Dans notre cas les données de la décennie (1995 -2005) pour notre zone d'étude présentent encore beaucoup de fluctuations.

Sachant que les résultats sont obtenus avec la structure la plus simple et les algorithmes d'apprentissage sont à améliorer pour de meilleures efficacités. Il est aussi intéressant de revoir le cas du nombre des variables en entrée et de vérifier par l'analyse de sensibilité leur pertinence dans le modèle. En effet l'analyse nous a permis de juger que le régime pluviométrique du bassin de oued Sebdo est aléatoire sur l'ensemble de la décennie en relation avec son climat vu la simulation obtenue par le modèle, en montrant toutefois que la performance est limitée par le manque de données.

Comme perspectives nous proposons d'améliorer l'apprentissage du modèle pluie/débit par des techniques plus robustes comme les algorithmes génétiques afin d'éviter les minimums locaux .Une hybridation des réseaux de neurones avec la logique floue peut augmenter la transparence du modèle en utilisant l'interprétabilité des règles floues extraites après apprentissage .

## Références Bibliographiques

**ADJIM FOUZIA (2006)** :Karstification , hydrologie et vulnérabilité des eaux karstique .  
Mise au point d’outil pour leur protection (application aux monts de Tlemcen-ouest oranais) .  
*Thèse de doctorat* -Université de Tlemcen, pages 197.

**ANDRONOVA VANIA (2006)** : Utilisation des données météo et des réseaux de neurone pour la  
prédiction des vitesses de vent .Master 2 université de corse –Pasquale Paoli. pages 18-30.

**BABA HAMED KAMILA (2001)** :Contribution a l’étude hydrologie de trois sous bassin de la  
Tafna (Bassin de Sebdou, de Mouilah et d’Isser ) *Mémoire de Magister* -Université d’Oran. pages  
195.

**BENEST MICHEL MUSTAPHA BENSALAH HAMZA BOUABDELAH TAYEB OUADAS  
(1999)** : La couverture mésozoïque et cénozoïque du domaine tlemcenien  
(avant pays tellien d’Algérie occidental) Stratigraphie, paleoenvironnementale , Sédimentation et  
tectonique alpine –Bulletin du Service Géologique de l’Algérie Vol.n°2 pages.127-157,7fig.1999.

**BENNIS SAAD (2007)** : Hydraulique et hydrologie 2<sup>e</sup> édition revue et augmentée –collection  
Ecole de technologie supérieure Québec – Canada - 474 pages, D1521, ISBN 978-2-7605.

**BOUANANI ABDERRAZAK (2004)** :hydrologie, transport solide et modélisation , étude de  
quelques sous bassins de la Tafna (NW – Algérie)-*Thèse de doctorat d’état* -Université de  
Tlemcen. pages 249.

**CHIKH MOHAMED AMINE (2005)** :Analyse du signal ECG par les réseaux de neurone et la  
logique floue : Application a la reconnaissance des battements ventriculaires prématurés. *Thèse de  
doctorat d’état* -Université de Tlemcen. pages 111-112.

**COULIBALY P., ANCTIL F BOBEE B (1999)** : Prévission hydrologique par réseaux de  
neurones artificiels Etat de l’art.j. of civil engineering. pages 293-301 .

**CW DAWSON C .HARPHAM RL WILBY and Y CHEN (2002)** :Evaluation of artificial neural  
network technique for flow forecasting in the river yangtze China  
Hydrology and Earth System Sciences , pages 619–626 .

**DECHMI .N, BENKACI.T ,ISSOLAH ;A (2003) :**Modélisation des débits mensuels par les modèles conceptuels et les systèmes neuro-flous-*Revue des science de l'eau* 16/03/2003 pages 407-427.

**DIMOPOULOS I, S. LEK & J. LAUGA (1996) :** Modélisation de la relation pluie-débit par les réseaux connexionnistes et le filtre de Kalman Université Paul Sabatier, Toulouse , France  
*Hydrological Sciences -Journal- des Sciences Hydrologique* , pages 179-194 .

**DUBREUIL, P. (1974):** Initiation à l'analyse hydrologique. Masson et Cie O.R.S.T.O.M., France , 216 p. N° ISBN : 2-225-40 140-3 .

**ELMAN, J.L. (1990) :** "Finding Structure in Time". *Cognitive Science* 14: pages 179–211

**FAHLMAN, S.E., AND LEBIERE, C. (1990) :** "The Cascade-Correlation Learning Architecture", in Touretzky, D. S. (ed.), *Advances in Neural Information Processing Systems 2*, Los Altos, CA: Morgan Kaufmann Publishers, pages. 524-532.

**FRENCH, M., KRAJEWSKI, W. & CUYKENDALL, R. (1992) :** Rainfall forecasting in space and time using neural network. *J. Hydrol* pages 137, 1–31.

**GENTIL LOUIS (1902 ):** Esquisse stratigraphique et pétrographique du Bassin de la Tafna (Algérie).

**HEBB D O (1949 ):**The Organization of Beha.iour. Wiley, New York

**HONG LE HUG ( 1998) :** Introduction a Matlab et Simulink .Département de génie électrique et de génie informatique Université Laval Québec, CANADA.

**HSU, K., GUPTA, H. & SOROOSHIAN, S. (1995) :** Artificial neural network modelling of the rainfall–runoff process. *WaterResour.Res.* 31(10), 2517–2530

**IMRIE .C ,E DURUCAN ,S .AND KORRE ,A, (2000) :** River flow prediction using artificial neural network :generalisation beyond calibration range .*J .Hydrol*, pages 233,138 -153

**JEAN BAPTISTE FILIPPI (2004)** :Analyse conception et programmation d'un logiciel de simulation de bassin versant –Rapport technique –Université de Corse pages 38-50.

**JODOUIN JEAN-FRANÇOIS (1994)** : Les réseaux de neurones: principes et définitions. Édition Hermes, pages 124.

**JORDAN, M. I. (1986a)** : Serial order a parallel distributed processing approach technical report ICS report 8604 institute for Cognitive Science ,university of California at San Diego LA Jolla ,CA.

**JORDAN, M. I. (1986b)** : "Attractor dynamics and parallelism in a connectionist sequential machine," In Proceedings of the Eighth Annual conference of the Cognitive Science Society, pages 531-546. Lawrence Erlbaum.

**KARUNANITHI, N., GRENNEY, W.J., WHITLEY, D., BOVEE, K., (1994)** : Neural networks for river flow prediction. *Journal of Computing in Civil Engineering* 8 (2), pages 201–220.

**LEK, S., DELACOSTE, M., BARAN, P., DIMOPOULOS, I., LAUGA, J., AULAGNIER,S., (1996)** : Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Modelling* 90, pages 39–52.

**KOHONEN, T. (1989)** :Self organisation and associative memory. 3e édition, Springer-Verlag, Berlin, 312 p.

**LUK, K.C., BALL , J.E. AND SHARMA, A., (2000).** : A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *J. Hydrol.*, **227**, pages 56–65.

**MARIE-PERRINE MIOSSEC (2004)** : Apport des Multi-Modèles pour la modélisation sur des bassins versants non jaugés-DEA Hydrologie-Université Pierre et Marie Curie, Université Paris-Sud.pages 46.

**MCCULLOCH W S, PITTS W A (1943)** : A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* **5**: pages 115-33

**MINNS, A. & HALL, J. (1996)** ;Artificial neural network as rainfall–runoff models. *Hydrol. Sc. J.* **41**(3), 399–417.

**MINSKY M, PAPERT S (1969)** : Perceptrons. MIT Press, Cambridge, MA .

**ROSENBLATT F ( 1958 )** :The Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review* v65 No. 6, pp. 386–408

**RUMELHART D E, HINTON G E, WILLIAMS R J (1986)** : Learning internal representations by error propagation. In: Rumelhart D E, McClelland J L et al. (eds.) *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, Cambridge, MA, Vol. 1, pp. 318 - 62

**SAJIKUMAR AND THANDAVESWARA (1999)** : On encapsulation of numeric –hydraulic models in artificial neural networks ,journal of hydrology ,pages 216.

**SIVAKUMAR B JAYAWARDENA A.W AND FERNANDO TMKG (2002)** : River flow forecasting :use of phase space reconstruction and artificial neural networks approaches.J.Hydrol 265, 225-245.

**SHAMSLEDIN Y.(1997)** : Application of neural network technique to rainfall-runoff Modeling.J. of Hydrology pp 201, 272–288.

**SMITH, J., ELI, R.N., (1995)** : Neural-network models of rainfall–runoff processes. *Journal of Water Resources Planning and Management* 121 (6), 499–508.

**SUDHEER AK GOSAIN RAMASASTRI (2002)** :a data driven algorithm for constructing artificial neural network rainfall-runoff models pp.554

**TOKAR AND JOHSON (1999)** : Rainfall runoff modeling using artificial neural networks journal of hydrology engineering pp. 232-239

**YESHEWATESFA HUNDECHA, ANDRAS BARDOSSY & HANS-WERNER THEISEN (2001) :** Development of a fuzzy logic-based rainfall-runoff Model -Hydrological Sciences- Journal~des Sciences Hydrologiques. vol. 46, no3, pp. 363-376 (13 ref.)

**VAZQUEZ J., ZUG M., BELLEFLEUR D., GRANDJEAN. B.ET. SCRIVENER. O (1999) :** « Utilisation d'un réseau de neurones pour appliquer le modèle de Muskingum aux réseaux d'assainissement » Revue des sciences de l'eau / Journal of Water Science, vol. 12, n° 3, 1999, p. 577-595.

**WIDROW, B., AND HOFF, M.E., JR., (1960) :** "Adaptive switching circuits," IRE WESCON Convention Record. part 4, pp. 96-104. Reprinted in Anderson and Rosenfeld (1988).

liste des Figures

## Liste des Figures

Fig -01-	Un Neurone Biologique :.....	5
Fig -02-	La Comparaison Entre Un Neurone Biologique Et Un Neurone Artificiel :....	6
Fig -03-	Un schéma simple d'un réseau de neurone:.....	7
Fig -04-	La structure d'un neurone artificiel :.....	7
Fig -05-	Apprentissage supervisé et Non –supervisé (V.Andronova 2006) :.....	10
Fig -06-	La topologie des réseaux de neurones :.....	12
Fig -07-	Une classification par une fonction linéaire :.....	13
Fig -08-	Un Perceptron monocouche :.....	14
Fig -09-	La Mise à jour des poids :.....	15
Fig -10-	Un réseau multicouche avec l couches d'unité :.....	16
Fig -11-	La Fonction logique AND,OR : Séparation linéaire.	
	La Fonction logique XOR : Séparation non linéaire.....	17
Fig -12-	Le perceptron Multicouche :.....	17
Fig -13-	Le réseau de Jordan :.....	18
Fig -14-	Le réseau de ELMAN :.....	19
Fig -15-	La structure de la carte de kohonen :.....	21
Fig -16-	L'effet de nombre de neurone caché sur la performance du réseau :.....	22
Fig -17-	Evolution de l'erreur d'apprentissage et de test :.....	23
Fig -18-	La diminution de l'erreur pour le Réseau :.....	23
Fig -19-	L'effet de la grandeur des échantillons d'apprentissage sur le taux d'erreur :...	24
Fig -20-	La fenêtre principale du logiciel Pythia :.....	28
Fig -21-	Image SNNS (Stuttgart Neural Network Simulator ):.....	29
Fig -22-	NeuroXL Predictor et NeuroXL Classifier :.....	30
Fig -23 -	La vue Général de Neuroshed :.....	31
Fig -24-	Fitting tool de réseau de neurone :.....	32
Fig -25-	L'architecture du réseau de neurone pour le monocouche :.....	34
Fig -26-	La vue du réseau de neurone utilisé (monocouche) :.....	34
Fig -27-	L'entraînement de réseau (monocouche) :.....	34
Fig -28-	L'architecture du réseau de neurone pour le monocouche :.....	36
Fig -29-	La vue du réseau de neurone utilisé (multicouche :.....	36
Fig -30-	L'entraînement du réseau multicouche.....	37
Fig -31-	Le bassin versant de la Tafna :.....	39
Fig -32-	Le Réseau hydrographique de Tafna :.....	40
Fig -33-	Courbe Hypsométrique et histogramme de fréquence altimétrique du sous bassin de l'oued sebdou DE LA Tafna (NW Algérie).....	43
Fig -34-	Carte des pentes de la wilaya de Tlemcen y compris la zone d'étude (sous-bassin de l'oued sebdou)-PAW Tlemcen 2000 :.....	43
Fig -35-	Cartes d'occupation du sol du sous-bassin de l'oued Sebdou :.....	47
Fig -36-	Schéma structural de la chaîne alpine de la Méditerranée occidentale :.....	49
Fig -37-	Colonne stratigraphique des monts deTlemcen jusqu'aux hautes plaines (Benest &Bensalah 1999) :.....	50
Fig -38-	Carte lithologique du bassin versant de l'oued Sebdou (Bouanani 2004) :.....	50
Fig -39-	Ajustements des précipitations annuelles de la station de Beni bahdel du bassin versant de l'oued sebdou Tafna à la loi normale (Bouanani 2004) :.....	54
Fig -40-	Variations interannuelles des modules de l'oued Sebdou à Béni Bahdel :.....	56
Fig -41-	Variations des débits moyens mensuels de l'oued Sebdou à Beni bahdel :.....	57
Fig -42-	Variations interannuelles des débits mensuels de l'oued Sebdou à Beni Bahdel:	58

Fig -43-	Variations des débits moyens journaliers de l'oued Sebdou à Beni Bahdel .....	59
Fig -44-	Schéma globale de notre approche : .....	62
Fig -45-	La Convergence du modèle : .....	71
Fig -46-	Corrélation de Pearson entre débit et pluie (1995-2005) : .....	71
Fig -47-	Hydrogramme de simulation entre le Débit mesuré et le débit Désiré pour la saison de l'automne 1996 : .....	72
Fig -48-	Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'automne 1996 : .....	72
Fig -49-	Hydrogramme de simulation entre le Débit mesuré et le débit Désiré pour la saison de l'hiver 2000: .....	73
Fig -50-	Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'hiver 2000 : .....	73
Fig -51-	Hydrogramme de simulation entre le Débit mesuré et le débit Désiré pour la saison de l'été 2002 : .....	74
Fig -52-	Comparaison entre le débit liquide mesuré et le débit liquide simulé par RNA phase du test pour la saison de l'été 2002 : .....	74

liste des tableaux

## Liste des Tableaux

Tableau -01-	Les différentes fonctions d'activation pour les neurones :.....	08
Tableau -02-	La fonction logique « OU » pour un réseau monocouche :.....	33
Tableau -03-	La fonction logique « OU » pour un réseau multicouches :.....	35
Tableau -04-	Caractéristiques de forme pour le sous bassin de oued sebdou :.....	40
Tableau -05-	Paramètres morphométriques du sous bassin oued sebdou :.....	41
Tableau -06-	Répartition hypsométrique du sous bassin oued sebdou :.....	42
Tableau -07-	Caractéristique du sous bassin d'oued Tafna :.....	44
Tableau -09-	Classification du relief selon Ig par l'ORSTOM :.....	45
Tableau-10-	Valeurs des coefficients de torrentialité et les temps de concentrations de l'oued sebdou :.....	46
Tableau -11-	Distribution du couvert végétal dans le bassin d'oued Sebdou (BNEDER, 1993) :.....	47
Tableau -12-	Principaux paramètres physique du sous bassin oued Tafna :.....	48
Tableau -13-	Caractéristiques des précipitations annuelles pour les deux stations pluviométriques du bassin versant de l'oued sebdou. :.....	53
Tableau -14-	Caractéristiques de station hydrométrique de Beni bahdel :.....	54
Tableau -15-	Débits moyens annuels de l'oued Sebdou à Béni bahdel.....	55
Tableau -16-	Valeurs caractéristiques des modules au niveau du bassin versant de l'oued Sebdou :.....	55
Tableau -17-	Répartition des débits mensuels de l' oued Sebdou à Béni bahdel :.....	56
Tableau -18-	Paramètres choisis pour chaque expérimentation réalisé (Nc1=20,Nc2=20) :.....	65
Tableau -19-	Paramètres choisis pour chaque expérimentation réalisé (Nc1=25,Nc2=25) : .....	65
Tableau -20-	Paramètres choisis pour chaque expérimentation réalisé (Nc1=10,Nc2=10) : .....	66
Tableau -21-	Paramètres choisis pour chaque expérimentation réalisé (Nc1=30,Nc2=30) :.....	66
Tableau -22-	Paramètres choisis pour chaque expérimentation réalisé (Nc1=40,Nc2=40) :.....	66
Tableau -23-	Algorithme d'apprentissage des modèles neuronales LM :.....	67
Tableau -24-	Algorithme d'apprentissage des modèles neuronales Gd:.....	69
Tableau -25-	Algorithme d'apprentissage des modèles neuronales gdx:.....	69
Tableau -26-	Les modèles neuronaux avec un bon apprentissage (convergence atteinte)	70

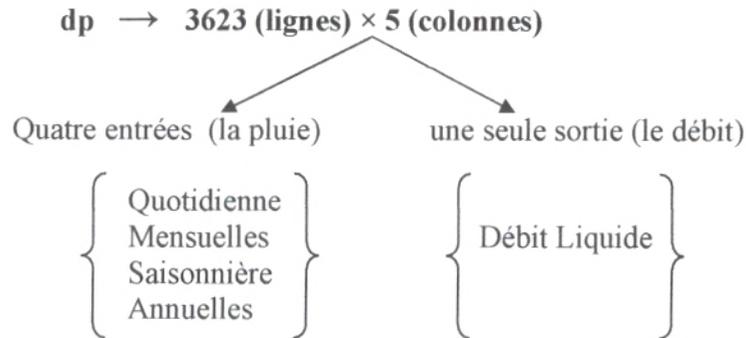
# Annexes

## Annexes

## 1-La matrice des données d'entrées :

Notre base d'apprentissage (dp) est une matrice de  $n= 3623$  exemple (lignes) ou bien de 3623 jours pour une période entre 1995 et 2005.

Chaque exemple est représenté par un paramètre qui est  $m=5$  (colonnes) .



$$\begin{aligned} dp &= n \times m & dp &= 3623 \times 5 \\ [n \ m] &= \text{size}(dp) & n &= 3623 \quad m = 5 \end{aligned}$$

$$d_1 = dp(:, [1 \ 2 \ 3 \ 4]) = 3623 \times 4$$

$$t_1 = dp(:, 5) = 3623 \times 1 \text{ (Sortie Désirée).}$$

$$dp = [d_1 \ t_1]$$

$$p = dp(:, 1:4) = 4 \times 3623$$

$$t = dp(:, 5) = 1 \times 3623$$

- a- Les quatre premiers paramètres représentent respectivement : la précipitation quotidienne, mensuelle, saisonnière et annuelle.  
Nous notons que chaque paramètre caractérise partiellement le débit liquide.
- b- Le cinquième paramètre représente le débit liquide mesuré.

Ensuite nous avons normalisé cette base donnant naissance une nouvelle base qui est (dl) juste pour faire régler le problème de grandeur .

$$\begin{aligned} dl &= dp [ 1 \ 2 \ 3 \ 4 ] / 10 \\ dl &= 3623 \times 4 \end{aligned}$$

Nous obtenons la matrice (dl) de dimensions  $(3623 \times 4)$  qui est composé de 4 paramètres caractérisant pour tous les exemples.

- Le vecteur (t) contenant le débit liquide mesuré de tous les exemples de la base (dp) pour 3623 exemples.

$$dp = [ dl \ t ] \rightarrow [ 3623 \times 4 \quad 3623 \times 1 ]$$

- La matrice (p) est la transpose de la matrice (dl) :  $(p) = [ 4 \times 3623 ]$

$$(p) \begin{pmatrix} J \dots\dots\dots 3623 \\ M \dots\dots\dots 3623 \\ S \dots\dots\dots 3623 \\ A \dots\dots\dots 3623 \end{pmatrix}$$

- La matrice (t) est la matrice désirée :  $(t) = [ 3623 \times 1 ]$  ,  $(t) = [ 1 \times 3623 ]$

$$(t) \begin{pmatrix} t \dots\dots\dots 3623 \end{pmatrix}$$

Pour le calcul de l'apprentissage il faut avoir plusieurs procédés pour l'entraînement de chaque réseau a titre exemple les epochs :

Epoch : lorsque j'applique 3623 exemples

Itérations : lorsque j'applique un exemple donc on peut dire que l'epoch est égale a 3623 itérations .

Nous avons appliqué 1000 epoch pour notre réseau ce qui veut dire 3623000 itérations ce qui montre l'ampleur du temps de calcul de l'apprentissage.

Chaque itération le RN fait tous les calculs a travers ses 81 neurones [20, 20, 1] ce qui construit la base de l'apprentissage  $80 + 400 + 20 = 500$  poids et 500 connexions

**2- Le choix de la base d'apprentissage :**

Nous avons pris (ii) comme le choix des données de la base d'apprentissage :  $ii \text{ train} = [ 1 : 4 : q , 2 : 4 : q , 3 : 4 : q ]$  pour cela nous avons choisi 2718 (3 /4) données parmi les 3623 de la base ainsi  $zz = p( :, ii \text{ train} )$  qui est une matrice de dimension  $(4 \times 2718)$  contenant les 2718 exemples d'apprentissage et chaque exemple est caractérisé par 4 paramètres cités ci-dessus .

ii test est le choix des données de la base de test  $[ 1 \times 905 ]$  autrement dit nous avons pris 905 (1/4) données pour la base de test .

la matrice  $zz ; zz = p( :, ii \text{ train} )$  est la matrice d'apprentissage  $[ 4 \times 2718 ]$  des paramètres d'entrées .

la matrice  $hh = t( :, ii \text{ train} )$  de dimension  $[ 1 \times 2718 ]$  est la sortie du réseau qui est le débit liquide.

$test\_P = p( :, ii \text{ test} )$  est la matrice de test avec les dimensions de  $[ 4 \times 905 ]$  qui sont des données de test pour les paramètres de l'entrée.

$test\_T = t( :, ii \text{ test} )$  est la matrice de test avec les dimensions de  $[ 1 \times 905 ]$  qui sont des données de test pour les paramètres de la sortie (débit liquide).

### 3- Dimensionnement du réseau neuronal :

La construction du réseau de neurones se fait par un processus itératif sur les échantillons d'une base de données contenu dans le fichier d'apprentissage.

Chaque itération permet de minimiser l'erreur quadratique moyenne entre les sorties du RNA et les échantillons donnés.

Après plusieurs essais plus de 90 réseaux , un réseau multicouches à été retenu avec la topologie suivante :

- 20 neurones pour la couche caché .
- 20 neurones pour la couche sortie .

Une fois que l'architecture du réseau a été décidée, la phase d'apprentissage permet de calculer les poids synaptiques menant à chaque neurone formel.

En utilisant l'algorithme Levenberg-Marquardt. Cet algorithme consiste à présenter au réseau des exemples d'apprentissage, c'est-à-dire des jeux d'activités des neurones d'entrée ainsi que ceux des activités des neurones de sortie.

On examine l'écart entre la sortie du réseau et la sortie souhaitée et on modifie les poids synaptiques des connexions jusqu'à ce que le réseau produise une sortie très proche de celle souhaitée. L'apprentissage par le logiciel Matlab est supervisé . Les fonctions sigmoïdes, et linéaire sont affectées respectivement à la couche cachée et à la couche de sortie.

L'objectif essentiel ici, est de trouver le meilleur apprentissage qui permet de donner un bon modèle.

Après l'identification des paramètres ainsi leurs matrices on peut créer le réseau afin de lancer les opérations pour l'apprentissage et le test .

Net = newff (min max zz)

Net : réseau .

New : nouveau.

Feed : retro.

Forward : propagation.

(min max zz) : pour chaque paramètre d'entrée  $[4 \times 2718]$  on fixe son max et son min.

Donc la commande **newff** définit et initialise en même temps le réseau de neurone (type d'architecture, le nombre des neurones et le type d'algorithme d'apprentissage à utiliser.

Lr = 0,8 ( step learning) entre 0 et 1 c'est le pas d'apprentissage :

Lr = 1 → apprentissage rapide

Lr = 0 → apprentissage lent

Le seuil d'erreur est fixé a 0,2 ainsi le reseau soit comme suite pour le lancement de l'apprentissage :

net = train ( net, zz , hh )

Net newff ( [min,max] zz ,hh , [ 20 ,20 ,1 ] , { logsig , logsig , purelin} , train LM )

- 20 est le nombre de neurones dans la première couche.
- 20 est le nombre de neurones dans la deuxième couches.
- 1 est le nombre de neurones dans la couche de sortie.
- Logsig : fonction d'activation des 20 neurones pour la première couche.

- Logsig : fonction d'activation des 20 neurones pour la deuxième couche.
- Purelin : fonction d'activation du neurone de la couche de sortie.
- train LM : algorithme d'apprentissage choisi.

Les paramètres d'apprentissage :

- Net.trainParam.lr = 0,8 fixer le pas d'apprentissage.
- Net.trainParam.epochs = 1000 fixer le nombre maximum d'itérations.
- Net.trainParam.goal =  $10^{-2}$  fixer le seuil d'erreur (critère d'arrêt).

Pour améliorer la performance du réseau, il faut augmenter le nombre des neurones cachés soit pour une seule couche ou bien les deux couches ainsi en essayant la fonction d'apprentissage approprié et le changement des paramètres pour simuler les résultats mesurés.

En fin il faut tester le réseau de neurones sur des nouvelles bases que se soit pour une saison choisie ou bien une période donnée.

Donc pour le test (a) est la sortie réelle du réseau [  $1 \times 905$  ]

Test\_P = p( :,iitest) est l'entrée du test.

Test\_T = t( :,iitest) est la sortie du test .

a = Y

Y = sim (net,ptrain) est l'équation ou le programme qui teste la base de l'apprentissage.

Pour cela nous avons effectué un test pour l'hiver 96 (h95) afin de valider le réseau , donc il fallait charger les 3mois à **titre d'exemple** :

```
[load Dec 95 → save Dec 95, Dec 95]
```

```
h=S ; h95=S
```

```
S = [ S ; Dec 95 (21:31,1 :4) ; JAN96 (:,1 :4) ; FEV96 (:,1 :4) ; MARS :,96 (1 :21 :4) ]
```

```
hd 95 → Hiver Désiré .
```

```
hd 95 = [ hd95 ; Dec 95 (21:31, 5) ; JAN96 (:,5) ; FEV96 (:,5) ; MARS :,96 (1 :21 ,5) ]
```

```
load h95 ; load reseau 21 ; P= pluie .
```

```
P(j) = h95 (1, :) ;
```

```
P(mn) = h95 (1, :) ;
```

```
P(sn ) = h95 (1, :) ;
```

```
P(an ) = h95 (1, :) ;
```

```
a= Sim ( net , h95) ;
```

On applique les mêmes étapes pour l'automne 2000 (Sep 2000) et l'été 2002 ;

```
[load Sep 2000 → save Sep 2000, Sep 2000]
```

```
Sep=S ; Sep 2000 =S
```

```
S = [ S ; SEP 2000 (21:31,1 :4) ; OCT2000 (:,1 :4) ; NOV2000 (:,1 :4) ; DEC :,2000 (1 :21 :4) ]
```

```
Ad 2000 → Automne Désiré .
```

```
Ad 2000 = [ Ad2000 ; SEP 2000 (21:31, 5) ; OCT2000 (:,5) ; NOV2000 (:,5) ; DEC :,2000 (1 :21 ,5) ]
```

load Ad 2000 ; load réseau 21 ; P= pluie .

P(j) = Ad 2000 (1, :);

P(mn) = Ad 2000 (1, :);

P(sn) = Ad 2000 (1, :);

P(an) = Ad 2000 (1, :);

a= Sim ( net , Ad 2000);

**[load été 2002 → save été 2002, été 2002]**

E=S ; eté02=S

S = [ S ; JUI02 (21:31,1 :4) ; JUI02 (:,1 :4) ; AOOUT02 (:,1 :4) ; SEP 02 (1 :21 :4) ]

Ed 02 → Eté Désiré .

Ed 02 = [ Ed02 ; JUIN02 (21:31, 5) ; JUI02 (:,5) ; AOOUT02(:,5) ; SEP:,02 (1 :21 ,5) ]

load Ed 02 ; load reseau 21 ; P= pluie .

P(j) = Ed 02 (1, :);

P(mn) = Ed 02 (1, :);

P(sn) = Ed 02 (1, :);

P(an) = Ed 02 (1, :);

a= Sim ( net , Ed 02);

#### **4- Programme d'apprentissage et de test du model neuronal :**

##### **4-1- Programme d'apprentissage :**

```
load dp;
[n m] = size(dp);
dl=dp(:, [1 2 3 4])/10;
t1 = dp(:,m);
dp=[dl t1]
% [n m] = size(dp);
p = dp(:,1:m-1)';
t = dp(:,m)';
% % Preprocess the data so that the mean is 0 and the standard deviation is 1
% % [pn, meanp, stdp] = prestd(p);
% % Preprocess the network input training set by applying a principal component analysis
% % [ptrain, transMat] = prepca(pn, 0.075);
[r, q] = size(p);
% Divide data into training and test subsets
iitrain= [1:4:q 2:4:q 3:4:q];
iitest= 4:4:q;
% iitrain= [1:6:q 2:6:q 3:6:q 4:6:q 5:6:q];
% iitest= 6:6:q;
zz= p(:,iitrain);
%yy=ptrain(:,1:500);
hh= t(:,iitrain);
%tt=t(:,1:500);
test_P= p(:,iitest);
save test test_P
test_T= t(:,iitest);
```

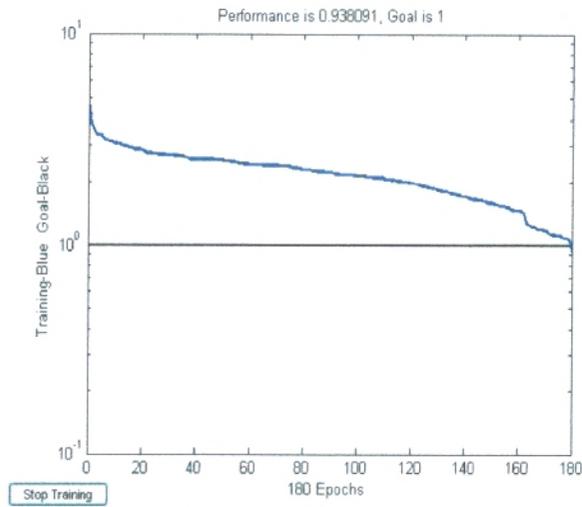
```
save sortie test_T
net = newff(minmax(zz), [20,20, 1], {'logsig','logsig', 'purelin'},'trainlm');
%'
net.trainParam.epochs=1000
net.trainParam.lr= 0.8
% %net.trainParam.goal= 0.000000000001
% net.inputWeights{1,1,1,1,1,1,1,1}.learnParam.lr=0.005
%net.biases{1,1,1,1,1,1,1,1}.learnParam.lr=0.05
%net.b{1}=[1;1;1;0;0;0;0;0]
net.trainParam.goal=0.2
tic
net = train(net,zz,hh);
toc
save reseau21 net

%net = train(net,ptrain,ttrain,test.P)
% Y = sim(net,ptrain);
```

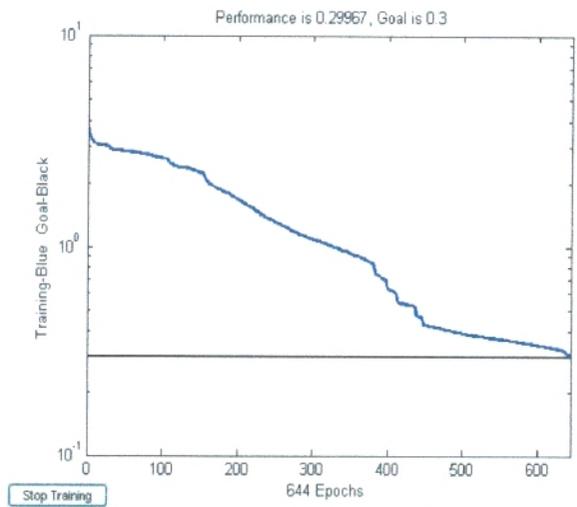
### 4-2 -Programme d'apprentissage et de test :

```
load reseau21;
load test;
load sortie;
% load DEC05.m;
% [n m] = size(DEC05);
% dl=DEC05(:,[1 2 3 4])/10;
% t1 = DEC05(:,m);
% DEC05=[dl t1];
% [n m] = size(DEC05);
% p = DEC05(:,1:m-1)';
% t = DEC05(:,m)';
% test_P= p;
% test_T= t;

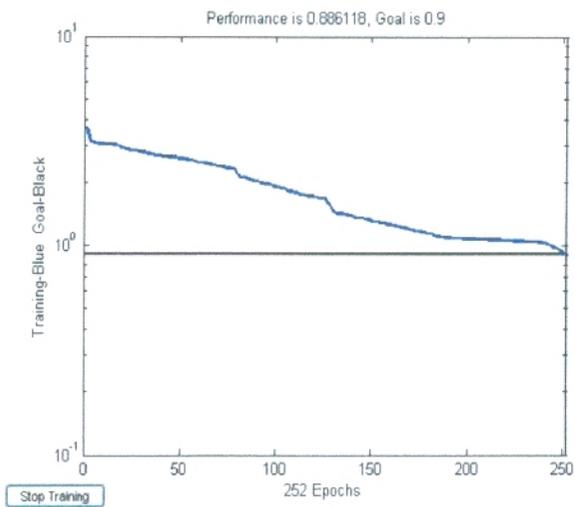
a= sim(net,test_P);
figure
%plot(a)
hold on
plot(test_T.^2,'r')
x=a;
plot(x.^2,'g')
e=a-test_T;
plot(e,'b')
%plot(Y,hold on plot(test_T)
```



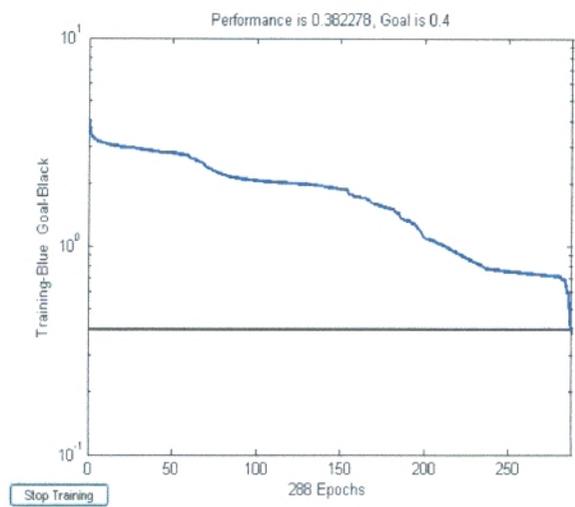
Réseau -9-



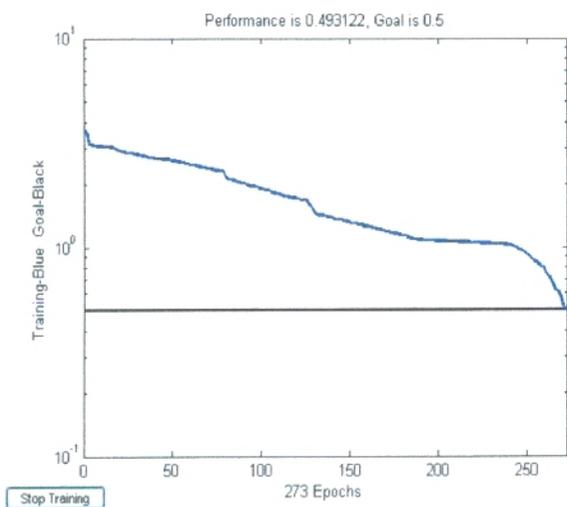
Réseau -19-



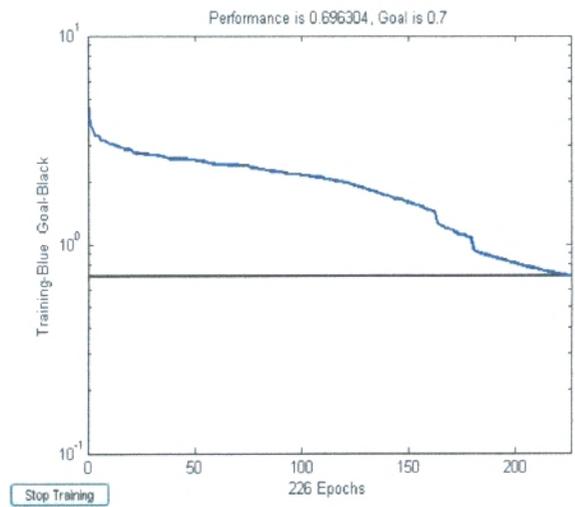
Réseau -14-



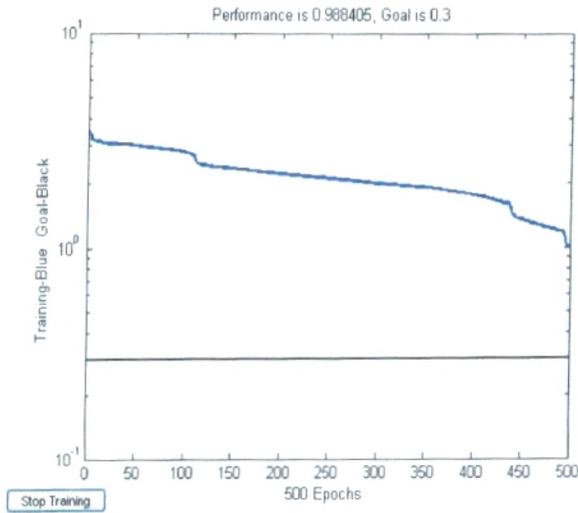
Réseau -12-



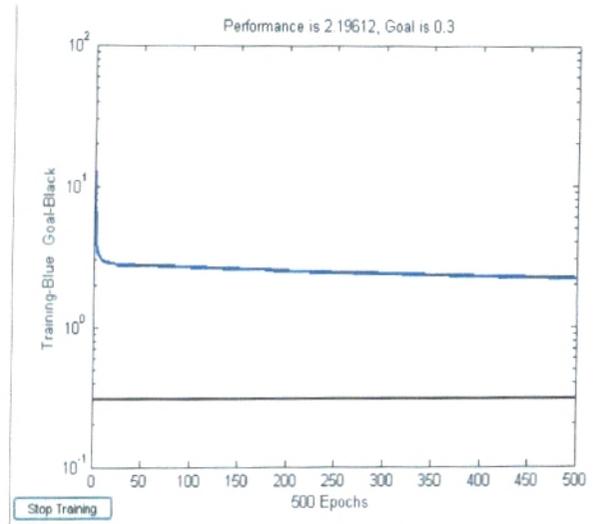
Réseau -11-



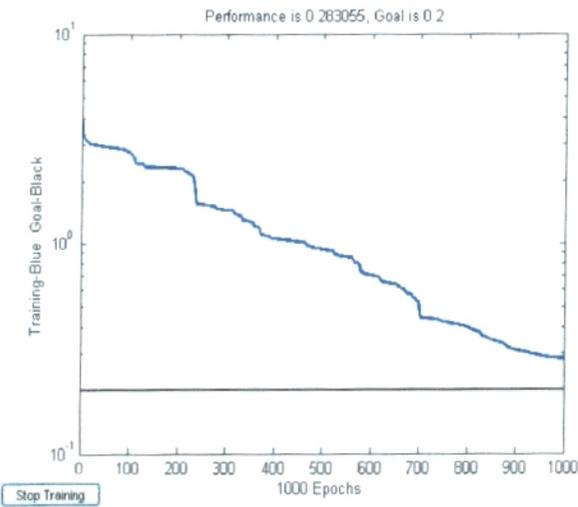
Réseau -19-



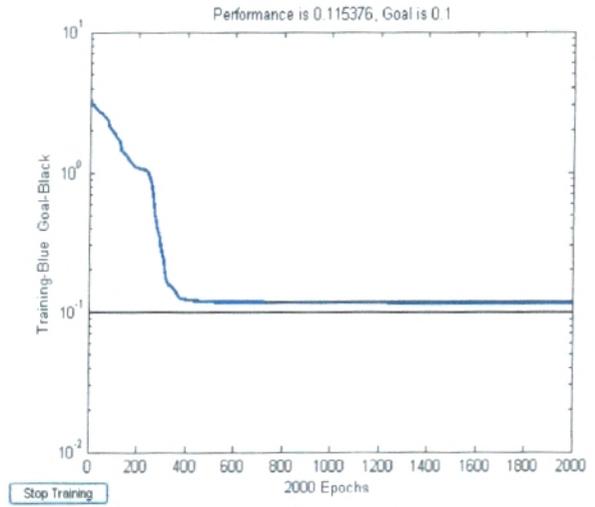
**Réseau -33-**



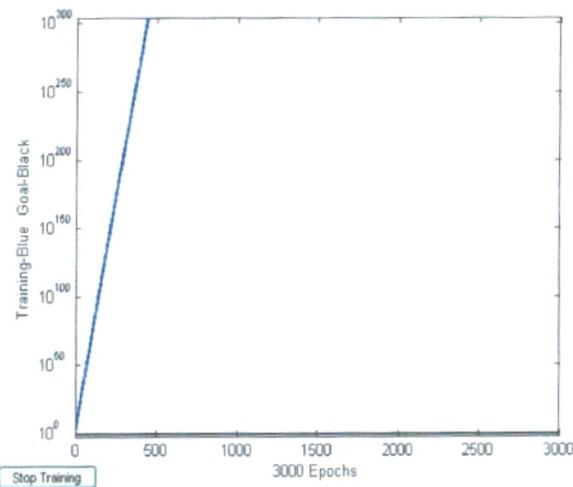
**Réseau -41-**



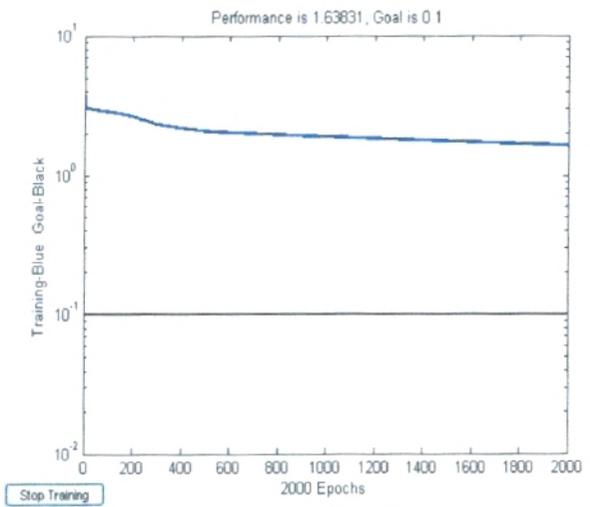
**Réseau -34-**



**Réseau -57-**



**Réseau -61-**



**Réseau -49-**

MEMOIRE DE MAGISTER

Option :Hydrogéologie

MODELISATION HYDROLOGIQUE PAR L'APPROCHE CONNEXIONNISTE :  
CAS DU BASSIN DE L'OUED SEBDOU (TAFNA- NORD OUEST ALGERIEN )

Résumé :

Les réseaux de neurones artificiels (RNA) constituent une nouvelle méthode d'approximation de systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l'aide des méthodes statistiques classiques. Une classe de modèles de RNA appelée perceptrons multicouches (PMC) a ces dernières années, été privilégiée pour la prévision de phénomènes hydrologiques. La théorie et le langage connexionniste restent, malgré cette percée, encore peu connus de la communauté des hydrologues.

Notre travail a pour objectif la mise en place d'un modèle (pluie/débit) basé sur la l'approche connexionniste par les réseaux neuronaux sur le sous bassin de l'oued Sebdou (Tafna-Nord ouest Algérien) afin d'évaluer sa capacité de simulation les débits liquides observés.

Prédire le débit de l'oued Sebdou, un phénomène naturel qui dépend des conditions météorologiques et géographiques. La prévision du débit d'un cours d'eau est une motivation primordiale pour tenter de décrire le comportement d'un bassin versant.

**Mots clés :** Réseaux neurones artificiels - Perceptrons multicouches - Hydrologique - Bassin versant- Modèle (pluie /débit) - Connexionniste -Simulation - Prédire.

Abstract :

The artificial neural networks ( ANN ) are a new method of approximation of complex systems especially useful when these systems are difficult to model using classical statistical methods . One class of models of RNA called multiplayer perceptrons ( PMC ) has in recent years been privileged to forecast hydrologic events . The theory and connectionist language remain , despite this breakthrough , still little known in the community of hydrologists .

Our work aims at establishing a model ( rain / flow ) based on the connectionist approach for neural networks in the sub basin of the river Sebdou ( Tafna North West Algeria ) has assessed its end simulation capability liquid flows observed .

Predict the flow of the river Sebdou , a natural phenomenon that depends on the weather and geography. Predicting the flow of a river is a primary motivation to try to describe the behavior of a watershed .

**Key words :** The artificial neural networks - multiplayer perceptrons - hydrologic - watershed-connectionist - model ( rain / flow )- simulation - Predict.

ملخص

الشبكات العصبونية الاصطناعية هي طريقة جديدة لتقريب النظم المعقدة معقدة بشكل خاص عندما تكون هذه الأنظمة صعبة إيجاد نموذج باستخدام الأساليب الإحصائية الكلاسيكية . فئة واحدة من النماذج هي الـرسترون متعدد الطبقات في السنوات الأخيرة كانت متميزة لتوقع الأحداث الهيدرولوجية . اللغة النظرية للإتصالات لازالت قائمة ، على الرغم من هذا التقدم لاتزال غير معروفة في المجتمع طرف علماء المياه .

عملنا يهدف إلى إقامة نموذج ( المطر / تدفق ) . إستنادا إلى هيح إتصالات للشبكات العصبونية في حوض واد سدو ( شمال

غرب الجزائر ) الذي له القدرة على تقييم الظاهر للتدفقات السائلة الملاحظة .

التوقع لتدفق واد سدو هو ظاهرة طبيعية تعتمد على الطقس و الجغرافيا التوقع لتدفق الواد هو الدفاع الرئيسي لمحاولة وصف سلوك

مستجمعات المياه .

**الكلمات المفتاحية :**

الشبكة العصبونية الاصطناعية -الرسترون متعدد الطبقات -الهيدرولوجية-مستجمعات المياه-نموذج (مطر / تدفق) - الإتصالات -

الظاهر-التوقع.