

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVESITE DES SCIENCES ET DE LA TECHNOLOGIE HOUARI BOUMEDIENE



ACULTE D'ELECTRONIQUE ET D'INFORMATIQUE

MEMOIRE

Présenté pour l'obtention du diplôme de MAGISTER
EN : ELECTRONIQUE

Spécialité : Rayonnement Atmosphérique

Par

M^{elle} : DOULACHE SAMIRA

Thème

Classification des échos radar par approche

Neuro Floue

Soutenu le 29/06/2008, devant le jury composé de :

M^{me} R, TOUHAMI
Mr B, HADDAD
Mr Ab, AMROUCHE
Mr S, CHITROUB

Professeur U.S.T.H.B.
Professeur U.S.T.H.B.
Maître de Conférence U.S.T.H.B.
Maître de Conférence U.S.T.H.B

Présidente
Directeur de mémoire
Examineur
Examineur

REMERCIEMENTS

Je tiens à remercier vivement Mr B. HADDAD, Professeur à l'USTHB, pour avoir accepté de proposer et de diriger ce travail. Je tiens à lui témoigner mes reconnaissances pour son aide, sa disponibilité et ses conseils judicieux.

Je tiens à témoigner ma profonde gratitude à Mr ADANE Abd-El-Hamid, Professeur à l'USTHB, pour m'avoir accueilli dans son équipe.

Je tiens à remercier Mme TOUHAMI Rachida, Professeur à l'USTHB qui a bien voulu présider le jury.

Je tiens à remercier Mr Abd Arahman AMROUCHE, Maître de Conférences à l'USTHB qui a accepté de faire partie de ce jury. Qu' il trouve ici l'expression de ma très sincère reconnaissance.

Je remercie Mr Salim CHITROUB Maître de Conférences l'U.S.T.H.B, qui a bien voulu examiner ce travail.

Enfin, je remercie toutes les personnes du laboratoire rayonnement ainsi que mes amis et toute ma famille, pour leurs encouragement et soutien moral.

SOMMAIRE

Introduction Générale	01
------------------------------------	----

Chapitre I :

Le Radar

Introduction.....	03
I.1. le Principe de fonctionnement du radar.....	04
I.1.1 Radar non cohérent.....	05
I.1.2. Radar cohérent.....	07
I.2. Caractéristiques du radar.....	08
I.2.1. La résolution ou pouvoir séparateur.....	09
• La résolution transversale.....	09
• la résolution radiale.....	10
I.2.2. Visualisation des données.....	10
I. 3. Equation radar.....	11
I.4. Le facteur de réflectivité radar Z	13
I.5. Ambiguïtés du radar.....	14
I.6. Techniques d'élimination des échos du sol.....	15
I.6.1. Filtrage Doppler.....	15
I.6.2. Filtrage en peigne	16
I.6.3. Filtrage par polarisation.....	16
I.6.4. Circuits MTL.....	17
I.6.5. Filtrage par seuillage.....	17
I.6.6. Méthode de masquage.....	18
Conclusion.....	18

Chapitre II :

Les réseaux de neurones

Introduction.....	19
II.1 Fondement biologique.....	19
II.1.1 Structure des neurones.....	19
• Le corps cellulaire.....	20
• Les dendrites	20

• L'axone.....	20
II.1.2 fonctionnement d'un neurone	20
II.2 Modèle mathématique.....	21
II.2.1 La structure de neurone artificiel.....	21
II.3. Architecture du réseau.....	23
II.3.1 LES RESEAUX "FEED-FORWARD "	23
• Le perceptron Monocouche.....	23
• Le perceptron Multicouches.....	24
II.3.2. LES RESEAUX ""FEED-BACK "	25
• Réseaux dynamiques ou récurrents.....	25
II.4. Apprentissage.....	26
II.4.1.Apprentissage supervisé.....	27
II.4.2.Apprentissage non supervisé.....	27
II.5. Algorithme d'apprentissage du Réseau multicouche.....	27
• Algorithme de la Rétro propagation.....	28
II.6. Certaines considérations pratiques.....	30
II.7 La classification d'image par les réseaux de neurones.....	32
II.8. Données expérimentales.....	33
II.8.1. Traitement des données	36
II.8.2. Analyse des différents échos.....	37
a. Le site de Sétif.....	37
b. Le site de Bordeaux.....	37
II.9. Architecture du perceptron Multicouche.....	38
pour l'identification d'échos de précipitation	
II.9.1. La phase d'apprentissage.....	38
II.9.1.1. Vitesse de convergence.....	39
II.9.1.2. Influence du nombre de nœuds.....	41
II.9.2. Phase de classification.....	42
II.9.2.1.Matrices de confusion.....	42
II.9.2.2 Calcul de l'Erreur	43
II.9.2.3. Estimation du taux de filtrage.....	43
II.10. Résultats du filtrage.....	44

II.10.1. Etude du site de Sétif.....	45
II.10.2. Etude du site de Bordeaux.....	47
Conclusion.....	49

Chapitre III :

La Combinaison Neuro Floue

Introduction.....	50
III.1. Les combinaisons neuro floue	50
III.2. Théorie des ensembles flous.....	51
III.2.1. Introduction.....	51
III.2.2. La théorie des sous ensembles flous.....	52
III.2.3. Les Opérateurs sur les ensembles floue.....	52
III.2.4. Modèle de degré d'appartenance flou.....	53
III.3. Etude comparative entre le modèle neuro flou	53
et le réseau de neurones	
III.3.1. Appréciation visuelle	54
III.3.1.1. Etude du site de Sétif.....	56
III.3.1.2. Etude du site de Bordeaux	58
Conclusion.....	60

Conclusion générale.....	61
---------------------------------	-----------

Liste des figures

1.1 Le fonctionnement d'un radar.....	4
1.2 Schéma bloc d'un radar non cohérent	5
1.3 Schéma bloc d'un radar cohérent à impulsion.....	7
1.4 Impulsion radar.....	9
1.5 Train d'impulsions émis par le radar.....	14
1.6 Décalage Doppler du spectre pour une cible en mouvement.....	16
2.1 Structure d'un neurone Biologique.....	19
2.2 Structure d'un neurone artificiel.....	21
2.3 Fonctions d'activations.....	22
2.4 Architecture d'un réseau multicouche.....	25
2.5. Architecture d'un réseau récurrente monocouche.....	26
2.6 Réseau multicouche	28
2.7 Schéma simplifié de la classification.....	30
2.8 Image radar brute prise à Sétif.....	35
2.9 Image radar brute prise à Bordeaux.....	36
2.10 Images radar prises à Sétif.....	37
2.11 Les différents échos du site de Bordeaux.....	36
2.12 Evaluation de l'erreur quadratique ou cours du temps pour un réseau.....	40
(a : une couche cache, b : deux couche cachée)	
2.13 Influence du nombre de nœuds pour un réseau à une couche cachée.....	41
2.14 Influence du nombre de nœuds pour un réseau à deux couches cachées.....	42
2.15 Des images radar avant filtrage.....	45
2.16 Des images radar après filtrage.....	45
2.17 Image radar avant filtrage.....	46
2.18 Image radar après filtrage	46
2.19 Image radar avant filtrage.....	47
2.20 Image radar après filtrage	47
2.21 Image radar avant filtrage.....	48

2.22 Image radar après filtrage	48
3.1 Les combinaisons neuro floue.....	51
3.2 Image radar avant filtrage (Sétif).....	56
3.3 Image radar après filtrage	56
3.4 Image radar avant filtrage (Sétif).....	56
3.5 Image radar après filtrage	56
3.6 Image radar avant filtrage.....	57
3.7 Image radar après filtrage	57
3.8 Image radar avant filtrage (Bordeaux).....	57
3.9 Image radar après filtrage	57

Liste des Tableaux

1.1 Taux de reconnaissance par classe sur les ensembles.....	44
d'apprentissage et de test pour une couche cachée	
1.2 Taux de reconnaissance par classe sur les ensembles.....	44
d'apprentissage et de test pour deux couches cachées	
3.1 Taux de bonne reconnaissance de réseau de neurones.....	55
et de la combinaison neuro floue	

Liste des symboles

A : la surface effective de l'antenne radar

c : vitesse de la lumière dans le vide

D : le diamètre des gouttes de pluie

d_{ij} : la distance euclidienne entre $X(t)$ et W_{ij}

E : l'erreur quadratique

$e(t)$: signal radar émis

f : la fonction d'activation

f_c : la fréquence de l'oscillateur cohérent

f_d : la fréquence Doppler

f_I : fréquence intermédiaire

f_r : la fréquence de répétition des impulsions

f_0 : la fréquence du signal radar

$G(\theta, \varphi)$: le gain de l'antenne radar

G_0 : le gain maximum de l'antenne radar

$I(\theta, \varphi)$: la densité de puissance électromagnétique rétro diffusée par la cible

L : le facteur d'atténuation dans l'atmosphère

L_r : l'atténuation dans le récepteur radar

p : la puissance collectée par l'antenne radar

P_T : puissance total du signal radar émis

r : la distance qui sépare la cible du l'antenne radar

s : la sensibilité du radar

S_R : la sortie du réseau.

S_d : la sortie désirée

T_r : la période de répétition des impulsions

v_r : vitesse radiale du déplacement d'une cible

W_i : les poids des neurones

W_{ij} : le poids synaptique ou connexion entre i et j

$X = (x_1; x_2; \dots; x_n)$: le vecteur d'entrée

X_i : les entrées des neurones

$X(t)$: vecteur d'entrée à l'instant t

$Y=(y_1; y_2; \dots; y_n)$: le vecteur de sortie désirée

$S=(s_1; s_2; \dots; s_n)$ le vecteur qui de sortie réelle calculée.

Z : le facteur de réflectivité radar

Z_e : l'écho radar effectif

α : le taux d'apprentissage

$\alpha(t)$: le gain d'apprentissage

γ : momentum

Δt : le temps qui sépare l'impulsion d'émission de son écho à la réception

$\Delta i,j(t)$: la valeur de modification du neurone $C_{i,j}$, à l'étape t

$\delta_j^{[S]}$: l'erreur locale

η : la réflectivité radar

θ_0 : ouverture du lobe principal du signal radar à 3dB en site

λ : la longueur d'onde du signal radar

σ : la section efficace de rétro diffusion de la cible

$\sigma_\theta, \sigma_\phi$: les écarts types de la distribution gaussienne de la puissance dans le lobe principal

τ : largeur d'impulsion radar

$\Phi_r(t)$: phase du signal radar rétro diffusé

ϕ_0 : ouverture du lobe principal du signal radar à 3dB en azimuth

$\mu_A(x)$: la fonction d'appartenance de l'élément x à A

c : le nombre de vecteurs dans le fichier des exemples.

M : nombre de neurones dans la couche de sortie.

N : nombre d'entrées du réseau.

TMBR : le taux moyen de bonne reconnaissance.

TBR : le taux de bonne reconnaissance d'une classe i ..

N_i : nombre des pixels de la classe i .

X_{ii} : nombre de pixels bien classés à la classe

Introduction

Les météorologues ont eu recours pendant de nombreuses années à des méthodes empiriques dans les prévisions météorologiques. Ces méthodes qui sont essentiellement à caractère subjectif, donnent des résultats relativement satisfaisants. Elles s'appuient sur des règles simples fondées sur l'extrapolation des phénomènes d'échelle synoptique. Elles font parfois référence à des situations analogues rencontrées dans le passé et à l'observation de phénomènes locaux liés à ces situations, mais aussi à la nature du sol ou à l'orographie. A notre époque, ces méthodes ont été totalement remplacées dans les services météorologiques modernes par l'utilisation de technique numérique, des radars et des satellites météorologiques. Ces instruments permettent une meilleure prévision de phénomènes externes et de catastrophe naturelle.

Le radar météorologique est l'instrument le plus utilisé dans les stations météorologique de part le monde. En effet, il fournit une observation globale, permanente, précise, cohérente et rapide des phénomènes météorologique dans le temps et dans l'espace. Cependant, les images radar sont souvent contaminées par les échos en provenance de la surface terrestre, considérés par les météorologues comme des échos parasites. Ces derniers réduisent les capacités du radar à estimer les précipitations et à identifier les différents types du nuage. Les échos en provenance de la surface terrestre sont des échos fixes observés autour du radar et qui sont dus à des obstacles tels que les constructions, les pilons. On peut aussi observer des échos parasites à des distances lointaines du radar causés par une propagation anormales. Ces échos sont appelés échos A.P (Anomalous Propagation) ou Anaprops. Diverses techniques d'élimination des échos en provenance de la surface terrestre sont proposées dans la littérature. Il s'agit principalement de la technique Doppler, de l'approche texturale [Sadouki, 2003], la technique de masquage [Raaf, 2002], de la technique polarimétrique, des circuits M.T.I. (Moving Target Indicator) ou de l'approche statistique.

Les réseaux de neurones ont été utilisés dans un grand nombre d'applications très diverses et ont permis d'obtenir de très bons résultats à certains types de problèmes que ceux obtenus par les autres méthodes. Leurs intérêts résident dans le fait que les réseaux apprennent par l'exemple, qu'ils sont capables de trouver des solutions à des configurations qu'ils n'ont pas apprises et qu'ils possèdent une architecture parallèle qui fait qu'ils peuvent être câblés dans des composants en technologie. Par exemple, un système de guidage permet à un camion de se garer à un quai de déchargement de manière autonome. Ils ont aussi été utilisés en robotique pour apprendre à marcher à un robot à six pattes, ou encore un système de guidage pour automobile [Bennis and al, 2001 ; Lelu and al, 2002]. Ils sont aussi utilisés en système de lecture automatique de chèques bancaires et d'adresses postales [Ayat and al, 2000]. Ils trouvent aussi un large spectre d'application des systèmes de traitement du signal pour différentes applications militaires, dans le système pour la synthèse de la parole, pour le diagnostic médical, en télécommunication. D'où l'intérêt de l'utilisation des réseaux neuronaux et ensuite une méthode hybride neuro floue pour une meilleure classification des échos radar.

L'objectif recherché est d'éliminer les échos parasites sans altérer les précipitations dans les images radar. Compte tenu de cet objectif, nous avons organisé notre étude en trois chapitres :

Le premier chapitre porte sur les divers types de radars météorologiques et leurs configurations électroniques, ainsi qu'un bref rappel sur les techniques d'élimination des échos parasite en provenance de la surface terrestre.

Dans le second chapitre, nous exploitons la méthode de classification par les réseaux de neurone pour préserver les échos de précipitation et éliminer les échos du sol. L'apprentissage est effectué en premier lieu par l'algorithme standard de rétro propagation du gradient.

Le troisième chapitre est consacré à l'application d'une méthode de classification hybride « neuro floue ». Cette approche est utilisée pour améliorer le taux de bonne reconnaissance. Nous proposons un modèle pour le calcul du degré d'appartenance.

Nous terminons par une conclusion et des perspectives.

Chapitre II

Les Réseaux de Neurones

Introduction :

Aujourd'hui de nombreux termes sont utilisés dans la littérature pour désigner le domaine des réseaux de neurones artificiels. L'idée sous-jacente et assez ambitieuse, est de copier l'architecture du cerveau. Ce dernier, qu'il soit humain ou animal est en effet le seul exemple de « machine » intelligente que nous connaissons. Il peut donc paraître naturel de s'en inspirer non seulement au niveau fonctionnel, mais aussi au niveau architectural. Dans ce chapitre, nous allons rappeler cette technique très utilisée dans divers domaines tels que la robotique, la classification, l'optimisation, l'approximation et le traitement du signal.

II.1. Fondements biologique :

II.1.1 Structure des neurones :

Le système nerveux compte plus de 10^{12} neurones (mille milliards) interconnectés. Bien que les neurones ne soient pas tous identiques, leur forme et certaines caractéristiques permettent de les répartir en quelques grandes classes. Un neurone est composé de trois régions principales (figure 2.1).




Figure (2.1) : Structure d'un neurone Biologique

- **Le corps cellulaire (soma) :**

Il contient le noyau du neurone et effectue les transformations biochimiques nécessaires à la vie du neurone. Sa taille est de quelques microns de diamètre.

- **Les dendrites :**

Ce sont de fines extensions tubulaires qui se ramifient autour du neurone et forment une sorte de vaste arborescence. Les signaux envoyés au neurone sont captés par les dendrites. Leur taille est de quelques dizaines de microns de longueur.

- **L'axone :**

C'est la fibre nerveuse qui permet de transporter les signaux émis par le neurone. Il est plus long que les dendrites et se ramifie à son extrémité là où il communique avec les autres neurones en des endroits appelés synapses. Sa taille peut varier de quelques millimètres à plusieurs mètres.

Chaque neurone est une cellule. Autour du noyau, on trouve le corps cellulaire (soma). Celui-ci se prolonge par un axone unique et comporte de nombreuses dendrites qui constituent son organe d'entrée.

II.1.2 Fonctionnement d'un neurone

Chaque neurone est asservi au maintien d'un gradient électrique (potentiel membranaire) d'environ -50mV entre le milieu extérieur et le soma. L'influx nerveux est assimilable à un signal électrique, se propageant dans les neurones de la manière suivante :

- Les dendrites reçoivent l'influx nerveux d'autres neurones.
- Le neurone évalue alors l'ensemble de la stimulation qu'il reçoit (c'est à dire sa dépolarisation par rapport à l'extérieur).
- En fonction de cette stimulation (si la dépolarisation est suffisante $>-50\text{mV}$ par exemple), le neurone transmet ou non un signal de type « tout ou rien » le long de son axone, selon une fréquence fonction du niveau de dépolarisation. On dira alors que le neurone est ou non excité.
- L'excitation du neurone est propagée le long de l'axone jusqu'aux autres neurones ou fibres musculaires qui sont connectés via les synapses.

II.2. Le modèle mathématique :

Les réseaux de neurone biologique réalisé facilement un certain nombre d'applications telles que la reconnaissance de formes, le traitement du signal, l'apprentissage par l'exemple, la mémorisation, la généralisation. Ces applications sont pourtant, malgré tous les efforts déployés en algorithmique et en intelligence artificielle, à la limite des possibilités actuelles. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels se sont développés. Les réseaux de neurones artificiels sont des modèles, et ils peuvent être décrits à ce titre par leurs composants, leurs variables descriptives et les interactions des composants.

II.2.1. La structure de neurone artificiel :

La figure (2.2) montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amont. A chacune de ces entrées est associé un poids w abréviation de weight (poids en anglais) représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones en avals [Touzet, 1992]. A chaque connexion est associé un poids.




Figure (2.2) : Structure d'un neurone artificiel

D'une façon plus générale, on peut définir un neurone formel par les cinq éléments suivants :

- La nature de ses entrées qui peuvent être Booléen ou réelles
- La fonction d'entée totale P qui définit le prétraitement effectué sur les entrées.

$$\text{Avec} \quad P = \sum_{i=1}^n X_i \cdot W_i \quad (2-1)$$

Ou X_i : représente les entrées des neurones

W_i : représente les poids des neurones

- La fonction d'activation (ou d'état) du neurone qui établit une correspondance entre les valeurs présentées en entrées de la cellule et la valeur de sortie. Il existe de nombreuses formes possibles pour la fonction de transfert. Les plus courantes sont présentées sur la figure (2.3) [Werbos, 1974].

- La fonction de sortie qui calcule la sortie du neurone en fonction de son état d'activation

$$S = f(P)$$

- La nature de la sortie du neurone qui peut être Booléen ou réelle.


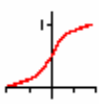

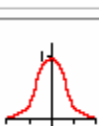

Pas unitaire		$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$
Sigmoïde		$f(x) = \frac{1}{1 + e^{-\beta x}}$
Linéaire Seuillée		$f(x) = \begin{cases} 0 & \text{if } x \leq x_{min} \\ mx+b & \text{if } x_{max} > x > x_{min} \\ 1 & \text{if } x \geq x_{max} \end{cases}$
Gaussienne		$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
Identité		$f(x) = x$

Figure (2.3): Fonctions d'activations

II.3. L'architecture d'un réseau :

L'architecture d'un réseau est entièrement déterminée par le modèle de ses neurones et la topologie de leurs connexions (figure 2.3).

Dans le cerveau, un très grand nombre de neurones sont interconnectés pour former un réseau et accomplir des activités intelligentes très évoluées. Par analogie, un réseau de neurones artificiels est construit à partir des modèles de neurones (i.e., neurones artificiels) connectés entre eux. A chaque connexion est associé un poids synaptique.

Les réseaux de neurones peuvent être regroupés en deux catégories:

- Les réseaux à circulation de l'information vers l'avant « feed forward networks » dans lesquels les neurones sont organisés en couches. Dans cette catégorie, on distingue les réseaux possédant une seule couche (perceptron) et les réseaux de multicouches possédant une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées [Chen, 2000]
- Les réseaux récurrents ou bouclés « recurrent / feedback networks » dans lesquels sont classés les réseaux compétitifs, le réseau de Kohonen, le réseau de Hopfield et les modèles ART (théorie de la résonance artificielle).

II.3.1. LES RESEAUX "FEED-FORWARD" :

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

➤ Le perceptron Monocouche :

Historiquement, il est le premier RNA. On l'appelle aussi le Perceptron. C'est un réseau simple, puisque il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il est calqué, à la base, sur le système visuel et de ce fait a été conçu dans un but premier de reconnaissance des formes. Cependant, il peut aussi être utilisé pour faire de la classification et pour résoudre des opérations logiques simples (telle "ET" ou "OU"). Sa principale limite est qu'il ne peut résoudre que des problèmes linéairement séparables. Il suit généralement un apprentissage supervisé

➤ Le perceptron Multicouches :

C'est une extension du perceptron, avec une ou plusieurs couches cachées entre l'entrée et la sortie. L'interconnexion des neurones est réalisée entre couches adjacentes, suivant un sens préférentiel de transfert de l'information. Typiquement, les entrées des neurones d'une couche sont également les sorties des neurones de la couche adjacente qui la précède. Au sein d'une même couche, les neurones ne sont pas interconnectés

Par convention, un réseau multicouche à n couches effectives comporte en pratique $(n+1)$ couches.

- La première couche ne présente pas d'unités de traitement (neurones), mais des unités de transfert d'information sensorielle. Elle est généralement qualifiée de couche d'entrée étant donné que son rôle consiste uniquement à transmettre les stimuli externes au réseau.
- Les couches indexées 2 à n sont dénommées couches de neurones cachées ou plus simplement couches cachées.
- La dernière couche d'indice $(n+1)$ constitue quant à elle, la couche de neurones de sortie. Cette dernière fournit, comme son nom l'indique implicitement, les réponses du réseau.

L'évolution des stimuli dans ces réseaux ne dépend nullement du temps d'où leur nomination. En effet, la modification de l'entrée n'entraîne qu'une modification stable de la sortie et non un retour d'information vers cette entrée. Du point de vue architecture, ce type de réseaux est multicouche, constitué par des neurones statiques, de sorte que chaque neurone de la couche i reçoit des informations des neurones de la couche $(i-1)$, et est connecté à tous les neurones de la couche $(i+1)$ comme le montre la figure 2.4.

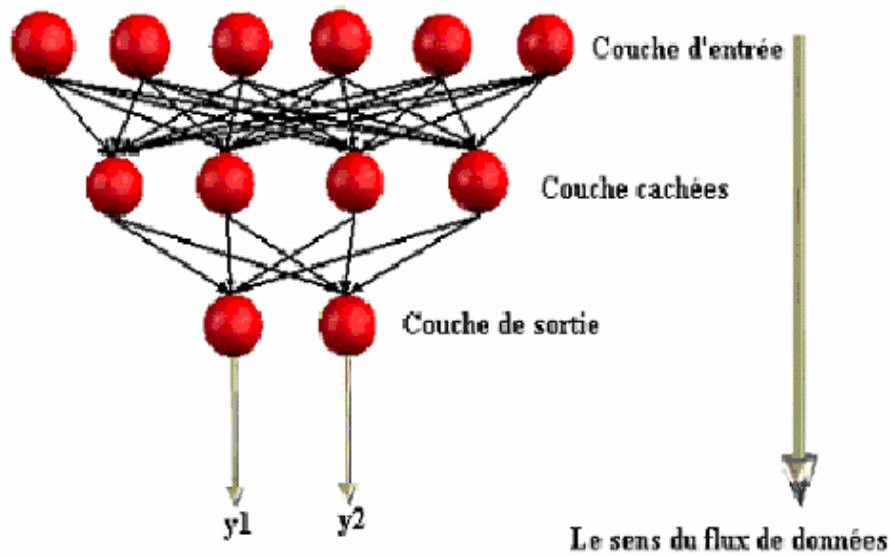


Figure (2.4) : Architecture d'un réseau multicouche.

Il peut résoudre des problèmes non linéairement séparables et des problèmes logiques plus compliqués, et notamment le fameux problème du XOR. Il suit aussi un apprentissage supervisé.

II .3.2. LES RESEAUX "FEED-BACK"

Appelés aussi "réseaux récurrents", ce sont des réseaux dans lesquels il y a retour en arrière de l'information.

➤ Réseaux dynamiques ou récurrents :

Un réseau dynamique, au sens large, désigne un réseau dont chaque neurone est en mesure de communiquer avec tout autre neurone (éventuellement avec lui-même). En pratique, un réseau récurrent se présente sous la forme d'un réseau mono- ou multicouche doté de boucles de réaction internes au sein des couches. Les sorties des neurones d'une couche sont alors ré- injectées à l'entrée de ces mêmes neurones. En raison des retards ou délais introduits par les boucles de réaction, un réseau récurrent présente un comportement dynamique qui lui permet d'intégrer explicitement la dimension temporelle.

Ce sont des réseaux dont l'évolution dépend du temps, ou en d'autre terme, l'état présent du réseau dépend de ces états passés. Donc a priori, ces réseaux contiennent des rebouclages entre neurones (Figure 2.5).




Figure (2.5): Architecture d'un réseau récurrent monocouche.

II.4. Apprentissage :

Parmi les propriétés désirées pour un réseau de neurones, la plus fondamentale est sûrement la capacité d'apprendre de son environnement, d'améliorer sa performance à travers un processus d'apprentissage.

Définition :

L'apprentissage est une phase de développement d'un réseau de neurone durant laquelle le comportement du réseau est modifié, jusqu'à l'obtention du comportement désiré [Touzet, 1992].

Dans les algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids de 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 de connexions d'un réseau pour une application donnée. L'apprentissage peut être supervisé, non supervisé ou renforcé.

A l'issue de l'apprentissage, les poids sont fixés : c'est alors la phase d'utilisation. Un ensemble de règles bien définies permettant de réaliser un tel processus d'adaptation des poids constitue ce qu'on appelle l'algorithme d'apprentissage du réseau.

II.4.1.Apprentissage supervisé :

Il se fait en présence d'un superviseur qui connaît parfaitement la sortie désirée ou correcte, guide le réseau en lui apprenant à chaque étape le bon résultat.

Dans ce type d'apprentissage, les poids des connexions sont déterminés par le biais d'algorithmes qui consistent à minimiser l'erreur entre la sortie désirée et la sortie du réseau jusqu'à l'obtention d'une performance acceptable.

Donc l'apprentissage ici, consiste à comparer le résultat désiré et le résultat réel, puis à ajuster les poids des connexions pour minimiser la différence entre les deux. C'est par exemple le cas de réseau multicouche à rétro propagation du gradient.

II.4.2.Apprentissage non supervisé :

La détermination des poids, dans ce cas, n'est pas en fonction des erreurs, mais en présentant au réseau une quantité suffisante d'exemples contenant des corrélations de sorte que celui-ci en dégage les régularités automatiquement. Ces réseaux sont souvent appelés "auto-organiseurs" (self-organizing neural networks) ou encore à apprentissage compétitif.

II.5. Algorithme d'apprentissage du Réseau multicouche :

A l'issue de l'apprentissage, les poids sont fixés : c'est alors la phase d'utilisation. Un ensemble de règles bien définies permettant de réaliser un tel processus d'adaptation des poids constitue ce qu'on appelle l'algorithme d'apprentissage du réseau.

Il existe plusieurs algorithmes d'apprentissage. Dans cette partie, nous mettrons le point sur l'algorithme de Rétro propagation du gradient qui est une généralisation de la règle Windrow et Hoff et s'applique à un réseau multicouche.

➤ La règle de windrow-Hoff ou règle delta

Après avoir étudié la règle du perceptron, Windrow et Hoff (1960) constatèrent que le Perceptron se limitait à des sorties binaires. Ils proposent alors une règle intéressante qui consistait à utiliser l'algorithme d'apprentissage du perceptron, en considérant une fonction d'activation continue et différentielle.

Dans le Perceptron, le signal d'erreur utilisé pour calculer la modification des poids est égal à la différence entre la somme pondérée des entrées après le seuillage et le résultat attendu.

Dans la règle de Windrow et Hoff, le signal d'erreur est égal à la différence entre la somme pondérée des entrées non seuillées et le résultat attendu. Cette règle est aussi connue sous le nom de la méthode des moindres carrés dont le principe est :

-Calcul de l'erreur quadratique selon la formule :

$$E = \sum_{j=1}^n (d_i - y_i)^2 \quad (2-2)$$

$$\text{Avec } y_i = \sum_{i=1}^m x_i \cdot w_{ij} \quad (2-3)$$

-Minimiser cette erreur en modifiant les poids de chaque neurone suivant la règle :

$$\text{Où : } W_{ij}(t+1) = W_{ij}(t) + \alpha \cdot x_i \cdot (d_i - y_j) \quad (2-4)$$

n : le nombre de neurones à la sortie

d_i : est la sortie désirée

y_i : est la sortie calculée

x_i : l'entrée i du neurone j

m : nombre de neurones à l'entrée

α : coefficient d'apprentissage

La règle de Windrow et Hoff pose le problème de l'apprentissage comme un problème de minimisation de l'erreur globale.

➤ **Algorithme de la Rétro propagation :**

Backpropagation (ou rétro propagation de l'erreur) est une méthode d'apprentissage basée sur la minimisation d'un critère quadratique de l'erreur (la somme des carrés des erreurs entre la sortie désirée et la sortie du réseau). Ceci est fait en changeant continuellement les paramètres du réseau dans la direction de la plus grande descente de l'erreur (procédure de descente du gradient). Le changement de chaque paramètre est proportionnel à sa relative contribution dans la somme des carrés des erreurs.

L'apprentissage par cette méthode s'effectue en deux étapes :

➤ **Première étape :**

Un signal d'entrée appliqué au réseau se propage à travers les couches supérieures, pour enfin générer un signal de sortie.

➤ **Deuxième étape :**

La sortie du réseau est comparée avec la sortie désirée et un signal d'erreur est généré. Ce dernier va se propager en sens inverse (d'où le nom *Rétro propagation*) en partant des sorties, provoquant ainsi une modification des poids dans le sens de la minimisation de l'erreur.

➤ **Dérivation de l'algorithme :**

Pour des raisons de simplicité, nous dérivons l'algorithme de *Rétro propagation* pour un réseau à trois couches. La généralisation à un réseau de plus de trois couches peut être faite par simple analogie. Afin de présenter cet algorithme, considérons le réseau à 3 couches de la figure (2.7)

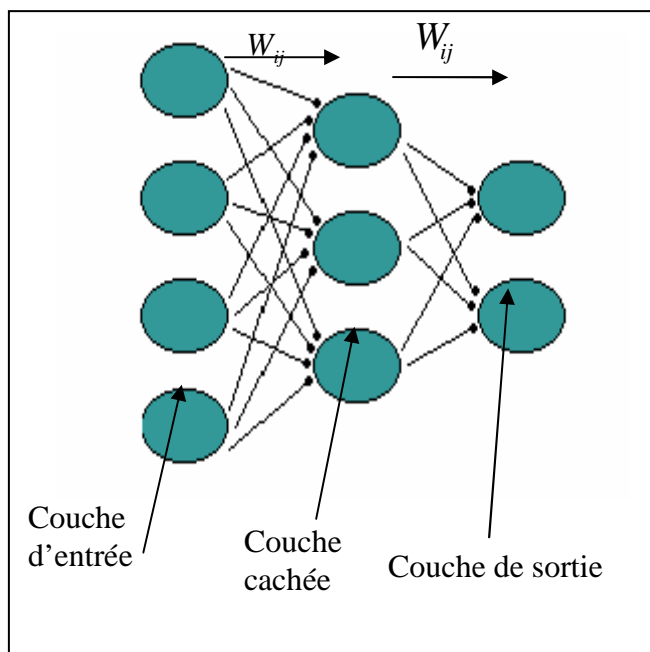


Figure (2.6) : Réseau multicouche

L'apprentissage fonctionne comme suit:

On dispose d'un ensemble d'exemples qui sont des couples d'entrée / sortie désirés.

Soient :

$X = (x_1; x_2; \dots; x_n)$ le vecteur d'entrée.

$Y = (y_1; y_2; \dots; y_n)$ le vecteur de sortie désirée.

Soit $S = (s_1; s_2; \dots; s_n)$ le vecteur qui dénote la sortie réelle calculée.

A chaque étape, un exemple est présenté à l'entrée du réseau. Une sortie réelle est calculée par la formule :

$$S_i = f\left(\sum_{i=1}^n W_{ij} \cdot x_i\right) \quad (2-5)$$

Où f dénote la fonction d'activation

W_{ij} : Le Poids de la connexion entre i et j .

Ce calcul est effectué de proche en proche de la couche d'entrée à la couche de sortie. Cette phase est appelée propagation avant. Ensuite l'erreur quadratique, E , est calculée par la formule suivante :

$$E = \sum_{i=1}^n (y_i - s_i)^2 \quad (2-6)$$

Cette erreur est ensuite rétro propagée dans le réseau, donnant lieu à une modification de chaque poids synaptique. La règle de modification des poids synaptiques est donnée par:

$$W_{ji}^{[s]}(t+1) = W_{ji}^{[s]}(t) + \Delta \cdot W_{ji}^{[s]}(t) \quad (2-7)$$

$$W_{ji}^{[s]}(t) = \alpha \cdot \delta_j^{[s]} \cdot o_i^{[s-1]} + \gamma \cdot \Delta \cdot W_{ji}^{[s]}(t-1) \quad (2-8)$$

Avec $\alpha > 0$, $0 \leq \gamma \leq 1$

Où : $s = 1, 2, 3$ (relativement à la couche d'entrée, la couche cachée, la couche de sortie)

$\delta_j^{[s]}$: l'erreur locale

o_i : le neurone d'entrée

α : le coefficient d'apprentissage (ou le gain d'adaptation) positif compris entre 0 et 1.

γ : momentum

t : représente l'étape d'apprentissage

Ce processus est répété, en présentant successivement chaque exemple. Si pour tous les exemples, l'erreur est inférieure à un seuil choisi, on dit alors que le réseau a convergé.

II.6. Certaines considérations pratiques :

Avant de procéder à l'apprentissage d'un réseau de neurones artificiels, un certain nombre de paramètres doivent être fixés (dimensionnement du réseau, pas d'apprentissage, etc ...), au risque de compromettre le processus d'entraînement s'ils sont mal choisis.

❖ Dimensionnement du réseau:

Il n'existe pas de méthodes systématiques pour la détermination du nombre de couches dans le réseau ou bien le nombre de neurones par couche. Néanmoins, il existe des règles pratiques tirées à partir de l'expérience, parmi lesquelles nous pouvons citer [Barazane, 2003] :

- ✓ **Règle 1** : plus la relation entre les données en entrée et les sorties désirées est complexe plus il faut augmenter le nombre de neurones par couche.
- ✓ **Règle 2** : pour les réseaux à une seule couche cachée, le nombre de neurones dans la couche cachée est égal à :

$$h = \frac{c}{10(M + N)} \quad (2-9)$$

Où

c : le nombre de vecteurs dans le fichier des exemples.

M : nombre de neurones dans la couche de sortie.

N : nombre d'entrées du réseau.

- ✓ **Règle 3** : le nombre de couches cachées est égal au nombre de relations qui existent entre les neurones de la couche d'entrée et les neurones de la couche de sortie.

❖ Paramètre d'apprentissage ou pas de correction η :

Le choix du paramètre d'apprentissage η a un effet important sur les performances du réseau. Généralement, η prend de petites valeurs de l'ordre de 0.05 à 0.25 pour assurer une convergence vers une solution. Ce paramètre présente en réalité un dilemme : s'il est trop grand, il peut entraîner des oscillations. Par contre, s'il est trop petit, le temps d'apprentissage devient infini. Pour résoudre ce problème, on choisit η variables, à partir d'une valeur grande qu'on diminuera par la suite.

❖ Poids initiaux :

Les poids initiaux sont choisis aléatoirement entre -0.5 et 0.5. Il ne faut jamais initialiser les poids à une même valeur.

❖ Minimums locaux :

L'algorithme d'apprentissage peut, ce qui est fréquemment rencontré, converger vers un minimum local du critère d'erreur. Alors l'erreur va stagner autour d'une valeur relativement grande, et les performances requises ne seront jamais atteintes. Pour remédier à ce problème, il existe plusieurs solutions : changer le pas de correction, changer les poids initiaux, utiliser Rétro propagation avec momentum, changer la fonction d'activation, augmenter le nombre de couches cachées, augmenter le nombre de neurones par couche.

Donc les différentes étapes pour l'apprentissage d'un réseau de neurone sont les suivantes :

- Déterminer les données d'apprentissage avec les sorties désirées correspondantes.
- Définir la structure de réseau.
- Initialiser les poids par des valeurs aléatoires petites car il est impossible d'obtenir des valeurs des poids contenant des connaissances du réseau si tous les poids sont initialisés à des valeurs égales.
- Le taux d'apprentissage (pas du gradient) doit être positif, compris entre 0 et 1. Plus le pas du gradient est grand, plus les poids changent vite, ce qui permet un apprentissage rapide.
- Le momentum doit être compris entre 0 et 1, mais très proche de 1.

II.7 La classification d'image par les réseaux de neurones :

La classification d'image fait partie des méthodes couramment utilisées pour exploiter des images radar. Elle consiste à affecter à chaque entité de la scène traitée une étiquette indiquant son appartenance à une classe particulière [Comon, 1990]. L'entité utilisée caractérise généralement le pixel ou une région de pixel tandis que l'étiquette constitue un thème choisi par l'utilisateur.

De nombreux algorithmes de classification existent, la majorité d'entre eux reposent sur la modélisation des classes selon des lois. Cependant les images radars à classifier n'obéissent généralement pas à ces lois ; ce qui explique l'utilisation des réseaux de neurones qui ne nécessitent pas la connaissance préalable des lois associées aux classes. La figure (2.8) représente le schéma simplifié de la classification :

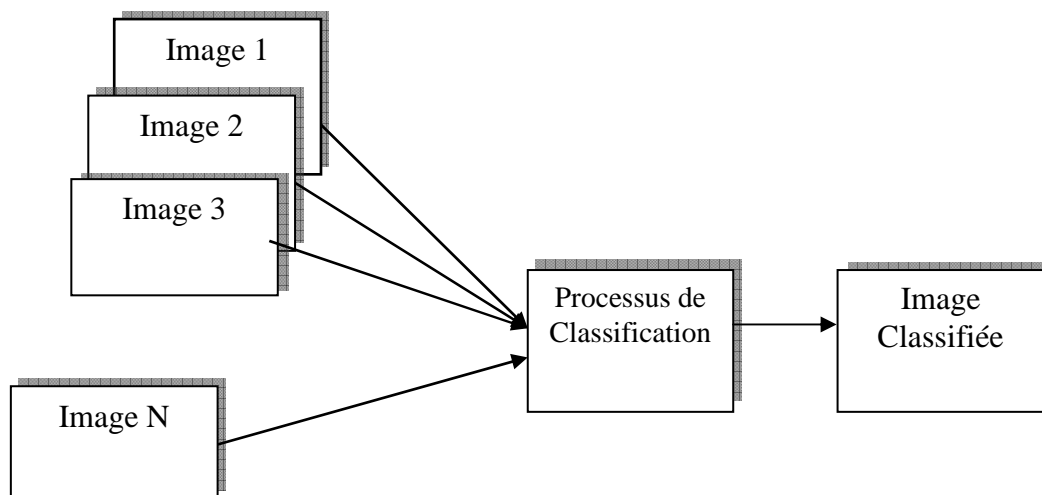


Figure (2.7) Schéma simplifié de la classification

Cette approche, qui sera utilisée dans notre étude, n'impose aucune hypothèse sur les données d'images. Elle requiert, seulement, une connaissance des données en entrée et sortie. Donc ce type de classification s'effectue en deux phases: une phase d'apprentissage et une autre de reconnaissance du réseau.

- **Phase d'apprentissage** : lors de cette phase, le réseau de neurones apprend la fonction entrées/sorties. On effectue le calcul des poids du réseau en minimisant l'erreur quadratique entre la sortie désirée et la sortie actuelle du réseau.
- **Phase de classification**: une fois l'apprentissage effectué, le réseau est prêt à évaluer la classification de la scène traitée.

II.8. Données expérimentales:

La banque de données dont nous disposons se compose de 10 052 images prises à Bordeaux et de 5799 images collectées à Sétif. Ces images ont été prises par deux radars pulsés non cohérents. Les spécifications techniques de ces deux radars sont indiquées dans la table 2.1.

Paramètres du radar	Sétif	Bordeaux
Fréquence d'émission	5,6 GHz	2,8 GHz
Puissance d'émission	250 kW crête	700 kW crête
Sensibilité à la réception	-110 dBm	-105 dBm
Résolution spatiale	1 km x 1km	1 km x 1km
Durée de l'impulsion	2 μ s	2 μ s
Ouverture du faisceau à 3 dB	1,1 °	1,9 °

Table 2.1 : Caractéristiques technique des radars de Sétif et Bordeaux

Les images prises à Sétif durant l'année 2000 ont été obtenues avec une résolution de 1km par pixel dans la représentation en mode PPI (Plan Position Indicator). Leur format est de 512 x 512 pixels. Le nombre de niveaux de gris correspondre chaque pixel de ces images est de 52 pour Bordeaux et 16 pour Sétif.

L'office national de la météorologie (ONM) dispose d'un réseau d'observation des précipitation qui comporte sept radars répartis essentiellement dans le nord de l'Algérie. Le radar qui fait l'objet de notre étude, est installé à l'ouest de Sétif. Sétif une ville des hautes plateaux entourée des montagnes du Djurdjura, des monts des Babors et des Bibans. Plusieurs obstacles terrestres existent autour du radar et les échos du sol les plus proches sont produits, en grande partie, par la zone industrielle. Au-delà de l'horizon, les obstacles terrestres produisent plusieurs échos du sol dans les images radar (voir figure 2.9).

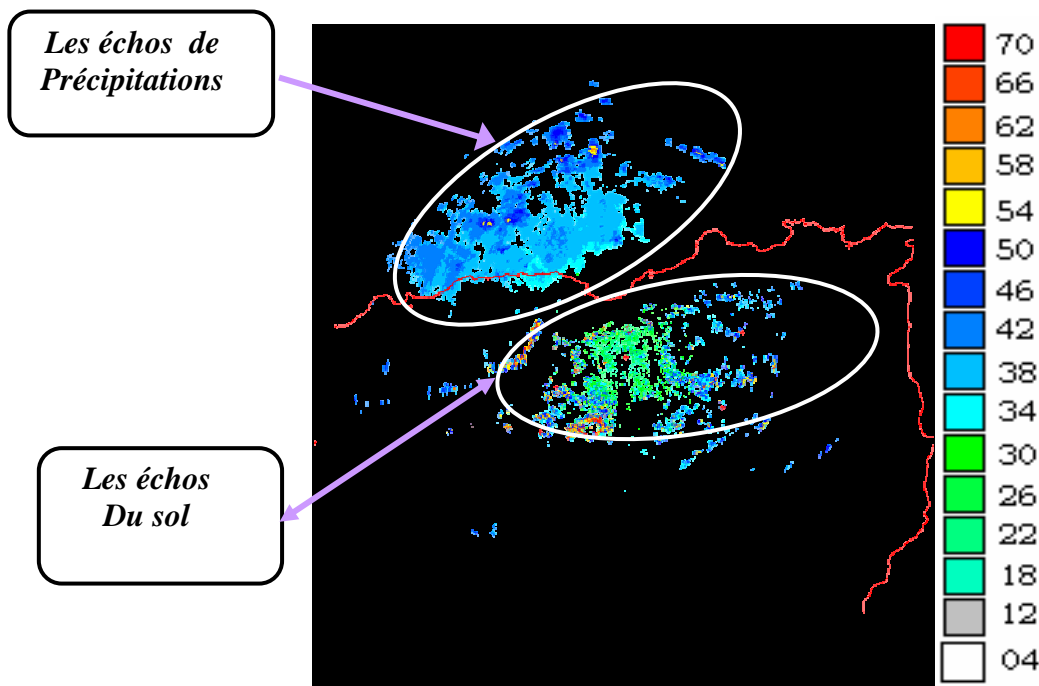


Figure (2.8): Image radar brute prise à Sétif.

Le radar de Bordeaux est situé au niveau de l'aéroport de Bordeaux Mérignac. Il constitue un élément du réseau radar français opérationnel géré par Météo France. La région de Bordeaux est une partie importante du sud-ouest de la France. A 200 km du radar, se présentent les montagnes des Pyrénées. Les images radar sont en grande partie contaminées par les échos fixes du sol causés par la zone industrielle de Bordeaux. En outre, les échos A.P (Anomalous propagation) produits par les collines et les montagnes voisines, apparaissent également de manière fréquente dans ces images (voir figure 2.10). Les images considérées ont été collectées quotidiennement toutes les cinq minutes au cours de l'année 1996

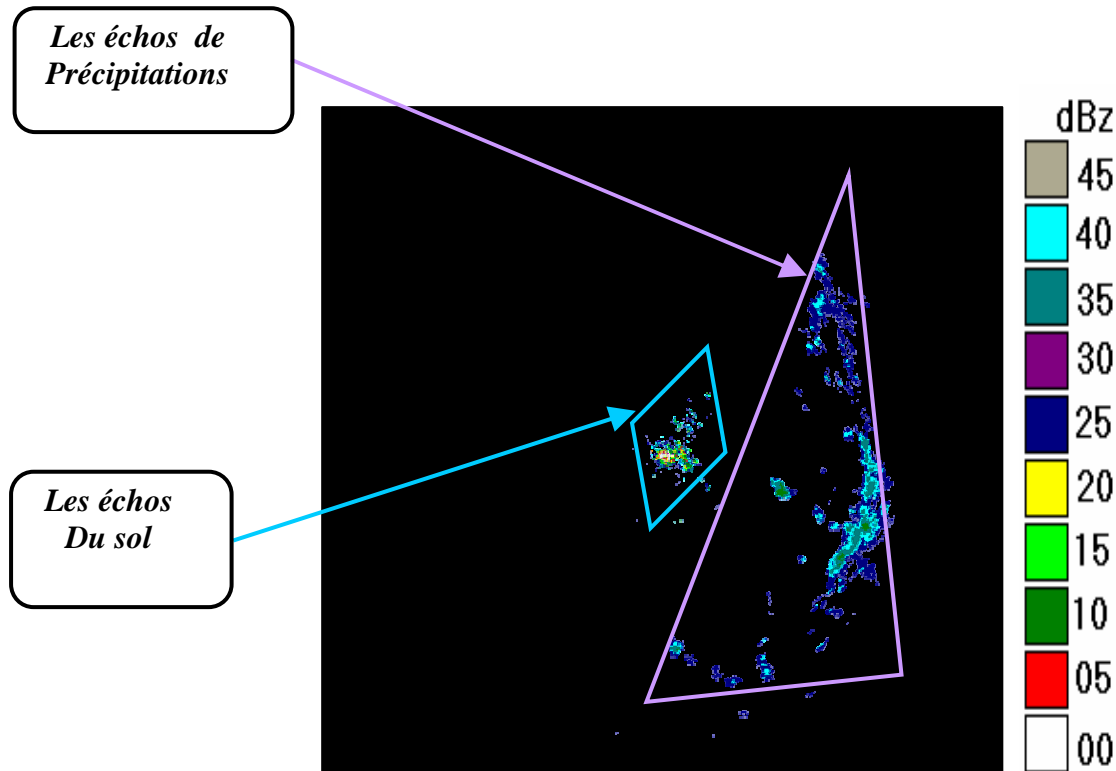


Figure (2.9) : Image radar brute prise à Bordeaux.

II.8.1. Traitement des données :

De façon générale, les images radar sont composées d'échos de précipitation mélangés aux d'échos fixe provenant de la surface terrestre. Notre travail consiste à distinguer les échos de précipitation des échos parasites. A première vue, il n'est donc pas aisé de faire la différence entre les deux types d'échos. Pour les distinguer, on peut procéder par animation des images radar. Pour ce faire, nous avons appliqué un logiciel d'animation et de traitement d'images (ACD see 4.0) aux images collectées successivement pendant la journée. Lors de l'animation, les échos dus au relief montagneux, ne bougent pas puisque ce sont des échos fixes. Par contre les échos de précipitation varient en position et en surface d'une image à l'autre [Raaf, 2003].

II.8.2. Analyse des différents échos :

a. Le Site de Sétif :

La figure (2.10) donne un exemple d'image prise par le radar de Sétif




Figure (2.10) : Images radar prises à Sétif

Pour le site de Sétif, les échos du sol se réduisent aux échos fixes causés par la zone industrielle de Sétif et les montagnes entourant le radar. En outre, la structure des échos de précipitations est plus homogène que celle des échos parasites [Sadouki, 2003 ; Haddad, 2004]

b. Le Site de Bordeaux

Les images de Bordeaux sont contaminées non seulement par les échos fixes causés par la zone industrielle de Bordeaux, mais aussi par les échos A.P provenant des montagnes des Pyrénées. Les images de Bordeaux sont composées de trois types d'échos à savoir les échos de précipitations, les échos fixes et les échos A.P.




Figure (2.11) : Les différents échos du site de Bordeaux

Les propriétés texturales des échos fixes et des échos de précipitations pour le site de Bordeaux sont identiques à celles observés pour la région de Sétif [Sadouki, 2003]. Dans le cas des images de Bordeaux, la difficulté réside dans l'identification et l'élimination des échos A.P. En effet, ces derniers se présentent à des endroits qui varient d'une image à l'autre selon les conditions atmosphériques. D'autre part, ces échos, sont constitués d'une grande variété de pixels à forte réflectivité ; ce qui rend leurs images très pixélisées.

II.9. Architecture du perceptron Multicouche pour l'identification d'échos de précipitation :

II.9.1. La phase d'apprentissage :

Plusieurs paramètres sont pris en considération lors de l'apprentissage du réseau. Généralement, les algorithmes d'apprentissage du perceptron multicouches exigent que les données soient arrangées dans l'intervalle [0 1]. Pour la normalisation de nos paramètres, nous avons divisé chaque facteur de réflectivité observé par la valeur maximum relevée pour chaque site.

d'apprentissage d'un réseau de petite taille jusqu'à plusieurs jours. Alors nous avons initialisé les poids par des valeurs aléatoires, petites et non nulles pour accélérer la convergence.

Hormis les couches d'entrée et de sortie, on doit fixer le nombre de couches intermédiaires. Sans couche cachée, le réseau n'offre que de faibles possibilités d'adaptation. Par contre avec des couches cachées, il est capable d'approximer n'importe quelle fonction [Milgram, 1993]. Nos tests seront donc limités aux réseaux à une et à deux couches cachées.

Pour évaluer les performances de ce réseau, nous avons retenu comme critère d'évaluation « l'erreur quadratique ». Cette erreur est la différence entre les sorties obtenues par le réseau et les sorties désirées. Les tests porteront sur la vitesse de convergence, sa sensibilité envers la variation de l'architecture du réseau.

Les paramètres d'apprentissage sont fixés comme suit :

- Pas d'apprentissage = 0.9.
- Momentum = 0.1.

A partir de notre banque de donnée, nous avons choisi une base d'apprentissage contenant 250 exemples repartis en deux classes. Nous avons procédé de la même manière pour choisir également notre base de contrôle.

II.9.1.1. Vitesse de convergence :

Dans ce test, nous comparons l'évolution de l'erreur quadratique moyenne à la sortie du réseau au cours du temps. Le résultat est représenté par les Figures 2.12 et 2.13.





Figure (2.12) : Evaluation de l'erreur quadratique au cours du temps pour un réseau (a : une couche cache, b : deux couche cachée)

Nous constatons que le fait de d'ajouter une deuxième couche cachée ralentit l'apprentissage de l'algorithme RP

II.9.1.2. Influence du nombre de nœuds :

Pour illustrer l'influence du nombre de nœuds sur la convergence du réseau, nous avons calculé le nombre d'itérations nécessaires pour atteindre une erreur quadratique moyenne prédéterminée en faisant varier à chaque fois le nombre de nœuds cachés. Les résultats obtenus sont représentés par les figures (2.14) et (2.15).




Figure. (2.13) : Influence du nombre de nœuds pour un réseau à une couche cachée




Figure. (2.14) : Influence du nombre de nœuds pour un réseau à deux couches cachées

Nous constatons que le réseau entraîné par l'algorithme rétro propagation nécessite un nombre d'itérations important. Ces résultats montrent que le nombre d'itération dépend du type de réseau. En effet, on constate qu'il est plus élevé pour un réseau à une couche cachée. En outre, nous avons remarqué que l'algorithme RP exige un nombre d'itération important avec toutes les architectures pour atteindre une erreur quadratique minimale.

II.9.2. Matrices de confusion :

Dans ce test, nous évaluons la capacité de reconnaissance des réseaux de neurones entraînés par l'algorithme en calculant l'erreur commise par le réseau.

Après plusieurs essais, nous avons retenu la configuration suivante :

- La première couche cachée contient 7 nœuds.
- La seconde couche cachée contient 12 nœuds.
- Le seuil de détection est fixé à 0.9.

II.9.2.2 Calcul de l'Erreur

Dans un premier temps, nous présentons à notre réseau les 250 données de la base de données. Nous comparons les sorties issues du réseau avec les sorties désirées et nous calculons l'erreur commise par le réseau. Cette erreur est donnée par l'expression suivante :

$$E = \frac{1}{N} \sum_{i=0}^{N-1} (S_R - S_d)^2 \quad (2-10)$$

Où : N représente le nombre de points (ou échantillons) considérés.

S_R : la sortie du réseau.

S_d : la sortie désirée

II.9.2.3. Estimation du taux de filtrage

L'estimation du taux de filtrage, revient à déterminer le taux de préservation des échos de précipitations et le taux d'élimination des échos fixes. Pour ce faire, on calcule le taux moyen de bonne reconnaissance (noté *TMBR*), et le taux de bonne reconnaissance d'une classe *i* (noté *TBR*). Ces taux sont donnés par les expressions suivantes [Bàrdossy et Samaniego, 2002]

$$TMBR = \frac{\sum_{i=0}^r X_{ii}}{N} \times 100 \quad (2-11)$$

$$TBR = \frac{X_{ii}}{N_i} \times 100 \quad (2-12)$$

Où :

r : le nombre de classe.

N : nombre totale des pixels.

N_i : nombre des pixels de la classe *i*.

X_{ii} : nombre de pixels bien classés à la classe *i*.

Les résultats sont décrits dans la table (2.1 et 2.2)

.

❖ Réseau à une couche cachée :

La première classe représente les échos fixes parasites. La seconde classe décrit les échos de précipitations.

classes	1	2
TBR (app)	97.2%.	94.7%.
TBR (test)	95.87%.	92.62%.
TMBR	92.73%.	

Tab (2.1) : Taux de reconnaissance par classe sur les ensembles d'apprentissage et de test.

❖ **Réseau à deux couches cachées :**

classes	1	2
TBR (app)	98%.	97.03%.
TBR (test)	97.21%.	96%.
TMBR	97 %.	

Tab (2.2) : Taux de reconnaissance par classe sur les ensembles d'apprentissage et de test.

A Partir des différents résultats, nous constatons que :

- La deuxième couche cachée augmente la précision du réseau.
- La précision globale (TMBR) la plus élevée est obtenue par le réseau à deux couches cachées entraîné par l'algorithme RP.

II.10. Résultats du filtrage:

L'évaluation visuelle du résultat sur la scène entière peut être effectuée de différentes façons. Le cas le plus simple consiste à analyser des images contenant plusieurs configurations de précipitations.

II.10.1. Etude du site de Sétif :

Les images du site de Sétif sont principalement composées d'échos de précipitation et d'échos fixes. Pour cela, nous exposons les différents cas envisageables, qui sont :

a. les échos fixes séparés des échos de précipitations

La première situation considérée est celle où on distingue les échos fixes des échos de précipitations. Elle est illustrée par les figures (2.15 a et 2.15.b)




Figure (2.15) : Des images radar avant filtrage **Figure (2.16):** Des images radar après filtrage

Pour évaluer les performants de la technique, nous avons calculé le taux de rejection des échos parasites et le taux de préservation des échos de précipitation. Pour ce faire, nous avons calculé le rapport de la surface occupée avant et après le filtrage [voir figures 2.16 a et 2.16.b] par les échos fixes ainsi pour les échos de précipitations. Les résultats sont comme suit :

- Les échos de précipitations sont préservés à 96 %.
- Les échos fixes sont éliminés à 97.21 %.

Cette situation se présente comme la plus simple à traiter. Nous allons maintenant considérer le cas où les échos de la précipitation sont au dessus des échos fixes.

b. Les échos de précipitations au dessus des échos fixes :

Les figures (2.17) et (2.18) décrivent le cas où les échos de précipitation sont mélangés aux échos parasites





Figure (2.17) : Image radar avant filtrage

Figure (2.18) : Image radar après filtrage

Dans ce cas, il est difficile d'estimer le taux de préservation des précipitations et celui de rejection des échos parasites. Pour tester la puissance de notre approche, nous avons procédé à l'animation des images. On constate que la majorité des échos parasites ont été supprimés.

II.10.2. Etude du site de Bordeaux :

Pour évaluer les performances de notre technique, pour le site de Bourreaux, nous avons calculé le taux de rejection des échos parasite et le taux de conservation des échos de précipitation. Les résultats de traitement sont donnés par les figures (2.19 et 2.20)






Figure (2.19) : Image radar avant filtrage

Figure (2.20) : Image radar après filtrage


- Les échos de précipitations sont préservés à 98.75 %
- Les échos fixes sont éliminés à sont quasiment éliminés.

➤ Les échos fixes et les échos A.P :


La situation de présence des anaprops est la plus complexe. Ces données sont caractérisés par des facteur de réflectivité élevés qui rendent les images très pixélisés .et dotés d'une texture inhomogène



(a)



(b)



(c)



(d)

Figure (2.21) : Image de radar avant le filtrage
(a,c)

Figure (2.22): Image de radar après le filtrage
(b,d)

- Les échos fixes sont éliminés à 100 %
- Les échos A.P sont éliminés à 97.52 %

Conclusion :

Dans ce chapitre nous avons présenté les réseaux de neurones. En premier lieu, nous avons défini l'aspect structural du neurone formel et ses fonctions de bases. Ensuite, nous avons appliqué cette technique à la classification des échos radar.

Les premiers résultats montrant que le perceptron multicouches entraîné par l'algorithme de RP présente de bonnes performances pour la reconnaissance, et la classification des échos radar. En outre, l'approche neuronale permet d'éliminer quasiment les échos parasites en préservant presque totalement les échos de précipitation. De plus, nous avons montré que cette technique est aussi puissante pour traiter les anaprops qui demeurent difficile à supprimer. De même, le temps de traitement est de l'ordre de deux seconde pour les deux sites considérés. On peut donc implémenter cette technique pour le traitement en temps réels pour les radars non cohérents

Aussi, le taux de préservation des échos de précipitation est très élevé (96%). L'inconvénient de cette méthode réside dans le fait que l'apprentissage doit être fait pour chaque site étudié.

Chapitre III

La combinaison Neuro Floue

Introduction :

Les Systèmes hybrides qui combinent la logique floue et les réseaux neuronaux, prouvent leur efficacité dans une variété de problèmes de monde réel et dans l'industrie.

Chaque technique intelligente a des propriétés particulières et résoud certains problèmes spécifiques. En effet, les réseaux neuronaux ont été appliqués avec succès dans de nombreux problèmes d'interprétation d'images [Verrelst et Moreau, 1999]. Les réseaux de neurone sont calés grâce à un algorithme d'apprentissage mis en œuvre sur une variété d'exemples pour porter ensuite le processus de décision. Ils sont incapables d'expliquer comment ils atteignent leurs décisions. Le système de la logique floue peut raisonner avec l'information imprécise et expliquer ses décisions mais ne peut cependant pas acquérir automatiquement les règles qu'il utilise pour prendre ces décisions.

Ces limites sont à l'origine de la création de systèmes hybrides intelligents où, deux ou plus de techniques sont combinées afin de vaincre les limitations d'une seule technique.

Dans ce chapitre, nous allons présenter les notions sur la logique floue et proposer un modèle pour le calcul du degré d'appartenance fondé sur une combinaison neuro floue [Nemmour and al, 2006].

III.1. Les combinaisons neuro floue :

Dans le but d'améliorer le taux moyen de bonnes reconnaissances (TMBR), nous avons utilisé les combinaisons neuro floue. Takagi (1997), (Fuller,1995) a rapporté que quatre combinaisons sont possibles entre un réseau de neurones (RN) et un système flou (SF) (figure 3.1).

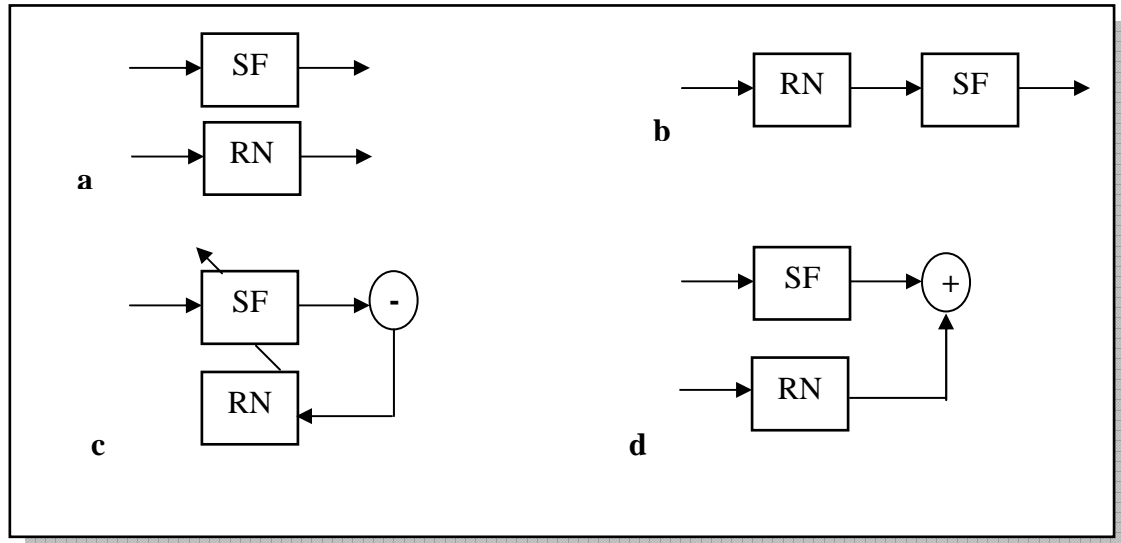


Figure (3.1) : Les combinaisons neuro floue

Dans notre cas, nous avons adopté la combinaison en cascade représentée par la figure (3.1.b). Dans ce modèle, la combinaison est de type $RN \longrightarrow SF$

Nous allons présenter les notions de base et la classification des modèles flous.

III.2. Théorie des ensembles flous :

III.2.1. Introduction :

L'être humain manipule d'une façon remarquable des notions floues et imprécises tel que grand, fort, loin alors que l'ordinateur exige souvent de la précision. C'est pour ces raisons que l'informatique a besoin de nouveaux outils remplaçant la logique à deux estimations (vrai ou faux) exigeant une dichotomie de n'importe quel modèle mathématique, pour tenir compte de l'imprécision et de l'incertitude de la connaissance humaine.

Le concept de logique floue vient de la constatation que la variable booléenne, qui ne peut prendre que deux valeurs (vrai ou faux) est mal adaptée à la représentation de la plupart des phénomènes courants. Alors que la logique classique considère qu'une proposition est soit vraie soit fausse. La logique floue distingue une infinité de valeurs de vérité (entre 0 et 1)

Dans ce qui suit, nous ne retiendrons que les éléments indispensables à la compréhension du principe du réglage par la logique floue. Ces éléments sont : [HUG 04]

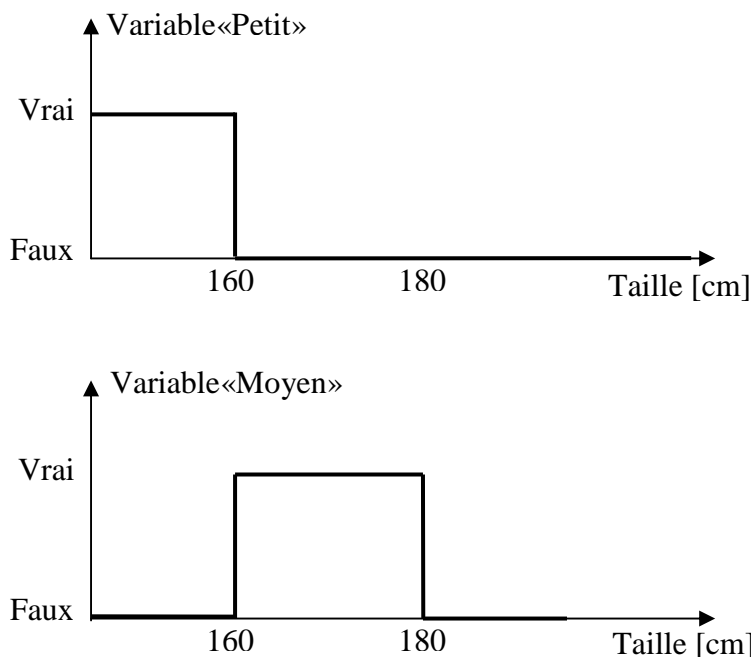
- Les variables floues (linguistiques)
- Les fonctions d'appartenances

III.2.2 Les Variables Linguistiques

Les ensembles flous sont utilisés pour la description des valeurs que peut prendre une variable tant que l'univers du discours d'une variable est discrétisé en un certain nombre de segments d'où chaque segment est associé à une étiquette. Ces étiquettes sont appelées « variables linguistiques » [Maeda, 1990; Maeda, 1991].

Contrairement aux variables binaires qui sont définies par les deux états « vrai » ou « faux », les variables floues présentent toute une gradation entre la valeur « vrai » et la valeur « faux ». L'exemple qui suit permet de mieux saisir la distinction qui existe entre les variables binaires et les variables floues :

Si l'on désire classer un groupe d'individu par leur taille en définissant la catégorie des petits par une taille en dessous de 160 cm, la catégorie des moyens par une taille comprise entre 160 cm et 180 cm et la catégorie des grand par une taille supérieure à 180 cm, la logique binaire donne la représentation de la figure 3.2 pour les trois variables « petit », « moyen » et « grand »






Figure (3.2) Valeur de vérité de la proposition

Deux remarques s'imposent au sujet de cette représentation :

D'une part, on préfère représenter l'état de la variable à l'aide de son degré de vérité en associant la valeur 1 (degré de vérité de 100%) à la valeur « vrai » et le degré de vérité nul à la valeur « faux ».

D'autre part, nous constatons que cette façon de faire est très éloignée de ce que fait l'être humain lorsqu'il résout ce genre de problème. En effet, l'homme ne fait pas naturellement une distinction franche entre « petit » et « moyen » par exemple. Il utilise des expressions du genre « plutôt petit » pour qualifier une taille légèrement inférieure à 160 cm et « plutôt moyen » pour une taille légèrement supérieure à cette valeur.

III.2.3. Fonction d'Appartenance :

La notion de fonction caractéristique proposée par la logique binaire est étendue en une fonction prenant toutes les valeurs comprises entre 0 et 1, appelée « fonction d'appartenance ». Cette fonction indique le degré d'appartenance d'un élément à un ensemble.

La valeur 0 sera remise dans le cas d'une non appartenance totale tandis que la valeur 1 sera pour une appartenance absolue.

Le but essentiel de l'utilisation des ensembles flous est la description des valeurs que peut prendre une variable. Prenons toujours comme exemple de variable : la taille d'un homme. On peut dire dans un contexte bien précis, que la taille est "très grande", "grande", "moyenne", "petite" ou "très petite".

Ces adjectifs sont des ensembles flous définis dans le domaine des valeurs de la taille (univers de discours). Cependant ; il n'existe aucune règle permettant la définition du nombre d'ensembles flous qu'il faudrait utiliser et c'est pour cela que ce nombre est défini d'une manière subjective.

Les ensembles flous correspondant à une même variable doivent nécessairement se recouvrir mais ce qui peut être demandé est : "de combien doivent se recouvrir les ensembles flous ?". (Figure.3.3.)

La réponse sera de la forme suivante :

- Trop de recouvrement diminue la possibilité du système flou à faire la distinction entre deux ensembles flous.
- Trop peu de recouvrement tend à faire fonctionner le système flou comme un système gouverné par la logique bivalente réduisant sa souplesse et sa possibilité de traiter des situations intermédiaires.
- Les pourcentages de recouvrement les plus utilisés sont de 25% à 50% [VER 92].




Figure (3.3) Différents taux de recouvrement

❖ Quelques types de fonction d'appartenance

En générale, les fonctions d'appartenance sont des fonctions mathématiques simples de forme triangulaire, trapézoïdale, ou curviligne (Figure.3.4).

Mais le problème qui est posé par les personnes qui s'initient à la théorie des ensembles flous est : comment trouve-t-on ces fonctions d'appartenance ?

Malheureusement, la théorie des ensembles flous ne fournit aucune méthode systématique pour déterminer ces fonctions.

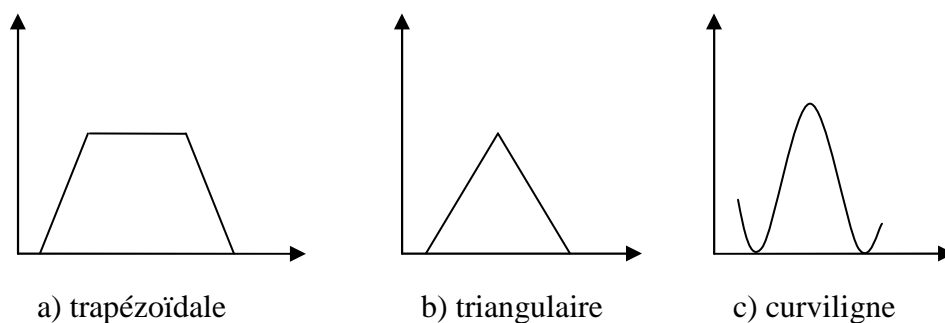


Figure (3.4) Les différentes formes des fonctions d'appartenance

III.2.4. La théorie des sous ensembles flous :

La théorie des sous ensembles flous s'articule sur les définitions suivantes :

• **Définition 1 :**

Un ensemble flou A de X est défini comme étant une application caractérisée par une fonction d'appartenance $\mu_A(x)$ associée à chaque élément $x \in X$, dont le degré est compris entre 0 et 1

$$\begin{array}{l} \mu_A : X \longrightarrow [0 \ 1] \\ x \longrightarrow \mu_A(x) \end{array}$$

- **Définition 2 :**

On définit le sous ensemble flou A de X comme étant l'ensemble des couples ordonné

$$\mu_A(x) = \{(x, \mu_A(x)) / \forall x \in X\}$$

Où $\mu_A(x)$ est une fonction caractéristique d'appartenance qui prend ses valeurs dans le segment [0,1]. Elle indique le degré d'appartenance de l'élément x à A dans X

III.2.5. Les Opérateurs sur les ensembles Floue :

La logique floue est une extension de la logique classique. En conséquence, les opérateurs déjà rencontrés dans cette dernière ont été adaptés par ZADEH (1965) à la logique floue.

Soient A et B deux ensembles flous d'un référentiel X de fonctions d'appartenance respectivement $\mu_B(x)$ et $\mu_A(x)$

- **Egalité :**

On dit que A et B sont égaux si et seulement si :

$$\mu_A(x) = \mu_B(x).$$

- **Inclusion :**

On dit que A est inclus dans B si et seulement si :

$$\mu_A(x) \leq \mu_B(x).$$

- **Complémentation :**

La fonction de complémentation de A est donnée par :

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x).$$

- **L'intersection et l'union dans les ensembles floue :**

➤ L'opération **ET** correspond à l'intersection de deux ensembles A et B, on définit :

$$C = A \cap B = A \text{ ET } B.$$

Dans le cas de la logique floue, l'opérateur ET est réalisé par la formation du minimum appliqué aux fonctions d'appartenance $\mu_A(x)$ et $\mu_B(x)$ des deux ensembles A et B, et il est formulé comme suit :

$$\forall x \in X, \mu_C(x) = \text{Min} \{ \mu_A(x), \mu_B(x) \}.$$

➤ L'opération **OU** correspond à l'union de deux ensembles A et B, donc :

$$C = A \cup B = A \text{ OU } B.$$

La réalisation de cet opérateur au niveau de la logique floue se fait par la formation du maximum appliqué aux deux fonctions d'appartenance des deux ensembles A et B, et il est décrit par :

$$\forall x \in X, \mu_C(x) = \text{Max} \{ \mu_A(x), \mu_B(x) \}.$$

III.2.6. La Fuzzification :

La fuzzification consiste à calculer les degrés d'appartenance de chaque valeur d'entrée aux ensembles flous correspondant à la variable qu'elle représente.

III.2.7 La défuzzification :

C'est l'opération inverse de la fuzzification. Les règles d'inférence nous remettent les degrés d'appartenance de la sortie à différents ensembles flous. Ces degrés sont appelés coefficients de sortie. Puisque la sortie doit être déterministe et non floue, le contrôleur détermine à partir de ces coefficients une valeur de sortie non floue [HAN].

III.2.8. Modèle de degré d'appartenance flou:

La classification floue ne fournit pas une étiquette indiquant l'appartenance d'un pixel à une classe particulière mais plutôt des degrés d'appartenance de ce pixel dans les différentes classes d'intérêt. Nous adaptons à notre étude le modèle flou proposé par Deer (1998) pour calculer le degré d'appartenance de chaque pixel.

Le modèle de degré d'appartenance du pixel dans les différentes classe i est calculé comme suit [Nemmour and al, 2006] :

$$\mu_i = \frac{(y_i^2)^x}{\sum_{j=0}^1 (y_j^2)^x} \quad (3-1)$$

Où : $1 \leq i \leq c$ et $j=1 \dots c$ (c étant le nombre de classes).

y_i : la valeur de la sortie du réseau de neurones dans la classe i .

x : le paramètre de fuzzification (toujours supérieur à 0).

La détermination des degrés d'appartenance de cette manière implique que pour chaque pixel de l'image, la somme des ces degrés d'appartenance dans différentes classes est égale à 1.

$$\sum_{i=0}^1 \mu_i = 1 \quad (3-2)$$

La formule (3.1) permet à un pixel d'avoir un degré d'appartenance maximal dans sa classe et des degrés d'appartenance minimaux dans toutes les autres classes.

III.3. Etude comparative entre le modèle neuroflou et le réseau de neurones :

Nous comparons dans ce test les performances de la combinaison neuroflou (CNF) à celles de réseau de neurones (RN). Les CNF et RN ont la même architecture neuronale et sont entraînés par l'algorithme de rétro propagation. Le seuil de détection est fixé à 0.9.

Dans le cadre de notre application, nous avons utilisé les résultats obtenus d'après les études qui sont faites pour l'évaluation de la valeur du degré d'appartenance du pixel d'une classe en fonction des différentes valeurs du paramètre de fuzzification.

D'après Nemmour (2003), à partir de la valeur 1.5, les pixels présentent des degrés d'appartenance maximaux dans leurs classes et des degrés pratiquement négligeables dans les autres classes. Dans notre cas, nous avons choisi la valeur 2, comme paramètre de fuzzification.

Chaque combinaison RN attribue les pixels à la classe qui correspond au degré d'appartenance ayant la valeur maximale. Le tableau suivant résume les résultats obtenus par le RN et CNF.

classes	TBR (RN)	TBR (CNF)
1	97.21%.	97.2%.
2	96%.	97%.
TMBR	97 %.	98 %.

Tableau (3.1) : Taux de bonne reconnaissance de réseau de neurones et de la combinaison neuro floue

Les résultats obtenus montrent que la combinaison neurofloue améliore le taux de bonne reconnaissance de la seconde classe (classe de précipitation), et réduit celui de la première classe [classe des échos fixes (voir la table 3.1)].

A partir de ces résultats, on peut déduire que la méthode des réseaux de neurones donne des résultats meilleurs de point de vue filtrage des échos fixes, alors que la combinaison neurofloue préserve quasiment les échos de précipitations.

III.3.1. Appréciation visuelle :

Pour voir l'apport visuel de la combinaison neurofloue, nous présentons les résultats de traitement des images radar par l'approche neuro floue.

III.3.1.1. Etude du site de Sétif :

Nous allons d'abord considérer une image radar où on distingue les échos de précipitation des échos du sol.

a. les échos fixes séparés des échos de précipitations

Les figures (3.6) et (3.8) donnent les images filtrées par l'approche neuro flou




Figure (3.5) : Image radar avant filtrage

Figure (3.6): Image radar après filtrage




Figure (3.7) : Image radar avant filtrage

Figure (3.8): Image radar après filtrage

Pour évaluer les performants de l'approche neurofloue, nous avons calculé le taux de rejection des échos parasite et le taux de préservation des échos de précipitation. Les résultats sont comme suit :

- Les échos de précipitations sont préservés à (98.50 %).
- Les échos fixes sont éliminés à 96 %.

a.Les échos de précipitations au dessus des échos fixes :

Dans cette partie, nous avons étudié le cas où les échos de précipitation sont mélangés aux échos du sol




Figure (3.9) : Image radar avant filtrage




Figure (3.10) : Image radar après filtrage

Pour tester la puissance de notre approche, nous avons procédé à l'animation des images, car il est difficile d'estimer le taux de reconnaissance des précipitations et celui de rejection des échos parasite. De même, nous avons comparé l'image traitée à celle du masque qui représente la cartographie des échos parasite. On constate que la majorité des échos parasites ont été supprimés

III.3.1.2. Etude du site de Bordeaux :

Pour le site de bordeaux, les résultats de traitement sont illustrés par la figure (3.12)





Figure (3.11) : Image radar avant filtrage

Figure (3.12) : Image radar après filtrage


- Les échos de précipitations sont préservés à 99%
- Les échos fixes sont quasiment éliminés.

a. Les échos fixes et les échos A.P :

Le traitement des échos anaprops ou A.P par l'approche neuro floue est illustré par les figures (3.14.b et 3.14.d)




(a)



(b)

Figure (3.13): Image de radar avant le filtrage **Figure (3.14):** Image de radar après le filtrage



(c)

Figure (3.13): Image radar avant le filtrage
(a,c)



(d)

Figure (3.14): Image radar après le filtrage
(b,d)

- Les échos fixes sont éliminés à 100 %
- Les échos A.P sont éliminés à 97.52 %

Conclusion :

D'après les résultats présentés ci-dessus, nous pouvons conclure que la combinaison neurofloue assure une meilleure conservation des précipitations et n'améliore pas le filtrage des échos de sol

A partir de cette étude comparative, on peut conclure que la méthode des réseaux de neurones permet une bonne classification des échos radar. La combinaison neuro floue assure seulement une meilleure conservation des précipitations. Le temps de traitement de ces images ne dépasse guère une (01) minute permettant ainsi un filtrage en temps réel des échos parasites. Cette technique peut être implémentée sur les radars non cohérents composant la plupart des stations météorologiques au sol.

Conclusion Générale

L'objectif de ce travail est l'élimination des échos en provenance de la surface terrestre tout en préservant les échos de précipitation

Après avoir décrit brièvement le fonctionnement du radar, nous avons d'abord appliqué les réseaux de neurone pour la détection et l'élimination des échos en provenance de la surface terrestre. Nous avons testé plusieurs configurations de réseaux de neurones et celle composée de quatre couches cachées : la première à 16 noeuds représente l'entrée du réseau, deux couches cachées, à 7 et 12 noeuds respectivement et une couche de sortie à deux noeuds. Les tests effectués par le perceptron multicouche monte par l'algorithme de rétro propagation permet une rejection des échos parasite avec un taux dépassant 96 % pour Sétif alors qu'ils sont pratiquement éliminés pour Bordeaux. Cette légère différence peut s'expliquer par le fait que le du radar de Sétif, est entouré de reliefs montagneux tels que des montagnes du Djurdjura, des montes de Bibans et des Babors, alors que la région de Bordeaux est plutôt plate.

Pour améliorer le taux de bonne reconnaissance du classifieur qui est de 97%, nous avons appliqué la technique hybride « neuro floue. Dans un premier temps, nous avons rappelé quelques notions sur la théorie des ensembles flous et proposé un modèle appliqué pour le calcul du degré d'appartenance dans les différentes classes fondé sur une combinaison neuro floue en cascade. Les résultats obtenus montrent qu'elle apporte un meilleur résultat du point de vue conservation des échos de précipitations (98.50%) sans améliorer le filtrage des échos fixes.

A partir de cette étude comparative, on peut conclure que la méthode des réseaux de neurones permet une bonne classification des échos radar. Le taux de préservation des échos de précipitation est de (96%) et le temps de traitement de ces images ne dépasse guère une (01) minute permettant ainsi un filtrage en temps réel des échos parasites.

Ces techniques peuvent être implémentées sans difficulté sur les radars non cohérents composant la plupart des stations météorologiques au sol qui seront alors dotés d'un outil puissant de traitement automatique d'écho radar et de généraliser cette étude à différents sites du territoire national.

L'inconvénient de la méthode neuronale est qu'elle nécessite un apprentissage pour chaque site. Elle est souvent piégée dans un minimum local à cause de leur comportement similaire à celui d'une recherche locale via l'algorithme de rétro propagation du gradient.

Il serait intéressant d'introduire les algorithmes génétiques pour l'élaboration d'un système d'hybridation entre les trois techniques : les réseaux de neurones, la logique floue et les algorithmes génétiques et ceci pour optimiser les performances du point vue filtrage des échos parasite

Références Bibliographiques

- Aoyagi, J, 1983. « A study on the MTI weather radar system for rejecting ground clutter ». Pap. Meteor. Geophys., 33, 187-243
- Assous, N, 2004. « Classification des échos radars par les réseaux de neurone ».Mémoire de Magistère, USTHB.
- Ayat, N.E., Cheriet, M. Suen, C.Y, 2000. « Un système neuro flou pour la reconnaissance de montants numérique de cheque arabes ». Laboratoire d'Imagerie, Vision et d'Intelligence Artificielle, École de Technologie Supérieure, Université du Québec. Canada.
- Bàrdossy, A, et Samaniego, L, 2002. « Fuzzy Rule-Based Classification of Remotely Sensed Imagery ». IEEE Transactions on Geoscience and Remote Sensing, Vol, 40, No, 2, pp.362-374.
- Bennis, F., Chedmail, P., Helary, O. 2001. « Conception en environnement incertain. Représentation des connaissances par réseaux de neurones ». In 15ème Congrès Français de Mécanique, CFM2001. Nancy, France.
- Bouchard, G, 2005. « Les modèles génératifs en classification supervisée et applications à la catégorisation d'images et `a la fiabilité industrielle ». Thèse de Doctorat de l'université Joseph Fourier – Grenoble 1 (spécialité mathématique appliquée).
- Breton, S, 1999. « Une approche neuronale du contrôle robotique utilisant la vision binoculaire par reconstruction tridimensionnelle ». Thèse de doctorat, Université de Haute Alsace.
- Carpentier, M. H., 1981. « Eléments constitutifs du radar : l'élimination du clutter ». Tome III. Ed. E.N.S.T.A.
- Chen,W ; Gadert.P, 2000. « Word level Discriminative training for liandwritten Word Recognition ». IWFHR 7.pp.393-402. Amestrdam.
- Comon. P, 1990. « Classification Bayésienne distribuée”, Reconnaissance des formes et réseau de neurones ». Revue technique Thomson-CSF.

- Chang, S, et Greenberg, S, 2002. « Application of fuzzy integration based multiple information aggregation in automatic speech recognition ». Report University of California USA.
- Darricau, J, 1981. « Physique et théorie du radar ». Tomes I et II, Ed Sodipe, Paris.
- Davallo, E., Naim, P. 1993. « Des Réseaux de neurones ». Edition Eyrolles, Paris
- Doviak, R. J., and D. S. Zrnic, 1993. « Doppler Radar and Weather Observations ». Academic Press. 562 pp.
- Deer, P, 1998. « Digital change detection in remotely sensed imagery using fuzzy set theory », PHD thesis Department of geography and department of computer science, University of Adelaide, Australia, 185 pages.
- Frédéric, J, lacaille, 1998. « Présentation de la Logique Floue ». Ecole nationale supérieure de cachan, Magistère de Mathématiques.
- Gabella, M., G. Galli, O. Ghigo, J. Joss, and G. Perona, 1999. « Clutter elimination and agreement between hourly precipitation amounts as measured by two radars and network of gauges ». Proc. Advanced Weather Radar System. Inter. Seminar on COST 75 – Locarno, European Communities, Bruxelles, Belgium
- Gacogne, L, 1997. « Eléments de logique floue ». Ministère de l'éducation nationale conservatoire national des arts et métiers, l'institut d'informatique d'entreprise.
- Giuli, D., M. Gharardelli, A. Freni, T. A. Seliga, and K. Aydin, 1991. « Rainfall and clutter discrimination by means of dual-linear polarisation radar measurements. ». J. Atmos. Oceanic Technol., **8**, 777-789.
- Hachouf, F, Mezhoud, N. « Segmentation Neuro-floue Application aux Images à Résonance Magnétique ». Département d'électronique, Université Mentouri Constantine
- Haddad, B. 2000. « Etude des échos du sol dus aux anomalies de propagation : Application aux radars météorologiques ». Thèse de Doctorat d'Etat, USTHB.
- Haddad, B., N. Assous, and L. Sadouki , 2004. « Identification du clutter du sol par les réseaux de neurones. » .XVII Colloque de l'A.I.C., Caen (France)
- Hamuzu, K., and M. Wakabayashi, 1991. « Ground clutter rejection. Hydrological Applications of Weather Radar, Clukie and Collier ». Ed. Ellis Horwood Ltd., 131-142
- Keeler, R. J., and R. E. Passareli, 1990 . Signal processing for atmospheric radars. Radar in Meteorology : Battan memorial and 40th anniversary : Radar Meteorology Conference, 199-229, Ed. atlas, American Meteorological Society, Boston.

- Kuhn, D.1997, « Une approche neuronale pour l'asservissement visuel d'un robot manipulateur ». Thèse de doctoral, Université de Haute Alsace
- Lelu, C., Dahan, M. 2002 Utilisation des règles d'inférences floues pour le calcul des cotes d'un assemblage mécanique soumis à contraintes. In 4ème Conférence Internationale sur la conception et fabrication intégrées en mécanique, IDMME'2002. Clermond-Ferrand, France.
- Maeda, Y, 1990, « Collision avoidance control among moving obstacles for a mobile robot on the Fuzzy reasoning», laboratory for international fuzzy engineering research, japan.
- Maeda, Y, Murakani, S,1991, «Fuzzy drive control of an autonomous mobile robot » Fuzzy sets and systems .
- Marée, R, 2005, « Classification automatique d'images par arbres de décision ». Thèse de doctorat en informatique, institut montefiore, Université de liège.
- Milgram, M, 1993. « Reconnaissance des formes : méthodes numériques et connexionnistes », Armand Colin
- Moszkowicz, S., G. J. Ciach and W. F. Krajewski, 1994. « Statistical detection of anomalous Propagation in radar reflectivity patterns ». J. Atmos. Oceanic Technol., 11, 1026-1034.
- Nemmour, H., 2002. « Methodes de détection de changement dans les images optiques de télédétection ».Thèse de Magister en électronique,USTHB.
- Nemmour, H., 2006. « Fuzzy Neural ntework Architecture for Change Detection in Remotely Sensed Imagery. International Journal of Remote Sensing, 27(3-4):705-717
- Raaf, O, 2002, Application de l'instrumentation radar pour le pluviomètre. Thèse de Magister en électronique, USTHB.
- Rebert de bois, « Structure et application des émetteurs et des récepteurs ».
- Sadouki, L, 2003 « Etude des propriétés texturales des images Radar en vue d'applications météorologiques ». Thèse de Magister, USTHB.
- Sauvageot H, 1990, « radar météorologie : télédétection active de l'atmosphère ». Ed dunod. Paris.
- Sauvageot, H., and G. Despaux, 1990 : SANAGA : « Un système d'acquisition numérique et de visualisation des données radar pour la validité des estimations satellitaires de précipitations. » *Veille Climatique Satellitaire*, **31**, 51-55.

- Semani, D, Frélicot, C, Courtellemont, P « Combinaison d'étiquettes floues/ possibilistes pour la sélection de variables ». Laboratoire d'Informatique – Image – Interaction (UPRES EA 2118), Université de La Rochelle, avenue M. Crépeau, France
- Takagi, H., 1997, « Introduction to Fuzzy Systems, Neural Networks, and Genetic Algorithms », Intelligent Systèmes : Fuzzy Logic, Neural Networks, and Genetic Algorithms, CH.1, D. Ruan, Kluwer Academic Publishers (Norwell, Massachusetts, USA), Spetember, 1997, pp.1 1-33.
- Talibi-Alaoui, M. Touahni, R. Sbihi, A, 2004, « Classification des Images Couleurs par association des Transformations Morphologiques aux Cartes de Kohonen ». Laboratoire Image et Reconnaissance des Formes, Université Ibn Tofail, Maroc.
- Tatehira, R., and T. Shimizu, 1978, « Intensity measurement of precipitation's echo superposed on Ground clutter, a new automatic technique for ground rejection ». Proc. 18th Radar Meteor.Conf. Amer. Meteo. Soc., Boston, 364-369.
- Thourel I, 1982. « Initiation aux techniques modernes des radars ». Ecole nationale supérieur de l'aéronautique et de l'espace SUPAERO.Toulouse.
- Touzet, C, 1992. « Les réseaux de neurones artificiels, introduction au connexionnisme, cours, exercices et travaux pratiques ».
- Verrelst, H., and Y. Moreau, 1999. « Use of Multi-Layer Perceptron to Predict Malignancy in Ovarian Tumors ». Department of Electronical Engineering, Catholic Leuven University.
- Werbos, P, 1974. « Beyond Regression: New tools for Prediction and Analysis in the Behavioral Sciences ». Ph.D. thesis, Dept. of Applied Mathematics, Harvard University, Cambridge, Mass.
- Zadeh., L, 1997. « The role of soft computing and fuzzy logic in the conception, design and deployment of intelligent systems ». Proc. Sixth Int IEEE Int. Conf. On Fuzzy Systems, Barcelona, july 1-5.