

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



## **Extraction de réseaux routiers à partir d'images satellitaires**

**M.ZITOUNI Abdelkader**

Mémoire

Présenté pour l'obtention du diplôme de Magister en Electronique

Soutenu publiquement le 13/12/2011 devant le jury composé des membres :

Président	BERKANI	Daoud	Professeur (ENP)
Rapporteur	HAMAMI	Latifa	Professeur (ENP)
Examineurs	GUERTI	Mhania	Professeur (ENP)
	BOUSBIASALAH	Hichem	MC-A (ENP)

## ملخص:

ركزنا هذا البحث حول مسألة استخراج الطرق من صور الأقمار الصناعية . لقد قدمنا طريقة تلقائية، بواسطة الشبكات العصبية متعددة الطبقات. شبكة الطرق التي تم الحصول عليها مشابهة للمعطيات المرجعية ، مع وجود القليل من الاكتشافات الخاطئة. ويمكن أن تؤول النتيجة الأخيرة إلى مزيد من التحسين من خلال النظر في خصائص أخرى للطرق مثل أشكال الطرق (شكل خطي). لهذا طبقنا محولة Hough على الصورة التي تحصلنا عليها بواسطة الشبكات العصبية ، بهدف نزع المناطق التي لا تمثل شبكات طرق . في الصورة الناتجة من محولة Hough تم الكشف عن جميع الطرق تقريبا ، وانخفضت كذلك الاكتشافات الخاطئة . وأخيرا، اعتمدنا نهج آخر للكشف عن الطرق وهو نهج التصنيف، لأن تفسير الصور الناتجة عن طريق التصنيف أسهل من تفسير صور الأقمار الصناعية الأصلية . وقد استعملنا كطريقة لتصنيف خريطة Kohonen .

**كلمات البحث :** صورة الاستشعار عن بعد ، استخراج الطرق، الشبكات العصبية متعددة الطبقات ، محولة Hough ، التصنيف ، خريطة Kohonen.

## Résumé :

Ce mémoire s'intéresse au problème de l'extraction du réseau routier à partir des images satellitaires. Nous avons présenté une méthodologie automatique, c'est la méthode d'extraction des routes par réseaux de neurones multi couches (MLP). Le réseau obtenu est proche des données de référence et présente peu de fausses détections et d'omissions, étant donné le caractère complètement automatique de la méthode. Ce résultat peut être encore amélioré en considérant d'autres caractéristiques de routes telles que leurs formes (forme linéique). Nous avons alors appliqué la Transformée de Hough à l'image obtenue par (MLP) dans le but d'éliminer encore les zones qui ne représentent pas le réseau routier. En effet, dans l'image obtenue on a détecté presque toutes les routes et on a diminué encore les fausses détections.

Enfin, nous avons utilisé une autre approche pour la détection des routes, c'est l'approche de classification, car l'interprétation de l'image obtenue par classification est plus facile que celle de l'image satellitaire originale. On a utilisé la classification non supervisée par la carte de Kohonen.

**Mots clés :** image de télédétection, extraction des routes, réseaux de neurones multi couches, Transformée de Hough, Classification, carte de Kohonen.

## Abstract:

We focused this brief on the issue of road extraction from satellite images. We have presented an automatic method, the method of extraction of roads by multilayer neural networks (MLP). The network obtained is close to baseline, and this bit of false detections and omissions, given the fully automatic method. The latter result can be further improved by considering other characteristics such as roads forms (linear form). Then we applied the Hough transform to the image obtained by (MLP), designed to eliminate even the areas that do not represent road network. Indeed, in the resulting image was detected almost all roads, and it decreased further false detections. Finally, we used another approach for the detection of roads, is the classification approach, because the interpretation of the image obtained by classification is easier than the original satellite image. It was unsupervised classification used by the Kohonen map.

**Keywords:** remote sensing image, extraction of roads, multilayer neural networks, Hough transforms, Classification, Kohonen map.

# *DÉDICACES*

*A MA FAMILLE*

*A MES PROCHES*

*A MES AMIS(ES)*

## *Remerciements*

*Le travail présenté dans ce mémoire a été mené au laboratoire signal et communications du département d'Electronique de l'Ecole Nationale Polytechnique.*

*Je tiens vivement à remercier Madame L. HAMAMI, Professeur à l'ENP, pour avoir proposé un sujet aussi intéressant, pour la confiance et l'intérêt qu'elle m'a témoigné tout au long de la réalisation de ce travail.*

*Je remercie également Madame F. BENKOUIDER, pour sa disponibilité, son aide, et pour tout ce qu'elle a mis en œuvre afin que ce travail se déroule dans de bonnes conditions.*

*Je remercie les membres du jury, qui m'ont fait l'honneur de participer au jugement de ce travail.*

*Je tiens également à remercier l'ensemble des enseignants d'électronique.*

# *Sommaire*

<i>Introduction générale</i> .....	1
 <i>Chapitre I - Analyse et traitement d'images satellitaires</i>	
I.1. Les images satellitaires .....	4
I.1.1. Types de satellites .....	4
I.1.2. L'imagerie satellitaire .....	6
I.1.2.1 La résolution spatiale ou géométrique .....	6
I.1.2.2 La résolution spectrale .....	7
I.1.2.3 La résolution radiométrique et la résolution numérique .....	7
I.2. Les prétraitements .....	8
I.2.1 Les corrections radiométriques .....	8
I.2.2 Les corrections géométriques .....	8
I.2.3 Les corrections atmosphériques .....	8
I.3. Les canaux bruts .....	9
I.4. La composition colorée .....	11
I.5. Les filtre .....	12
I.6. L'analyse en composante principale .....	14
I.7. Conclusion .....	17
 <i>Chapitre II - Etat de l'art sur l'extraction des routes</i>	
II.1. Introduction .....	18
II.2. Variabilité des réseaux routiers .....	18
II.2.1 Variabilité intrinsèque et extrinsèque des routes .....	18
II.2.2 Variabilité typologique par rapport à l'environnement .....	19

II.2.3 Variabilité due au mode d'acquisition .....	19
II.2.3.1 L'angle de prise de vue .....	19
II.2.3.2 La résolution spatiale et spectrale du capteur .....	20
II.3. Méthodes semi-automatiques .....	20
II.3.1 Méthodes de suivi et filtrage .....	20
II.3.2 Contours Actifs .....	21
II.3.3 Programmation dynamique .....	21
II.4. Méthodes automatiques .....	22
II.4.1 Méthodes de segmentation et de classification .....	22
II.4.2 Morphologie mathématique .....	22
II.4.3 Détecteurs de lignes .....	23
II.4.4 Champs de Markov sur graphe .....	23
II.4.5 Méthodes fondées sur l'analyse multi-échelle (multi-résolution) .....	23
II.4.6 Systèmes d'interprétation .....	24
II.4.7 Apport de données cartographiques .....	24
II.5. Conclusion .....	24
 <b><i>Chapitre III - Détection des réseaux linéiques par réseaux de neurones</i></b>	
III.1. Introduction .....	26
III.2. Modèle biologique .....	26
III.2.1. Définition du neurone .....	26
III.2.2. Structure du neurone biologique .....	26
III.3. Modèle artificiel .....	28
III.3.1. Définition du réseau de neurones artificiel .....	28

III.3.2. Fonctionnement du réseau de neurones.....	28
III.3.3. Neurone formel .....	29
III.3.4. Fonctions d'activation .....	30
III.4. Apprentissage .....	31
III.4.1. Apprentissage non supervisé .....	32
III.4.2. Apprentissage supervisé .....	32
III.4.3. Apprentissage semi-supervisé .....	32
III.5. Protocole d'apprentissage des réseaux de neurones .....	32
III.5.1. Procédure d'apprentissage .....	32
III.5.2. Organigramme de la procédure d'apprentissage .....	33
III.5.3. Procédure de validation croisée .....	34
III.6. Architecture et classification des réseaux de neurones .....	34
III.6.1. Les réseaux non bouclés "FEED-FORWARD" .....	34
III.6.1.1. Les Perceptrons .....	34
III.6.1.2. Les réseaux à fonction radiale .....	36
III.6.2. Les réseaux bouclés "FEED-BACK" .....	36
III.6.2.1. Les cartes auto-organisatrices de Kohonen .....	36
III.6.2.2. Les réseaux de Hopfield .....	37
III.6.2.3. Les ARTs .....	37
III.7. Domaines d'applications des réseaux de neurones .....	38
III.8. Propriétés et limites des réseaux de neurones .....	39
III.8.1. Propriétés .....	39
III.8.2. Limites .....	39

III.9. Réseau multicouche .....	40
III.9.1. Structure et fonctionnement .....	40
III.9.2 Apprentissage par rétropropagation du gradient .....	41
III.10 Application des réseaux de neurones pour la détection des routes .....	41
III.10.1 Architecture du réseau .....	41
III.10.2 Résultats et interprétation .....	45
III.11 Conclusion .....	47

#### ***Chapitre IV - La Transformée de Hough***

IV.1 Introduction .....	48
IV.2 Transformation de Hough .....	48
IV.2.1 Principe .....	48
IV.2.2 Taille du buffer et représentation polaire .....	50
IV.2.3 Propriétés de la THS .....	52
IV.2.4 Implémentation classique de la THS .....	53
IV.3 Résultats et interprétation .....	54
IV.4 Conclusion .....	58

#### ***Chapitre V - Classification d'images satellitaires***

V.1. Introduction .....	59
V.2. Les catégories de classifications .....	59
V.3. Carte auto-organisatrice de Kohonen (SOM) .....	60
V.3.1. Principe des cartes auto-organisatrices de Kohonen .....	61
V.3.2. Classification et cartes auto-organisatrices .....	61
V.3.3. Architecture neuronale des cartes auto-organisatrices .....	62

V.3.4. Méthodologie de la technique .....	62
V.3.5 Différentes organisations topologiques .....	64
V.3.6. Procédé de calcul des S.O.M .....	65
V.3.7 Organigramme du programme SOM .....	67
V.4. Application du K-SOM comme outils de classification de l'image satellitaire .....	68
V.4.1 Définition des Paramètres .....	68
V.4.2 Architecture du réseau .....	68
V.4.3 Tests réalisés .....	69
V.5. Conclusion .....	70
<b><i>Conclusion générale</i></b> .....	72
<b><i>Annexe 1</i></b> .....	73
<b><i>Annexe 2</i></b> .....	78
<b><i>Références bibliographiques</i></b> .....	89

## *Liste des figures*

### *Chapitre I :*

Figure I.1 : Les satellites en orbite géostationnaire et les satellites en orbite polaire .....	5
Figure I.2 : Les satellites en orbite polaire .....	5
Figure I.3 : Effet de l'atmosphère sur le signal lumineux .....	9
Figure I.4.a : Canal vert .....	10
Figure I.4.b: Canal rouge .....	10
Figure I.4.c: Canal proche infrarouge .....	10
Figure I.5 : Rehaussement de contrastes .....	11
Figure I.6 : Codage des trois canaux d'une image SPOT .....	12
Figure I.7 : Image filtrée (passe-bas) .....	13
Figure I.8 : Image filtrée (passe-haut) .....	13
Figure I.9 : observation de la terre à partir d'un point de vue élevé .....	14
Figure I.10: scattérogramme, images de télédétection (partie inf), image colorée (partie sup)....	14
Figure I.11 : ACP d'une image de télédétection .....	15

### *Chapitre II :*

Figure II.1 : Effet de l'angle de prise de vue : (a) schéma d'acquisition d'image, (b) effet d'une prise de vue oblique (Image Ikonos) .....	19
--	----

### *Chapitre III :*

Figure III.1 : Structure du neurone biologique .....	27
Figure III.2 : Réseau de neurones artificiel .....	28

Figure III.3 : Dualité entre un neurone artificiel et biologique .....	29
Figure III.4 : Schéma du neurone formel (Mac Culloch et Pitts) .....	29
Figure III.5 : Représentation mathématique du neurone formel .....	30
Figure III.6 : Organigramme de la procédure d'apprentissage .....	33
Figure III.7 : Réseau de neurones non bouclé .....	34
Figure III.8: Perceptron monocouche .....	35
Figure III.9 : Perceptron multicouche (à trois couches) .....	35
Figure III.10: Réseau de neurones bouclé .....	36
Figure III.11 : Carte auto-organisatrice de Kohonen .....	37
Figure III.12 : Schéma récapitulatif des différentes classes des réseaux de neurones .....	38
Figure III.13: Perceptron multicouche .....	40
Figure III.14 : image satellite multi bande .....	42
Figure III.15 : réseau routier extrait .....	42
Figure III.16: Image originale (à gauche), Image des ACP (à droite) .....	44
Figure III.17: Les deux premières composantes principales .....	44
Figure III.18: Réseau routier extrait par MLP .....	45
Figure III.19: détection des zones qui ne représentent pas des routes .....	46
<b>Chapitre IV :</b>	
Figure IV.1 : Représentation de la droite (D) .....	48
Figure IV.2 : La transformation de Hough du point A .....	49
Figure IV.3 : transformation de Hough du point B .....	49
Figure IV.4 : Point $P_0(x_0, y_0)$ et la sinusoïde $S(\theta_0, \rho_0)$ correspondante .....	51
Figure IV.5 : Point $Q_0(\theta_0, \rho_0)$ associé à la droite $D(\theta_0, \rho_0)$ .....	52
Figure IV.6 : Image prétraitée.....	54

Figure IV.7 : THS de l'image .....	55
Figure IV.8 : Image originale (à gauche), Image des contours (à droite) .....	55
Figure IV.9 : Les 2 courbes les plus probables extraites .....	55
Figure IV.10 : Les 5 courbes les plus probables extraites .....	56
Figure IV.11 : Image originale (à gauche), Image zoomée (à droite) .....	56
Figure IV.12 : Les 7 courbes les plus probables extraites .....	56
Figure IV.13 : THS sur l'image obtenue par MLP (au centre) et les THS des sous images.....	57
Figure IV.14 : résultat final de la détection des routes .....	58
<b>Chapitre V :</b>	
Figure V.1 : Connexion des données d'entrée au nœud neuronal .....	62
Figure V.2 : Forme Topologique Unidimensionnelle .....	64
Figure V.3 : Forme Topologique Bidimensionnelle .....	65
Figure V.4 : Organigramme Du Programme SOM Appliqué .....	67
Figure V.5 : Évolution du pas d'apprentissage en fonction de t .....	69
Figure V.6 Image obtenue par classification .....	70
Figure V.7 Emplacements des points de données et les vecteurs de poids .....	71
<b>Annexe 1 :</b>	
Figure 1: Adaptation des poids .....	74
<b>Annexe 2 :</b>	
Figure 1 : Fenêtre de démarrage .....	78
Figure 2 : Choix de La phase d'apprentissage .....	79
Figure 3 : Boite de dialogue pour choisir l'image à utiliser .....	79
Figure 4 : chargement de l'image .....	80

Figure 5 : Calcul et affichage des ACP de l'image utilisée .....	80
Figure 6 : Boîte de dialogue pour choisir l'image de référence .....	81
Figure 7 : Chargement de l'image des routes de référence .....	81
Figure 8 : fenêtre de progression de l'apprentissage du MLP .....	82
Figure 9 : Extraction des routes par MLP .....	82
Figure 10: La THS de l'image obtenue par MLP .....	83
Figure 11 : fenêtre de progression de l'apprentissage du K-SOM .....	83
Figure12 : Emplacements des points de données et les vecteurs de poids .....	84
Figure 13 : Classification de l'image utilisée .....	84
Figure 14 : Choix de La phase d'apprentissage .....	85
Figure 15 : Boite de dialogue pour choisir l'image .....	85
Figure 16 : chargement de l'image .....	86
Figure 17 : Calcul et affichage des ACP de l'image .....	86
Figure 18 : Extraction des routes par MLP .....	87
Figure 19 : Classification de l'image .....	87

## *Liste des Tableaux*

Tableau III.2 : Matrice de corrélation (Image originale) .....	43
Tableau III.3 : Matrice de corrélation (Image des ACP) .....	43
Tableau III.4 : Valeurs propres .....	43
Tableau III.5 : MSE pour différents nombres de neurones dans la couche cachée .....	46
Tableau V.1 : MSE pour différents nombres d'itérations .....	70

# Introduction Générale

*Avant l'âge de raison l'enfant ne reçoit pas des idées, mais seulement des images. (J.-J. ROUSSEAU.)*



### *Contexte*

L'image de télédétection satellitaire est considérée comme étant le modèle visuel le plus fidèle et le plus riche de l'espace. Elle est la source d'informations abondantes et précises sur l'occupation du sol et sur les phénomènes qui se déroulent à la surface de la planète ou sur d'autres astres.

L'activité de recherche consacrée à la télédétection occupe une position de première importance depuis de nombreuses années. La mise sur orbite de plusieurs satellites d'observation civils (ERS2, Radarsat, Météosat, etc) ou militaires (Helios), aussi bien dans le domaine optique que dans celui des hyperfréquences, est venue soutenir ce choix. Le lancement de la série des satellites à haute résolution assure à ce domaine une activité soutenue pour de nombreuses applications.

Le besoin en cartes fiables et actualisées est grandissant, le flux des images de télédétection est croissant, les systèmes d'information géographique (SIG) ont connu une évolution extrêmement rapide au cours de la dernière décennie. Ainsi, il devient nécessaire de développer des outils automatiques performants d'analyse de toutes ces données, et particulièrement les images.

L'analyse d'images satellitaires est une discipline en plein essor portée par un souci mondial d'aménagement des surfaces urbaines ou rurales et de protection de l'environnement. Elle constitue une technique d'observation moins coûteuse que des enquêtes de terrain et peut être utilisée aussi bien par des régions technologiquement développées comme l'aménagement des villes, la conversion des zones rurales, la surveillance et la protection contre les catastrophes naturelles ou d'origine humaine, que par des régions défavorisées comme la mise en œuvre des ressources naturelles, l'analyse et la surveillance de la croissance urbaine, la désertification, etc.

De nombreuses méthodes ont été développées pour répondre aux différents problèmes d'interprétation et d'extraction de l'information à partir d'images de satellites et aériennes, notamment dans le cas particulier de la détection et l'extraction d'objets surfaciques ou linéiques tel que les réseaux routiers.



### ***Objectif***

Dans ce mémoire, nous considérons le problème cité ci-dessus qui concerne l'extraction des routes à partir de l'imagerie satellitaire. Ce travail est organisé suivant l'objectif principal: la mise en œuvre d'une méthode complètement automatique permettant de répondre à la problématique de l'extraction des routes.

Nous nous situons dans la catégorie d'approche, qui se propose de fournir une extraction complètement automatique du réseau routier. Ainsi, l'intervention d'un opérateur extérieur pour contrôler, corriger ou initialiser l'extraction, est réduite, et la plupart des informations nécessaires au processus d'extraction sont obtenues directement de l'image. Dans le cas des méthodes semi-automatiques, l'initialisation s'effectue de telle sorte que les points de départ soient proches de la route à extraire, donc, les fausses détections sont exclues et c'est la précision de détection que l'on cherche à améliorer. Dans notre cas, automatique, la qualité de l'extraction se mesure alors en termes d'exhaustivité et de limitation des fausses détections et non en termes de précision.

### ***Organisation du manuscrit***

Ce document est organisé de la façon suivante :

- En introduction, nous présentons notre objectif et nous situons notre contribution par rapport aux méthodes déjà développées.
  
- Dans le premier chapitre, nous abordons le thème de l'analyse d'une séquence d'images satellitaires ainsi que les différentes étapes de traitement telles que la détection, le filtrage ... etc.
  
- Dans le chapitre 2 nous décrivons en premier lieu, une description des caractéristiques principales des réseaux routiers et de leur variabilité dans les images satellitaires et aériennes, puis, nous exposons un état de l'art sur l'extraction de réseaux routiers.
  
- Le chapitre 3 concerne l'extraction automatique des routes. Dans ce chapitre, nous présentons la méthodologie développée en décrivant en détails l'extraction des routes par



réseau de neurones multicouche (MLP), et à la fin nous évaluons ses performances en utilisant des données de référence.

- Dans le chapitre 4 et pour améliorer le résultat obtenu par (MLP) nous considérons d'autres caractéristiques de la route telle que la forme des routes (forme linéique) ; nous appliquons alors la Transformée de Hough (méthode classique de détection de lignes droites) à l'image obtenue par réseau de neurones (MLP), dans le but d'éliminer d'avantage les zones qui ne représentent pas des routes.
- Enfin, dans le chapitre 5 nous décrivons une autre approche pour la détection des routes, c'est l'approche de classification, qui consiste à extraire le réseau routier à partir de l'image classifiée, car l'interprétation de l'image obtenue par classification est plus facile que celle de l'image satellitaire originale.

Pour conclure, les avantages et les inconvénients des approches proposées seront précisés.

# *Chapitre I*

## *Analyse et traitement d'images satellites*



## ***I.1. Les images satellitaires :***

### ***I.1.1. Types de satellites :***

Aujourd'hui, quelques milliers de satellites gravitent autour de la Terre. Cette famille de satellites se divise en trois catégories génériques : télécommunications, observation de la planète et aide à la navigation.

Les satellites de télécommunications sont des satellites commerciaux, qui relient les lignes téléphoniques et les chaînes de télévision (ils sont les plus nombreux).

Les satellites d'observation de la Terre sont ceux qui prennent des images de celle-ci pour être utilisées dans plusieurs domaines comme par exemple en météorologie où les images informent quotidiennement des températures et de la répartition des masses nuageuses.

Les satellites d'aide à la navigation ont pour rôle de fournir automatiquement une position exacte aux avions, bateaux, mobiles (autobus, taxis, voitures, randonneurs) équipés d'un récepteur en tout point du monde. [1]

Les principaux satellites voués à l'observation de la terre sont assez nombreux (une vingtaine environ) mais il existe des leaders qui fournissent la plupart des images utilisées aujourd'hui tels que IKONOS, JERS, LANDSAT, SPOT, etc.

Les satellites d'observation terrestre disposent chacun d'un ou de plusieurs capteurs spécialisés dans un domaine précis du spectre électromagnétique appelés « radiomètres ». Les domaines les plus utilisés sont:

- le domaine du visible de 400 à 700 nm pour les observations directes (google earth...)
- le domaine infrarouge de 700 à 1 mm pour capter les différences de températures et observer le déplacement des nuages.

On distingue deux types de satellites selon leur orbite :

**✚ Satellites géostationnaires :** Comme leur nom l'indique, ils semblent être immobiles depuis la Terre. Leur orbite est calculée de telle manière à ce que leur période de rotation coïncide avec celle de la Terre. Ces satellites se situent environ à 36000Km de la surface de la Terre sur le même plan que l'équateur. Ils permettent d'avoir une vision globale de la planète (un satellite de ce type peut observer 42% de la surface totale du globe). Dans cette catégorie, on peut citer les satellites Météosat lancés par l'Agence Spatiale Européenne (ESA).

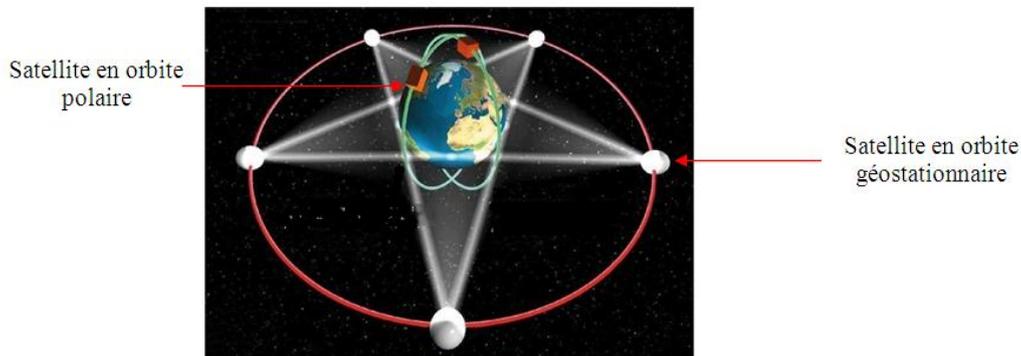


Figure I.1 : Les satellites en orbite géostationnaire et les satellites en orbite polaire

✚ **Satellites d'orbite basse** : Ils se situent à une altitude beaucoup moins élevée (600 à 1500Km). Ils ont donc une période de révolution beaucoup plus faible suivant la 3ème loi de Kepler ( $a^3/T^2 = C$  où  $a$  est le demi-grand axe de l'orbite,  $T$  est la période de révolution et  $C$  une constante qui dépend notamment de la masse de la planète). En imagerie, on utilise des satellites dits polaires. Leur caractéristique est que le plan de leur orbite est perpendiculaire à l'équateur et leur altitude de 850Km. Ce type de satellite possède une période de révolution de 100 minutes ce qui lui permet de balayer toute la surface terrestre en 12H. [2]

Son énorme avantage est qu'il survolera toujours un point de la Terre à la même heure chaque jour.

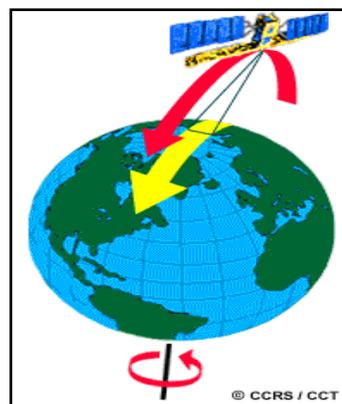


Figure I.2 : Les satellites en orbite polaire



### ***1.1.2. L'imagerie satellitaire :***

L'imagerie satellitaire présente, comparée à d'autres moyens tels que la photographie aérienne, les relevés de terrain ou les cartes géographiques, des avantages certains :

- Elle est obtenue de manière numérique et ne nécessite donc pas de conversion de données.
- Elle est universelle : elle ne connaît pas de frontière géographique ou politique.
- Elle est aussi synthétique, flexible, précise et actuelle (renouvellement de l'information, automatique ou à la demande).

Selon l'application que l'on souhaite obtenir, on dispose de plusieurs types d'images :

- ***L'imagerie panchromatique*** : Elle est acquise par un capteur numérique qui mesure la réflectance dans une large bande électromagnétique. Les données panchromatiques sont représentées sous forme d'images en noir et blanc. Elle sert principalement à obtenir des informations de type " géométrique " comme la forme, la dimension et la surface.
- ***L'imagerie multi-bande*** : Elle est acquise par un capteur numérique qui mesure la réflectance dans de nombreuses bandes spectrales (typiquement, une dizaine). Ces multiples valeurs de réflectance se combinent pour créer des images couleur.
- ***L'imagerie radar*** : Le radar imageur, permet l'élaboration d'images de jour comme de nuit même à travers les nuages. Le radar est sensible aux propriétés diélectriques des milieux telles que la teneur en eau, et à leur rugosité. Il est également sensible aux structures géométriques à l'échelle de la longueur d'onde. [1]

Une image satellitaire est caractérisée par sa résolution spatiale, sa résolution spectrale, sa résolution radiométrique et sa résolution numérique. Dans un système de mesurage, on appelle résolution l'aptitude d'un instrument à discriminer deux objets ou deux valeurs proches l'une de l'autre. Dans le cas d'une image, il est aussi employé pour désigner l'aptitude à rendre distincts deux points voisins.

#### ***1.1.2.1 La résolution spatiale ou géométrique :***

La résolution spatiale ou géométrique est la distance la plus petite permettant de discriminer deux objets voisins. Cette résolution s'exprime en mètres ou en kilomètres et mesure le côté



d'un pixel. Ainsi une résolution grossière (plusieurs centaines de mètres voire plusieurs kilomètres) ne permettra pas de distinguer des objets spatiaux de petites tailles comme des bâtiments ou de petites parcelles agricoles. Une résolution plus fine (quelques dizaines de mètres à un mètre) autorise par exemple l'identification des réseaux de communication les plus fins (routes, chemins...). Ainsi, pour une image à 20 mètres de résolution, chaque pixel représente une superficie correspondant à 20 x 20 mètres au sol.

Une résolution spatiale élevée autorise la distinction d'objet spatial de petite taille.

Mais plus la résolution augmente, plus la taille informatique (exprimée en octets) des images est importante, ce qui ralentit les traitements et nécessite un matériel très performant. De plus, l'augmentation de la résolution spatiale va de pair avec la diminution de la taille des scènes (portion de surface terrestre observée et enregistrée).

La course à la plus petite résolution possible n'a donc pas de sens. Le choix d'une résolution doit se faire en fonction d'une problématique de recherche précise. De plus, plus la résolution spatiale augmente, plus le prix de l'image est élevé. Il faut donc adapter les choix des images à sa problématique de recherche et non l'inverse.

### ***1.1.2.2 La résolution spectrale :***

La résolution spectrale décrit la capacité d'un capteur à utiliser de petites fenêtres de longueur d'onde. L'eau ou la végétation par exemple ne nécessitent pas une résolution spectrale fine, à l'inverse des roches et minéraux qui réclament une résolution beaucoup plus grande. Si la résolution spectrale est trop grossière, il ne sera alors plus possible de bien différencier les différents minéraux.

Les images panchromatiques sont thématiquement moins intéressantes que les images multispectrales. Effectivement, il est préférable d'avoir trois bandes spectrales : vert, bleu et rouge, plutôt qu'une seule bande spectrale visible. Il existe également des capteurs très perfectionnés capables de détecter des centaines de bandes spectrales, on les appelle capteurs hyperspectraux.

### ***1.1.2.3 La résolution radiométrique et la résolution numérique :***

La résolution radiométrique d'un système de télédétection décrit sa capacité de reconnaître de petites différences dans le spectre électromagnétique. Plus la résolution radiométrique d'un capteur est fine, plus le capteur est sensible à de petites différences dans l'intensité de l'énergie reçue.



Plus la résolution numérique est grande, plus la qualité thématique des images est bonne. Il est évident qu'une image de faible résolution radiométrique ne peut avoir une forte résolution numérique significative.

## ***1.2. Les prétraitements :***

Les prétraitements sont des opérations effectuées sur les images en amont de tout traitement de façon à les corriger ou les améliorer géométriquement et thématiquement. Il existe trois types de prétraitements : les corrections radiométriques, les corrections géométriques et les corrections atmosphériques.

### ***1.2.1 Les corrections radiométriques :***

Les corrections radiométriques sont appliquées sur les images pour réaffecter à chaque pixel une valeur radiométrique la plus proche possible de celle mesurée sur le terrain.

Les variations enregistrées peuvent être dues au vieillissement des capteurs, à leur dérèglement ou aux défauts lors de la conception des instruments.

### ***1.2.2 Les corrections géométriques :***

Les corrections géométriques sont appliquées sur les images pour réduire les déformations géométriques intervenues lors de l'enregistrement de la scène telles que les distorsions causées par l'environnement (courbure de la terre, variation d'altitude au sol, réfraction atmosphérique...), les distorsions dues aux erreurs des systèmes de mesure et les distorsions provenant des mouvements de la plate-forme (roulis, tangage, lacet...).

### ***1.2.3 Les corrections atmosphériques :***

Le signal lumineux mesuré par les capteurs d'un satellite traverse deux fois l'atmosphère terrestre (Figure I.3), la première fois lors du trajet soleil-cible et la seconde lors du trajet cible-capteurs. A chacun de ces deux traversées, le rayonnement électromagnétique va subir des transformations dues aux propriétés physico-chimiques des deux composants majeurs de l'atmosphère terrestre qui sont les gaz (oxygène, ozone, vapeur d'eau...) et les aérosols (poussières, pollens...).

La contribution de l'atmosphère dans la valeur radiométrique d'un pixel peut ainsi dépasser 50% dans certaines longueurs d'ondes, comme le bleu par exemple. Il est donc parfois nécessaire d'appliquer des corrections atmosphériques sur les images en fonction des caractéristiques thématiques de la zone d'étude et de la méthode de traitement d'image employée.



Il est impossible d'obtenir la contribution réelle de l'atmosphère sans posséder les données décrivant les conditions météorologiques lors de l'enregistrement de l'image. C'est donc par simulation que les corrections atmosphériques vont être effectuées, pour obtenir au final une évaluation la plus précise possible de l'état de l'atmosphère lors de la prise de vue.

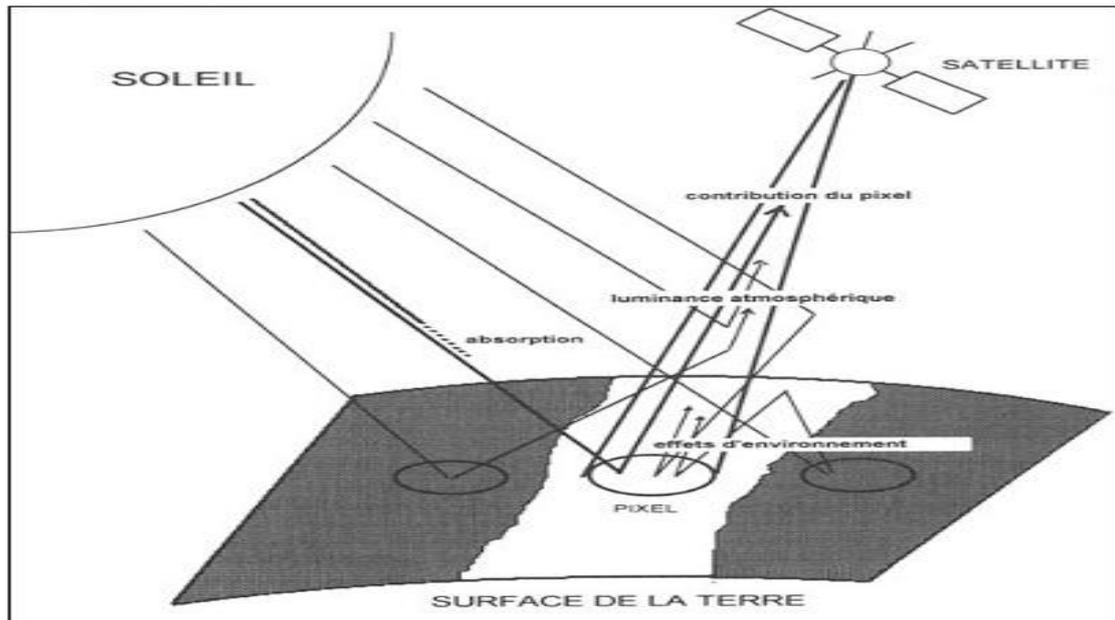


Figure I.3 : Effet de l'atmosphère sur le signal lumineux

Nous représentons sur la figure I.3 l'effet de l'atmosphère sur le signal lumineux mesuré par les capteurs d'un satellite

Une fois la contribution de l'atmosphère connue, il suffit de la soustraire à la valeur radiométrique des pixels. [1]

### ***1.3. Les canaux bruts :***

Les canaux bruts sont quasiment illisibles si les contrastes ne sont pas ajustés.

Effectivement, il est très rare d'avoir des valeurs extrêmement fortes quelle que soit la bande spectrale. Dans le visible, par exemple, la quasi totalité des valeurs se trouve entre 0 et 80, sur une échelle qui va de 0 à 255. Or, dans la nature, peu de surfaces ou d'objets ont un albédo supérieur à 50%, hormis peut être les glaciers, les surfaces enneigées et autres banquises, ou encore les sols nus très minéralisés. Les canaux bruts sont donc très sombres, parfois quasiment noirs.

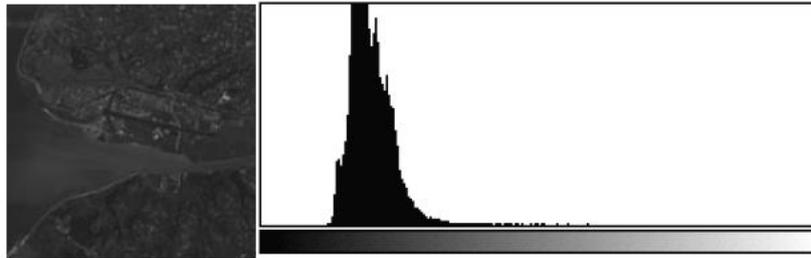


Figure I.4.a : Canal vert

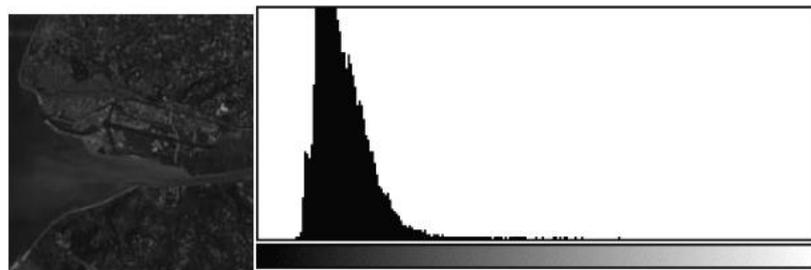


Figure I.4.b: Canal rouge

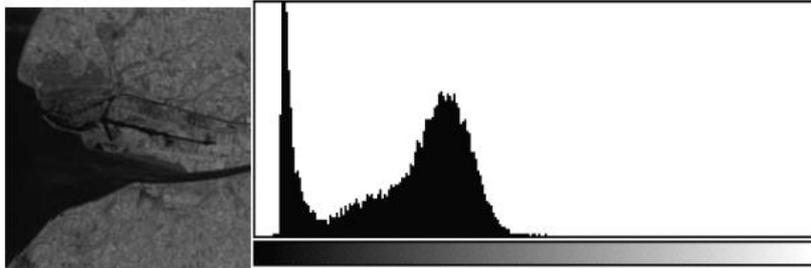


Figure I.4.c: Canal proche infrarouge

Les images de la figure I.4 sont des extraits des trois canaux bruts d'une image SPOT.

Ces canaux sont dans l'ordre : le vert, le rouge et le proche infrarouge.

L'histogramme représente le nombre de pixels par valeur radiométrique. L'axe des abscisses est la valeur radiométrique (0 à 255) et l'axe des ordonnées le nombre de pixels.

Le dégradé de gris montre la couleur correspondant à chacune des valeurs spectrales. Seul le canal proche infrarouge est relativement clair, les deux autres sont inexploitable.

Les canaux bruts sont non seulement très sombres, mais ils sont de surcroît très peu contrastés. C'est pourquoi le premier traitement effectué est un rehaussement de contraste.



L'histogramme est étiré de façon à ce que la mesure la plus forte soit codée à 255 et la plus faible à 0. Les images, comme on peut le voir dans la figure I.5, sont alors plus claires et surtout beaucoup plus contrastées. [1]

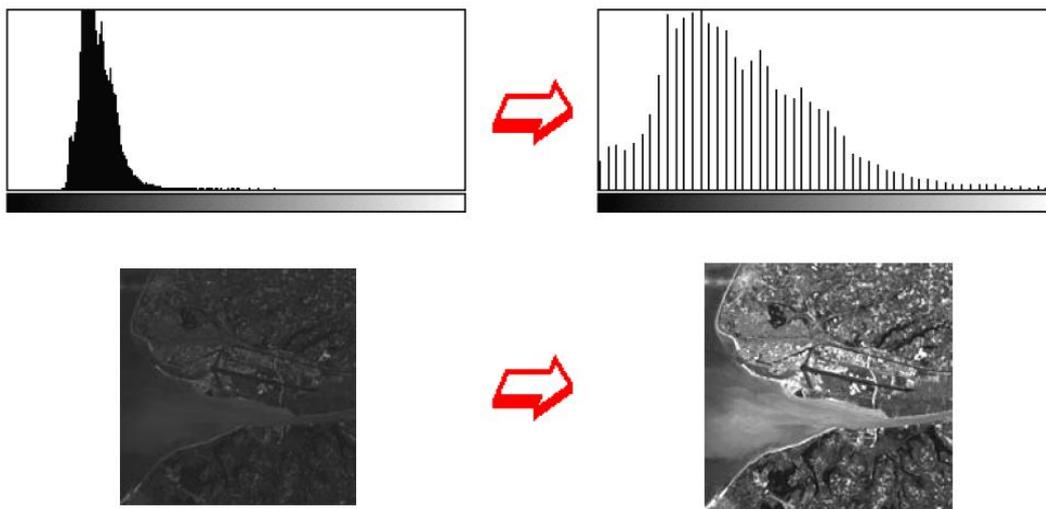


Figure I.5 : Rehaussement de contraste

#### ***1.4. La composition colorée :***

Toutes les couleurs sont formées par l'addition de la lumière des trois couleurs primaires additives : rouge, vert et bleu (procédé utilisé pour afficher de la lumière sur un écran par exemple). En partant du noir, c'est à dire l'absence de lumière, on va ajouter des quantités variables de lumières rouge, verte et bleue pour afficher une couleur précise.

Chaque couleur est donc une combinaison singulière des trois couleurs primaires, la couleur blanche étant l'addition des trois couleurs primaires à intensité maximale. Ce procédé est appelé synthèse trichromique additive.

La synthèse trichromique soustractive est le procédé inverse. Toutes les couleurs sont créées par soustraction de la lumière des trois couleurs soustractives : cyan, magenta et jaune (procédé utilisé pour la peinture, l'imprimerie ou la photographie). En partant du blanc, c'est à dire la lumière la plus intense, on va soustraire des quantités variables de lumières rouge, verte et bleue pour afficher une couleur précise.



Aux trois couleurs fondamentales sont donc associés trois canaux d'une image satellitaire. L'illustration de la figure I.6 montre le codage des trois canaux d'une image SPOT:

Le canal XS3 (proche infrarouge) est codé en rouge, le canal XS2 (rouge) est codé en vert et le canal XS1 (vert) est codé en bleu. Le résultat est appelé composition colorée.

En codant les trois canaux d'une image SPOT avec les trois couleurs fondamentales, on peut ainsi élaborer 27 compositions colorées différentes ( $3^3 = 3 \times 3 \times 3 = 27$ ).

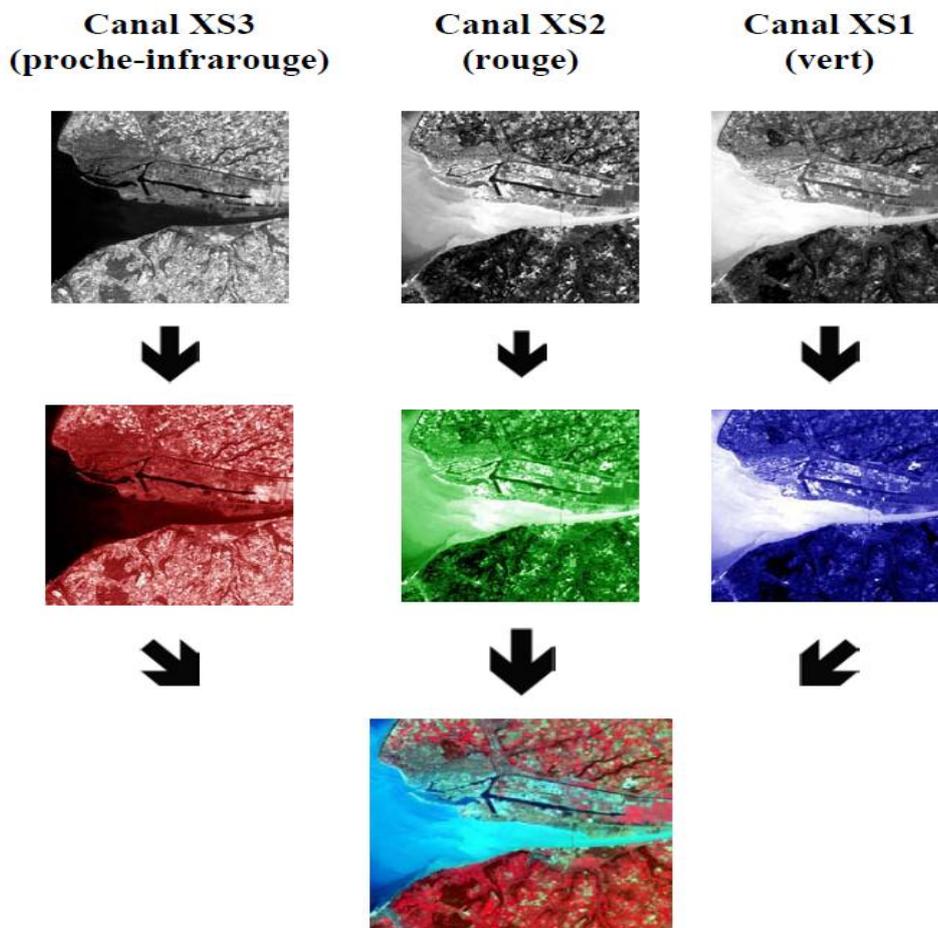


Figure I.6 : Codage des trois canaux d'une image SPOT

### ***1.5. Les filtres :***

Les filtres sont des analyses univariées c'est à dire des traitements ne portant que sur un seul canal. Ainsi, des filtres sont appliqués sur les images afin d'homogénéiser les images ou au contraire d'en rehausser les contrastes. Par exemple, le filtre passe-bas (Figure I.7) ou lissage



consiste à éliminer les pixels "aberrants" qui forment le bruit de l'image ou les irrégularités locales. Ce traitement génère un effet de flou plus ou moins accentué en fonction des réglages. Il est, par exemple, possible de lisser une image en affectant à chaque pixel la valeur radiométrique moyenne de la somme de ses voisins. Dans l'exemple suivant le voisinage est composé des pixels voisins immédiats, mais il est possible d'accentuer le lissage en définissant un rayon de deux pixels (donc une grille de 5\*5 pixels) ou encore de trois pixels (donc une grille de 7\*7 pixels).

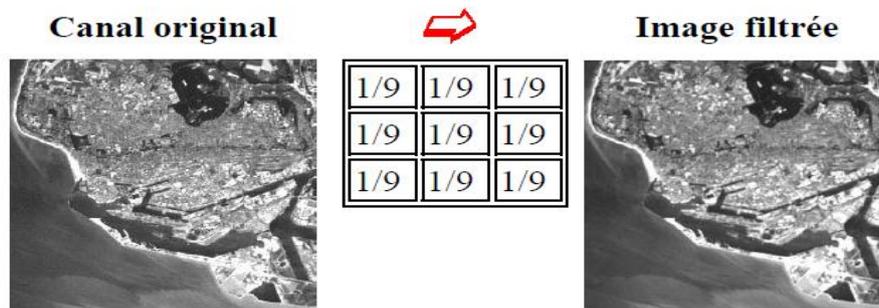


Figure I.7 : Image filtrée (Filtre passe-bas)

Le filtre fréquemment utilisé pour produire l'effet inverse, c'est à dire non plus homogénéiser l'image mais au contraire rehausser les détails, est appelé passe-haut (Figure I.8). Il est notamment utilisé pour accentuer les arêtes et ainsi mieux identifier les objets linéaires (réseau hydrographique et routier, failles géologiques...).

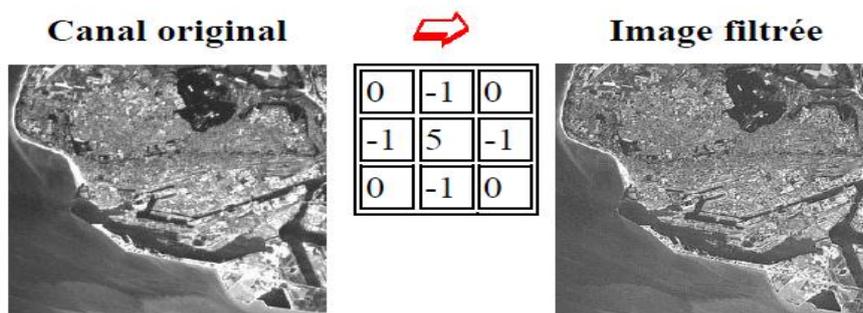


Figure I.8 : Image filtrée (Filtre passe-haut)



## I.6. L'analyse en composantes principales :

### I.6.1 Introduction :

Quand on observe la terre à partir d'un point de vue élevé, on est surpris de constater que la gamme de couleurs des paysages naturels est assez peu variée, et qu'il existe peu de couleurs très vives. Vues de l'espace, les zones continentales tempérées apparaissent vertes, et les vastes zones désertiques ont des couleurs où le gris, le beige et le brun dominant. (Voir Figure I.9)



Figure I.9 : observation de la terre à partir d'un point de vue élevé.

Traduite en termes d'image numérique, cette observation explique que les histogrammes des images de la surface de la terre ne sont guère contrastés, et que les composantes spectrales ne varient pas de manière indépendante.

La figure I.10 représente l'histogramme à 2 dimensions (scattérogramme) des composantes rouges et vertes d'une image numérique, on remarque de suite que les images de télédétection (partie inférieure) ne comportent qu'un nombre restreint de couleurs, en comparaison avec une image très colorée.

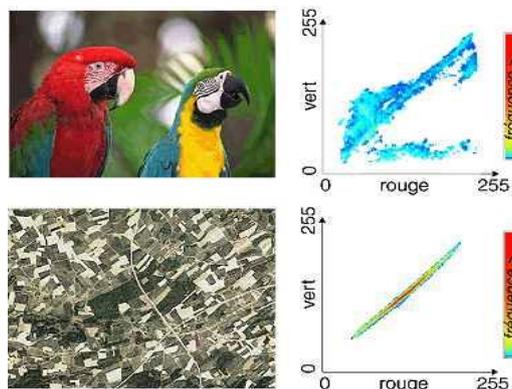


Figure I.10: scattérogramme, images de télédétection (partie inférieure), image très colorée (partie supérieure).



L'allure du scattérogramme de l'image de télédétection (tous les vecteurs spectraux sont regroupés le long de la diagonale) est l'indice d'une forte corrélation entre canaux: lorsqu'un pixel a une valeur élevée dans le rouge, il y a de fortes chances pour qu'il ait également une valeur élevée dans le vert. [3]

Cela signifie aussi que les différentes composantes spectrales n'ajoutent pas beaucoup d'information à l'image, qui pourrait pratiquement s'interpréter comme une image noir et blanc.

Le but de l'analyse en composantes principales est de réorganiser les données de telle manière qu'elles ne soient plus corrélées (c.-à-d. qu'elles deviennent indépendantes).

Une particularité intéressante de cette transformation, lorsqu'elle est appliquée à des données comprenant plusieurs bandes spectrales, est qu'elle concentre la quasi-totalité de l'information dans les deux ou trois premières composantes, les autres composantes ne renfermant généralement que du bruit. En ne conservant que les composantes les plus significatives pour l'analyse, il est possible de réduire considérablement le volume de données à traiter. En effet les axes principaux ainsi calculés permettent à la fois une réduction des données et une interprétation plus facile du domaine traité, car les nouvelles dimensions sont souvent très significatives.

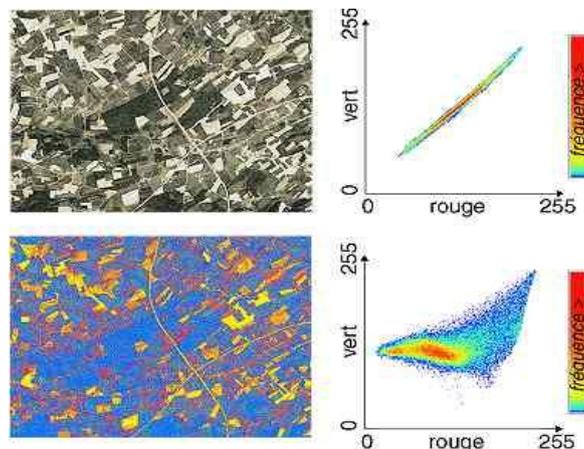


Figure I.11 : ACP d'une image de télédétection.

La figure I.11 représente l'ACP d'une image de télédétection.



Les différentes opérations de l'ACP sont :

- le calcul des matrices de covariance et de corrélation de l'image multi spectrale, ce sont des matrices carrées dont la dimension est égale au nombre de canaux spectraux de l'image.
- le calcul des valeurs et vecteurs propres de la matrice de covariance.
- le calcul des composantes principales de l'image multi spectrale, le nombre des composantes est au plus égal à celui des canaux spectraux. [4]

Pour ces calculs, on pose les variables suivantes  $X_1, X_2, X_3$  représentant les  $N$  pixels en niveaux de gris des trois images obtenues par les capteurs spectraux. Les moyennes de ces variables sont calculées suivant  $i=1, 2, 3$ .

$$\overline{X_i} = \frac{1}{N} \cdot \sum_{j=1}^N X_i^j \quad (1)$$

Ces moyennes servent à calculer les covariances et les corrélations entre deux variables. La covariance entre les variables  $X_i$  et  $X_j$  où  $i, j=1, 2, 3$  est :

$$Cov(X_i, X_j) = \frac{1}{N} \cdot \sum_{k=1}^N [(X_i^k - \overline{X_i}) \cdot (X_j^k - \overline{X_j})] \quad (2)$$

La matrice de covariance  $Q$  constituée des covariances entre les variables où  $i, j=1, 2, 3$  :

$$Q = \{Cov(X_i, X_j)\} \quad (3)$$

D'où la variance de chaque variable est donnée par l'expression suivante :

$$\sigma_i^2 = \frac{1}{N} \cdot \sum_{j=1}^N [(X_i^j - \overline{X_i})^2] \text{ Avec } i=1, 2, 3 \quad (4)$$

On obtient les écarts type de chaque variable en prenant la racine carrée des variances. Ces écarts type interviennent dans le calcul des corrélations entre deux variables. La corrélation entre les variables  $X_i$  et  $X_j$  où  $i, j=1, 2, 3$  est :



$$Cor(X_i, X_j) = \frac{1}{N} \cdot \sum_{k=1}^N \left[ \frac{(X_i^k - \overline{X_i}) \cdot (X_j^k - \overline{X_j})}{\sigma_i \cdot \sigma_j} \right] \quad (5)$$

La matrice de corrélation S constituée des corrélations entre les variables où  $i, j=1, 2, 3$  :

$$S = \{Cor(X_i, X_j)\} \quad (6)$$

Le polynôme caractéristique de la matrice de covariance nous permet le calcul des valeurs propres. Les valeurs propres sont les valeurs qui vérifient :

$$\det(Q - \lambda \cdot Id) = 0 \quad (7)$$

Dans notre cas, on obtient trois valeurs propres associées à trois vecteurs propres  $V_1, V_2, V_3$  tels que :

$$Q \times V_i = \lambda_i \cdot V_i \text{ Avec } i=1, 2, 3 \quad (8)$$

A partir de ces vecteurs propres, on peut obtenir les composantes principales  $Y_i$  avec  $i=1, \dots, I$  et  $I \leq 3$ ; on a: [4]

$$Y_i^k = \sum_{j=1}^N [V_k^j \cdot (X_i^j - \overline{X_i})] \quad (9)$$

### 1.7. Conclusion :

L'analyse d'images satellitaires à différentes résolutions consiste à reconnaître d'une façon quasi-automatique les objets pertinents, présents dans la scène, à les dissocier de leur environnement et à les classer pour une exploitation ultérieure. Cette analyse nécessite une chaîne de traitement allant des prétraitements tels que les corrections radiométriques, géométriques et atmosphériques jusqu'à la classification supervisée ou non supervisée, en passant par les méthodes de filtrage et de l'analyse en composantes principales. [1]

# *Chapitre II*

## ***Etat de l'art sur l'extraction des routes***



### ***II.1. Introduction :***

La détection de routes dans les images satellitaires et aériennes a fait l'objet de nombreuses recherches depuis plus de quinze ans. En effet, l'importance croissante des Systèmes d'Information Géographique (SIG) et surtout le besoin d'acquérir des données de façon automatique ont motivé ces études. L'extraction de réseaux routiers est une tâche délicate puisque les routes dans les images peuvent apparaître de manière très différente.

Ce chapitre propose un état de l'art sur l'extraction de réseaux routiers à partir d'images satellitaires et aériennes. Après une description des caractéristiques principales des réseaux routiers et de leur variabilité, nous présenterons les deux catégories de méthodes proposées dans la littérature : les méthodes semi-automatiques par opposition aux méthodes complètement automatiques. [5]

### ***II.2. Variabilité des réseaux routiers :***

Un réseau routier se définit généralement pour un système de reconnaissance de formes comme un ensemble de lignes qui s'entrecroisent plus ou moins régulièrement. Ainsi, avant de procéder à une extraction de ce type de réseau, il convient de citer les principales caractéristiques des routes et dans quelle mesure ces caractéristiques varient d'un type d'image à un autre.

#### ***II.2.1 Variabilité intrinsèque et extrinsèque des routes :***

Les caractéristiques géométriques et radiométriques d'une route sont très variables quel que soit son environnement. En effet, la radiométrie d'une route est étroitement liée à son type de revêtement. Dans une même image, on peut trouver des portions de route sombres et d'autres qui apparaissent claires.

Quant aux caractéristiques géométriques des routes (largeur, courbure, longueur...), on observe également une forte variabilité selon le type de routes que l'on cherche à extraire (autoroutes, routes, rues ou chemins) et leur contexte (rural, péri-urbain, urbain ou forestier). Egalement, les propriétés des réseaux routiers varient d'un pays à un autre. A titre d'exemple, les réseaux routiers présents dans les villes américaines diffèrent fortement de ceux présents dans les villes européennes et nord africaines. En effet, les réseaux américains sont caractérisés par une structure de grille, une particularité qui peut être exploitée de façon efficace lors de l'extraction. [5]



### II.2.2 Variabilité typologique par rapport à l'environnement :

La variabilité typologique de la route est aussi très dépendante du contexte, leur aspect est lié à l'environnement dans lequel elle se situe. On peut ainsi trouver des courbures faibles et variant peu pour des routes nationales ou pour des autoroutes, alors qu'une route en montagne pourra comporter de nombreux virages à fortes courbures. Le contexte urbain présente aussi des particularités comparées aux milieux péri-urbains ou ruraux. On peut se rendre compte que la difficulté d'extraction des routes augmente lorsque l'environnement s'urbanise.

Également, dans l'analyse du milieu urbain, l'infrastructure de la ville étudiée joue également un grand rôle. Ainsi, les récentes zones de la ville caractérisées par des structures urbaines espacées et par un réseau quadrangulaire sont relativement faciles à cartographier. En revanche, la partie ancienne de la ville aux trames serrées et aux réseaux routiers tortueux nécessite une résolution spatiale plus fine.

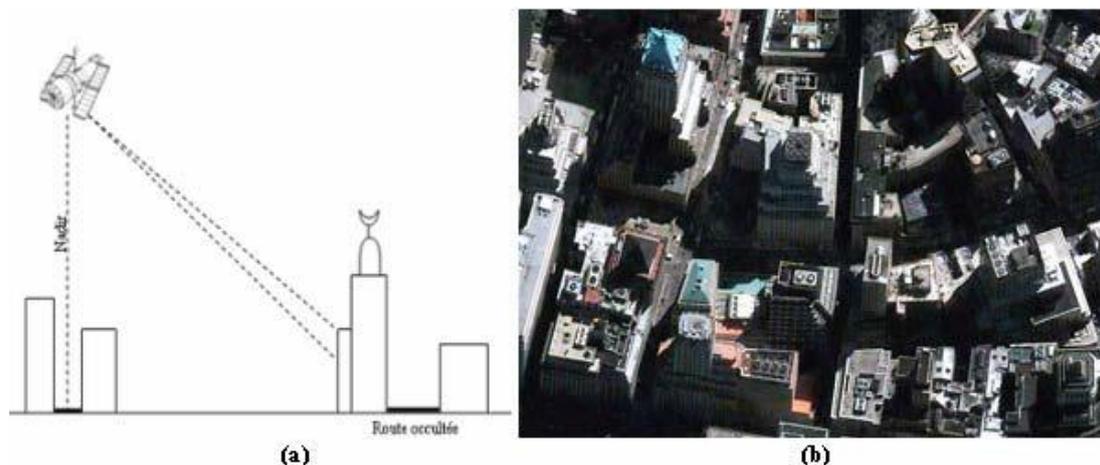
Cette dernière remarque nous amène alors à parler des conditions d'acquisition, qui jouent aussi un rôle important pour l'apparence du réseau routier dans l'image.

### II.2.3 Variabilité due au mode d'acquisition :

L'apparence des routes dans l'image est directement liée au mode d'acquisition.

#### II.2.3.1 L'angle de prise de vue :

En milieu urbain, la route étant très souvent située entre deux rangées de bâtiments. Une prise de vue qui n'est pas au nadir peut produire des occlusions partielles, voire totales. Elle induit aussi des distorsions géométriques.



**Figure II.1 :** Effet de l'angle de prise de vue : (a) schéma d'acquisition d'image, (b) effet d'une prise de vue oblique (Image Ikonos)



### ***II.2.3.2 La résolution spatiale et spectrale du capteur :***

L'apparence des routes dans l'image est directement liée à la résolution spatiale du capteur satellite ou aéroportée. Ainsi, le réseau routier, qui apparaît comme un réseau linéique de un à trois pixels de large sur les images de faible résolution, apparaît comme un réseau surfacique à haute résolution. Cette variabilité d'apparence induit une variabilité dans les méthodes proposées.

La nature spectrale des données est également importante lors de la détection des routes sur les images. Par exemple, le bruit présent dans une image radar diffère fortement de celui présent dans les images optiques. De plus, sur certaines bandes spectrales des capteurs optiques, l'apparence des routes diffère d'une bande à une autre, elles peuvent se présenter par rapport à leur environnement comme des lignes brillantes ou bien comme des lignes sombres selon la résolution spectrale de la bande. Sur une image radar les routes sont sombres (sauf en montagne).

Notre cadre d'étude est le milieu urbain et les images utilisées sont de moyenne résolution spatiale. Ainsi, nous cherchons à extraire les routes de l'image en tant qu'éléments linéaires. Différents travaux menés dans ce contexte concernent le milieu rural, péri-urbain ou urbain. Le classement des différentes techniques d'extraction des routes utilisées est très difficile, étant donné la variété des propositions existantes dans la littérature. Cependant, nous pouvons les classer en deux principaux groupes : les méthodes semi-automatiques et les méthodes automatiques. [5]

## ***II.3. Méthodes semi-automatiques :***

### ***II.3.1 Méthodes de suivi et filtrage :***

Les méthodes de suivi consistent à «suivre» la route en comparant ses caractéristiques avec un modèle théorique (souvent par corrélation des profils radiométriques de la route le long de son axe principal). Leur rôle est principalement d'assister en quasi temps-réel l'opérateur humain lors de la saisie du réseau routier. Les algorithmes de suivi nécessitent des points d'amorce. Ces amorces peuvent soit être sélectionnés manuellement ou automatiquement. De cette manière, alors que dans [17] les points d'amorce sont définis par l'utilisateur, dans [18] un algorithme automatique est présenté pour choisir ces points.



Considérant les routes comme des surfaces sans discontinuité apparente plutôt que des lignes, [19] [20] proposent d'effectuer un suivi reposant sur un critère d'homogénéité directionnelle. Ce critère est fondé sur une hypothèse de variance minimale dans la direction longitudinale de la route. A partir d'un point et d'une orientation d'origine, l'algorithme recherche le chemin optimal parmi un arbre de chemin possible. Chaque chemin est composé de segments de droite choisis localement suivant le critère d'homogénéité.

Parmi les travaux utilisant des techniques de filtrage, [21] présente une méthode d'extraction de routes qui se repose sur la détection des contours et l'utilisation du filtre de Kalman pour la génération du contour actif. [22] proposent aussi d'utiliser un filtrage récursif de Kalman pour estimer la position de la route à chaque instant. L'algorithme est initialisé par un segment fourni par un opérateur à partir duquel un profil caractéristique de la route est défini. La prédiction d'un nouveau segment se fait à partir des estimations de la direction et la courbure de la route. Une mise en correspondance entre le profil caractéristique de la route et le profil courant permet d'évaluer la distance entre les deux profils. La position du nouveau segment est mise à jour selon cette distance. En incorporant les positions obtenues antérieurement, les autres paramètres tels que la direction et la courbure de la route peuvent être également mis à jour.

### ***II.3.2 Contours Actifs :***

Les modèles des contours déformables (contours actifs) se basent sur une approche analysée dans [23]. En effet, c'est une méthode précise et efficace. Les contours actifs doivent néanmoins être initialisés près de l'objet à détecter. Le contour évolue ensuite selon un algorithme de minimisation d'énergie qui favorise en général une faible courbure et un fort gradient au niveau du contour. Cette méthode est largement utilisée pour la détection et la localisation des frontières afin de faciliter le problème de segmentation d'images, et aussi pour l'extraction des structures telles que les routes et les bâtiments à partir des images en niveaux de gris.

### ***II.3.3 Programmation dynamique :***

De nombreux travaux d'extraction de réseaux linéiques reposent sur une optimisation par programmation dynamique, technique efficace permettant d'optimiser une fonction de coût dans un graphe, ce qui revient à la recherche d'un chemin optimal.



## **II.4. Méthodes automatiques :**

### **II.4.1 Méthodes de segmentation et de classification :**

Ces méthodes utilisent la segmentation et la classification supervisée ou non supervisée d'une image afin d'extraire le réseau routier. Souvent, le processus de segmentation est basé sur l'analyse de texture qui peut offrir une image binaire assez propre pour servir comme entrée d'un processus de vectorisation postérieure. En liaison avec le sujet d'extraction des routes, [24] présente un système de segmentation d'une image infrarouge utilisant la technique de classification par maximum de vraisemblance.

[25] conçoivent l'extraction de routes sur les images de télédétection comme un problème de classification, où les pixels doivent être classés en "route" et "non route", ils proposent d'utiliser un réseau de neurones multicouches. Les entrées du réseau sont des fenêtres de taille  $n \times n$  centrées sur chaque pixel  $p$  de l'image. Le réseau calcule par lui-même des valeurs discriminantes dans les nœuds de l'unique couche cachée à partir des  $n^2$  entrées, puis classifie le pixel  $p$  à partir des nœuds cachés dans le nœud de sortie. Ce réseau est entraîné par un algorithme de type rétro-propagation à partir de quelques échantillons de type "route" et "non route" sélectionnés manuellement par l'utilisateur, à partir d'une image provenant d'un certain type de capteur. Le réseau entraîné est ensuite utilisé pour l'extraction de routes dans d'autres images provenant du même capteur.

### **II.4.2 Morphologie mathématique :**

La Morphologie mathématique est une approche de la théorie des ensembles développée par [26] et [27]. Basée sur un cadre mathématique formel, elle fournit une approche pour le traitement des images numériques, qui se base sur la forme géométrique. Elle utilise un ensemble d'opérations telles que l'union, l'intersection et la complémentation, ainsi que la dilatation, l'érosion, l'amincissement et d'autres opérations dérivées.

Dans [28] une approche sur l'extraction automatique du réseau routier à partir des images à haute résolution est proposée. Cette méthode classe premièrement l'image pour trouver les régions du réseau routier, puis des ouvertures morphologiques triviales sont utilisées successivement pour filtrer le bruit des objets qui ont des caractéristiques spectrales semblables à celles des surfaces de routes.



### ***II.4.3 Détecteurs de lignes :***

Un des opérateurs les plus connus pour la détection de ligne est l'opérateur DUDA, proposé par [29]. Il utilise quatre masques à convoluer avec l'image correspondant à des structures linéaires de trois pixels de long et les pixels voisins associés. Des scores sont calculés pour chaque masque mesurant conjointement l'homogénéité du niveau de gris le long de la structure et le contraste avec le voisinage. Le score maximal est assigné au pixel central du masque. Cet opérateur est sensible à l'orientation de la route, à la discrétisation, aux changements brutaux d'orientation ainsi qu'au faible contraste par rapport à l'environnement. De plus, cet opérateur détecte les profils de type contour simple et engendre donc un nombre significatif de fausses détections.

### ***II.4.4 Champs de Markov sur graphe :***

Les champs de Markov sur graphe sont un outil puissant pour la détection automatique de réseau. Le réseau est modélisé dans sa totalité par un graphe où chacun des arcs correspond à une section du réseau. On entre dans le cadre d'une approche objet par opposition aux approches par champ de Markov usuelles, dans lesquelles le champ est défini sur une grille de pixels. Tout en bénéficiant des bonnes propriétés des approches par champ de Markov, comme la robustesse au bruit, cette modélisation permet d'introduire des contraintes géométriques fortes sur le réseau. L'inconvénient de cette méthode est qu'elle nécessite une phase d'initialisation exhaustive : un arc non détecté dans la phase d'initialisation ne pourra pas l'être par la suite.

### ***II.4.5 Méthodes fondées sur l'analyse multi-échelle (multi-résolution) :***

L'extraction des routes au moyen d'analyse multi-échelle offre un contrôle sur la largeur des routes dans l'image. Ainsi, c'est un outil efficace pour la détection de route étroite à partir des images à haute résolution (grande échelle) et également pour l'identification des autoroutes dans les images de basse résolution (petite échelle). Certains auteurs proposent d'utiliser les techniques multi-échelles, par exemple en fusionnant le résultat de l'extraction de l'axe central à basse résolution, moins sensible au bruit géométrique, avec le résultat de l'extraction des bordures de route à haute résolution fournissant une meilleure localisation du réseau [30] [31].



#### **II.4.6 Systèmes d'interprétation :**

Les systèmes d'interprétation (nommés aussi systèmes d'exploitation et de valorisation d'images) ne cherchent pas directement à extraire les objets d'une image, mais plutôt à interpréter la scène qu'elle contient. Ils se basent sur le principe de pensée d'un interprète d'images face à une recherche d'objets particuliers dans une image. Ainsi, l'extraction du réseau est réalisée via une interprétation de la scène observée.

#### **II.4.7 Apport de données cartographiques :**

L'intégration des données complémentaires a pour but de parvenir à une extraction fiable des objets d'intérêt. Les informations peuvent être symboliques: une base de données cartographique ou une carte topographique de la scène par exemple.

[32] propose une méthode de mise en correspondance locale des cartes avec des images SPOT, en utilisant un champ markovien sur un graphe. La carte est utilisée pour initialiser le graphe. Ensuite, le graphe est modifié en minimisant une fonction d'énergie. L'énergie comporte des termes d'attache aux données relatifs à la carte et l'image, et un terme de structure imposant des contraintes topologiques.

[33] propose un système utilisant des données externes fournies par une base de données cartographiques pour l'extraction des routes à partir d'images aériennes. La base de données est utilisée pour générer des hypothèses de route. L'interprétation de la scène consiste alors à extraire dans l'image les routes correspondant à différentes hypothèses, c'est-à-dire à trouver la position exacte de la route dans l'image. Pour chaque hypothèse, l'extraction de route consiste à choisir l'algorithme le plus adapté et à régler ses paramètres en fonction des caractéristiques intrinsèques et contextuelles de l'hypothèse de route.

### **II.5. Conclusion :**

Au cours de ce chapitre, la grande variabilité des types de réseaux routiers a été présentée. Plusieurs raisons ont été avancées, notamment les caractéristiques géométriques et radiométriques des routes, le changement de résolution spatiale et spectrale des capteurs et le contexte de prise de l'image. Cette grande variabilité a conduit à un grand nombre de méthodes d'extraction, utilisant un large champ des techniques de reconnaissances de formes et de traitement d'images. Ainsi, ce chapitre présente un état des travaux récents menés sur



l'extraction des routes. Nous avons décrit principalement deux catégories de méthodes. La première regroupe les méthodes dites semi-automatiques, pour lesquelles un opérateur humain ou bien, plus rarement, un algorithme de détection a préalablement marqué des points de départ et d'arrivée pour les routes. La seconde regroupe les méthodes automatiques, qui n'utilisent aucune connaissance a priori sur la localisation des routes. [5]

# *Chapitre III*

## ***Détection des réseaux linéiques par réseaux de neurones***



### ***III.1. Introduction***

Le cerveau humain est capable de s'adapter, d'apprendre et de décider, et c'est sur ce fait que des chercheurs se sont intéressés à comprendre son principe de fonctionnement et de pouvoir l'appliquer au domaine de l'informatique. C'est ainsi que dans les années cinquante on formalise le neurone en un modèle mathématique à partir du modèle biologique. [6]

Nous allons présenter dans ce chapitre une étude générale sur les réseaux de neurones, le passage du modèle biologique au modèle artificiel, le protocole d'apprentissage ainsi que les différentes classes et architectures de ces réseaux.

### ***III.2. Modèle biologique.***

#### ***III.2.1. Définition du neurone***

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. [6]

#### ***III.2.2. Structure du neurone biologique***

Le système nerveux compte plus de 1000 milliards de neurones interconnectés. Bien que les neurones ne soient pas tous identiques, leur forme et certaines caractéristiques permettent de les répartir en quelques grandes classes. [6]

La figure III.1 présente le schéma d'un neurone biologique:

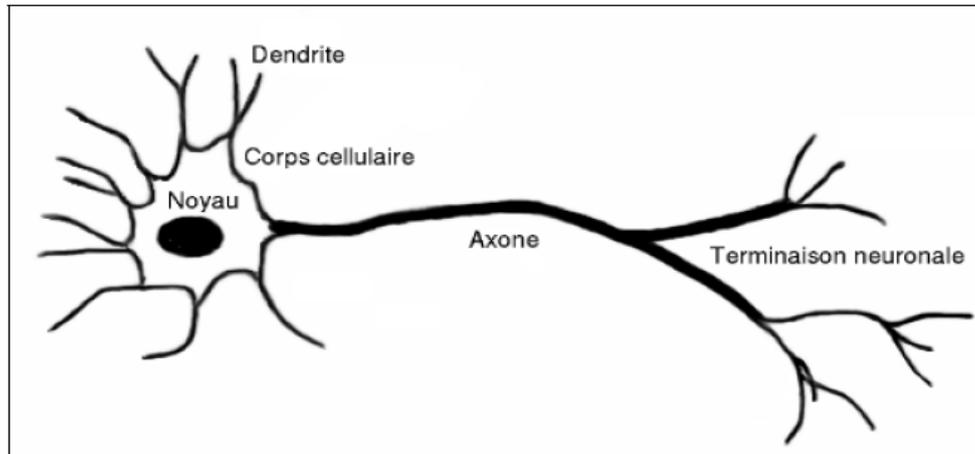


Figure III.1 : Structure du neurone biologique.

On peut le décomposer en trois régions principales:

**Le corps cellulaire** : Il contient le noyau du neurone ainsi que la machine biochimique nécessaire à la synthèse des enzymes. Ce corps cellulaire de forme sphérique ou pyramidale contient aussi les autres molécules essentielles à la vie de la cellule. 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 le long de l'axone que les signaux partent du neurone. Contrairement aux dendrites qui se ramifient autour du neurone, l'axone est plus long et se ramifie à son extrémité où il se connecte aux dendrites des autres neurones. Sa taille peut varier entre quelques millimètres à plusieurs mètres.

**Synapse** : Une synapse est une jonction entre deux neurones, et généralement entre l'axone d'un neurone et une dendrite d'un autre neurone (mais il existe aussi des synapses axo-axonales par exemple).



### III.3. Modèle artificiel

#### III.3.1. Définition du réseau de neurones artificiel (RNA)

Ce que l'on désigne habituellement par "**réseau de neurones**" (neural network), ou réseau neuromimétique est un réseau de neurones artificiel basé sur un modèle simplifié du neurone. Ce modèle permet certaines fonctions du cerveau, comme la mémorisation associative, l'apprentissage par l'exemple, le travail en parallèle, etc. Cependant le neurone formel ne possède pas toutes les capacités des neurones biologiques, comme le partage de synapses, l'activation membranaire ou la structuration prénatale des neurones, par conséquent les réseaux de neurones actuels sont loin d'avoir les possibilités du cerveau. [6]

#### III.3.2. Fonctionnement du réseau de neurone

La figure III.2 représente schématiquement un Réseau de neurones artificiel.

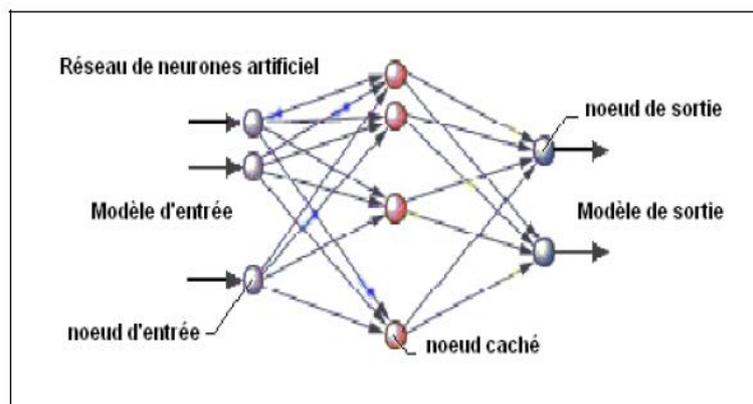


Figure III.2 : Réseau de neurones artificiel.

On pourrait penser que plus le nombre de neurones est important, plus le réseau est performant. Ceci n'est pas certain. Lorsque les concepteurs des réseaux essayent d'augmenter le nombre de neurones, ils sont limités par plusieurs contraintes, et en particulier par la durée d'apprentissage qui augmente avec le nombre de neurones. En effet, l'apprentissage s'effectue par l'exemple et il faut que le nombre de ceux-ci soit bien plus important que le nombre de connexions. Quand on sait qu'un système de 1000 neurones possède plus de 1000 000 connexions, on peut craindre le temps d'apprentissage. [6]

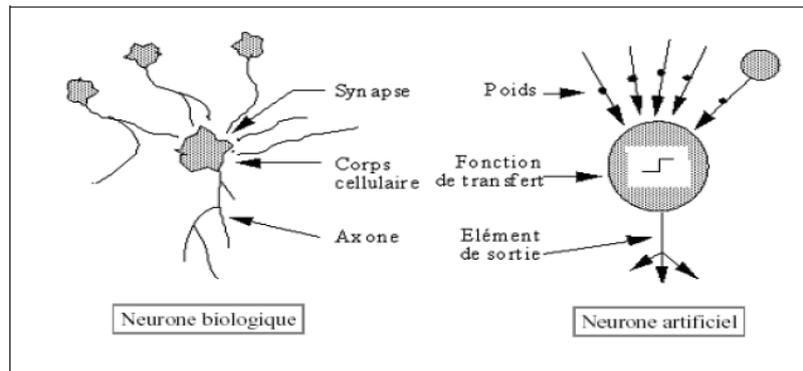


Figure III.3 : Dualité entre neurone artificiel et biologique.

La figure III.3 représente la dualité entre un neurone artificiel et un neurone biologique.

**III.3.3. Neurone formel :** Le premier neurone formel est apparu en 1943 (Mac Culloch et Pitts). La figure III.4 représente un schéma du modèle :

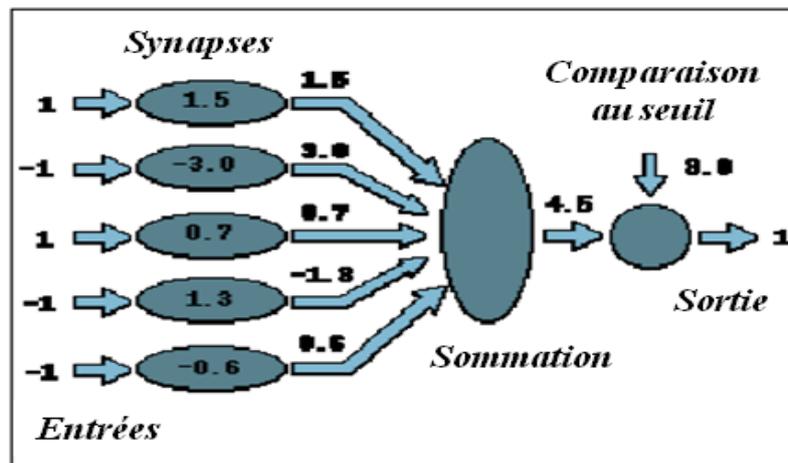


Figure III.4 : Schéma du neurone formel (Mac Culloch et Pitts).

Le neurone formel est donc une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation des entrées. Sachant qu'au niveau biologique, les synapses n'ont pas toutes la même « valeur » (les connexions entre les neurones étant plus ou moins fortes), les auteurs ont donc créé un algorithme qui pondère la somme de ses entrées par des poids synaptiques (coefficients de pondération). Les 1 et les -1 en entrée sont là pour figurer une synapse excitatrice ou inhibitrice

**Interprétation mathématique :** D'un point de vue mathématique, le neurone formel peut être représenté de la manière suivante:

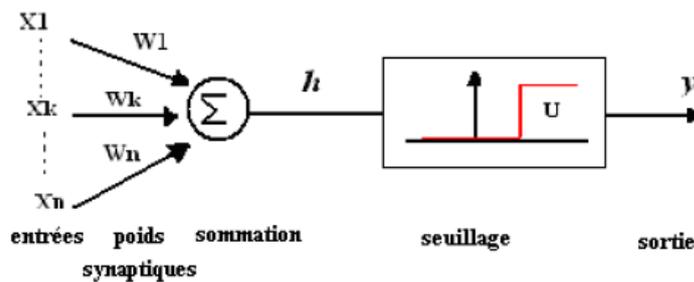


Figure III.5 : Représentation mathématique du neurone formel.

Pour un nombre compris entre  $j$  ( $=1$ ) et un nombre quelconque  $n$ , le neurone formel va calculer la somme de ses entrées ( $x_1, \dots, x_n$ ), pondérées par les poids synaptiques ( $w_1, \dots, w_n$ ), et la comparer à son seuil  $\theta$ . Si le résultat est supérieur au seuil, alors la valeur renvoyée est 1, sinon la valeur renvoyée est 0. D'où la formule:

$$y = f\left(\sum_{j=1}^n (w_j x_j - \theta)\right) \quad (1)$$

Où  $f$  est la fonction de seuil.

### III.3.4. Fonctions d'activation:

Chaque neurone calcule sa valeur de sortie à partir de la somme pondérée de ses entrées et de ses poids, il existe différentes fonctions d'activation permettant de calculer cette valeur. Dans sa première version, le neurone formel était donc implémenté avec une fonction à seuil, mais de nombreuses versions existent. Ainsi le neurone de McCulloch et Pitts a été généralisé de différentes manières, en choisissant d'autres fonctions d'activations, comme les fonctions linéaires ou les sigmoïdes par exemple.

Le tableau III.1 récapitule les différents types de fonctions d'activation les plus utilisées, avec leurs équations mathématiques et leurs dérivées. [14]



Catégorie	Type	Equation	Allure	Dérivée
Seuil	Binaire (fonction de Heaviside)	$f(x) = 1$ si $x > 0$ $f(x) = 0$ si $x \leq 0$		-
	Signe	$f(x) = 1$ si $x > 0$ $f(x) = -1$ si $x \leq 0$		-
Linéaire	Identité	$f(x) = x$		$f'(x) = 1$
	Saturé positif	$f(x, k) = 0$ si $x < 0$ $f(x, k) = 1$ si $x \geq 1/k$ $f(x, k) = k.x$ sinon		$f'(x, k) = 0$ si $x < 0$ $f'(x, k) = 0$ si $x \geq 1/k$ $f'(x, k) = k$ sinon
	Saturé symétrique	$f(x, k) = -1$ si $x < -1/k$ $f(x, k) = 1$ si $x \geq 1/k$ $f(x, k) = k.x$ sinon		$f'(x, k) = 0$ si $x < -1/k$ $f'(x, k) = 0$ si $x \geq 1/k$ $f'(x, k) = k$ sinon
Sigmoide	Positive (type logistique)	$f(x, k) = \frac{1}{1 + e^{-k.x}}$		$f'(x, k) = \frac{k}{2 + e^{-k.x} + e^{k.x}}$
	Symétrique (type tanh)	$f(x, k) = \frac{1}{1 + e^{-k.x}} - 1$		$f'(x, k) = \frac{2k}{2 + e^{-k.x} + e^{k.x}}$

Tableau III.1 : Tableau récapitulatif de différents types de fonctions d'activation.

### III.4. Apprentissage:

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux neuronaux. Elle ne concerne cependant pas tous les modèles, mais les plus utilisés.

#### **Définition:**

*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. [7]*

Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt.



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.

A l'issue de l'apprentissage, les poids sont fixés : c'est alors la phase d'utilisation.

#### **III.4.1. Apprentissage non supervisé:**

L'apprentissage non supervisé, dans lequel on se contente de présenter des formes sans indication sur leur identité. Une règle d'apprentissage est la règle de Hebb (voir annexe) qui revient à augmenter le poids de la connexion entre deux cellules si celles-ci sont simultanément actives et à le diminuer dans le cas contraire. Les cartes de Kohonen (qu'on verra par la suite), utilisent un apprentissage non supervisé compétitif, inspiré de la loi de Hebb. Un autre exemple de modèle à apprentissage non supervisé est le modèle ART.

#### **III.4.2. Apprentissage supervisé**

Dans l'apprentissage supervisé, on impose une réponse en sortie du réseau pour une forme d'entrée donnée (il dispose d'un comportement de référence vers lequel il tente de faire converger le réseau). Dans ce cas, il s'agit de calculer l'erreur commise par le réseau comme une fonction de la "distance" entre la sortie désirée et la sortie obtenue.

#### **III.4.3. Apprentissage semi-supervisé**

L'apprentissage semi-supervisé suppose qu'un comportement de référence précis n'est pas disponible, mais qu'en revanche il est possible d'obtenir des indications qualitatives (par exemple, correct/incorrect).

### **III.5. Protocole d'apprentissage des réseaux de neurones :**

#### **III.5.1. Procédure d'apprentissage :**

L'apprentissage d'un réseau se fait généralement dans le contexte d'une tâche ou d'un comportement à apprendre. Les informations à traiter sont codées sous la forme d'un vecteur appelé *patron d'entrée*, qui est communiqué aux neurones d'entrée du réseau. La réponse du réseau s'interprète à partir de la valeur d'activation de ses neurones de sorties, dont le vecteur s'appelle *patron de sortie*. Lors d'un apprentissage supervisé, on dispose aussi du comportement de référence que doit apprendre le réseau, exprimé sous la forme de *patron de référence*, ou *patron de sorties désirées*.

En général, l'apprentissage se fait sur une période relativement longue, durant laquelle les patrons d'entrée (et éventuellement de sorties désirées) peuvent être présentés au réseau un



grand nombre de fois chacun. Cet apprentissage comprend quatre étapes de calcul :

**1. Initialisation des poids synaptiques du réseau.** En général, les poids trouvés par le réseau à la fin de l'apprentissage dépendent en partie de l'ensemble des poids dont il disposait au départ, et la pratique courante est d'initialiser les poids du réseau à des (petites) valeurs aléatoires au début de l'apprentissage.

**2. Présentation du patron d'entrée et propagation d'activation.**

**3. Calcul de l'erreur.** Pour chaque neurone du réseau, une valeur *d'erreur* est calculée à partir de son activation et de celle des neurones qui lui sont reliés. Dans le cas d'un apprentissage supervisé, l'erreur tient aussi compte de la différence entre l'activation des neurones de sortie et du patron de référence.

**4. Calcul du vecteur de correction.** A partir des valeurs d'erreur, on détermine alors la correction à apporter aux poids synaptiques des connexions des neurones. La correction effective des poids peut se faire après chaque présentation de patron ; alternativement, les vecteurs de correction peuvent être accumulés pendant un certain temps avant d'être appliqués au réseau. Le nombre de patrons à présenter au réseau avant d'effectuer la correction s'appelle *fenêtre de mise à jour* (batch size).

Les étapes 2-3-4 sont répétées jusqu'à la fin de l'apprentissage. [6]

**III.5.2. Organigramme de la procédure d'apprentissage :**

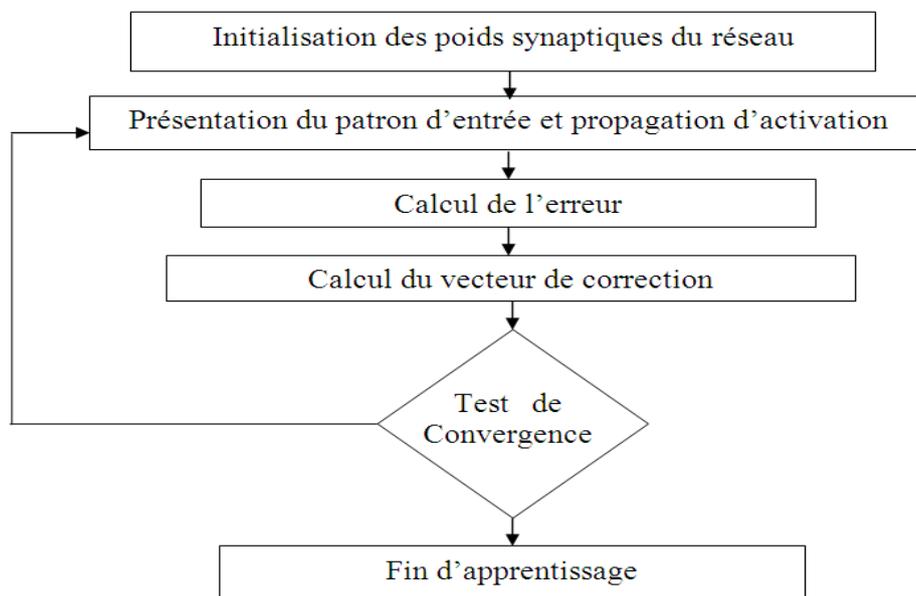


Figure III.6 : Organigramme de la procédure d'apprentissage.



### III.5.3. Procédure de validation croisée :

La validation croisée procède en trois étapes :

- *L'apprentissage même*, pendant lequel on évalue le comportement du réseau sur le corpus d'apprentissage.
- *Une étape de test*, où l'apprentissage est suspendu périodiquement, et où le corpus test est présenté au réseau. Les performances ainsi obtenues constituent une première indication des performances réelles du réseau.
- *Une étape de validation a posteriori*. Un troisième corpus (dit de validation) est présenté au réseau à la fin de l'apprentissage. Les performances du réseau sur celui-ci sont employées pour juger du succès ou de l'échec de l'apprentissage.

### III.6. Architecture et classification des réseaux de neurones :

On peut classer les RNA en deux grandes catégories: [6]

#### III.6.1. Les réseaux non bouclés "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 comme représenté sur la figure III.7.

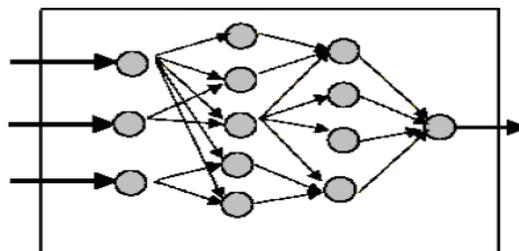


Figure III.7 : Réseau de neurones non bouclé.

#### III.6.1.1. Les Perceptrons

*a- Le Perceptron monocouche* : C'est historiquement le premier RNA, c'est le Perceptron de Rosenblatt. 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 (telles "ET" ou "OU"). Sa principale limite est qu'il ne peut résoudre que des problèmes linéairement



séparables. Il suit généralement un apprentissage supervisé selon la règle de correction de l'erreur (ou selon la règle de Hebb).

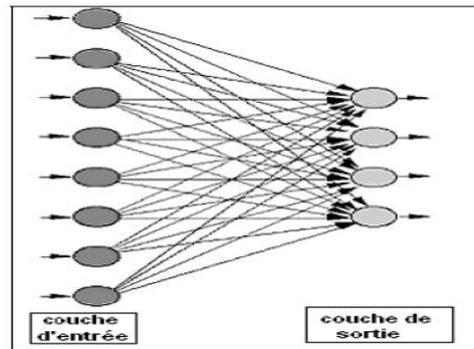


Figure III.8: Perceptron monocouche.

La figure III.8 représente schématiquement le perceptron monocouche.

**b- Le Perceptron multicouche (MLP) :** C'est une extension du précédent, avec une ou plusieurs couches cachées entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante et il n'y a pas de connexions entre les cellules d'une même couche. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes. 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 selon la règle de correction de l'erreur.

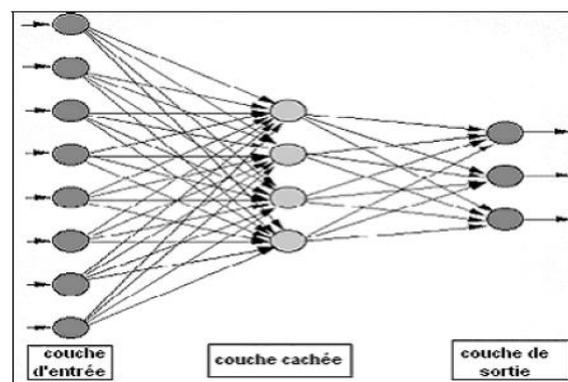


Figure III.9 : Perceptron multicouche (à trois couches).

La figure III.9 représente schématiquement le perceptron multicouche.



### III.6.1.2. Les réseaux à fonction radiale:

Ce sont les réseaux que l'on nomme aussi RBF ("Radial Basic Functions"). L'architecture est la même que pour les PMC cependant, les fonctions de base utilisées ici sont des fonctions Gaussiennes. Les RBF seront donc employés dans les mêmes types de problèmes que les PMC. L'apprentissage le plus utilisé pour les RBF est le mode hybride et les règles sont soit, la règle de correction de l'erreur soit, la règle d'apprentissage par compétition.

### III.6.2. Les réseaux bouclés "FEED-BACK" :

Appelés aussi "réseaux récurrents", ce sont des réseaux dans lesquels il y a retour en arrière de l'information (comme représenté en figure III.10).

Les réseaux bouclés possèdent un graphe cyclique tel que lorsqu'on se déplace dans le réseau suivant le sens des connexions, on peut toujours revenir vers notre point de départ. La sortie d'un neurone du réseau peut donc être fonction d'elle-même, la notion de retard est donc introduite.

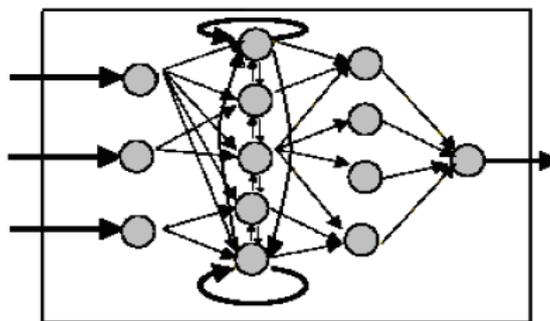


Figure III.10: Réseau de neurones bouclé

#### III.6.2.1. Les cartes auto-organisatrices de Kohonen

Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topologiquement, en fonction de patterns d'entrée. Le réseau forme ainsi une sorte de treillis dont chaque nœud est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins, vont être modifiés afin d'augmenter encore cette corrélation.

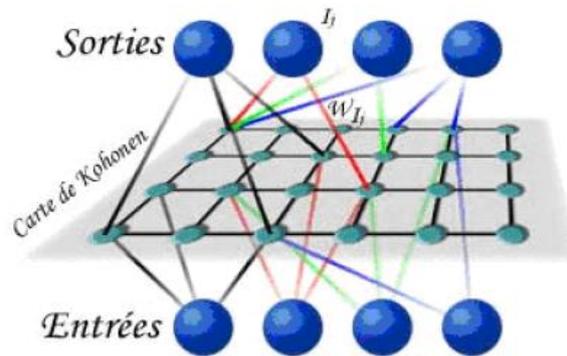


Figure III.11 : Carte auto-organisatrice de Kohonen.

La figure III.11 représente schématiquement la Carte auto-organisatrice de Kohonen.

### III.6.2.2. Les réseaux de Hopfield :

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune différenciation entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non-linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. L'application principale des réseaux de Hopfield est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation.

Le mode d'apprentissage utilisé ici est le mode non-supervisé.

### III.6.2.3. Les ARTs :

Les réseaux ARTs ("Adaptative Resonance Théory") sont des réseaux à apprentissage par 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 aillent rester stables. La seule possibilité, pour assurer la stabilité, serait que le coefficient d'apprentissage tende vers zéro, mais le réseau perdrait alors sa plasticité. Les ART ont été conçus spécifiquement pour contourner ce problème. Dans ce genre de réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche, d'un prototype déjà connu par le réseau. On parlera alors de résonance. A l'inverse, si l'entrée s'éloigne trop des prototypes existants, une nouvelle catégorie va alors se créer, avec pour prototype, l'entrée qui a engendré sa création. Il est à noter qu'il existe deux principaux types de réseaux ART : les ART-1 pour des entrées binaires et les ART-2 pour des entrées continues. Le mode d'apprentissage des ARTs peut être supervisé ou non.



**Récapitulation :**

Les différents réseaux de neurones peuvent être classés comme dans le schéma de la figure III.12:

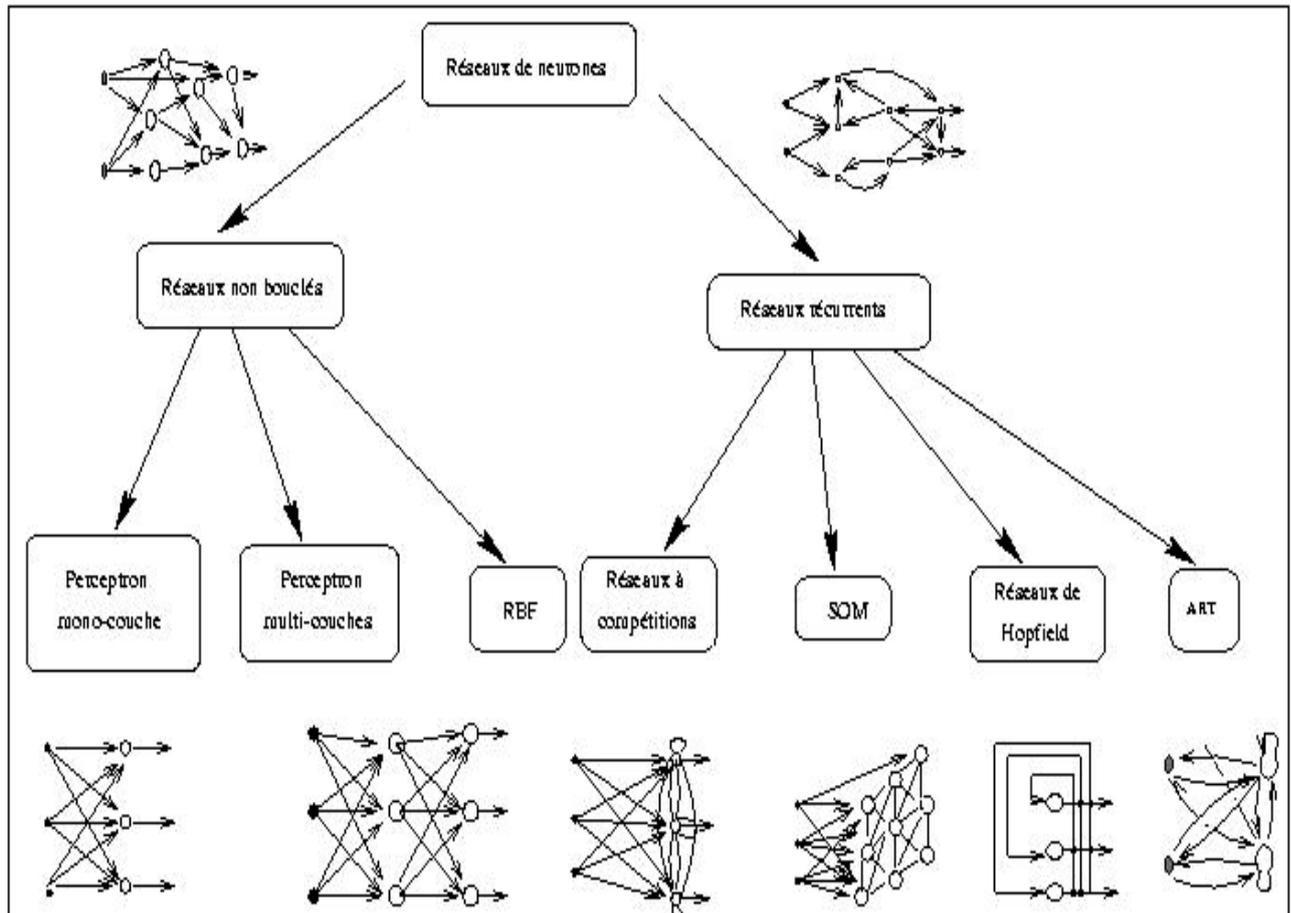


Figure III.12 : Schéma récapitulatif des différentes classes des réseaux de neurones. [14]

**III.7. Domaines d'applications des réseaux de neurones :**

Voici quelques exemples d'applications: [6]

- *La reconnaissance de formes.* Dans ce type de problème, les données d'entrée représentent l'information recueillie par un ou plusieurs capteurs (caméra, sonar, micro). Le but est de reconnaître les objets perçus par le capteur.
- *En reconnaissance de la parole :* Les entrées peuvent être une segmentation de la fréquence d'un signal sonore, et les sorties identifient la valeur de tel ou tel phénomène associé à l'entrée. Ou bien on peut transcrire le langage parlé en texte ASCII.



- *En reconnaissance de cibles* : Applications militaires qui utilisent des données issues d'images vidéo ou infrarouge pour déterminer la présence d'une cible ennemie.
- *En reconnaissance d'écriture* : Qu'elle soit manuscrite ou imprimée, le réseau va être confronté à un problème de classification, par rapport à la base d'apprentissage qui constitue la base de données.
- *La classification*. Ce type d'application ressemble beaucoup à la reconnaissance de formes, en ce que son but est d'associer à une entrée donnée l'étiquette d'une forme connue.
- *En médecine*. Les entrées du réseau peuvent être un ensemble de valeurs résultant d'une liste de tests médicaux, les sorties étant les symptômes possibles de maladies infectieuses.
- ...etc.

### **III.8. Propriétés et limites des réseaux de neurones :**

#### **III.8.1. Propriétés**

L'intérêt porté aujourd'hui aux réseaux de neurones tient sa justification dans les quelques propriétés fascinantes qu'ils possèdent : [6]

- **La capacité d'adaptation**. Elle se manifeste par la capacité d'apprentissage qui permet de tenir compte de nouvelles contraintes ou de nouvelles données du monde extérieur.
- **Le parallélisme**. Les réseaux de neurones sont considérés comme un ensemble d'entités élémentaires qui travaillent simultanément. Le parallélisme permet une rapidité de calcul supérieur mais exige de poser différemment les problèmes à résoudre.
- **La capacité de généralisation**. La capacité de généralisation d'un réseau de neurones est sa capacité à donner une réponse satisfaisante à une entrée qui ne fait pas partie de son ensemble d'apprentissage.

#### **III.8.2. Limites**

Les principales limites actuelles sont : [6]

- La plupart des réseaux de neurones sont simulés sur des machines séquentielles. Ce qui entraîne des temps de calculs importants dès que la taille du problème devient grande.
- Incapacité d'expliquer les résultats qu'ils fournissent. Les réseaux de neurones se comportent comme des boîtes noires dont les règles de fonctionnement sont inconnues.



### III.9. Réseau multicouche:

Apparus en 1985, les réseaux multicouches sont aujourd'hui les modèles les plus employés. Plusieurs couches de traitement leur permettent de réaliser des associations non linéaires entre l'entrée et la sortie. Ils sont ainsi capables de résoudre le cas du "ou exclusif". Depuis les années soixante, les possibilités de traitement des réseaux multicouches sont supérieures à celles du Perceptron, cependant l'algorithme d'apprentissage manquait. Pour la couche de sortie, on peut appliquer l'apprentissage du Perceptron, mais comment modifier les poids pour les connexions qui ne sont pas en relation avec un neurone de sortie ?

Le problème est ramené à l'obtention d'une estimation de la valeur désirée pour chaque neurone de la couche cachée. La rétropropagation (backpropagation) de gradient est une solution à ce problème.

Le principe utilisé par la rétropropagation du gradient est la minimisation d'une fonction dépendant de l'erreur (voir annexe).

#### III.9.1. Structure et fonctionnement:

Les neurones sont organisés en couches, chaque neurone est connecté à toutes les sorties des neurones de la couche précédente, et nourrit de sa sortie tous les neurones de la couche suivante. Les entrées de la première couche constituent les entrées du réseau. Les fonctions de transfert sont les mêmes pour les neurones d'une même couche, mais peuvent être différentes d'une couche à l'autre. Ainsi la fonction de transfert de la couche de sortie est généralement l'identité. [6]

On se retrouve facilement avec des représentations ressemblant à ce qui suit : (Figure III.13)

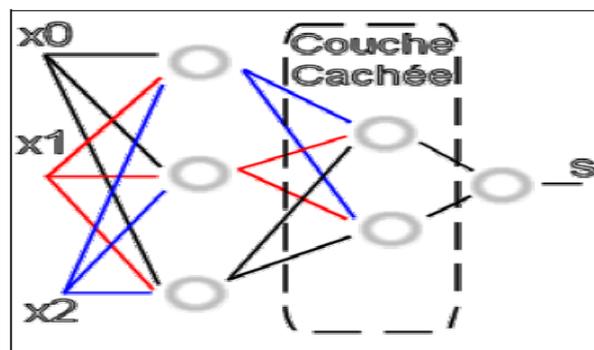


Figure III.13: Perceptron multicouche.

Les cercles représentent les neurones, les traits précédant les neurones correspondent aux poids des neurones (les couleurs ne sont là que pour aider à la lisibilité et n'ont aucune



importance). Les  $X_i$  sont la rétine (les paramètres d'entrée) et  $S$  est l'ensemble de décision (ou sortie). Ce Perceptron multicouche se désigne ainsi :  $\{3,2,1\}$ , signifiant 3 neurones en couche 0, 2 en couche 1 et 1 en couche 2. Ceci ne constitue qu'un exemple de PMC (Perceptron multicouche). Ainsi, il est courant de trouver des PMC de ce type :  $\{200,100,50\}$  ou autre. Il est également possible d'avoir plusieurs couches cachées :  $\{4,3,2,5,2,1,4\}$ .

### ***III.9.2 Apprentissage par rétropropagation du gradient :***

Les réseaux multicouches utilisent la règle de rétropropagation du gradient (décrite en annexe). Les fonctions de transferts doivent donc être différentiables, c'est pourquoi on utilise des fonctions sigmoïdes, qui sont une approximation infiniment dérivable de la fonction à seuil de Heaviside. Le principe est simple, il s'agit de calculer la sortie du PMC suivant une série d'échantillons, et de calculer l'erreur en comparant la sortie du PMC avec la sortie attendue, l'erreur étant ensuite corrigée. [6]

### ***III.10 Application des réseaux de neurones pour la détection des routes :***

Dans cette partie nous allons exposer la méthode utilisée pour l'extraction des routes par réseau de neurones.

L'image utilisée (Voir figure III.14) est une image multispectrale (550x550 pixels), issue du satellite NOAA à la date du 08 Juin 2009, avec une altitude au sol de 1,15 Km. Elle couvre la zone située géographiquement aux coordonnées : **36°43'30.98"N 3°08'53.80"W**

#### ***III.10.1 Architecture du réseau :***

Les recherches récentes ont montré que les réseaux de neurones permettent la reconnaissance des formes et la classification des données d'image.

Deux facteurs influent la capacité du réseau de neurones:

- 1- Le type d'information qui doit être extraite de l'image d'entrée.
- 2- Le nombre des itérations en phase d'apprentissage.

La détection des routes dans les images satellites peut être considérée comme un processus de classification dans lequel les pixels sont divisés en pixels appartenant aux routes et pixels appartenant au fond. [8]





2- Normalisation des valeurs de pixel (division par 255).

3- Calcul des composantes principales :

Premièrement on calcule la matrice de corrélation, pour voir la dépendance entre les canaux de l'image originale.

Variables	Rouge	vert	bleu
Rouge	1.0000	0.9754	0.9579
vert	0.9754	1.0000	0.9815
bleu	0.9579	0.9815	1.0000

Tableau III.2 : Matrice de corrélation (Image originale).

A partir du tableau III.2, on voit que les canaux sont très corrélés.

Après le calcul des ACP, on recalcule la matrice de corrélation des nouveaux axes :

Variables	ACP1	ACP2	ACP3
ACP1	1.0000	0.0000	-0.0000
ACP2	0.0000	1.0000	0.0000
ACP3	-0.0000	0.0000	1.0000

Tableau III.3 : Matrice de corrélation (Image des ACP).

A partir du tableau III.3, On remarque que les axes principaux sont carrément indépendants.

	F1	F2	F3	Total
Valeur propre	2.5832	0.4026	0.0142	3
En (%)	86.1067	13.4200	0.4733	100

Tableau III.4 : Valeurs propres

Le tableau III.4 signifie que le premier axe (F1) permet d'expliquer 86.1067% de la variance totale du nuage de points, et que le second axe (F2) permet d'expliquer 13.42% de la variance totale.

On utilise les deux premières composantes principales comme paramètres d'entrées du réseau de neurones (car elle représente 99.5267 % de la variance totale).

Alors la couche d'entrée est composée de deux neurones responsables de recevoir les valeurs des deux premières composantes principales de l'image.



Nous représentons sur la figure III.16 l'image des ACP, et sur la figure III.17 les images issues des deux premières composantes principales

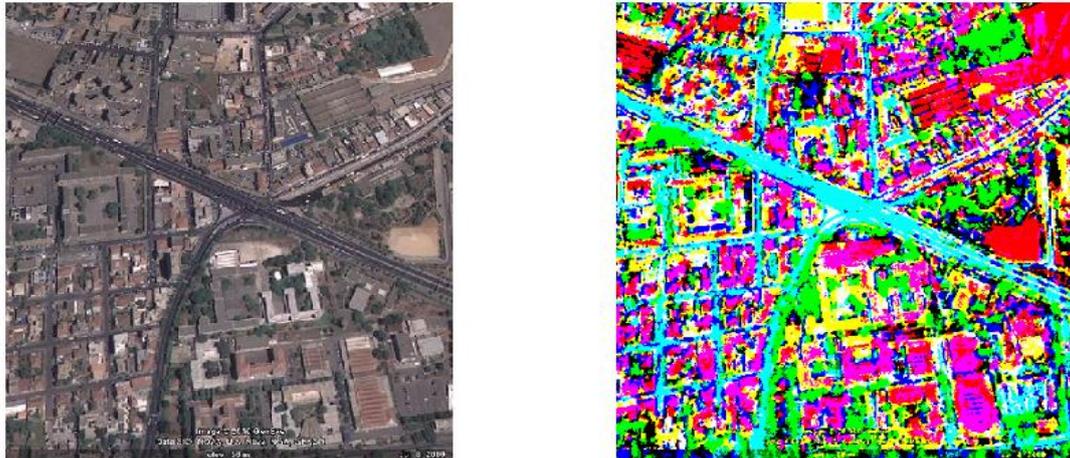


Figure III.16: Image originale (à gauche), Image des ACP (à droite)

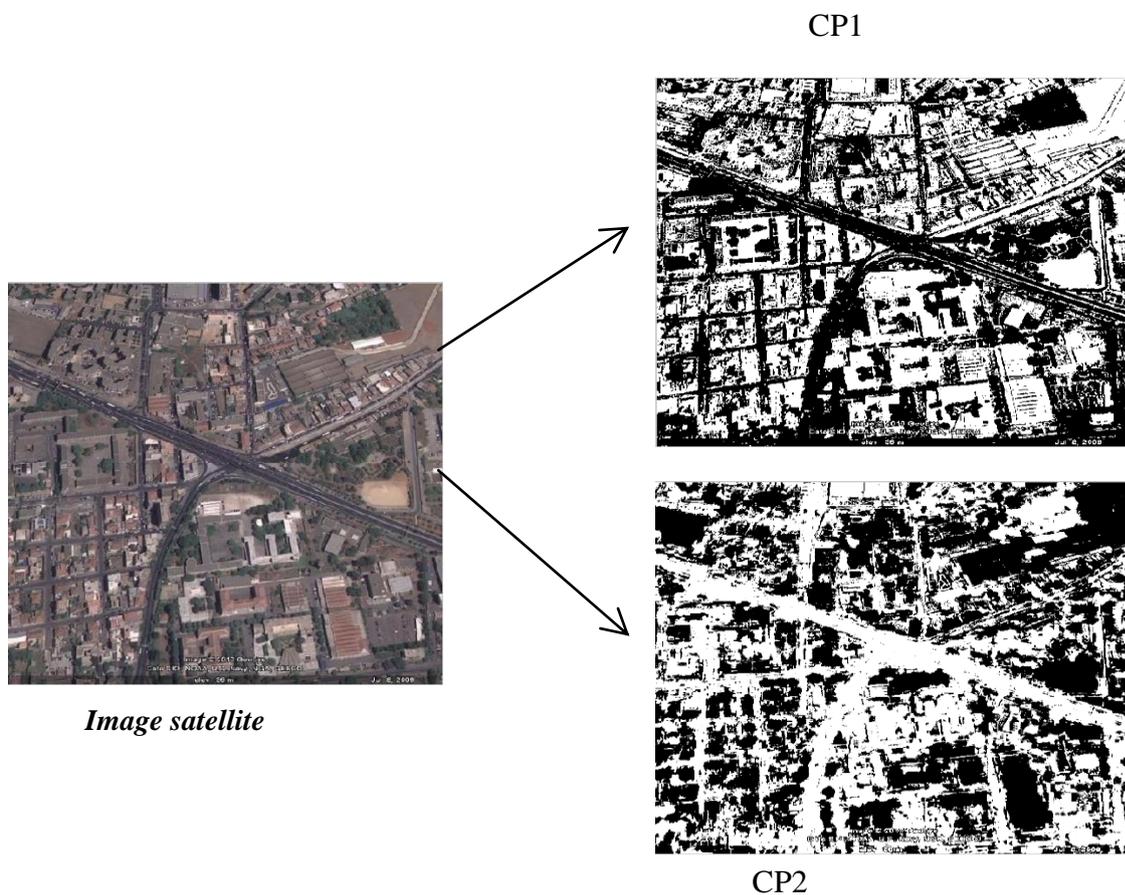


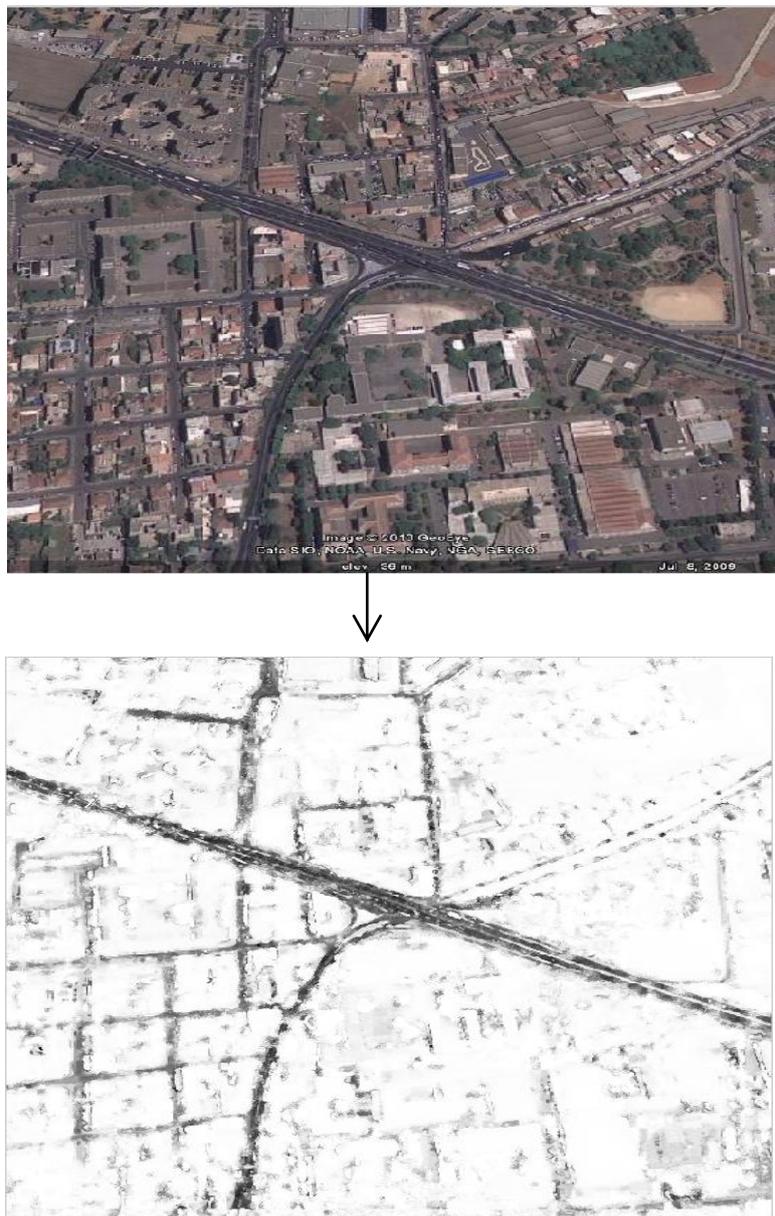
Figure III.17: Les deux premières composantes principales



- 4- Appliquer la fonction du réseau de neurones en choisissant la fonction de transfert et le nombre de couches cachées ainsi que le nombre de neurones dans chaque couche cachée.

D'habitude, une couche cachée est suffisante. Plus de neurones dans la couche cachée permettent au réseau d'apprendre des problèmes plus compliqués, mais il y aura une augmentation du temps associé dans l'apprentissage.

**III.10.2 Résultats et interprétation :**



**Figure III.18: Réseau routier extrait par MLP**



Nombre de neurones de la couche cachée	8	10	15	20
MSE	0.0339	0.0341	0.0337	0.034

**Tableau III.5 : MSE pour différents nombres de neurones dans la couche cachée**

I- D’après le tableau III.5, on remarque que : si on augmente le nombre de neurones de la couche cachée le résultat est pratiquement inchangé et l’erreur quadratique moyenne (MSE) reste presque inchangée (environ de la valeur 0,0337).

La convergence du réseau est obtenue après 173 itérations pour 8 neurones dans la couche cachée.

On note que l’exécution du programme est très lente surtout quand on augmente le nombre de neurones de la couche cachée. (Le programme de MLP pour 8 neurones dans la couche cachée dure presque 50 minutes, sur un PC de processeur Pentium de 2.2 GHz).

I- À partir de l’image obtenue par MLP, on remarque que les autoroutes ou bien les grands axes routiers peuvent être identifiés par cette méthode, due à leur radiométrie plus sombre par rapport à celle des autres éléments, à l’inverse des routes secondaires.

En plus, on a détecté, par cette méthode, des zones qui ne représentent pas des routes. L’apparition de ces zones est due à la présence d’objets dans l’image qui ont la même réponse spectrale que les routes ; à titre d’exemple : l’espace de stationnement des voitures (espace goudronné) comme montre la flèche sur la figure III.19



**Figure III.19: détection de zones ne représentant pas les routes**



Le réseau de neurones ne peut donc pas faire la différence entre les vraies routes et les zones ayant la même réponse spectrale qu'elles.

### ***III.11 Conclusion :***

Les résultats obtenus par la méthode utilisant un réseau de neurones, sont encourageants. En effet, le réseau obtenu est proche des données de référence, et présente peu de fausses détections et d'omissions, étant donné le caractère complètement automatique de la méthode. Ce dernier résultat peut être encore amélioré en considérant d'autres caractéristiques de routes telles que leurs formes (forme linéique).

Dans le chapitre suivant on va appliquer la Transformée de Hough (méthode classique de détection de lignes droites) à l'image obtenue par réseau de neurone (MLP), dans le but d'éliminer d'avantage les zones non représentatives du réseau routier.

# *Chapitre IV*

## ***La Transformée de Hough***



### IV.1 Introduction :

La Transformée de Hough Standard (THS) est une méthode classique de détection de lignes droites dans une image. Elle a été utilisée dans plusieurs applications : la détection des routes dans les images prises par satellite, la localisation des robots, la lecture robuste de code-barres ainsi que la détection des sillages de bateaux, il existe aussi d'autres applications. Partant de la dualité point-sinusoïde et point-droite, la THS propose un détecteur de ligne droite dans les images. Pour détecter les droites dans une image, chaque point allumé (image binaire) est transformé en une sinusoïde dans l'espace des paramètres (discrétisé) et les points parcourus par le plus de sinusoïdes représentent les droites passant par le plus de points dans l'image. La recherche des lignes droites dans une image se réduit donc à la détection des maxima locaux (pics) dans l'espace des paramètres. [9]

### IV.2 Transformation de Hough :

#### IV.2.1 Principe :

La figure IV.1 représente une droite (D) :  $y = m.x + p$  passant par deux points distincts A et B. La droite (D) vérifie donc les équations :

$$y_A = m. x_A + p \quad (1)$$

$$y_B = m. x_B + p \quad (2)$$

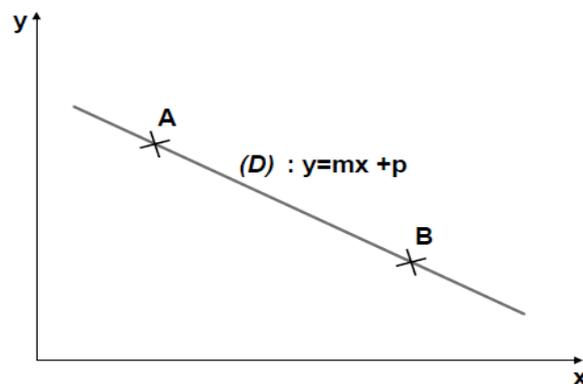


Figure IV.1 : Représentation de la droite (D).



La transformation de Hough propose de changer l'espace de représentation de ces droites et de ces points de la manière suivante :

$$(A): p = -x_A.m + y_A \quad (3)$$

$$(B): p = -x_B.m + y_B \quad (4)$$

L'équation (1) engendre la droite (A) (équation (3)) de coefficient directeur  $-x_A$  et d'ordonnée à l'origine  $y_A$ . Cette droite est associée spécifiquement au point A.

La transformation de Hough d'un point donne donc une droite. Cette droite passe par le point  $(m_D, p_D)$  ou  $m_D$  est le coefficient directeur de la droite (D) et  $p_D$  l'ordonnée à l'origine. [10]

La figure IV.2 représente la droite (A) qui passe par une infinité de couples  $(m_i, p_i)$  de points. Ces couples de points de l'espace  $(m_i, p_i)$  correspondent à toutes les droites passant par le point A dans l'espace  $(x, y)$ .

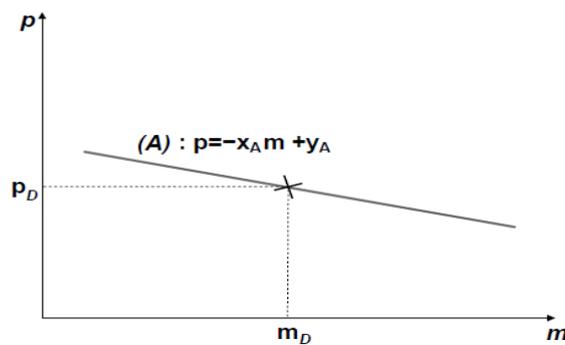


Figure IV.2 : La transformation de Hough du point A.

En faisant de même avec le point B, on obtient la droite (B) qui passe elle aussi par le point  $(m_D, p_D)$ . Ainsi, n points alignés dans l'espace  $(x, y)$  génèrent n droites sécantes dans l'espace  $(m, p)$ .

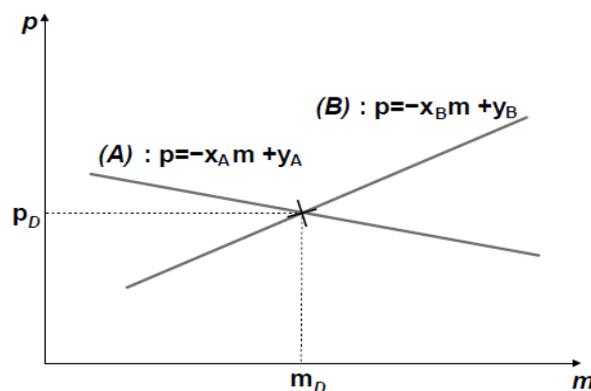


Figure IV.3 : transformation de Hough du point B.



Concrètement, la transformée de Hough est stockée dans « un buffer d'accumulation » c'est à dire un tableau à deux dimensions dans le cas de l'espace  $(m, p)$  sur lequel on dessine les droites associées aux points de l'espace  $(x, y)$ .

A chaque case de ce tableau on attribue un score variant selon le nombre de fois qu'elle a été parcourue par une droite. Ceci implique qu'un point intersecté par deux droites a un score supérieur à un point parcouru par une seule droite.

Pour trouver les droites présentes dans l'espace  $(x, y)$ , il suffit de chercher les pixels de score maximal dans l'espace  $(m, p)$ . Les pixels  $(m_i, p_i)$  choisis nous indiquent qu'un grand nombre de points sont alignés sur la droite  $y = m_i \cdot x + p_i$  dans l'espace  $(x, y)$ . [10]

#### IV.2.2 Taille du buffer et représentation polaire :

En utilisant la méthode décrite précédemment, on s'aperçoit rapidement que pour la plupart des points de l'espace  $(x, y)$ , les coefficients directeurs des droites obtenus sont très élevés et que pour certains points, l'ordonnée à l'origine est telle que la droite n'apparaît pas forcément dans le tableau (de taille finie) représentant l'espace  $(m, p)$ . De tels problèmes deviennent gênants pour les droites verticales. Il peut paraître suffisant d'agrandir la taille du « buffer d'accumulation » et de le décentrer mais en réalité, ce n'est pas suffisant. Alors on propose la solution suivante : [10]

La Transformée de Hough Standard est basée sur la représentation normale d'une droite :

$$D(\theta, \rho) = \{(x, y) \mid x \cos \theta + y \sin \theta = \rho\} \quad (5)$$

Où  $(\cos \theta, \sin \theta)$  est le vecteur normal à la droite et  $|\rho|$  est la distance de la droite à l'origine.

Soit un point  $P_0$  de coordonnées cartésiennes  $(x_0, y_0)$  et de coordonnées polaires  $(\theta_0, \rho_0)$ , de telle sorte que  $(x_0, y_0) = \rho_0(\cos \theta_0, \sin \theta_0)$  comme représenté sur la figure IV.4. Ce point peut être identifié à l'intersection des droites passant par  $P_0(x_0, y_0)$ . Comme le point  $P_0(x_0, y_0)$  doit être sur chacune des droites  $D(\theta, \rho)$  passant par ce point, nous avons de (5)

$$x_0 \cos \theta + y_0 \sin \theta = \rho$$

Et en utilisant ses coordonnées polaires, on a :

$$\rho_0 (\cos \theta_0 \cos \theta + \sin \theta_0 \sin \theta) = \rho$$

D'où :

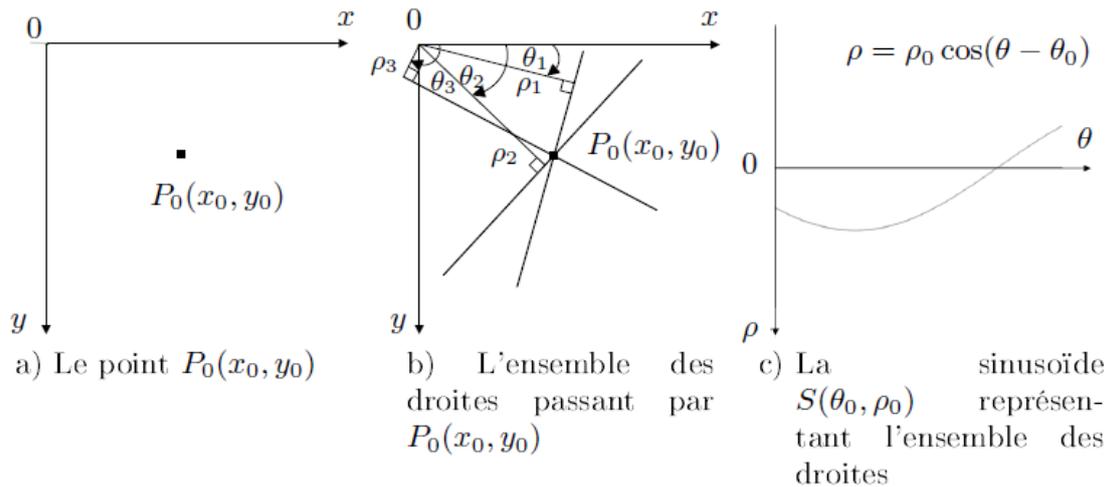
$$\rho_0 \cos(\theta - \theta_0) = \rho \quad (6)$$



Ce qui correspond à une sinusoïde de paramètres  $(\theta_0, \rho_0)$  dans le système d'axes  $(\theta, \rho)$  que nous noterons  $S(\theta_0, \rho_0)$ .

Cette sinusoïde correspond également à une représentation de l'ensemble des droites  $D(\theta, \rho)$  passant par le point  $P_0(x_0, y_0)$ . Nous noterons cette correspondance: [9]

$$P_0(x_0, y_0) \mapsto S(\theta_0, \rho_0) = \left\{ (\theta, \rho) \mid \begin{cases} (x_0, y_0) = \rho_0(\cos \theta_0, \sin \theta_0) \\ \rho = \rho_0 \cos(\theta - \theta_0). \end{cases} \right\}. \quad (7)$$



**Figure IV.4 : Point  $P_0(x_0, y_0)$  et la sinusoïde  $S(\theta_0, \rho_0)$  correspondante.**

Pour établir une procédure "inverse", on procède de façon semblable en partant de l'expression générale d'une sinusoïde de paramètres  $(\theta, \rho)$  donnée par :

$$S(\theta, \rho) = \left\{ (\tilde{\theta}, \tilde{\rho}) \mid \tilde{\rho} = \rho \cos(\tilde{\theta} - \theta) \right\}. \quad (8)$$

Soit  $Q_0$  un point de coordonnées  $(\theta_0, \rho_0)$  dans le système de coordonnées  $(\theta, \rho)$  comme représenté sur la figure IV.5. Dans ce système, nous identifions ce point  $Q_0$  à l'intersection de toutes les sinusoïdes  $S(\theta, \rho)$  passant par ce point.



Comme le point  $Q_0(\theta_0, \rho_0)$  doit être sur chacune des sinusoides, on doit avoir :

$$\rho_0 = \rho \cos(\theta_0 - \theta)$$

d'où

$$\rho_0 = \rho (\cos\theta \cos\theta_0 + \sin\theta \sin\theta_0)$$

$$\rho_0 = x \cos\theta_0 + y \sin\theta_0 \quad (9)$$

Où on a posé  $(x, y) = \rho (\cos\theta, \sin\theta)$ .

Remarquons que l'équation (9) correspond à la droite  $D(\theta_0, \rho_0)$ . Cette droite correspond également à l'ensemble des sinusoides (8) passant par ce point (dans le système d'axes  $(\theta, \rho)$ ).

Nous noterons cette correspondance : [9]

$$Q_0(\theta_0, \rho_0) \mapsto D(\theta_0, \rho_0) = \left\{ (x, y) \left| \begin{array}{l} (x, y) = \rho(\cos\theta, \sin\theta) \\ \rho_0 = \rho \cos(\theta_0 - \theta) \\ \rho_0 = x \cos\theta_0 + y \sin\theta_0 \end{array} \right. \right\}. \quad (10)$$

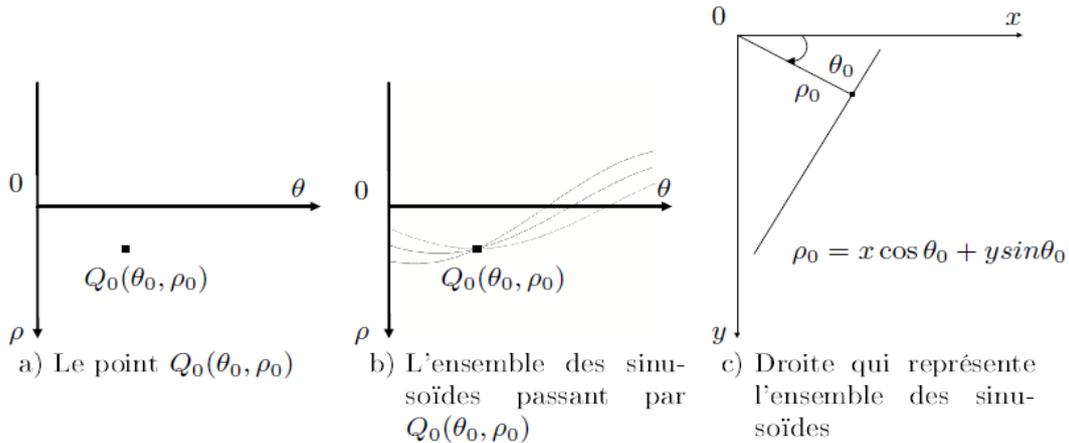


Figure IV.5 : Point  $Q_0(\theta_0, \rho_0)$  associé à la droite  $D(\theta_0, \rho_0)$ .

Les deux applications (7) et (10) définissent en fait la : Transformée de Hough Standard.

### IV.2.3 Propriétés de la THS:

Dans la suite, une image  $I$  sera décrite à l'aide des coordonnées cartésiennes de ses points.

Nous noterons par  $H$  l'espace des coordonnées  $(\theta, \rho)$  associées aux droites.



D'après sa définition, la Transformée de Hough Standard possède les propriétés suivantes : [9]

**Propriété 1 :** Un point dans l'espace d'observation (image I), correspond à une sinusoïde dans l'espace des paramètres H (Figure IV.4).

**Propriété 2 :** Des points appartenant à la même sinusoïde dans l'espace des paramètres H correspondent à des lignes qui se coupent en un même point dans l'espace d'observation (Figure IV.4).

**Propriété 3 :** Un point de l'espace des paramètres correspond à une droite dans l'espace d'observation I (Figure IV.5).

**Propriété 4 :** Des points appartenant à une même droite D dans l'espace d'observation I correspondent à des sinusoïdes qui se coupent en un même point P ( $\theta_0, \rho_0$ ) dans l'espace des paramètres H (Figure IV.5).

#### IV.2.4 Implémentation classique de la THS :

Dans l'implémentation de la THS, les espaces d'observation et de paramètres ont des pas discrets. L'image discrétisée I à niveaux de gris est de dimension  $N \times N$  pixels. Nous appelons HT la discrétisation de l'espace des paramètres H en un accumulateur de résolution de  $N_\theta \times N_\rho$  cellules. Nous utilisons HT pour comptabiliser le nombre de fois qu'une cellule a été parcourue par les sinusoïdes tracées par la THS (vote).

L'implémentation de l'algorithme de Hough se présente en deux étapes :

**Entrée :** Image binaire I.

**Étape 1 :** Transformation des points de contour de l'image I en sinusoïdes dans l'espace des paramètres H. Pour chaque pixel P ( $x_i, y_j$ ) allumé de l'image, nous lui associons la sinusoïde d'équation :

$$\rho(\theta) = x_i \cos \theta + y_j \sin \theta$$

Dans notre accumulateur HT nous incrémentons le vote de toutes les cellules correspondantes aux points de la sinusoïde.

**Étape 2 :** Détection des points ayant le plus de votes dans HT, ce qui détermine les alignements de pixels dans l'espace image I. Cela revient à la recherche de points ayant un nombre de votes dépassant un seuil fixé appelés pics. [9]



### IV.3. Résultats et interprétation :

Nous avons appliqué la Transformée de Hough à l'image obtenue par réseau de neurones (MLP) dans le but d'éliminer encore les zones qui ne représentent pas le réseau routier.

Avant d'appliquer la THS, nous avons fait les prétraitements suivants : Filtrage médian + érosion de l'image filtrée + binarisation de l'image érodée + érosion de l'image binarisée.

L'image obtenue après les prétraitements précédents est représentée par la figure IV.6 :

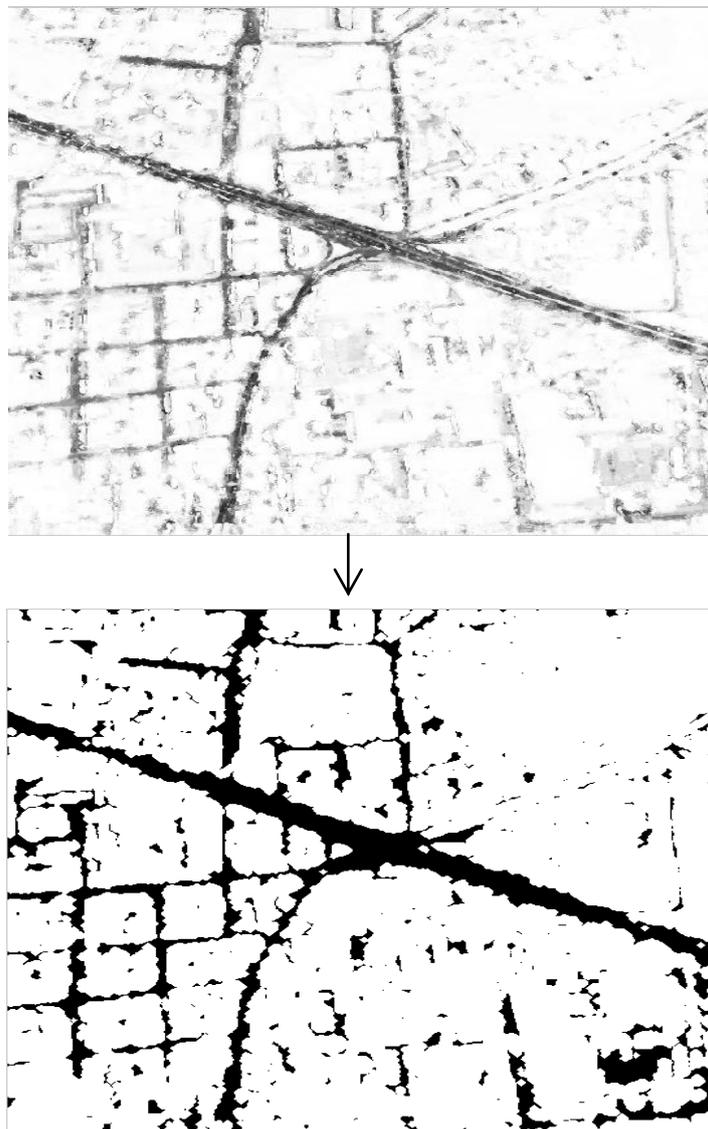


Figure IV.6 : Image prétraitée.



Résultat de la THS :

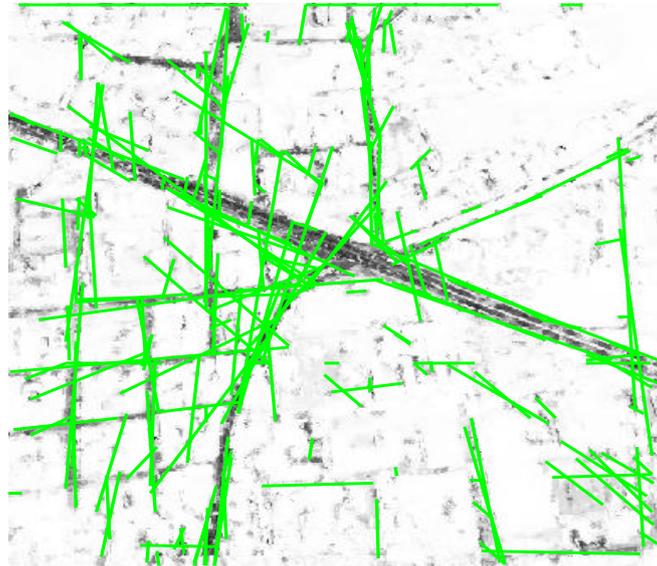


Figure IV.7 : THS de l'image.

La figure IV.7 représente le résultat après application de la THS à notre image.

Nous allons commenter ce résultat en considérant un exemple simple (étude d'un circuit imprimé) : [11]



Figure IV.8 : Image originale (à gauche), Image des contours (à droite).

Pour les deux premiers points ayant le plus de votes on a les courbes suivantes :(figure IV.9)

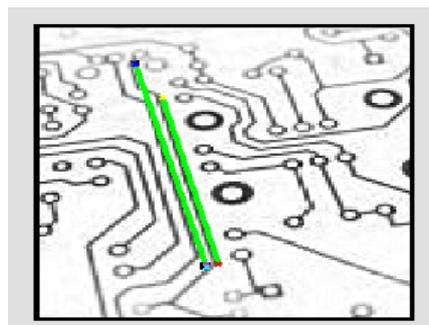


Figure IV.9 : Les 2 courbes les plus probables extraites.



Et pour les cinq premiers votes on a les courbes de la figure IV.10 :

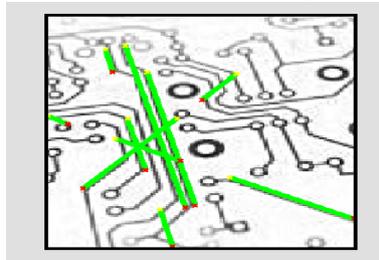


Figure IV.10 : Les 5 courbes les plus probables extraites.

**Commentaire :**

L'accumulateur compte le nombre de votes dans toutes les directions, alors pour résoudre ce problème nous avons zoomé l'image avant d'appliquer la THS (de telle sorte que, les longueurs des lignes à chercher prennent la taille de l'image). (voir la figure IV.11)

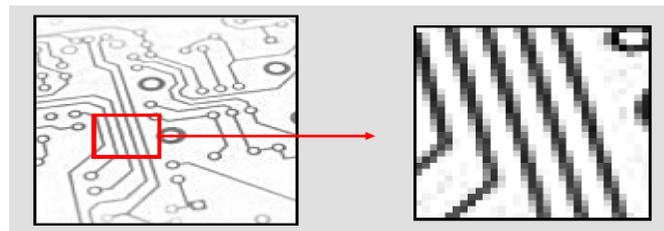


Figure IV.11 : Image originale (à gauche), Image zoomée (à droite).

Pour les sept premiers votes on a les courbes suivantes :(figure IV.12)

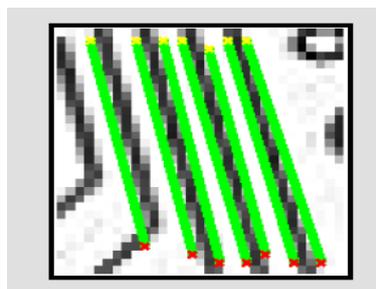


Figure IV.12 : Les 7 courbes les plus probables extraites.

A partir de l'image de la figure IV.12, on voit que les pics représentent les vraies lignes.

Alors pour que la THS devienne évidente, il faut que les longueurs des lignes à chercher prennent la taille de l'image. (La THS donne une mauvaise extraction des lignes ayant une longueur inférieure à la dimension de l'image).



Revenons à notre problème : divisons l'image obtenue par MLP en sous images sur lesquelles nous appliquons la THS, nous obtenons alors le résultat représenté en figure IV.13 :

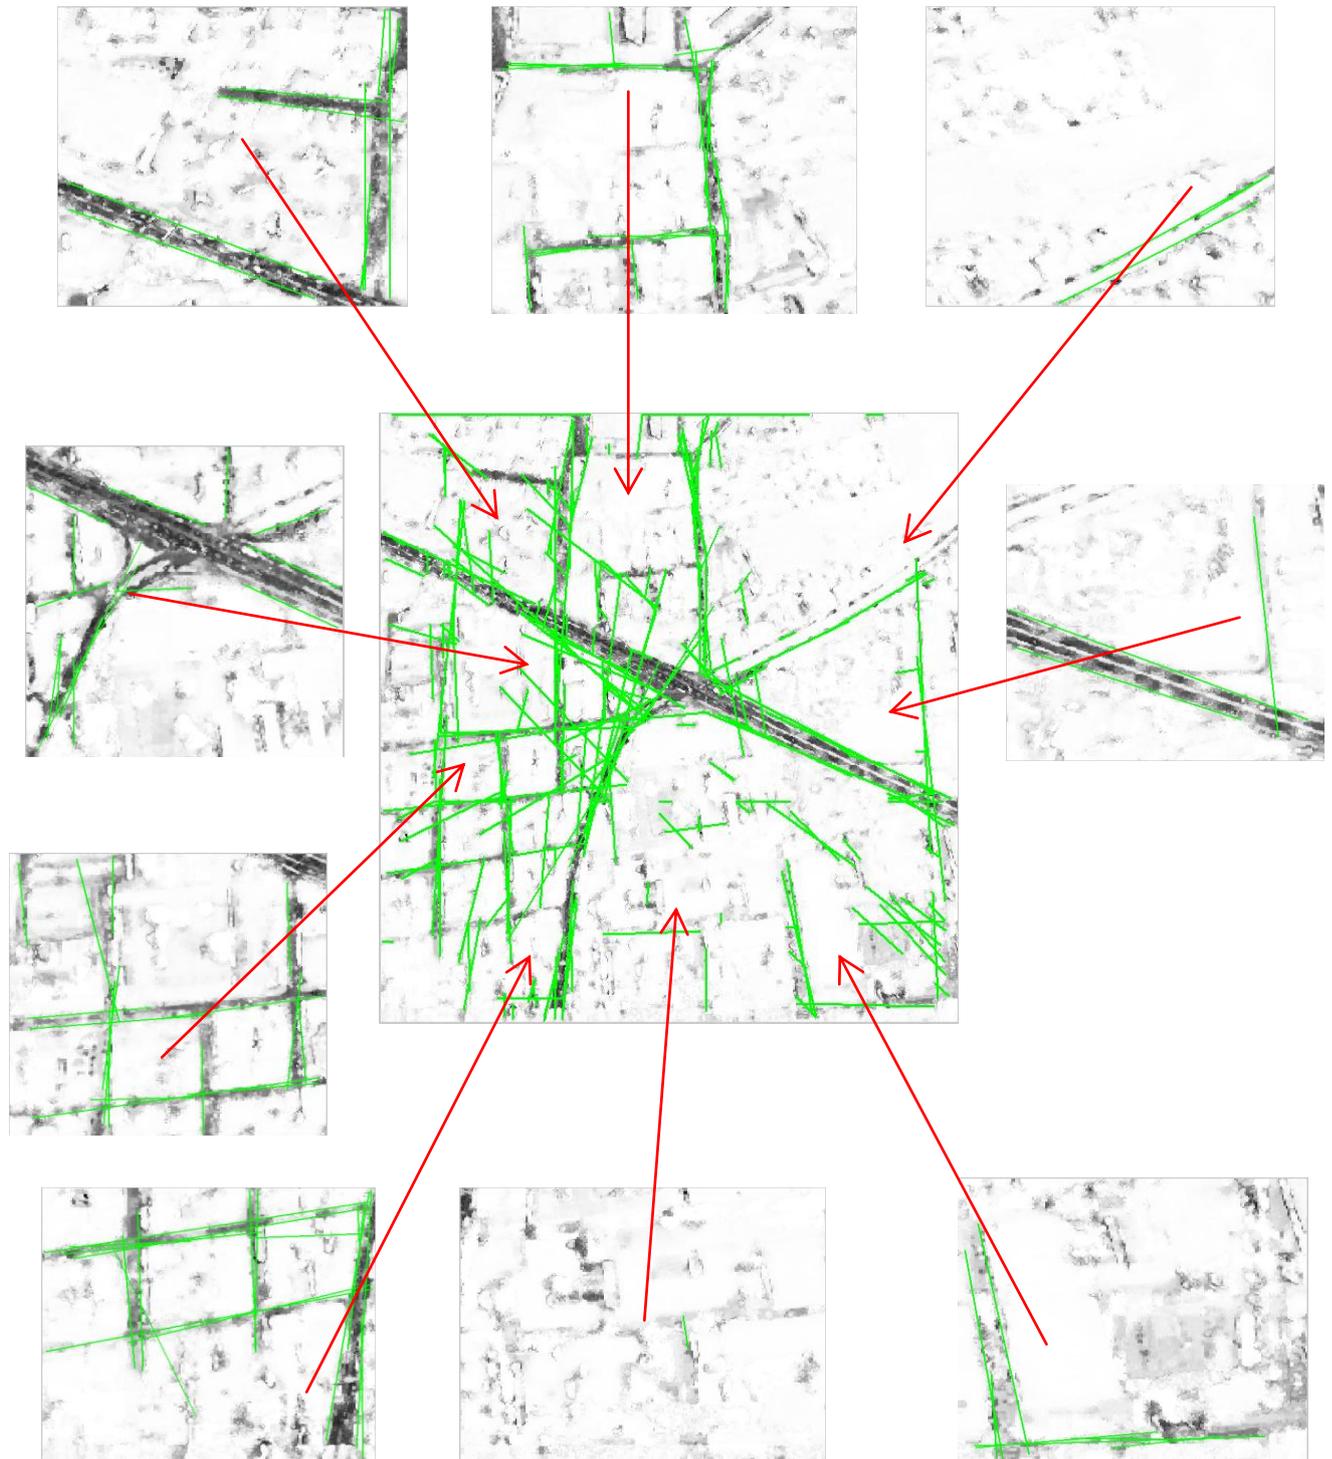


Figure IV.13 : THS sur l'image obtenue par MLP (au centre) et les THS des sous images.



La figure IV.13 permet de constater l'amélioration de la détection des routes en utilisant une division de l'image en sous-images.

En fusionnant les résultats obtenus sur les sous-images nous obtenons le résultat final de la détection des routes (voir figure IV.14).

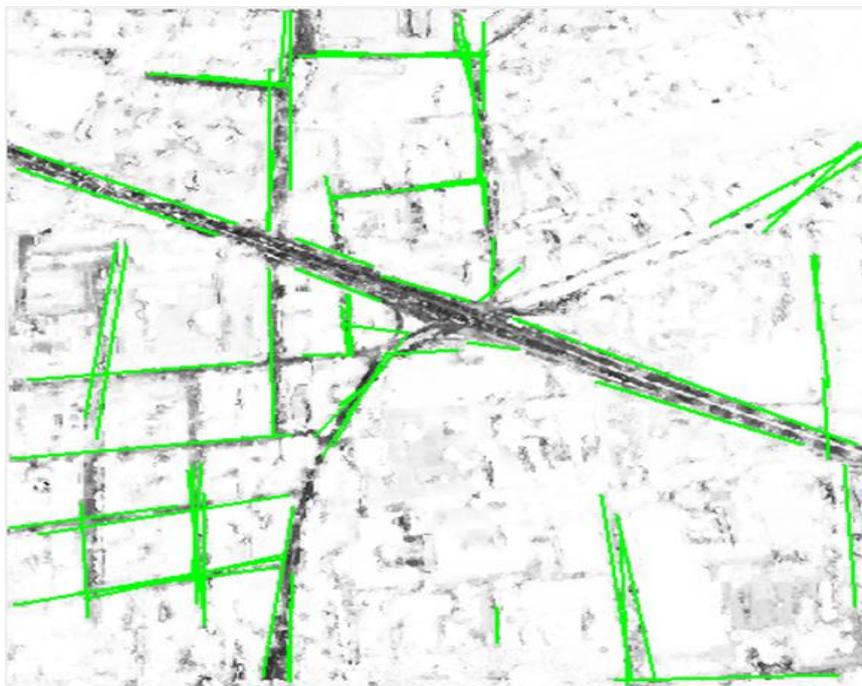


Figure IV.14 : résultat final de la détection des routes.

On voit alors, qu'avec l'introduction des opérations de division/fusion de l'image, une nette amélioration de détection des routes est obtenue (presque la totalité des routes sont détectées et on a encore limité les fausses détections).

#### **4. Conclusion :**

Dans ce chapitre on a utilisé une méthode basée sur la transformé de Hough. Cette méthode donne des résultats satisfaisants qui nécessitent toutefois des étapes de traitement et d'amélioration.

Dans le chapitre suivant on va utiliser une autre approche pour la détection des routes, c'est l'approche de classification.

On va dans ce cas, extraire le réseau routier à partir de l'image classifiée, car l'interprétation de l'image obtenue par classification est plus facile que celle de l'image satellitaire originale (les informations obtenues par classification présentent un grand intérêt par rapport à l'image originale).

# *Chapitre V*

## ***Classification d'images satellites***



### **V.1. Introduction :**

L'objectif du traitement d'images satellitaires est d'en extraire le maximum d'information qui intéresse le futur utilisateur de l'image, et d'évacuer tout ce qui est superflu. Un but réaliste est la classification thématique de ces images.

Le processus de classification est souvent rapproché de celui de la segmentation, mais les différences entre les deux sont grandes : le but de la segmentation est d'opérer une partition de l'image en zones connexes homogènes sans aucune sémantique, alors que celui de la classification est de déterminer, pour chaque pixel ou groupe de pixels de l'image à traiter, la classe de référence à laquelle il appartient, c'est-à-dire dans le cas des images de télédétection, c'est la partition de l'image en ensembles de pixels représentant une même occupation du sol. [5]

### **V.2. Les catégories des classifications :**

Une première partition des méthodes de classification peut être faite, entre les méthodes dites de classification supervisées et les méthodes non supervisées. Dans le premier cas l'algorithme nécessite l'intervention d'un utilisateur à un (ou plusieurs) stade(s) (le cas le plus fréquent étant l'apport d'échantillons d'apprentissage), alors que dans le second cas, aucune intervention n'est nécessaire.

La classification est un problème souvent étudié en télédétection, et il existe diverses façons d'effectuer cette opération. On distingue principalement deux catégories : les méthodes paramétriques dites approches de classification statistiques et les méthodes non paramétriques. [5]

Un classifieur est dit paramétrique s'il associe à la signature spectrale une distribution statistique connue, le plus fréquemment pour le traitement d'images, la loi normale ou multinormale. Cette association offre la possibilité d'affecter à chaque pixel une probabilité d'appartenance à une classe donnée. Un classifieur probabiliste est donc généralement paramétrique. L'algorithme le plus connu de cette catégorie est celui du *maximum de vraisemblance*.



Un classifieur non paramétrique se définit alors en négatif de la première catégorie.

Aucune distribution statistique paramétrique n'est exploitée, seule la distance spectrale est prise en compte. Cette catégorie comprend notamment : les méthodes fondées sur la minimisation de distance (hyperboîte ou parallélépipédique, la distance minimale et la distance de Mahalanobis, K plus proches voisins, Kmeans, ISODATA, etc), ainsi, de nouvelles méthodes apparues récemment s'ajoutent à cette catégorie comme les réseaux neuronaux et les Machines à Support Vecteurs (SVM). [5]

Nous nous sommes principalement intéressés dans ce travail aux méthodes de classification automatique non supervisées à l'aide des réseaux de neurones (Cartes auto\_organisatrices de Kohonen) qui ont montré leur capacité à réaliser ce genre de tâche.

### ***V.3. Carte auto\_organisatrices de Kohonen (SOM) :***

Pour le domaine de la classification d'images satellitaires, les méthodes de classification classiques permettent, en général, une analyse de données en les regroupant en classes en fonction de critères de ressemblance ou de similarité entre individus formant l'ensemble à classifier. Ces méthodes sont mal adaptées lorsqu'il s'agit de traiter des données obéissant à des lois de distribution différentes [15]. Ces méthodes de classification en mode dirigé ou non dirigé ont démontré leur impuissance lorsqu'il s'agit de situations complexes notamment dans les cas : [12]

- d'une topographie accidentée de la région à étudier ;
- d'hétérogénéité des systèmes de mesure lors d'intégration de données issues de différentes sources.

Les cartes topologiques de Kohonen présentent une nouvelle stratégie de classification en se basant sur un mode non dirigé et un principe de compétition et de coopération. Leur capacité de découvrir automatiquement des catégories dans un ensemble de données fait de ces réseaux des techniques efficaces de classification. [16]



### ***V.3.1. Principe des cartes auto-organisatrices de Kohonen :***

Les cartes auto-organisatrices de Kohonen (Kohonen Self Organizing Map, K-SOM) sont tirées par analogie de la capacité dont le cerveau humain organise l'information d'une façon logique. La recherche a démontré que le cortex cérébral du cerveau humain est divisé en subdivisions fonctionnelles. Le cortex contient des milliards de neurones et plusieurs de milliards de raccordements (synapses) entre eux. La subdivision du cortex est ordonnée. Les composants les plus importants sont : le cortex sensoriel, le cortex visuel et le cortex auditif. Le cortex auditif est également subdivisé en de nombreuses cellules, chacune fonctionne comme partie spéciale pour chaque signal auditif. Selon leur Topologie, les secteurs adjacents exécutent des fonctions relativement reliées. La méthode de Kohonen utilise un apprentissage non supervisé d'une façon élégante et extrêmement simple.

Les cartes auto-organisatrices ont été introduites pour la première fois par Teuvo Kohonen en 1981. C'est un réseau de neurones artificiel dont l'organisation topologique de ses neurones présente sa principale caractéristique.

La visualisation par cartes topologiques proposées par Kohonen cherche, par apprentissage à partir des données, à partitionner l'ensemble des observations disponibles en groupement similaires. Les groupements proposés possèdent la particularité caractéristique d'avoir une structure de voisinage qui peut être matérialisée à l'aide d'un espace discret que l'on appelle carte topologique. [13]

La carte auto-organisatrice est habituellement composée d'une grille de neurones à deux dimensions. Parfois des cartes à une dimension peuvent être employées pour résoudre certains problèmes. Cependant, des cartes multidimensionnelles peuvent être aussi bien mises en application. Une carte auto-organisatrice offre la possibilité d'effectuer une réduction de dimensions, car elle permet de projeter des données multidimensionnelles sur une carte à deux dimensions. Chacun des neurones composant cette carte sera reliée à chaque neurone d'entrée

### ***V.3.2. Classification et cartes auto-organisatrices :***

Les tâches de classifications sont les plus importantes parmi les différentes applications réalisées par les cartes auto-organisatrices. Le résultat d'un apprentissage non supervisé permet d'affecter une observation à un sous-ensemble d'une partition, indépendamment de toute notion de classe. On suppose que l'on dispose d'un très grand nombre de données



bruitées (observations) dont on ne connaît pas exactement la classe. L'idée générale de ce type d'application est de faire apparaître des groupements cohérents (classes) en relation avec les données traitées. Ces groupements sont appelés généralement « Classes ». [13]

### V.3.3. Architecture neuronale des cartes auto-organisatrices :

Ces cartes sont des réseaux de neurones constitués de deux couches :

La couche d'entrée sert à la présentation des observations (données) à classer. Cette couche contient alors exactement N neurones (N étant la dimension de l'espace des observations).

La couche d'adaptation est formée du treillis des neurones qui forme la carte.

Les neurones utilisés à ce niveau sont de simples neurones, chacun d'entre eux étant connecté à tous les éléments de la couche d'entrée. Le vecteur référent  $W_k$  associé à un neurone K de la carte n'est autre que le vecteur de poids. Puisque le réseau est totalement connecté à la couche d'entrée, chaque neurone possède N connexions (poids)

### V.3.4. Méthodologie de la technique :

Les cartes auto-organisatrices de Kohonen se composent d'une seule couche de neurones organisés dans une dimension, deux dimensions ou multidimensionnelles (plus de deux dimensions). Chaque neurone a un nombre de connexions d'entrée égal au nombre d'attributs utilisés dans la classification comme représenté sur la Figure V.1

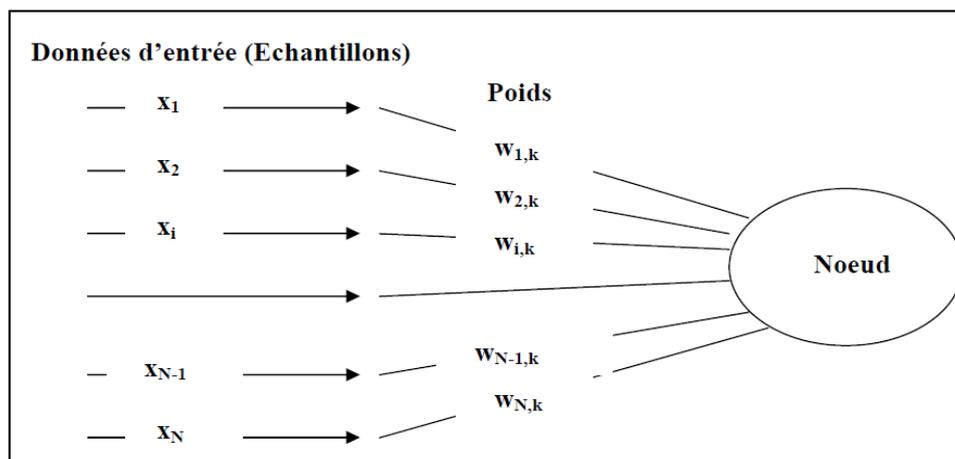


Figure V.1 : Connexion des données d'entrée au nœud neuronal

La procédure d'apprentissage consiste à trouver le neurone ayant le poids le plus proche du vecteur de données d'entrée et le déclarer comme neurone gagnant. Les poids de tous les neurones à proximité du neurone gagnant sont ajustés par une quantité inversement



proportionnelle à leur distance. Au fur et à mesure que le nombre d'itérations augmente, le rayon du voisinage admis sera réduit. Le processus d'apprentissage se termine si les erreurs MSE de toutes les entrées sont réduites à un niveau acceptable ou après un nombre d'itérations prédéfini. [13]

Il y a deux méthodes pour déterminer la similitude des réponses de données :

Dans la première, chaque entrée est pondérée par le vecteur poids du neurone correspondant et les résultats sont additionnés. Ceci représente l'entrée **net** du neurone. Soit  $k$  l'indice du  $k^{\text{ème}}$  neurone avec  $N$  attributs employés, alors l'entrée **net** sera (en termes de produit scalaire) :

$$\mathbf{net}_k = \sum_{i=1}^N [x(i) \cdot w(i,k)] \quad (1)$$

Le produit scalaire donnera la projection d'un vecteur sur un autre. Une entrée **net** égale à **1** représenterait deux vecteurs colinéaires, qui sont orientés dans la même direction et leurs paramètres sont semblables. Une valeur **net** égale à **0** signifiera que les deux vecteurs sont perpendiculaires, alors ils ne sont pas semblables.

La deuxième méthode pour mesurer la similitude des deux vecteurs est de calculer la distance euclidienne les séparant comme :

$$\|\mathbf{net}_k\| = \sqrt{\sum_{i=1}^N [x(i) - w(i,k)]^2} \quad (2)$$

Dans ce cas un résultat **net** égal à zéro signifiera que les deux vecteurs sont identiques. Une valeur de **2** signifiera qu'ils sont exactement opposés, donc ne sont pas semblables.

On applique cette opération à tous les neurones, et le neurone qui admet le résultat le plus grand du produit scalaire ou la distance euclidienne minimale sera choisi en tant que gagnant. Afin de maintenir la similitude des neurones les plus proches du point de vue topologie, les poids de tous les neurones dans un rayon choisi doivent être ajustés. Le neurone gagnant est le plus ajusté par un processus modifiant les poids du neurone gagnant de telle sorte qu'il soit plus près des valeurs des données d'entrée. Tous les autres neurones sont ajustés par de petites quantités inversement proportionnelles à leur distance du neurone gagnant. Avec la progression des itérations, les erreurs MSE se réduisent.



À la fin de l'apprentissage, les poids de chaque neurone représentent une référence et pourraient être utilisés pour la classification.

### V.3.5 Différentes organisations topologiques :

Les neurones peuvent être organisés sous plusieurs formes topologiques. La figure V.2 montre une organisation unidimensionnelle. Ceci permet de grouper ou de classifier avec un rapport (relation) topologique unidimensionnel, c'est-à-dire, chaque neurone aura de petites différences par rapport aux deux neurones adjacents. La différence augmentera graduellement avec l'augmentation de la distance. Chaque neurone est relié aux données d'entrée par leurs propres poids. Dans le cas de la S.O.M, ces poids seront équivalents aux attributs réels représentant les valeurs de l'attribut moyen de chaque groupe.

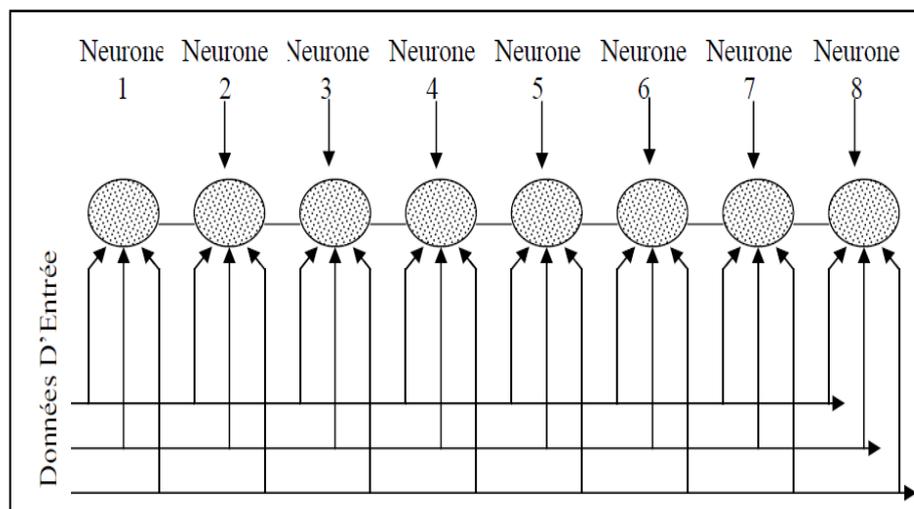


Figure V.2 : Forme Topologique Unidimensionnelle

La figure V.3 montre une forme topologique bidimensionnelle. Cette fois nous avons quatre neurones adjacents pour chaque neurone. Les différences seront inversement proportionnelles à la distance topologique entre les neurones. Nous pouvons utiliser, de la même manière, une forme tridimensionnelle. Dans la pratique, les cartes mono ou bidimensionnelle sont habituellement utilisées. [13]

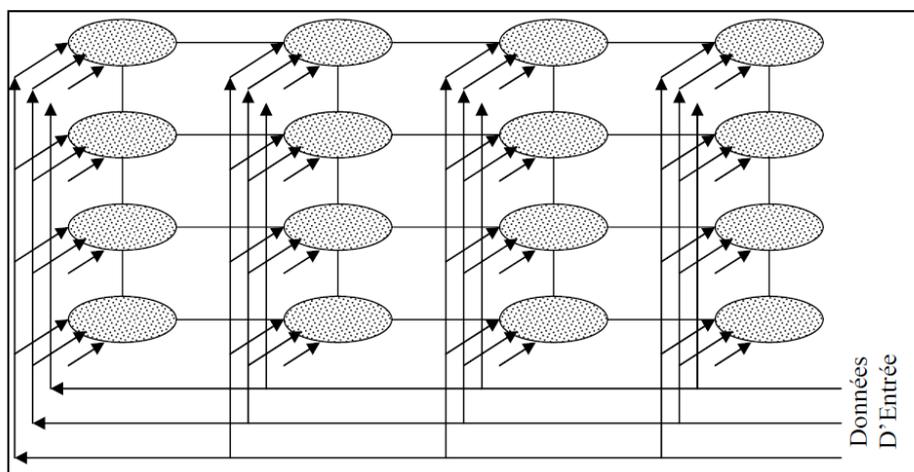


Figure V.3 : Forme Topologique Bidimensionnelle

### V.3.6. Procédé de calcul des S.O.M :

L'application des cartes auto-organisatrices de Kohonen (S.O.M) pour la classification peut être résumée sous forme d'un algorithme descriptif : [13]

#### V.3.6.1 Initialisation De Données :

Une fois que le groupe des attributs à utiliser dans la classification est sélectionné, chaque attribut doit être normalisé.

#### V.3.6.2 Initialisation des poids neuronaux :

Chaque neurone aura un poids pour chaque attribut. Au départ nous affectons de petits nombres aléatoires à chacun des poids et nous initialisons également le rayon de voisinage. Ce rayon sera grand au début pour couvrir un plus grand nombre de nœuds adjacents. Avec l'augmentation des itérations, ce rayon peut être systématiquement réduit à une distance égale à l'unité.

#### V.3.6.3 Choix des données d'entrée :

Les données d'entrée sont choisies au hasard à partir de l'ensemble des attributs.

#### V.3.6.4 Calcul de la distance euclidienne ou du produit scalaire et détermination du neurone gagnant :

La distance euclidienne ou le produit scalaire sont calculés entre l'ensemble des données d'entrée (vecteur) et chacun des nœuds neuronaux. Le nœud muni de la distance euclidienne minimale ou du produit scalaire maximum est déclaré gagnant.

Ceci détermine le nœud avec les poids les plus semblables aux attributs d'entrée.



**V.3.6.5 L'adaptation des poids du nœud gagnant et de ses voisins :**

Les poids des nœuds gagnants sont modifiés comme suit :

$$w_{(n+1)}(k,j) = w_n(k,j) + \eta(n)[x(j) - w_n(k,j)] \quad (3)$$

Où : n est le nombre d'itérations, k : le nœud gagnant et j : le j<sup>ème</sup> attribut.

$\eta(n)$ : le poids modifié sous forme d'une fonction décroissante du nombre d'itérations appelé aussi taux d'apprentissage.

Tous les nœuds associés à ce même nœud gagnant seront également modifiés, par une quantité inversement proportionnelle à la distance sur la carte. Si nous attribuons une dimension de l'ordre de un, de deux ou d'une dimension plus élevée pour chaque nœud, nous pouvons calculer la distance relative du nœud gagnant par rapport à n'importe quel autre nœud et calculer facilement les modifications.

**V.3.6.6 Adaptation des nœuds voisins selon leurs distances par rapport au nœud gagnant :**

L'adaptation des nœuds voisins du nœud gagnant selon leurs distances par rapport à ce dernier sera faite par la formule suivante :

$$w_{(n+1)}(m,j) = w_n(m,j) + d(m,k,n). \eta(n)[x(j) - w_n(m,j)] \quad (4)$$

Où :  $d(m, k, n)$  est une fonction du nombre d'itérations n et de la distance entre le nœud gagnant k et son nœud voisin m. Tous les autres nœuds en dehors du rayon associé au nœud gagnant n'auront aucune correction.

$w_n$  : Le poids du n<sup>ième</sup> nœud

**V.3.6.7 Adaptation du rayon associé à chaque nœud corrigé :**

Généralement, on considère un rayon initial assez long pour couvrir la plupart des nœuds neuronaux, ce rayon diminue en fonction de l'augmentation du nombre d'itérations. La fonction  $d(m,k,n)$  peut rendre n'importe quelle fonction inversement proportionnelle au nombre d'itérations n, et à la distance entre le nœud gagnant k et le nœud à ajuster m.

**V.3.6.8 Contrôle de la convergence pour continuer ou pour interrompre l'itération :**

On calcule l'erreur MSE (la racine carrée de la somme des carrés des erreurs. C'est-à-dire le carré de la distance entre les données d'entrée et les poids des neurones gagnants sur le nombre des données d'entrées) et contrôler si elle est au-dessous d'un certain niveau prédéfini.



Si ce test est vrai, alors l'objectif est atteint (les poids désirés), ces poids peuvent être utilisés pour la classification. Si non, on poursuit avec une nouvelle série d'itérations.

**V.3.6.9 Enregistrement des poids calculés.**

Les poids des nœuds neuronaux calculés sont des fonctions mémorisées qui seront employées pour la classification. Ces poids peuvent avoir de petites différences entre les neurones adjacents.

**V.3.6.10 Classification de l'ensemble des données d'entrée :**

Dans l'étape de classification pour chaque entrée, nous calculons la distance euclidienne de chaque nœud neuronal et classifions l'entrée en tant que membre de la classe représentée par le nœud gagnant.

**V.3.7 Organigramme du programme SOM :**

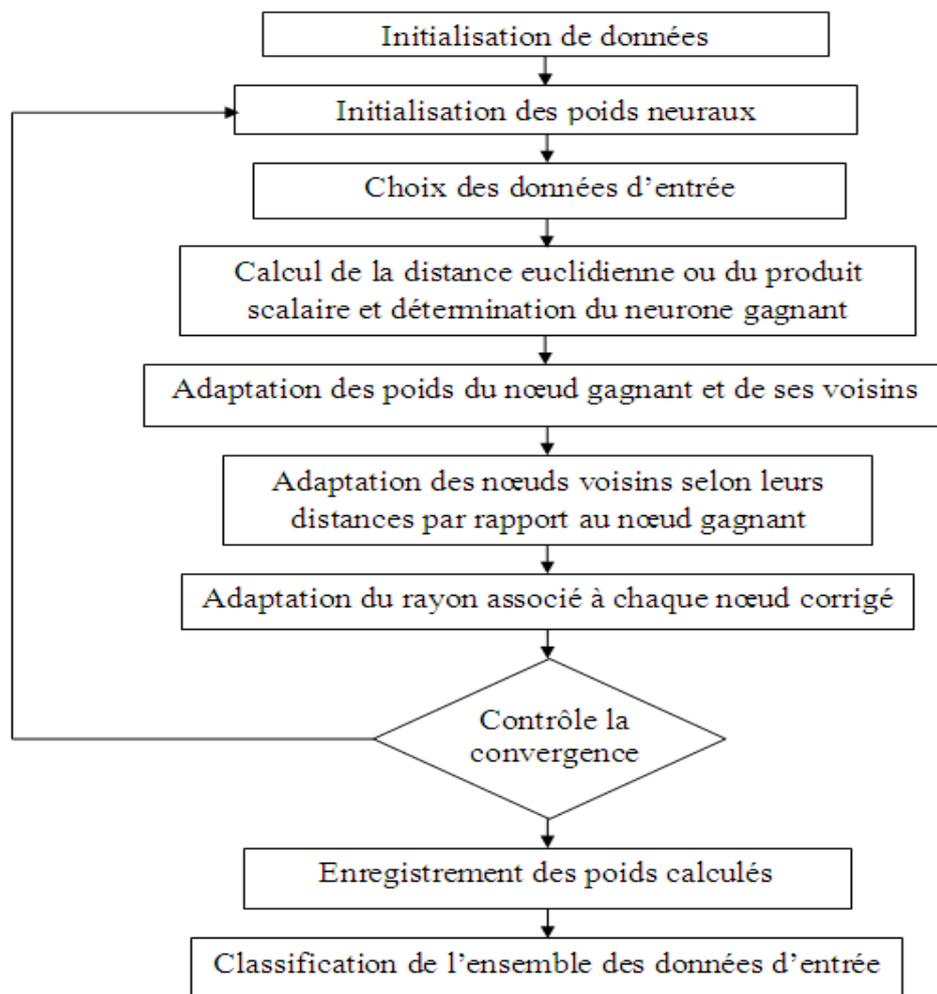


Figure V.4 : Organigramme Du Programme SOM Appliqué



#### **V.4. Application du K-SOM comme outils de classification de l'image satellitaire :**

##### **V.4.1 Définition des Paramètres :**

Une bonne classification par la méthode SOM nécessite quelques conditions que nous résumons comme suit : [13]

- Les données utilisées pour l'apprentissage doivent contenir les différentes classes qui peuvent exister dans les données à traiter. (*Sélection de la zone d'apprentissage*)
- Les attributs utilisés pour réaliser la classification doivent avoir des possibilités de discrimination pour identifier les différentes classes. (*Choix des attributs*)
- Le nombre de neurones et la configuration de carte dépendront du type de problème posé. Si le problème est simple, une structure linéaire du réseau (unidimensionnelle, 1D) peut suffire. Il a été montré que, dans des cas plus compliqués une carte bidimensionnelle (2-D) est préférable. (*Définition des dimensions de la carte*)
- Le nombre de neurones représente la dynamique du réseau pour définir les diverses classes. Devant un cas caractérisé par un petit nombre de classes, un petit nombre de neurones sera suffisant. Ainsi, des classes avec une petite densité seront séparés correctement. (*Définition du nombre de Neurones*)

Plusieurs paramètres doivent être choisis correctement pour obtenir la convergence désirée. Comme pour la plupart des autres techniques des réseaux de neurones, la technique SOM est une science d'une part et un art de l'autre. Tous les paramètres dépendront du type de problème réel et doivent être choisis par expérience.

La classification par les cartes de Kohonen (K-SOM) à deux phases importantes, La première phase de l'apprentissage s'appelle " phase de commande ". Dans cette phase on définit la topologie et tous les paramètres du réseau. La phase suivante appelée " phase de convergence ", est la phase de classification proprement dite au cours de laquelle on observe les différents résultats jusqu'à la convergence voulue. [13]

##### **V.4.2 Architecture du réseau :**

L'application est basée sur un ensemble de tests pour la détermination des paramètres optimaux du réseau. Ces paramètres sont utilisés pour la réalisation de la classification.



La couche d'entrée est composée de deux neurones responsables de recevoir les valeurs des deux premières composantes principales de l'image (on utilise les deux premières composantes principales comme paramètres d'entrées du réseau de neurones, car elle représente 99.5267 % de la variance totale).

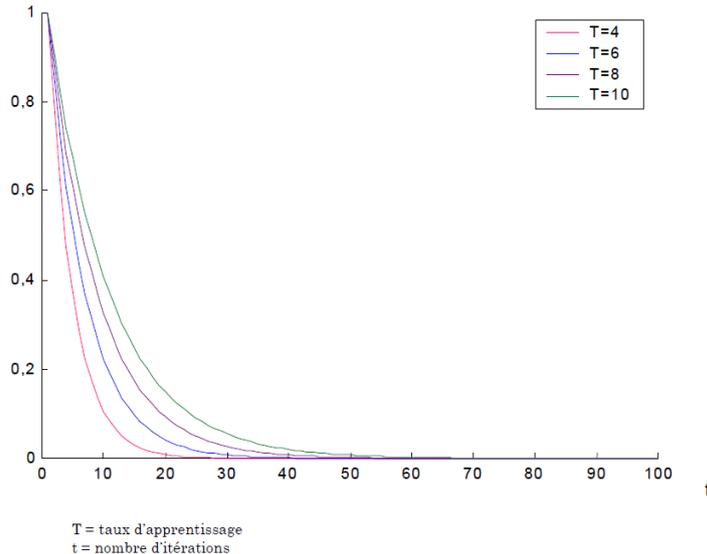
**V.4.2 Tests réalisés :**

Plusieurs tests ont été effectués en jouant sur les différents paramètres ayant une incidence sur le résultat final : le taux d'apprentissage T, le nombre d'itérations t, le nombre de neurones.

Ces tests ont permis de déterminer les valeurs optimales des paramètres du réseau :

\* Pour une valeur assez grande de T, l'adaptation est lente et, par conséquent,  $\eta(t)$  tend vers zéro lentement, ce qui induit un bon apprentissage. En revanche, de faibles valeurs de T entraînent une convergence rapide et le réseau peut oublier ce qu'il a déjà appris. [12]

Sur la figure V.5, on représente la fonction  $\eta(n) = e^{-t/T}$  pour les taux d'apprentissage suivants : T = 4, T = 6, T = 8 et T = 10.



**Figure V.5 : Évolution du pas d'apprentissage en fonction de t.**

On prend comme taux d'apprentissage T égal à 8.

\* La taille du voisinage est fixée au nombre de neurones de la couche de sortie.



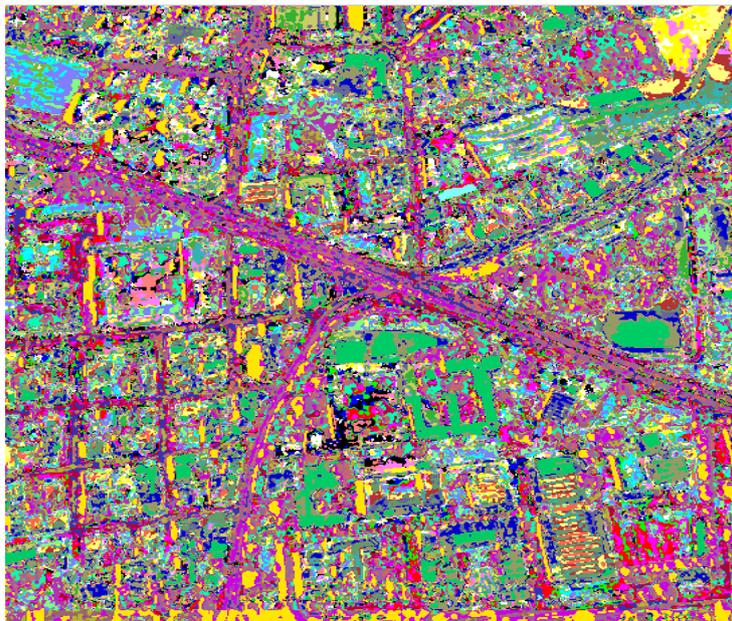
\* Une valeur assez grande de  $t$  permet un meilleur apprentissage, induisant ainsi une séparabilité des noyaux relatifs aux classes recherchées, ce qui décroît le taux d'erreur lors de l'affectation du pixel à la classe associée. Il est à noter, qu'à partir d'une valeur de  $t$  supérieure à 150, les tests donnent pratiquement les mêmes résultats (comme illustré sur le tableau V.1) :

Nombre d'itération ( $t$ )	20	70	100	150	200	500
MSE	0.0048	0.0024	0.0023	0.0015	0.0015	0.0015

**Tableau V.1 : MSE pour différents nombres d'itérations.**

\* Il est à noter aussi, qu'avec une carte de  $(6 \times 6)$  neurones, on obtient une erreur = 0.00076.

Le résultat obtenu est illustré par la figure V.6 :



**Figure V.6 : Image obtenue par classification**

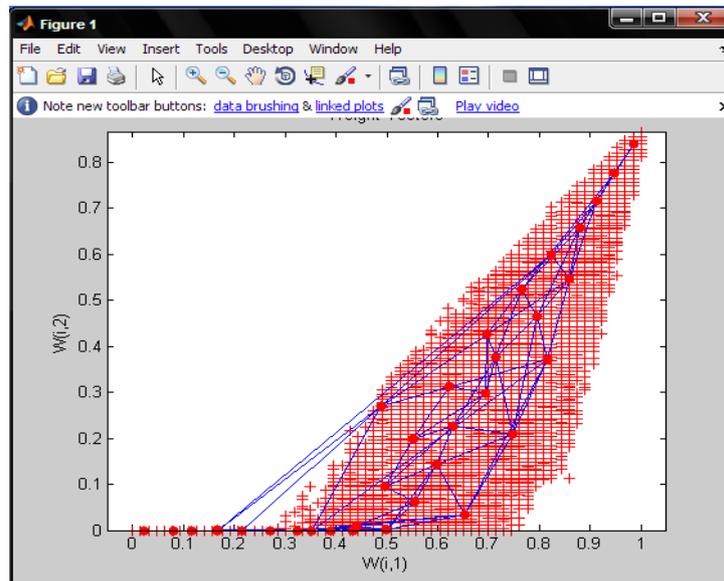


Figure V.7 : Emplacements des points de données et les vecteurs de poids

Comme l'indique la figure V.7, la carte est bien répartie dans l'espace d'entrée (la convergence).

### V.5. Conclusion :

La classification non supervisée permet de former des groupes d'objets susceptibles d'être intéressants pour l'utilisateur.

L'interprétation de l'image obtenue par K-SOM (Figure V.6) est plus facile que celle de l'image satellitaire originale (Les informations obtenues par K-SOM présentent un grand intérêt par rapport à l'image originale).

Mais malgré la qualité de l'image classifiée, on ne peut pas encore extraire le réseau routier à partir de cette image (car les routes ne sont pas représentées par une seule classe), alors on propose, comme perspective, de faire une analyse statistique à l'image classifiée pour diminuer le nombre total de classes en deux classes, l'une représentant le réseau routier et l'autre représentant le font (c'est-à-dire les autres objets).

*Conclusion*



Nous avons axé ce mémoire sur le problème de l'extraction du réseau routier à partir d'images satellitaires.

Après une synthèse des différentes approches existantes, qui se regroupent en deux catégories: semi-automatique et automatique ; nous avons présenté une méthodologie automatique, c'est la méthode d'extraction des routes par réseaux de neurones multi couches (MLP).

Nous avons utilisé les deux premières composantes principales de l'image utilisée comme paramètres d'entrées du réseau (car elle représente 99.5267 % de la variance totale). Les résultats expérimentaux sont encourageants. En effet, le réseau obtenu est proche des données de référence, et présente peu de fausses détections et d'omissions.

Ce dernier résultat a été encore amélioré en considérant d'autres caractéristiques de routes telles que leurs formes linéiques. Alors nous avons appliqué la Transformée de Hough (méthode classique de détection de lignes droites) à l'image obtenue par (MLP), dans le but d'éliminer d'avantage les zones qui ne représentent pas des réseaux routiers.

Cette transformée donne une mauvaise extraction des lignes ayant une longueur inférieure à la dimension de l'image. De ce fait, pour résoudre ce problème nous avons divisé l'image en sous images sur lesquelles nous appliquons la THS ; en effet, dans l'image obtenue on a détecté presque toutes les routes et on a diminué encore les fausses détections.

Enfin, nous avons utilisé une autre approche pour la détection des routes, c'est l'approche de classification, car l'interprétation de l'image obtenue par classification est plus facile que celle de l'image satellitaire originale. On a utilisée la classification non supervisée par la carte de Kohonen.

Nous avons appliqué un ensemble de tests pour déterminer les paramètres optimaux du réseau ; ces paramètres sont utilisés pour la réalisation de la classification.

Mais malgré la qualité de l'image classifiée qu'on a obtenue, on ne peut pas encore extraire le réseau routier à partir de cette image (car les routes ne sont pas représentées par une seule classe), alors on a proposé, comme perspective, de faire une analyse statistique à l'image obtenue par classification pour diminuer le nombre total de classes en le réduisant à deux classes, l'une représentant le réseau routier et l'autre les autres objets.

# Références Bibliographiques



- [1] Karim SAHEB ETTABAA, *vers une modélisation spatio-temporelle de scènes en imagerie satellitaire*, Thèse de Doctorat en Informatique, Ecole Nationale Supérieure des Télécommunications de Bretagne, Novembre 2007.
- [2] [http://www.lita.univ-metz.fr/~paris/Cours\\_Multimedia/exposes/ImaSat.ppt](http://www.lita.univ-metz.fr/~paris/Cours_Multimedia/exposes/ImaSat.ppt).
- [3] <http://eoedu.belspo.be/fr/guide/compprin.asp?section=3.10>
- [4] <http://www.mougel.org/informatique/IUP/IUP3/Rapport%20Traitement%20d%27Image.pdf>
- [5] Soufiane IDBRAIM, *Méthodes d'extraction de l'information spatiale et de classification en imagerie de télédétection : Applications à la cartographie thématique de la région d'Agadir (Maroc)*, Thèse de Doctorat, Université Toulouse III - Paul Sabatier, Le 16/07/2009.
- [6] BOULFANI Yasmine, DOUMANDJI Samah, *Implémentation sur DSP TMS320C5000 de filtres optimaux appliqués aux images et introduction de réseaux neuronaux*, Mémoire de fin d'études, Ecole Nationale Polytechnique, Algérie, juin 2004.
- [7] [http://gsite.univ-provence.fr/gsite/Local/umr\\_6149/umr/page\\_perso/Touzet/Les\\_reseaux\\_de\\_neurones\\_artificiels.pdf](http://gsite.univ-provence.fr/gsite/Local/umr_6149/umr/page_perso/Touzet/Les_reseaux_de_neurones_artificiels.pdf)
- [8] SEHAIRI Kamel, KORICHI Ali, *Extraction des éléments linéiques à partir d'image spot : Application au réseau routier de la ville de Laghouat*, Mémoire de fin d'études, Université Ammar Thelidji Laghouat, Algérie, 2009.
- [9] S. El mejdani, R. Egli, F. Dubeau, *Champ de hauteurs de la transformée de Hough standard*, Published in: Journal Pattern Recognition, Volume 41 Issue 6, Juin, 2008.
- [10] <http://igm.univ-mlv.fr/~vnozick/teaching/projetsMath/hough/line.pdf>
- [11] [http://www.creatis.insa-lyon.fr/~bernard/files/courses/DIP5ImageAnalysis\\_part3.pdf](http://www.creatis.insa-lyon.fr/~bernard/files/courses/DIP5ImageAnalysis_part3.pdf)
- [12] Tahar IFTENE, Habib MAHI et Hadria ISABATENb, *Approche de classification par réseaux de Kohonen pour établir des carte d'occupation du sol de la région d'Oran (Algérie)*, Contemporary Publishing International. Télédétection, 2003, vol. 3, n° 2-3-4, p. 361–372



- [13] MIHOUBI Abdelhafid, *Classification Lithologique des Attributs Sismiques par les Réseaux de Neurones Artificiels*, Mémoire de Magister, Université M'HAMED Bouguera Boumerdes, Le 26/04/2008.
- [14] BOULEMNADJEL Amel, *Partitionnement neuronal et validité des classes Application à la segmentation d'images*, Mémoire de Magister, Université Mentouri – Constantine Le 07/07/2009.
- [15] Zahzah, E, *Contribution à la représentation des connaissances et à leur utilisation pour interprétation automatique des images satellite*. Thèse de doctorat, Université Paul Sabatier de Toulouse, IRIT, 284 p, (1992).
- [16] Lambert, E, *Étude des techniques d'optimisation et de différents réseaux de neurones appliqués à la séparation de signaux en traitement du signal : Application à l'approximation de fonctions multivariées*. Mémoire de DEA, Université de Haute-Alsace, Mulhouse, 58 p, (1999).
- [17] Sakoda, W, Hu, J, Pavlidis, T, *Computer Assisted Tracing of Faint Roads in Satellite Imagery*, ACSM/ ASPRS, New Orleans, 1993.
- [18] Zlotnick, A, Carnine, P.D, *Finding roads seeds in aerial images*, Computer Vision, Graphics, and Image Processing, Image Understanding, vol. 57, no. 2, pp. 243-260, 1993.
- [19] Airault, S, Jamet, O, *Détection et restitution automatiques du réseau routier à partir d'images aériennes*, Traitement Signal, vol. 12, no. 2, 189–200 (Hermès), 1995.
- [20] Ruskoné, R, *Extraction automatique du réseau routier par interprétation locale du contexte*, Thèse de Doctorat, Université de Marne la Vallée, 1996.
- [21] Chiang, T.Y, Hsieh, Y.H, Lau, W, *Automatic road extraction from aerial images*, Stanford education, 2001.
- [22] Vosselman, G, De Knecht, J, *Road tracking by profile matching and Kalman filtering*, In: Gruen, Kuebler, Agouris, (Eds.), Workshop on Automatic Extraction of Man-Made Objects from Aerial and Space Images. Birkhauser, Basel, pp. 265–274. 1995.
- [23] Kass, M, Witkin, A, Terzopoulos, D, *Snakes: Active contour models*, Internat. J. Comput. Vis, pp. 321-331, 1987.
- [24] Benjamin, S, Gaydos, L, *Spatial resolution requirements for automated cartographic road extraction*, Photogrammet. Eng. Remote Sensing, vol. 56, no. 1, pp. 93-100, 1990.



- [25] Bhattacharya, U, Parui, S.K, *An improved back propagation neural network for detection of road-like features in satellite imagery*, International Journal of Remote Sensing, vol. 18, pp. 3379-3394, 1997.
- [26] Matheron, G, *Random Sets and Integral Geometry*, Wiley, New York, 1975.
- [27] Serra, J, *Image Analysis and Mathematical Morphology*, vol. 1, Academic Press, London, 1982.
- [28] Zhang, C, Murai, S, Baltsavias, E, *Road network detection by mathematical morphology*, In: Proc. ISPRS Workshop on 3D Geospatial Data Production: Meeting Applicat. Requirements, Paris, pp. 185–200, 1999.
- [29] Duda, R.O, Hart, P.E, *Pattern Classification and Scene Analysis*, John Wiley & Sons, NY, USA, 1973.
- [30] Heipke, C, Steger, C, Multhammer, R, *A hierarchical approach to automatic road extraction from aerial imagery*, In: McKeown, Jr. D.M, Dowman, I.J. (Eds), Integrating Photogrammetric Techniques with Scene Analysis and Machine Vision II, Proc. SPIE 2486, pp. 222-231, 1995.
- [31] Baumgartner, A, Steger, C, Wiedemann, C, Mayer, H, Eckstein, W, Ebner, H, *Update of roads in GIS from aerial imagery: Verification and multi-resolution extraction*, Internat. Arch. Photogrammet. Remote Sensing, vol. 31, no. 3, pp. 53–58, 1996.
- [32] Rellier, G, Descombes, X, Zerubia, J, *Local registration and deformation of a road cartographic database on a SPOT satellite image*, Pattern Recognition vol. 35, pp. 2213–2221, 2002.
- [33] Bordes, G, *Interprétation d'images aériennes guidée par une base de données cartographique: application à l'extraction automatique des routes*, thèse de doctorat, Université de Marne-la-Vallée, Marne-la-Vallée, France, 271 p, 1997.

# ANNEXE 1

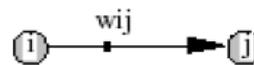
## *Règles d'apprentissage*



### 1. Règle de Hebb :

La première règle d'apprentissage connexionniste fut non supervisée, elle est inspirée de la biologie. En effet vers la fin des années 40, Hebb propose l'idée que le cerveau s'adapte à son environnement en modifiant l'efficacité des connexions entre neurones. Cette modification serait proportionnelle à l'activité simultanée des neurones reliés par la connexion. L'hypothèse est ici qu'une synapse améliore son efficacité seulement quand l'activité de ses deux neurones est corrélée. Le principe de Hebb demeure aujourd'hui biologiquement plausible, et la modification du poids synaptique qu'il décrit a été formulée mathématiquement de la façon suivante : [6]

$$W_{ij} = \eta \cdot a_i \cdot a_j$$



Où :

- $\eta$  ( $0 < \eta \ll 1$ ) est une constante quelconque.
- $W_{ij}$  représente le poids synaptique entre les neurones i et j.
- $a_i \cdot a_j$  représente la corrélation entre l'activation des neurones i et j du réseau.

Appliquée aux réseaux neuromimétiques, cette règle simple pousse les neurones à corrélérer leurs activations avec les valeurs des patrons d'entrée. Un des intérêts d'un tel comportement réside dans le cadre des mémoires associatives, et plusieurs modèles connexionnistes ont été proposés avec des variantes de l'apprentissage hebbien.

La corrélation d'activation peut avoir des effets utiles. Cependant, il n'en demeure pas moins qu'il soit un critère d'apprentissage fort limité, car il ne tient pas compte de la nature de la tâche qu'il doit effectuer. [6]

### 2. Règle du delta (ou règle de Widrow-Hoff) :

Son but est de faire évoluer le réseau vers le minimum de sa fonction d'erreur (erreur commise sur l'ensemble des exemples). L'apprentissage est réalisé par itération (les poids sont modifiés après chaque exemple présenté), et on obtient le poids à l'instant  $t+1$  par la formule :



$$\mathbf{w}(t + 1) = \mathbf{w}(t) + \eta * (\mathbf{y}^{des} - \mathbf{y}) \cdot \mathbf{x} \quad (1)$$

Où :  $\mathbf{w}$  est le poids,  $\mathbf{y}^{des}$  est la sortie théorique et  $\mathbf{y}$  est la sortie réelle,  $\mathbf{x}$  est l'entrée et  $\eta$  est un coefficient d'apprentissage (entre 0 et 1) que l'on peut diminuer au cours de l'apprentissage.

C'est en fait un cas particulier de l'algorithme de rétropropagation du gradient. [6]

### 3. *Rétropropagation du gradient (backpropagation) :*

La plupart des algorithmes d'apprentissage permettent d'obtenir les poids par minimisation d'une fonction de coût dérivable. La méthode la plus simple pour procéder à une minimisation est la méthode du gradient.

A un vecteur d'entrée, on veut associer un vecteur de sortie désiré. Si les poids ont des valeurs quelconques, le vecteur de sortie observé est a priori différent de celui désiré. On peut associer à cette différence l'erreur quadratique. *On peut modifier les poids du réseau en minimisant cette erreur quadratique.*

La mise à jour de l'ensemble des poids d'une couche nécessite la connaissance des erreurs associées à chaque neurone de la couche suivante. On appliquera l'algorithme d'ajustement des poids en partant de la dernière couche (pour laquelle les erreurs sont connues) vers la première, d'où l'appellation de cet algorithme : Algorithme de rétropropagation du gradient de l'erreur, ou simplement « backpropagation Algorithm » dans la désignation anglo-saxonne. [13]

La figure 1 représente un réseau simple composé d'une couche d'entrée, une seule couche cachée et une couche de sortie.

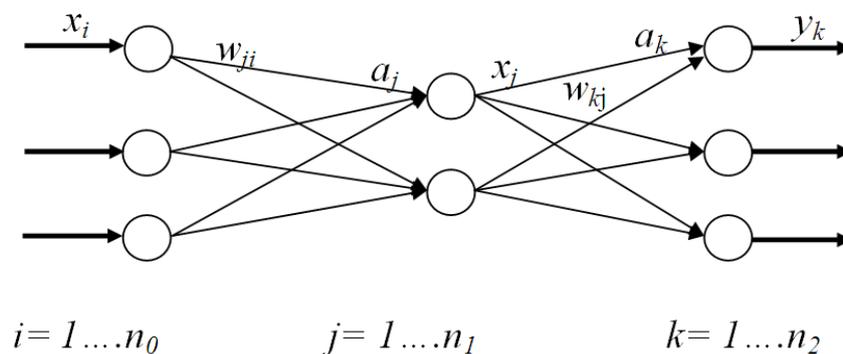


Figure 1 : Adaptation des poids



**Fonction de coût :**

On présente un exemple:  $X = [x_1, x_2, \dots, x_{n0}]$ , et on calcule la sortie correspondante:

$$Y = [y_1, \dots, y_{n2}]$$

Le vecteur d'erreur sera :

$$e_k = y_k^{des} - y_k \quad (2)$$

Où :  $y_k^{des}$  est la sortie désirée.

En utilisant la méthode de calcul au sens des moindres carrés, on calcule les opérateurs  $w$  qui minimisent la somme des carrés de la fonction d'erreur. [13]

$$E = \frac{1}{2} \sum_{k=1}^{n2} e_k^2 = \frac{1}{2} \sum_{k=1}^{n2} (y_k^{des} - y_k)^2 \quad (3)$$

Le gradient d'une surface d'erreur de  $n$  dimensions est donné par le vecteur défini par les dérivées partielles de la fonction d'erreur. Lorsqu'on atteint un minimum, la fonction:  $\frac{\partial E}{\partial w}$  sera égale à zéro pour toutes les valeurs de  $w$ .

Puisque le gradient est donné par les dérivées partielles, si nous utilisons comme variation des poids  $\Delta w$  proportionnels aux dérivées, nous obtenons l'erreur correspondante : [13]

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (4)$$

Avec :  $0 < \eta < 1$

Il ne faut pas oublier qu'on a des couches cachées, on retro-propage alors l'erreur commise vers l'arrière jusqu'à la couche d'entrée tout en modifiant la pondération alors :

**1-Pour la couche de sortie :**

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial a_k} \cdot \frac{\partial a_k}{\partial w_{kj}} \quad (5)$$

On a:  $\frac{\partial E}{\partial y_k} = -(y_k^{des} - y_k)$  car:  $E = \frac{1}{2} \sum_{k=1}^{n2} (y_k^{des} - y_k)^2$

$\frac{\partial y_k}{\partial a_k} = f'(a_k)$  car:  $y_k = f(a_k)$



$$\frac{\partial a_k}{\partial w_{kj}} = x_j \quad \text{car: } a_k = \sum_{j=1}^{n_1} w_{kj} \cdot x_j$$

$$\text{Posons : } Errk = \frac{\partial E}{\partial a_k} = -(y_k^{des} - y_k) \cdot f'(a_k) \quad (6)$$

$$\text{Donc : } \frac{\partial E}{\partial w_{kj}} = Errk \cdot x_j \quad (7)$$

2-Pour la couche cachée :

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial a_k} \cdot \frac{\partial a_k}{\partial x_j} \cdot \frac{\partial x_j}{\partial a_j} \cdot \frac{\partial a_j}{\partial w_{ji}} \quad (8)$$

$$\frac{\partial a_k}{\partial x_j} = w_{kj} \quad \text{car: } a_k = \sum_{j=1}^{n_1} w_{kj} \cdot x_j$$

$$\frac{\partial x_j}{\partial a_j} = f'(a_j) \quad \text{car: } x_j = f(a_j)$$

$$\frac{\partial a_j}{\partial w_{ji}} = x_i \quad \text{car: } a_j = \sum_{i=1}^{n_0} w_{ji} \cdot x_i$$

$$\frac{\partial E}{\partial w_{ji}} = Errk \cdot w_{kj} \cdot f'(a_j) \cdot x_i$$

$$\text{On pose: } Errj = Errk \cdot w_{kj} \cdot f'(a_j)$$

Donc:

$$\frac{\partial E}{\partial w_{ji}} = Errj \cdot x_i \quad (9)$$



*Changement des poids :*

*1-couche de sortie :*

$$w_{kj} = w_{kj} + \Delta w_{kj} = w_{kj} - \eta \frac{\partial E}{\partial w_{kj}} = w_{kj} - \eta \cdot Err_k \cdot x_j \quad (10)$$

*2-couche de cachée :*

$$w_{ji} = w_{ji} - \eta \cdot Err_j \cdot x_i \quad (11)$$

# ANNEXE 2

## *Interface graphique*



## **1. Introduction :**

Cette annexe est consacrée à la présentation des différents résultats que nous avons obtenus en appliquant les méthodes qui ont fait l'objet de ce mémoire.

Nous avons conçu notre interface sous environnement Windows, langage Matlab. Ainsi, nous avons exploité les fonctionnalités offertes par l'interface graphique puissante du Matlab, afin de concevoir une interface conviviale et souple pour l'utilisateur. Dans cet objectif, nous avons utilisé des fenêtres, menus et boîtes de dialogues,...

## **2. Présentation de l'application :**

Nous appelons notre application en tapant **Interfacegraphique** dans l'invité de commande de Matlab, à ce moment apparaît la fenêtre de démarrage (comme le montre la figure 1).



**Figure 1 : Fenêtre de démarrage**

## **3. Phase d'apprentissage :**

Cette partie permet d'appliquer les algorithmes d'apprentissage des deux types de réseaux de neurones utilisés (MLP et K-SOM).

Une fois que les réseaux convergent, on peut les utiliser pour détecter les routes, quelque soit l'image utilisée.

Cette partie regroupe les étapes suivantes :

- Le calcul des composantes principales de l'image (pour les utiliser comme paramètres d'entrée du réseau).
- L'apprentissage du réseau de neurones (MLP).



- La transformée de Hough de l'image obtenue par MLP.
- L'apprentissage de la carte de Kohonen.

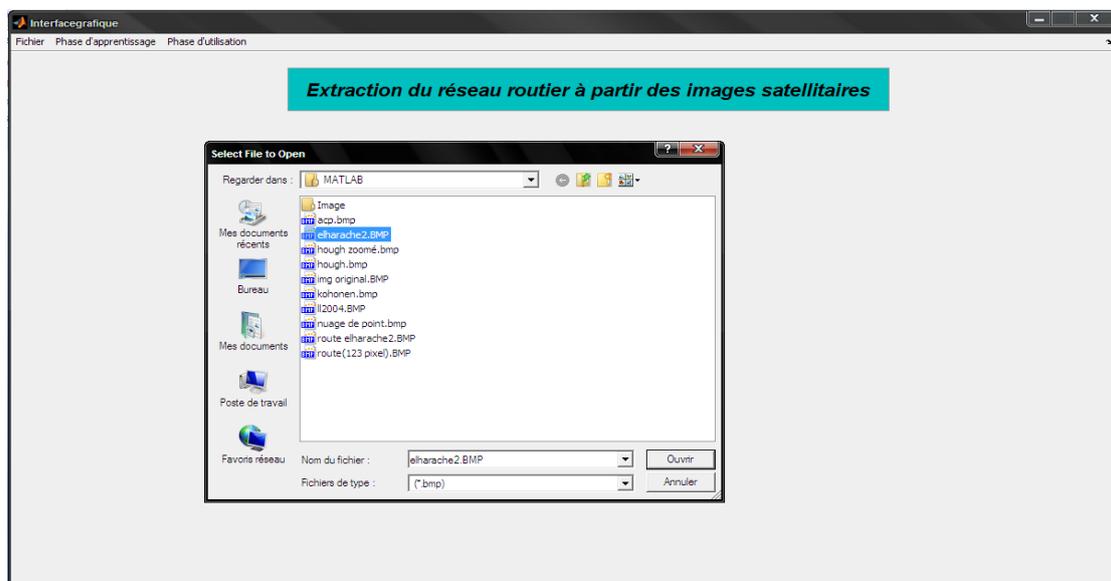
Les figures ci-dessous montrent toutes les étapes à suivre.

### 3.1 Chargement de l'image :

Si on clique sur la commande **'Open'** du Menu **'Phase d'apprentissage'**, la boîte de dialogue de la figure 3 apparaît qui permet de choisir l'image à utiliser pour faire l'apprentissage du réseaux de neurones.



**Figure 2 : Choix de La phase d'apprentissage**



**Figure 3 : Boite de dialogue pour choisir l'image à utiliser**

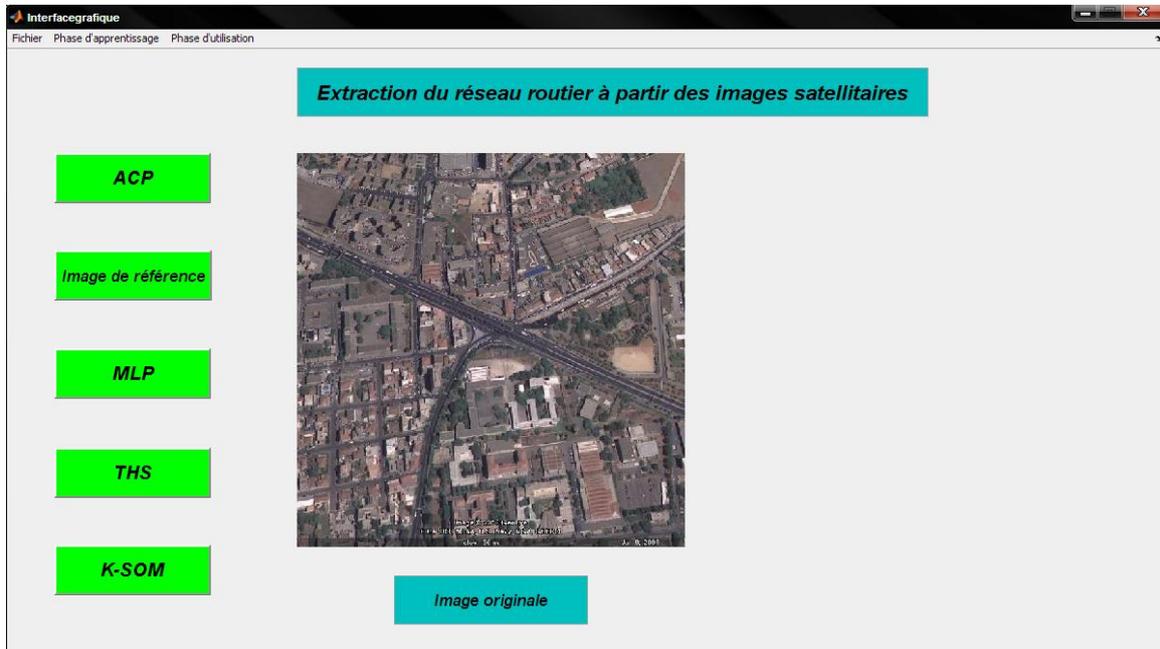


Figure 4 : chargement de l'image

### 3.2 Calcul des ACP :

Si on clique sur le bouton 'ACP', le programme va calculer les composantes principales de l'image chargée et afficher l'image des ACP comme le montre la figure 5.



Figure 5 : Calcul et affichage des ACP de l'image utilisée



### 3.3 Chargement de l'image de référence :

Si on clique sur le bouton 'Image de référence', la boîte de dialogue de la figure 6 apparaît qui permet de charger l'image à utiliser comme image de référence.

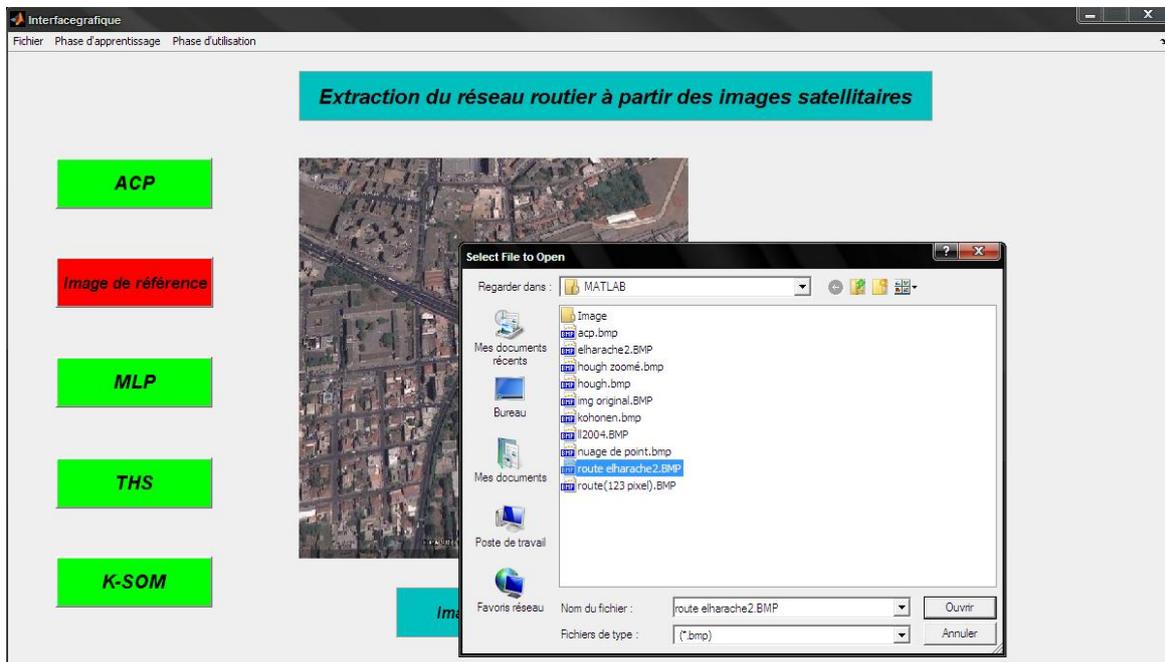


Figure 6 : Boîte de dialogue pour choisir l'image de référence

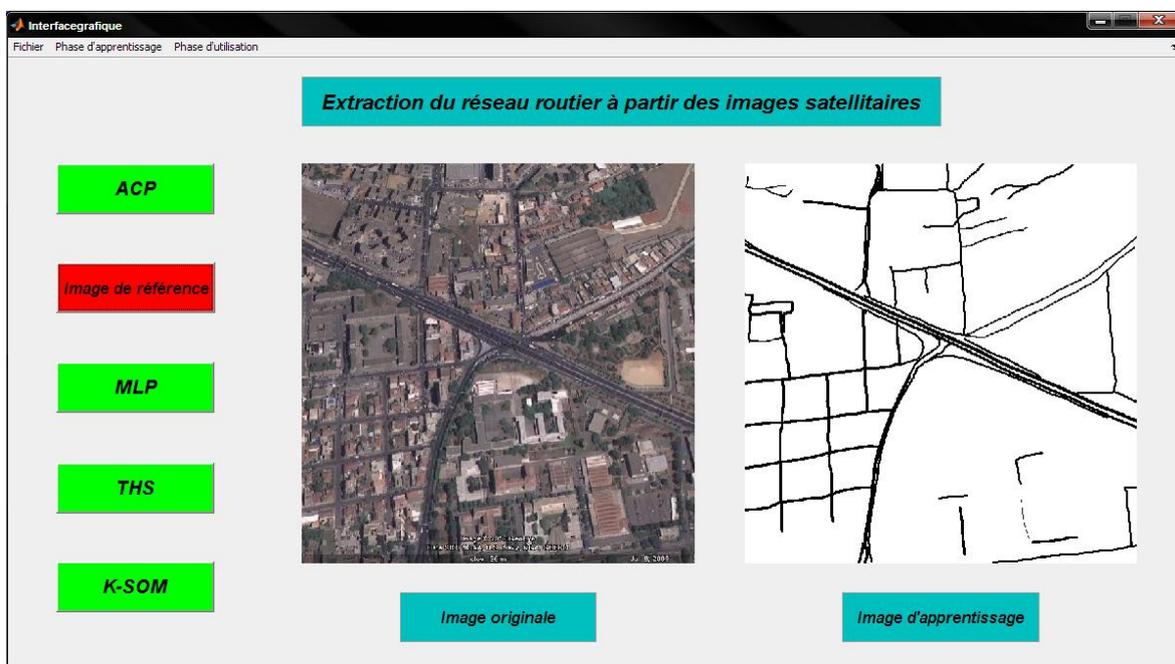


Figure 7 : Chargement de l'image des routes de référence



### 3.4 Apprentissage du MLP :

Si on clique sur le bouton 'MLP', la fenêtre de progression de l'apprentissage du MLP apparaît comme le montre la figure 8.

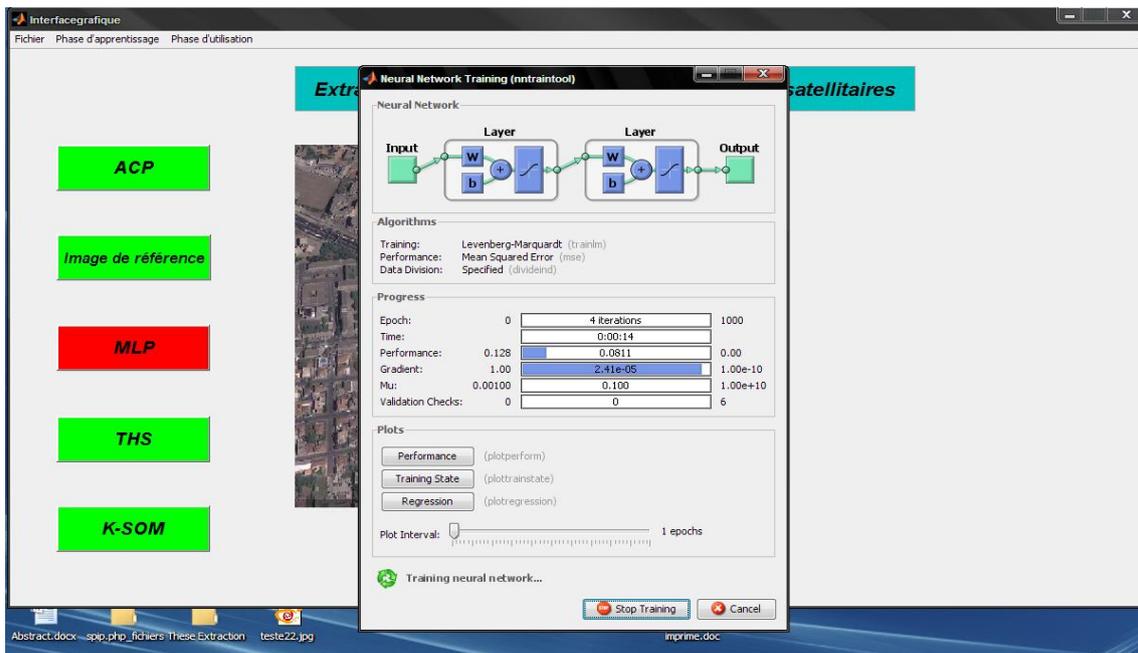


Figure 8 : fenêtre de progression de l'apprentissage du MLP

### 3.5 Extraction des routes par MLP :

Une fois que le réseau converge, on peut le tester par l'image utilisée en apprentissage, le résultat obtenu est illustré par la figure 9.

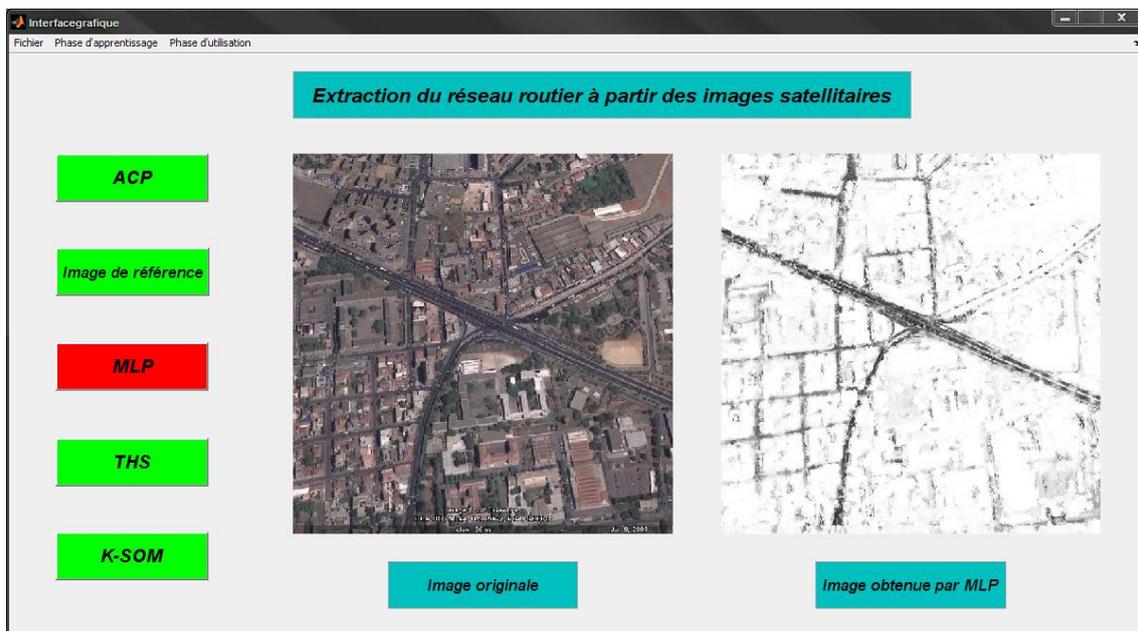


Figure 9 : Extraction des routes par MLP



### 3.6 La THS de l'image obtenue par MLP :

Si on clique sur le bouton 'THS', le programme va calculer la THS de l'image obtenue par MLP et afficher le réseau routier trouvé comme le montre la figure 10.



Figure 10: La THS de l'image obtenue par MLP

### 3.7 Apprentissage du K-SOM :

Si on clique sur le bouton 'K-SOM', la fenêtre de progression de l'apprentissage de la carte SOM apparaît comme le montre la figure 11.

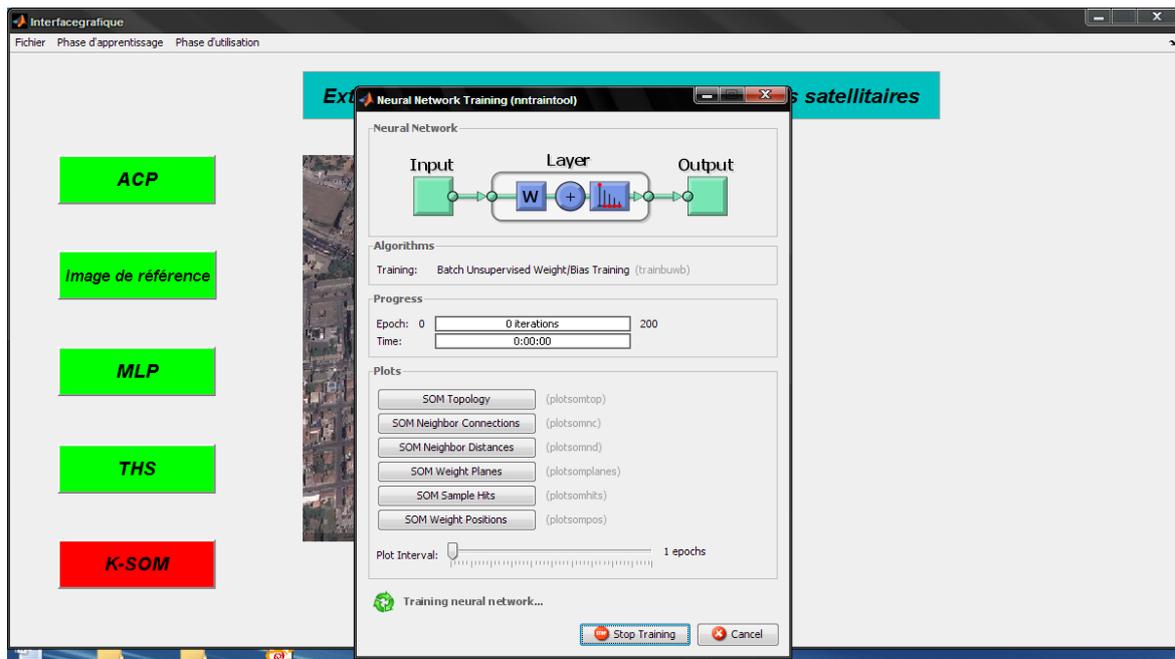


Figure 11 : fenêtre de progression de l'apprentissage du K-SOM



Après la convergence du réseau, si on clique sur ‘*SOM Weight Positions*’ de la fenêtre de progression de l’apprentissage du K-SOM, la figure 12 apparaît, qui montre l’emplacement des points de données et les vecteurs de poids.

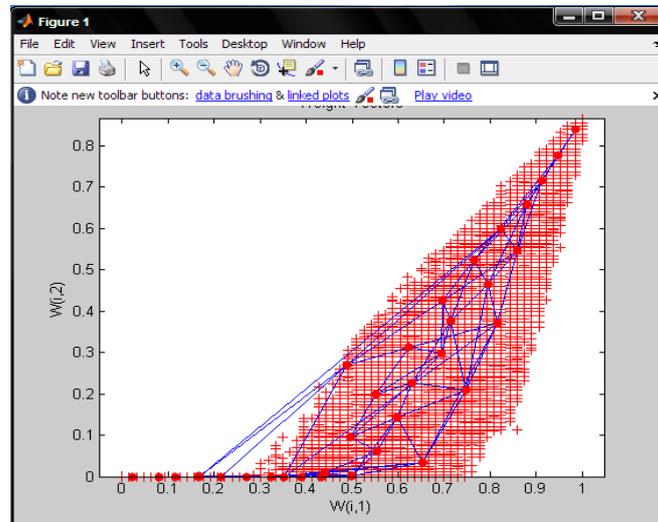


Figure12 : Emplacements des points de données et les vecteurs de poids

### 3.8 Classification par K-SOM :

Une fois que le réseau converge, on peut le tester par l’image utilisée en apprentissage, le résultat obtenu est illustré par la figure 13.

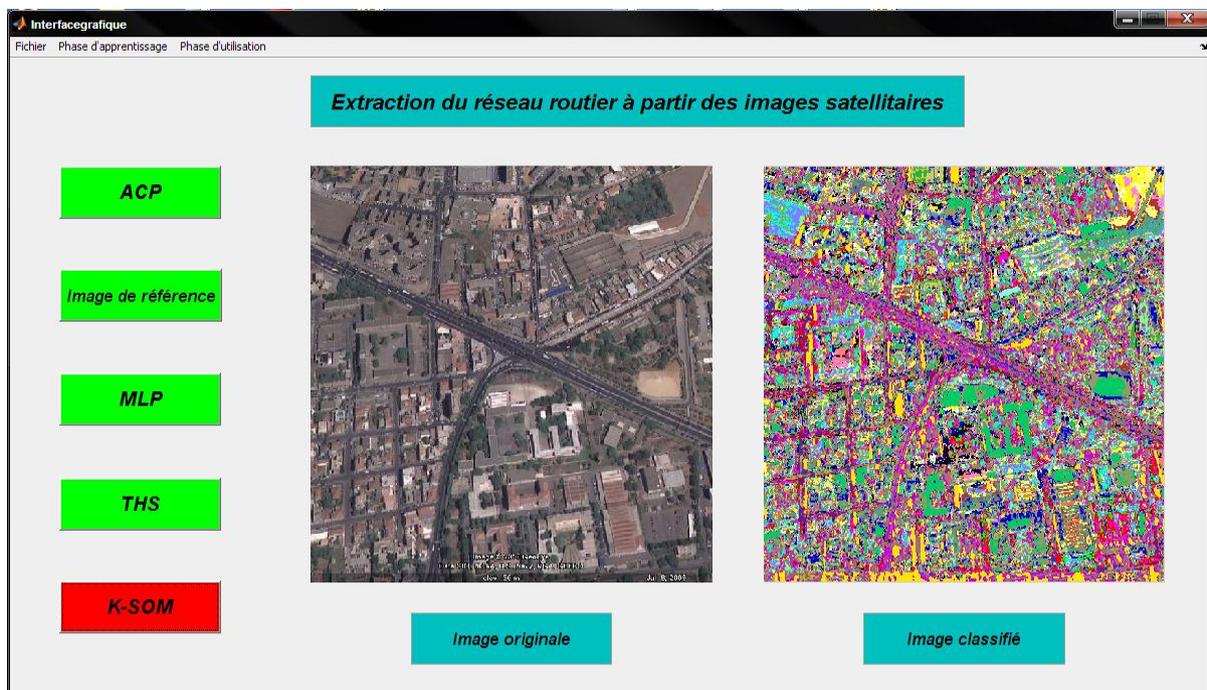


Figure 13 : Classification de l’image utilisée



#### 4. Phase d'utilisation :

A partir de la phase précédente, et après convergence des réseaux, on peut les utiliser pour l'extraction du réseau routier pour d'autres images.

Les figures ci-dessous montrent toutes les étapes à suivre pour détecter les routes dans une image quelconque (de même résolution que l'image utilisée dans la phase d'apprentissage)

##### 4.1 Chargement de l'image :

Si on clique sur la commande 'Open' du Menu 'Phase d'utilisation', la boîte de dialogue de la figure 15 apparaît qui permet de choisir une image.



Figure 14 : Choix de La phase d'utilisation

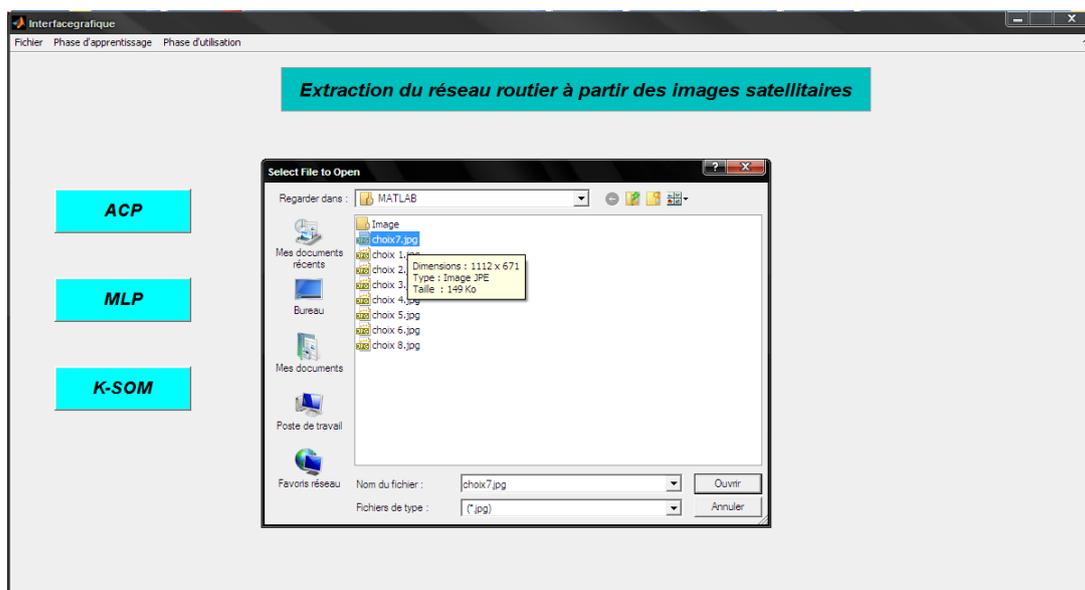


Figure 15 : Boîte de dialogue pour choisir l'image



Figure 16 : chargement de l'image

#### 4.2 Calcul des ACP :

Si on clique sur le bouton 'ACP', le programme va calculer les composantes principales de l'image choisie et afficher l'image des ACP, comme le montre la figure 17.

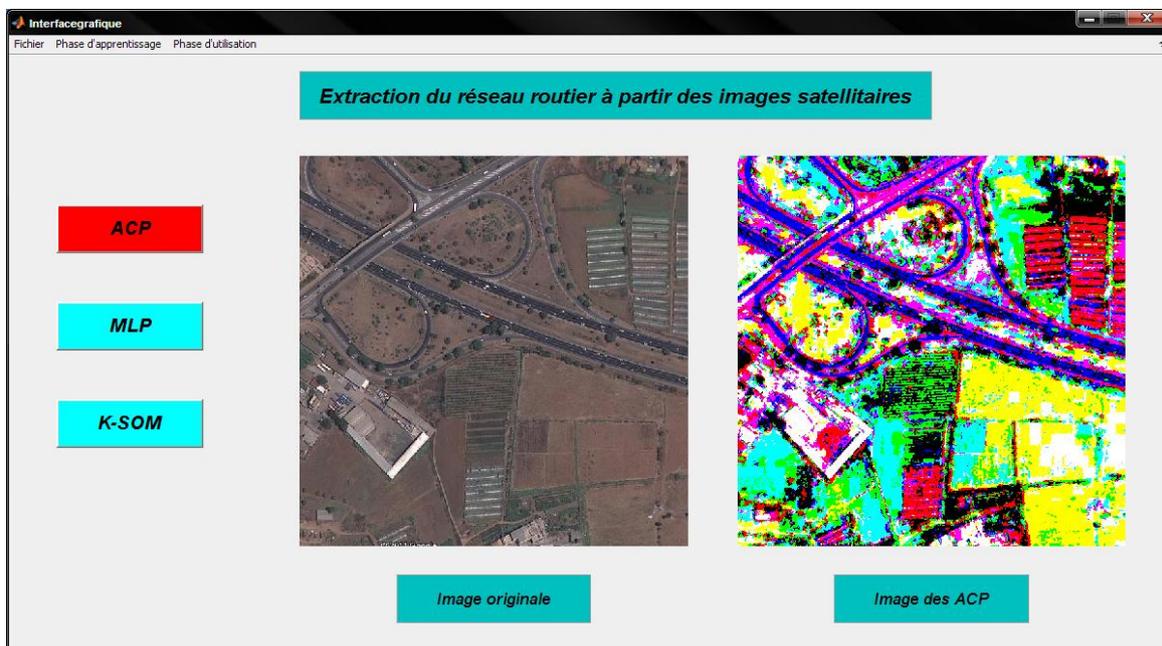


Figure 17 : Calcul et affichage des ACP de l'image



### 4.3 Extraction des routes par MLP :

La figure 18 illustre le réseau routier, obtenu par MLP, de l'image choisie.



Figure 18 : Extraction des routes par MLP

### 4.4 Classification par K-SOM :

Le résultat de la classification par K-SOM de l'image choisie est illustré par la figure 19.



Figure 19 : Classification de l'image



Enfin la conception de notre application '*Interfacegraphique*' reste ouverte à de futures améliorations pour obtenir de meilleures performances.