

Table des matières

Table des figures	2
Liste des tableaux	3
1 Introduction	5
2 Matériel	6
2.1 La zone d'étude	6
2.2 Le type d'images	6
2.3 Vérité terrain	6
3 État de l'Art des Méthodes de Segmentation / Classification	8
3.1 Introduction	8
3.2 Les Snakes	8
3.3 La Ligne de Partage des Eaux ou Watershed	8
3.4 La Connexité Floue	9
3.5 Champs de Markov	9
3.6 Les ondelettes	9
3.7 L'analyse de texture	10
3.8 Conclusion	10
4 Analyse du problème	11
4.1 Choix des indices de texture	11
4.1.1 Les indices de texture	11
Paramètres d'ordre 1	11
Co-occurrence	11
Différence de niveaux de gris	12
Longueurs de plages	12
Image de gradient	13
4.1.2 L'orientation et le vecteur de translation	13
4.1.3 La taille du voisinage	14
4.1.4 Conclusion	14
4.2 Choix des classes	15
4.3 Choix de la méthode de classification	16
5 Réseaux de Neurones	17
5.1 Modèle de neurone et réseau	17
5.1.1 Le neurone biologique	17
5.1.2 Le neurone formel	18
5.2 Perceptron multicouche et Rétropropagation	18
5.3 Réseau de l'étude	19
5.3.1 Le réseau	19

TABLE DES MATIÈRES

5.3.2 L'apprentissage	20
6 Résultat	21
7 Conclusion et Perspectives	22
7.1 Conclusion	22
7.2 Perspectives	22
Bibliographie	23
1 Glossaire	27
2 Localisation de la zone d'étude	28
3 Tableau recapitulatif des indices de texture	29

Table des figures

4.1	Exemples de vecteur de translation et orientation	13
4.2	Taille des voisinages	14
4.3	Taille des voisinages dans notre cas d'étude	15
4.4	Comparaison des textures : a) vieux abricotiers, b) vieux pêcheurs, c)vieux oliviers, d)vieux cerisiers, e) jeunes abricotiers, f) pommier, g) pré, h) champ, i) forêt, j) fiche, k) culture vivrière, l) vigne	16
5.1	Neurone Biologique	17
5.2	Neurone formel	18
5.3	Schéma représentatif du réseau	20
2.1	Zone de l'étude : en rouge les parcelles visitées sur le terrain	28

Liste des tableaux

2.1	Caractéristiques de notre image QuickBird	7
5.1	Exemples de Fonction de Transfert (FT)	19

Chapitre 1

Introduction

Cette étude s'inscrit dans le cadre d'un projet financé par le PNTS¹ intitulé "Nouvelles méthodologies d'extraction de l'information en imagerie satellite à Très Haute Résolution Spatiale (THRS)" pour la caractérisation de la végétation.

Ce projet consiste à développer des outils permettant d'extraire les informations contenues dans les images THRS² afin d'analyser et d'évaluer les systèmes d'agro-foresterie. Pour cela, il faut pouvoir estimer des indicateurs du fonctionnement de l'arbre (forme, taille, état physiologique, ...), mais aussi décrire l'organisation spatiale des arbres au sein de la parcelle (densité de plantation, organisation de la plantation, ...). Mais il paraît nécessaire dans un premier temps de détecter les zones homogènes (proches du parcellaire agricole) arborées et de les isoler de façon à les traiter individuellement.

Le premier travail à réaliser consiste donc en une segmentation et/ou classification renseignant si possible sur la nature de la plantation (espèces cultivées). C'est sur ce premier volet du projet que porte le travail présenté ici.

Ce stage a été effectué au sein du laboratoire GEOTROP situé à la Maison de la Télédétection (MTD) de Montpellier et dépendant du Centre de Coopération Internationale en Recherche Agronomique pour le Développement (CIRAD). Geotrop regroupe une vingtaine de personnes qui travaillent dans le domaine de la géomatique (télédétection, SIG, ...) appliquée à l'aide au développement de l'agriculture dans les pays tropicaux. Un des enjeux de cette recherche est de proposer des produits, cartographiques en particulier, à des coûts d'acquisition de la donnée limités, en raison de leur destination vers les pays en voie de développement. En ce sens la présente étude s'est limitée à l'utilisation d'une seule image satellite panchromatique.

L'objectif de mon stage a donc été de développer un algorithme de traitements d'une image THRS¹ panchromatique, acquise sur une zone agricole, dans le but de reconnaître et cartographier les parcelles de type vergers et autres plantations d'arbres (exemple : oliveraies, pinèdes, ...)

Ce rapport présente un état de l'art des techniques de segmentation et/ou de classification des images, les données utilisées pendant le stage et la méthode employée pour résoudre mon sujet de stage tout en justifiant et en discutant mes choix. Enfin j'apporterai une conclusion sur mon stage.

¹Programme National de Télédétection Spatiale

²Très Haute Résolution Spatiale

Chapitre 2

Matériel

2.1 La zone d'étude

La zone sur laquelle porte notre étude est située en France, au Sud de Nîmes dans le Gard (cf Annexe 2). Au Nord Est de la zone se trouve la base de l'armée de l'air de Garons, au Sud Est la ville de St-Gilles et au Nord Ouest la ville de Générac.

Cette zone a été choisie pour plusieurs raisons :

- elle est riche en vergers de toutes sortes (abricotiers, pommiers, pêchers, ...) ;
- un institut technique de recherches en agronomie, le SERFEL ¹ , y est localisé. De surcroît, ce centre cultive de nombreuses parcelles dans le secteur. Ceci nous permettra d'obtenir des informations précieuses sur la physiologie et la conduite de culture des arbres de ces parcelles, dans une étude ultérieure portant sur la caractérisation intra-parcellaire des vergers.

2.2 Le type d'images

Nous allons utiliser des images QuickBird ² car ce capteur fournit l'une des meilleures résolutions spatiales accessibles par satellite civil, de l'ordre de 70 cm par pixel. Grâce à cette résolution, on peut commencer à observer les arbres, car ils ont une taille bien supérieure (4 ou 5 mètres en moyenne) à la résolution de l'image (70 cm). Un arbre couvrira donc plusieurs pixels.

Mais cela n'est pas vrai pour tous les arbres puisque les petits (exemple : plantier) ont une taille d'environ 50cm donc inférieure à la résolution de l'image. Pour ces arbres un pixel donné sera donc une composition entre sol et arbre. Enfin, il faut noter que les jeunes arbres n'ont pas un feuillage très dense. Par conséquent même si l'arbre couvre en surface un pixel, la radiométrie obtenue est une composition entre les radiométries du sol et de l'arbre. Sur ce point nous touchons une limite de la méthode liée à la résolution de l'image.

L'image utilisée pour ce travail, acquise le dimanche 3 juillet 2005, possède les caractéristiques décrites dans le tableau 2.1. Il faut noter que le polygone délimitant la zone d'étude est découpé de manière à optimiser la surface utile (par exemple nous avons contourné les villes).

2.3 Vérité terrain

Nous avons par ailleurs procédé à une collecte d'informations de terrain vers la fin du mois de juin. Nous avons référencé environ 1000 parcelles, avec plus ou moins de détails sur la nature de la

¹Station Expérimentale de Recherches en Fruits et Légumes. <http://www.serfel.fr>

²Capteur multispectral américain, développé par Digitalglobe. <http://www.digitalglobe.com>

	Caractéristiques
Résolution	70 cm
Nombre de lignes	15704
Nombre de colonnes	15988
Format de Sortie	GeoTIFF
Taille (Mo)	239.8
Géoiide	WGS84
Type de projection	UTM
Zone	31N
Coordonnées géographiques du centre	43°43'N - 4°24'E

TAB. 2.1 – Caractéristiques de notre image QuickBird

culture pratiquée sur ces parcelles, en nous repérant à l'aide d'une ancienne image aérienne de la zone.

Une fois l'image QuickBird acquise nous avons saisi ces informations sous la forme d'une couche vectorielle de type SIG³, en numérisant manuellement les parcelles sous le logiciel ENVI⁴. Cette base de données constitue la référence de vérité terrain permettant d'une part l'apprentissage de la méthode et d'autre part la validation des résultats. Chaque parcelle peut être extraite suivant ses attributs et constituer un champ d'information lié par exemple au type d'occupation du sol (verger, champ, forêt, ...).

³Système d'Information Géographique

⁴Environnement for Vizualing Images Research Systems <http://www.researchsystems.com>

Chapitre 3

État de l'Art des Méthodes de Segmentation / Classification

3.1 Introduction

La segmentation / classification d'images panchromatiques est un domaine actif de la recherche en image numérique. En effet, depuis les années 1960 de nombreux travaux ont été entrepris dans ce domaine, dans divers secteurs d'application tels que la médecine, la défense ou encore la météorologie (cette liste n'étant pas exhaustive). Ce problème est difficile à résoudre et dépend fortement du type d'image que l'on désire analyser. Dans le domaine de l'imagerie satellite, sa complexité n'a fait qu'augmenter avec la résolution spatiale, car les objets réels peuvent y être identifiés.

De nombreuses méthodes ont été mises au point, que ce soit à base de détection de contours, de croissance des régions (Adams et Bischof, 1994 [1]), de contours actifs (Snakes) (Kass et al, 1988 [2]) ou encore de morphologie mathématique (Meyer et Beucher, 1990 [3]), ondelette (voir Mallat, 1998 [4] pour une présentation générale des ondelettes), analyse de texture (Haralick, 1973 [5]), ou champs de Markov (notamment Hu et Fahmy, 1992 [6]) pour ne citer que les plus importantes. Toutes ces méthodes ont fait l'objet de multiples optimisations et sont capables de répondre à de nombreux problèmes liés à la segmentation.

3.2 Les Snakes

Les méthodes les plus "classiques" de détection de contours sont les méthodes à base de contours actifs aussi appelées Snakes, initialement proposées par Kass et al [2]. Ces méthodes nécessitent une initialisation qui consiste en un contour grossier situé à l'intérieur ou à l'extérieur de l'objet et qui est ajusté, pendant le traitement, au contour dans l'image en minimisant une fonction d'énergie. Il en résulte un seul contour optimal. C'est une méthode qui a été très largement utilisée dans le domaine de l'imagerie médicale.

Néanmoins, les snakes ne sont pas adaptés à notre cas. Il serait en effet difficile, voire impossible, de trouver une fonction d'énergie définissant une parcelle de verger, étant donné que le contenu d'une parcelle n'est pas homogène d'un point de vue radiométrique. C'est pourquoi cette méthode n'a pas été retenue pour cette étude.

3.3 La Ligne de Partage des Eaux ou Watershed

La méthode du Watershed (Meyer et Beucher, 1992 [7]) est l'un des outils de segmentation fournis par la morphologie mathématique. Son principe repose sur la croissance de régions (Regions growing) à partir de points d'amorçage (germes), qui correspondent aux minima du gradient de l'image.

Le problème est qu'une image réelle contient beaucoup moins d'objets que de régions, ce qui conduit le plus souvent à une sur-segmentation de l'image.

Sur ce point, notre cas d'étude sera très réactif. En effet, les images THRS sont fortement texturées ce qui implique la présence de beaucoup de minima et maxima locaux et donc un résultat beaucoup trop sursegmenté par rapport à la parcelle.

3.4 La Connexité Floue

La notion de connexité floue provient de Rosenfeld, 1979 [8], et plus récemment Fontana et al, 1996 [9] ou d'Udupa et Samarasekara 1996 [10], qui ont été les premiers à prendre en compte dans un algorithme de segmentation le caractère flou des images naturelles. L'idée est de générer une carte des connexités de chaque pixel de l'image originale avec un pixel spécifique de l'objet d'intérêt, désigné manuellement. L'initialisation se fait avec des clics sur l'image.

Cette technique permet de ne détecter qu'un seul objet à la fois. Le principal inconvénient est le nombre et la complexité des paramètres que doit gérer l'utilisateur surtout pour la création de la carte des connexités.

Pour en simplifier l'utilisation, Cutrona et Bonnet 2001 [11] ont voulu intégrer la notion de compétition entre les points d'amorçage du Watershed dans leur méthode à base de connexité floue. En effet, il est naturel de penser qu'une région n'existe que relativement à une autre région ou par rapport au fond. Cutrona 2001 et Bonnet [11] expliquent comment ils évitent tout seuillage et démontrent que les résultats sont généralement améliorés par la prise en compte simultanée de plusieurs objets d'intérêt.

Néanmoins cette méthode nécessite une initialisation manuelle des zones à segmenter ce qui n'est pas envisageable dans notre cas en raison du nombre considérable de parcelles en présence : cela demanderait un repérage par l'expérimentateur, de l'ordre de la photointerprétation et représentant un temps de travail beaucoup trop important.

3.5 Champs de Markov

Les champs de Markov permettent de modéliser des entités en fonction de leur contexte. Et cela en partant d'un pixel et de son voisinage pour remonter vers des primitives de haut niveau qui sont spatialement dépendantes. Pour arriver à cela il faut décrire la parcelle et plus particulièrement sa structure spatiale sous forme d'un modèle mathématique, que l'on cherchera à retrouver dans l'image. Cette méthode n'a pas été retenue pour plusieurs raisons :

- l'hétérogénéité spatiale des parcelles au sein d'un même type de plantation, due à plusieurs paramètres comme l'âge, la méthode de récolte ... Il sera donc difficile de trouver un modèle unique, même déformable, pour un type de parcelle ;
- une thèse sur un sujet proche est en cours au sein d'un des laboratoires partenaires du projet (INRIA de Sophia Antipolis) et l'objectif de ce stage était d'envisager des méthodes alternatives.

3.6 Les ondelettes

Les méthodes d'analyse en ondelettes introduites au début des années 1980, dans le contexte de l'analyse du signal pour l'exploration pétrolière, peuvent être interprétées comme une "analyse de Fourier locale". Depuis, les ondelettes n'ont cessé de se développer et mettent à disposition un formalisme mathématique (voir Mallat 1998 [4]) qui permet l'analyse d'un signal (par exemple une image).

De nombreuses techniques de segmentation par ondelettes ont été réalisées (Voorons et al 2003 [12], Arivazhagan et Ganesan 2003 [13]) et donnent de bons résultats. En effet, les ondelettes permettent de trouver des singularités caractéristiques d'une texture. Par exemple Voorons et al 2003

[12], utilisent les ondelettes pour calculer un spectre multifractal du pixel puis effectuent une classification par k-moyennes sur ce spectre.

Mais nous avons écarté, pour le moment, cette méthode par faute de temps pour se l'approprier correctement. Néanmoins nous pensons l'évaluer dans un proche avenir.

3.7 L'analyse de texture

La texture est un ensemble homogène pour l'oeil humain, même si les éléments qui la constituent peuvent être complètement anarchiques. Il suffit de trouver un critère qui les caractérise. Les méthodes à base de texture sont largement utilisées depuis les années 1970, et consistent à trouver un descripteur à la texture choisie, puis à chercher ce descripteur dans l'image. L'avantage de ces méthodes est que l'on peut décrire de manière simple les textures en recherchant leurs propriétés mathématiques. Les principaux outils permettant de décrire une texture sont les statistiques, donc facile à mettre en oeuvre. Cette approche est donc en adéquation avec le problème étudié, car elle permet d'agréger des zones d'une image en prenant en compte le pixel et son contexte, d'une manière proche de la perception humaine.

3.8 Conclusion

La plupart des nombreuses méthodes rencontrées dans la littérature, sont donc limitées dans le contexte de la détection des vergers, ou trop complexe pour les comprendre parfaitement et les appliquer dans le temps imparti pour ce stage. Finalement, l'approche texturale nous a semblé la plus adaptée pour répondre au problème posé. Néanmoins, la diversité des descripteurs texturaux nous a conduits à une réflexion sur le choix des indices pertinents et sur la méthode de classification à utiliser. Le chapitre suivant présente cette analyse de façon argumentée.

Chapitre 4

Analyse du problème

Nous avons donc choisi la segmentation / classification par analyse de texture. Néanmoins, il n'existe pas un unique indice de texture qui permette de définir une texture à lui seul. Il nous faudra donc en choisir un jeu pertinent (cf 4.1) puis agréger les informations portées par ces indices afin d'obtenir une cartographie de la zone étudiée. La méthode que nous proposons est simple : utiliser ce jeu comme entrée d'un réseau de neurones (cf 5) qui renvoie en sortie, pour chacune des classes choisies (cf 4.2), une probabilité d'appartenance comprise entre zéro et un.

4.1 Choix des indices de texture

On trouve dans la littérature de nombreux indices de texture (cf tableau Annexe 3). Cependant certains ne sont pas adaptés à la détection de vergers, d'autres sont redondants. Nous allons donc expliquer nos choix de sélection d'un nombre utile de ces indices.

4.1.1 Les indices de texture

Parmi les nombreuses méthodes d'extraction d'indices de texture existantes, cinq ont retenu mon attention : les statistiques d'ordre 1, la matrice de cooccurrence, les différences de niveaux de gris, les longueurs de plage, les gradients.

Paramètres d'ordre 1

L'analyse statistique du premier ordre permet de calculer par exemple :

- Moyenne
- Variance
- Asymétrie (Skewness)
- Aplatissement (kurtosis)
-

Mais ces indices ne sont pas très efficaces dans notre cas, d'une part parce qu'ils n'intègrent pas l'organisation spatiale des pixels, et d'autre part certains de ces indices ont une forte sensibilité au bruit. De plus, étant donné que nous traitons des images naturelles et que l'on souhaite faire la différence entre des éléments qui se ressemblent, ces indices seront peu efficaces. Du fait que l'analyse de ces indices revient à travailler sur l'histogramme, on perd totalement l'information spatiale contenue dans la zone étudiée.

Co-occurrence

La méthode suivante est basée sur le calcul de la matrice de cooccurrence des transitions de niveaux de gris dans un voisinage et une direction donnés (Haralick 1973[5], Gil et al. 2004[14], Arvis

et al. 2004[15], Boukerroui et al. 1998[16]). Elle consiste à analyser deux pixels au regard de leurs niveaux de gris, mais aussi la distance et l'angle qui les séparent. Cette méthode permet de décrire l'arrangement spatial des niveaux de gris, en mesurant la distribution des couples de niveaux de gris présents dans une image. De nombreux indices de texture sont calculés à partir de cette matrice dont les 14 indices de Haralik[5].

1. Moyenne
2. Variance
3. Contraste
4. Energie
5. Entropie
6. Moment des différences inverses
7. Corrélation
8. ...

Certains de ces indices sont corrélés les uns aux autres ou ont un comportement inverse les uns par rapport aux autres (exemple : le contraste et l'homogénéité indiquent tous les deux l'homogénéité locale d'une région). Comme ils mettent en évidence les mêmes propriétés il n'est pas utile de tous les utiliser dans le cadre d'une classification. Les indices basés sur la matrice de cooccurrence que nous avons retenus sont les suivants :

- la variance, qui nous permet de refléter la distribution des transitions de niveau de gris. Si l'on est dans une forêt, tous les niveaux de gris se retrouvent autour de la moyenne ;
- le contraste, qui reflète les changements de la radiométrie dans la zone étudiée. On préfère le contraste à l'homogénéité (qui lui est inversement corrélée) car son calcul est plus léger (pas de division). Cet indice nous indique plus particulièrement les zones de prés ou de champs qui ont une radiométrie quasi homogène sur toute la surface ;
- l'entropie, qui mesure la granularité de la texture, nous sera très utile. En effet, dans l'image THRS, on peut assimiler l'arbre à un gros grain. On pourra alors avoir une mesure de la présence d'arbre ou non dans la fenêtre grâce au niveau d'entropie ;
- la corrélation, ou mieux encore la corrélation normalisée pour être le plus générique possible, et qui mesure l'uniformité de la texture. Cet indice permettra de distinguer les zones lisses (par exemple le sol nu) des zones à motifs (par exemple les vergers).

Différence de niveaux de gris

Les méthodes basées sur la différence de niveaux de gris (Gonzalez et Wintz 1987[17]) sont équivalentes à celles de cooccurrence. Mais il faut savoir que si on n'avait pas eu à calculer la corrélation (qui n'existe pas sous cette forme), on aurait préféré cette méthode car elle est beaucoup moins coûteuse que celle basée sur la matrice de cooccurrence.

Longueurs de plages

La méthode des matrices de longueurs de plages (Galloway, 1975 [18], Rosenfeld et al., 1976 [19]) ou matrices des isosegments, fonctionne sur le même principe que la matrice de cooccurrence, sauf qu'on compte le nombre de pixels qui forment un groupe de même niveau de gris. C'est à dire que l'on analyse des lignes de pixels suivant trois paramètres :

- leur niveau de gris,
- la longueur de la ligne,
- l'angle par rapport à l'horizontale.

Cette méthode nous permettra de mieux appréhender certaines subtilités des textures. Parmi tous les indices nous calculerons :

- ‘pourcentage de plages’, qui indique l’homogénéité des plages dans la texture.
- ‘le poids des petites plages de forts niveaux de gris’, qui nous permet de repérer les petites zones claires et nous indique qu’il n’y a pas d’arbre (l’arbre étant une petite zone sombre)
- ‘le poids des longues plages de forts niveaux de gris’, qui nous donne une indication sur les grandes zones claires, telles que champs, prés, ...

Image de gradient

Enfin toutes ces méthodes peuvent s’appliquer à l’image de gradient (Tao et Dickinson, 2000 [20]) ce qui permet d’introduire la notion de contour des objets. Nous recalculerons donc les indices précédemment cités sur l’image de gradient. Ceci nous apporte une information utile car dans les vergers l’on trouve beaucoup de contours qui ont la propriété d’être ordonnés, alors que dans les forêts les contours sont anarchiques, étant donné que les arbres se recouvrent les uns les autres.

4.1.2 L’orientation et le vecteur de translation

Un des paramètres importants lorsque l’on effectue une analyse de texture (notamment pour Haralick 1973 [5]) est le choix de l’orientation, c’est à dire la direction dans laquelle on va effectuer nos calculs. Le choix de la direction est intimement lié au format pixellaire des images et au vecteur de translation que l’on choisit (cf figure 4.1).




FIG. 4.1 – Exemples de vecteur de translation et orientation

En effet plus le vecteur de translation est faible, plus les possibilités d’angle sont réduites car pour un angle de séparation faible, on retombe sur le même pixel. Nous avons choisi de calculer les transitions entre les pixels adjacents en raison de la petite taille du motif "arbre" par rapport à la résolution. Ceci correspond à un vecteur de translation d’un pixel. D’autres vecteurs, comme le passage d’un arbre de verger à un autre, pourraient être envisagés dans une suite de ce travail.

L’orientation possible du vecteur est donc limitée à 8 directions (0°, 45°, 90°, 135°, 180°, 225°, 270° et 315°) sinon on ne tombe pas sur un pixel (cf figure 4.1). On s’aperçoit que l’on peut facilement limiter le nombre de ces directions à 4 par simple symétrie. Compte tenu de la forme du motif recherché qui est une plantation régulière selon 2 axes, on se rend compte que 2 directions perpendiculaires devraient nous suffire.

Nous choisirons donc de limiter l’étude pour un vecteur de translation de 1 pixel et 2 directions 0° et 90°.

4.1.3 La taille du voisinage

Le choix de la taille des voisinages dans lesquels sont calculés les indices de texture est un point très important. En effet, celle-ci conditionne l'ensemble des résultats que l'on peut attendre. Si l'on choisit une taille trop petite, on ne peut pas tirer assez d'informations pour différencier le sol d'un arbre, car si l'échelle est inférieure à celle de l'arbre celui-ci apparaîtra comme une texture "lisse". On pourra encore moins faire la différence entre un verger et une forêt. Si le voisinage est trop grand l'indice résultant intégrera toutes les différentes zones texturées qui le composent. Les statistiques tirées de ce voisinage seront un mélange entre les différentes textures et on ne pourra donc pas discriminer les différentes informations à extraire (cf figure 4.2).




FIG. 4.2 – Taille des voisinages

Néanmoins, certaines tailles de voisinage permettent d'apporter une partie de l'information nécessaire à la bonne extraction des parcelles. Par exemple, si l'on prend un voisinage de la taille d'un arbre plus son contexte (par exemple 1 ou 2 m autour), on pourra savoir si l'on se trouve ou non en présence d'un arbre mais l'on ne pourra pas savoir si cet arbre se trouve seul au milieu d'un pré ou dans un verger. A l'inverse, une taille plus grande permet de distinguer si l'on est présence d'un arbre seul ou d'un groupe d'arbres, mais peut nous amener à manquer certaines informations comme la présence de petits arbres (exemple les plantiers). Nous avons donc choisi d'utiliser deux tailles de voisinage :

- un arbre et son contexte immédiat, c'est à dire une zone inter-rang (cf figure 4.3 taille 1). En général les arbres de verger font entre 2 et 4 mètres de diamètre et sont espacés de 4 à 6 mètres les uns des autres. La taille représentative d'un arbre est donc de 7 pixels.
- le motif d'un regroupement minimal d'arbres représentatif d'un verger, c'est à dire que l'on prendra un alignement de plusieurs arbres. Concrètement, on prendra donc un voisinage de quatre arbres plus leur contexte soit 15 pixels (cf figure 4.3 taille 2). De plus, cette taille de voisinage est à l'échelle des arbres de forêts, ce qui nous permettra de les différencier des vergers (cf figure 4.3 à droite).

4.1.4 Conclusion

Nous avons donc choisi de travailler avec 4 indices de texture d'Haralick qui sont :

- variance




FIG. 4.3 – Taille des voisinages dans notre cas d'étude

- contraste
- entropie
- corrélation

et ces mêmes indices sur l'image de gradient, le tout pour deux tailles de voisinage (7 pixels, 15 pixels) et dans 2 directions (0° , 90°), ainsi que 3 indices de longueur de plages :

- pourcentage de plage (RPC)
- poids des longues plages de fort niveau de gris (HGLRE)
- poids des petites plages de fort niveau de gris (HGSRE)

Ceci représente un jeu de 35 paramètres qui constitue le vecteur que nous allons devoir classifier.

4.2 Choix des classes

Vu que l'on souhaite non seulement effectuer une segmentation en parcelles de la zone étudiée mais aussi extraire un début d'information sur le contenu de la parcelle, il nous faut définir des classes thématiques à identifier. Vu la variabilité de la scène étudiée, on souhaiterait dans l'idéal pouvoir reconnaître les classes suivantes :

- | | | |
|--------------|--------------------|-----------|
| - Abricotier | - Pêcher | - Olivier |
| - Cerisier | - Pommier | - Vigne |
| - Pré | - Culture vivrière | - Champ |
| - Forêt | - Friche | - Autres |

Mais une simple analyse visuelle de l'image permet de se rendre compte que ces classes ne sont pas discriminables par analyse de texture. En effet, les textures des classes Abricotier, Pêcher, Olivier et Cerisier sont très proches voir même identiques sur l'image panchromatique (cf figure 4.4 - comparer a, b, c et d), comme celles des prés et des champs (cf figure 4.4 - comparer g et h). Les pommiers semblent néanmoins se différencier des autres types de verger de par leur texture particulière en rangs continus et épais. D'autre part, il y a une grande différence de texture entre les vieux vergers et les jeunes vergers, liée essentiellement à la taille des arbres (cf figure 4.4 - comparer a et e). Ce point est notamment intéressant pour une future caractérisation de l'état de la plantation.

Il nous faut donc réorganiser les classes initialement souhaitées dans les 9 classes suivantes :

- Vieux Verger
- Jeune Verger

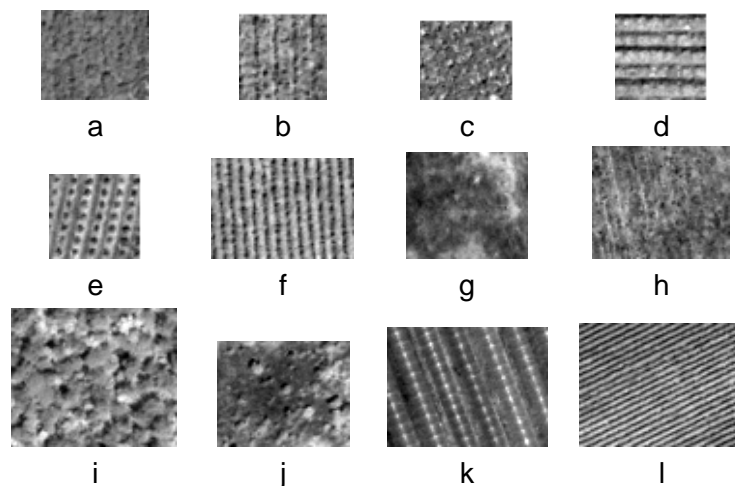


FIG. 4.4 – Comparaison des textures : a) vieux abricotiers, b) vieux pêchers, c) vieux oliviers, d) vieux cerisiers, e) jeunes abricotiers, f) pommier, g) pré, h) champ, i) forêt, j) friche, k) culture vivrière, l) vigne

- Pommier
- Vigne
- Pré ou Champ
- Culture vivrière
- Forêt
- Friche
- Autre

4.3 Choix de la méthode de classification

Disposant d'une base de données sur la zone, nous avons choisi d'utiliser une partie de cette information afin de fiabiliser la méthode et donc de nous livrer à une classification supervisée.

De nombreuses méthodes de classification existent, les plus utilisées dans la littérature étant soit le maximum de vraisemblance [21], soit les k-moyennes [22]. Elles nécessitent de la part de l'expérimentateur d'une part des connaissances sur les propriétés de l'image et d'autre part de régler les différents paramètres de la classification (écart type, seuil, ...). Nous avons choisi d'utiliser une voie différente, un réseau de neurone, qui permette d'avoir un apprentissage automatique des paramètres (poids du réseau) à partir d'une base d'apprentissage (que nous avons constituée à partir de la vérité terrain (cf 2)).

Chapitre 5

Réseaux de Neurones

Cette partie présentera tout d'abord le cadre général des réseaux de neurones, puis un cas particulier de réseau qu'est le perceptron multicouche et enfin le réseau spécifique que nous avons développé dans le cadre de ce stage.

5.1 Modèle de neurone et réseau

Le modèle de neurone utilisé aujourd'hui a été proposé en 1943 par Mc Culloch et Pitts [23] qui étudiaient le cerveau des chimpanzés. Ils présentèrent dans leur article [23] ce que l'on appelle aujourd'hui le neurone formel.

5.1.1 Le neurone biologique

Mais avant de parler du neurone formel, une rapide présentation du neurone biologique s'impose. Les biologistes s'accordent sur le paradigme (des théories récentes remettent en cause ce paradigme mais cela n'a pas encore d'influences sur la définition du neurone formel) qu'un neurone biologique possède trois composantes principales (voir figure 5.1) :

1. les dendrites
2. le corps cellulaire
3. l'axone




FIG. 5.1 – Neurone Biologique

Les dendrites reçoivent de l'énergie électrique et la transmettent au corps cellulaire qui l'accumule jusqu'à un seuil. Lorsque ce seuil est dépassé le corps cellulaire engendre un potentiel électrique qui se propage à travers son axone vers un autre neurone.

5.1.2 Le neurone formel

Le neurone formel fut décrit par Mc Culloch et Pitts avec le formalisme suivant :

- les entrées notées x_i , que l'on peut relier aux axones du neurone biologique,
- les coefficients synaptiques (ou poids synaptiques) notés W_i , équivalent de la connexion entre l'axone et les dendrites.
- une fonction d'accumulation, généralement une somme des entrées pondérées par les coefficients synaptiques. Le résultat de cette somme est noté p pour potentiel.
- une fonction de transfert $f(p)$ qui représente le corps cellulaire du neurone biologique,
- la sortie notée y représentant l'axone du neurone.

La figure 5.2 présente le schéma du neurone formel.




FIG. 5.2 – Neurone formel

D'un point de vue mathématique nous n'avons que deux formules :

- la fonction d'accumulation (5.1),
- la fonction de transfert. Initialement simple seuillage, celle-ci peut prendre plusieurs forme en fonction du choix la fonction de transfert (voir tableau 5.1). Pour cette étude nous avons choisi d'utiliser une sigmoïde de la forme de (5.2)

$$p = \sum_i^n x_i W_i \quad (5.1)$$

$$f(x) = 2 * \frac{k * e^{-kx}}{(1 + e^{-kx})^2} \quad (5.2)$$

5.2 Perceptron multicouche et Rétropropagation

F. Rosenblatt développa le modèle du Perceptron en 1958 [24]. Inspiré du système visuel, il possède deux couches de neurones : une couche de perception (à n neurones d'entrée) et l'autre liée à la prise de décision. Cette couche est constituée d'un simple neurone de sortie. Le perceptron multicouche est une simple évolution du perceptron qui permet de résoudre des problèmes plus complexes et non linéairement séparables. On intercale des couches de neurones entre la couche de perception et de décision du perceptron simple. Ceci permettra de résoudre des problèmes de plus en plus complexes à chaque couche rajoutée. Les entrées des neurones de la couche n sont un vecteur constitué des valeurs de sortie de la couche $n - 1$.

Nom	Fonction
Seuil	$f(x) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{sinon} \end{cases}$
Seuil lineaire	$f(x) = \begin{cases} -1 & \text{si } x < -k \\ 1 & \text{si } x > k \\ x/k & \text{sinon} \end{cases}$
Sigmoïde simple	$f(x) = \frac{1}{1+e^{-x}}$
Tangente hyperbolique	$f(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

TAB. 5.1 – Exemples de Fonction de Transfert (FT)

Lors de la phase d'apprentissage d'un tel réseau, on utilise l'algorithme de la rétropropagation du gradient de l'erreur, qui consiste à faire une descente de gradient à travers le réseau (de la sortie vers l'entrée), c'est à dire que l'on calcule l'erreur produite par un neurone en fonction de l'erreur des neurones de la couche suivante (cf formule(5.3)).

Pour tous les neurones sauf la couche de sortie :

$$e_{n-1,j} = f'^{n-1}(p^{(n-1)}) \sum_i W_{ji} e_{n,i}$$

$e_{n-1,j}$: erreur du neurone j de la couche $n - 1$

$e_{n,i}$: erreur du neurone i de la couche n

Pour la couche de sortie :

(5.3)

$$e_{sortie} = f'^{sortie}(p^{sortie}) [d_i - y_i]$$

$sortie$: numéro de la couche de sortie

d_i : valeur désirée pour le neurone i

y_i : sortie du neurone i obtenue

d_i : sortie du neurone i désirée

La dernière chose à faire est de choisir la topologie du réseau mais là on touche un sujet qui fait encore l'objet de recherches. On le déterminera donc par synthèse de différents réseaux vus dans divers articles ([25], [26], ...).

5.3 Réseau de l'étude

5.3.1 Le réseau

Le réseau développé au cours de ce stage est basé sur le perceptron multicouche présenté au 5.2 : en entrée de ce réseau nous avons un vecteur de 35 indices de texture, et nous souhaitons avoir 9 classes de sortie (cf 4.2).

Nous avons choisi d'utiliser un réseau à 4 couches cachées pour permettre :

- une phase d'extension de réseau visant à généraliser l'information contenue dans le vecteur d'entrée,
- une phase de compression de l'information afin d'arriver aux 9 classes désirées (cf 4.2). Dans cette phase de compression de l'information nous placerons un goulet d'étranglement qui nous permettra d'éviter le surapprentissage.

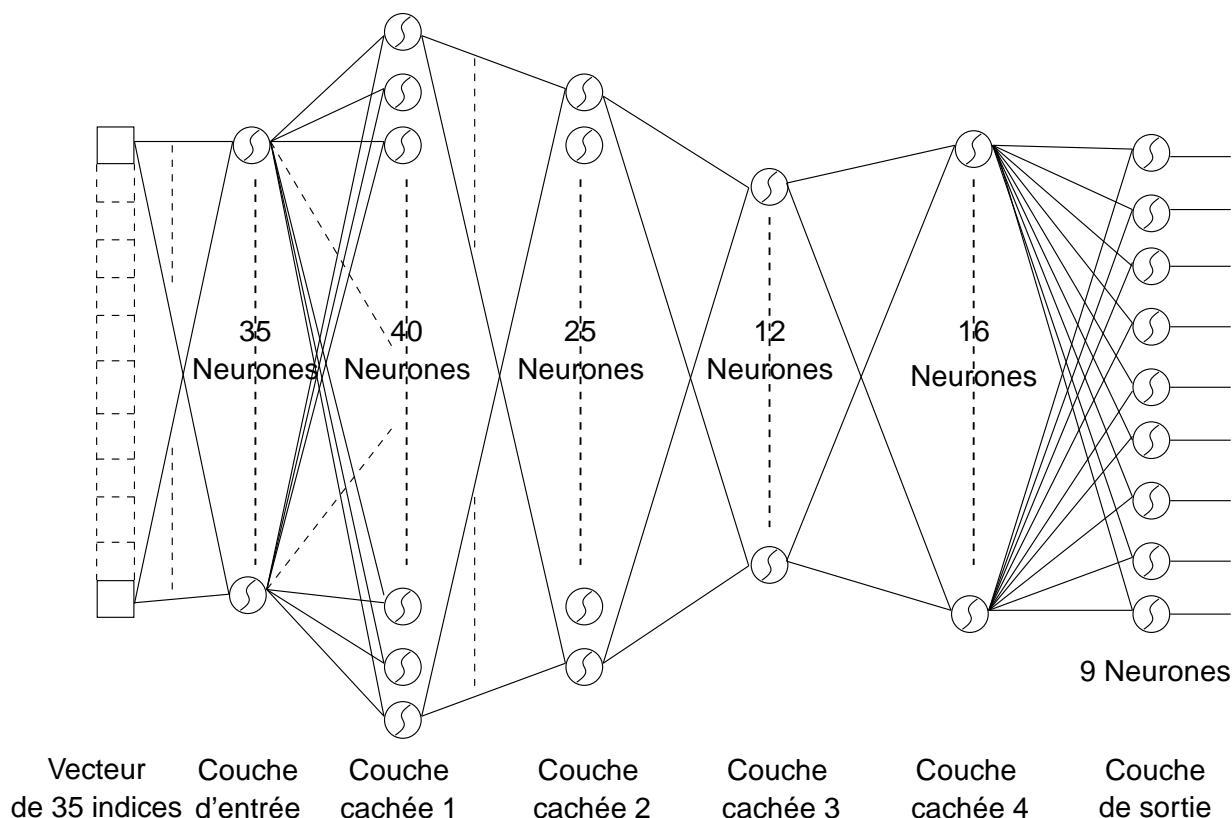


FIG. 5.3 – Schéma représentatif du réseau

Toutes les couches du réseau sont composées d'une fonction de transfert du type de (5.2). Cette fonction autorise un post traitement plus facile. En effet, elle nous fournit une information plus précise qu'un simple booléen, permettant d'utiliser des méthodes de prise de décision pour affecter le pixel à une classe en utilisant par exemple la logique floue.

5.3.2 L'apprentissage

En ce qui concerne la méthode d'apprentissage nous avons utilisé une méthode à base de rétropropagation du gradient de l'erreur. Pour cela, nous avons constitué notre base d'apprentissage contenant une partie des parcelles documentées sur le terrain. Les autres parcelles seront utilisées pour la validation de la classification.

En ce qui concerne l'ordre d'apprentissage des données nous avons choisi de faire un pseudo tirage au sort afin de ne pas privilégier une classe par rapport à l'autre. Mais pour ne pas faire un apprentissage totalement aléatoire, plusieurs règles de tirage ont été posées. Tout d'abord nous allons nous assurer que toutes les classes seront tirées au moins une fois avant de pouvoir retirer la même classe, puis nous appliquons la même règle pour les parcelles au sein de la classe considérée.

Enfin, afin de ne pas être victime d'un sur-apprentissage lié à la taille des parcelles (6000 à 10000 pixels minimum), nous ne prenons qu'un seul vecteur pixellaire à chaque parcelle tirée.

Chapitre 6

Résultat

Nous ne pourrions pas vous présenter les résultats de cette étude pour ce rapport de stage car ils ne sont pas encore disponibles. Nous allons donc vous présenter l'état actuel du projet, les résultats que nous attendons, ainsi que la méthode de validation que nous allons adopter.

Par cette méthode de classification nous pensons pouvoir obtenir une image de 9 couches (une par classe), chaque couche donnant un indice d'appartenance compris entre 1 et 255. Nous n'utilisons pas le zéro car celui-ci nous sert à indiquer une zone en dehors de la zone d'intérêt. Cet indice se rapportera à l'espérance du pixel d'appartenir à la classe de la couche, une valeur proche de 1 correspondra à une espérance nulle et une valeur de proche de 255 correspondra à une forte croyance. Nous espérons ensuite fusionner ces informations par un simple seuilage (nous prendrons le maximal sur les n couches). Bien sûr, en fonction des résultats obtenus nous mettrons ou non en place un traitement plus élaboré. Nous obtiendrons donc une seule image pouvant prendre 9 valeurs, chaque valeur correspondant à une classe.

Aujourd'hui, nous en sommes à la troisième version du programme. En effet la première version n'a pas fonctionné, car nous n'avions pas pris en compte l'aspect mémoire du problème et développé en cherchant à optimiser le temps de calcul. Les données ont donc saturé la mémoire. La deuxième version du programme est donc beaucoup plus lente puisqu'il y a trois jours de traitements. Les résultats obtenus nous ont permis de nous rendre compte que la méthode d'apprentissage que nous avons choisie dans un premier temps n'était pas la bonne. Nous apprenions tous les pixels de la parcelle et le passage d'un grand nombre de pixels d'une même classe entraîne un oubli des apprentissages précédents. Cela nous a amené à la méthode présentée en [5.3.2](#) et à la version trois qui est en cours de développement à l'heure actuelle.

En ce qui concerne la validation des résultats nous utiliserons la base de vérité terrain à partir de laquelle nous effectuerons la construction d'une image de type cartographique (une couleur par classe et une classe par parcelle). Puis nous construirons une matrice de confusion qui estimera le degré de validité des résultats obtenus. Une limite de cette méthode est qu'elle ne prend pas en compte les arbres manquants au sein d'un verger, ce qui peut introduire des erreurs de classification. C'est pourquoi il nous semble important de calculer une deuxième matrice de confusion qui travaillera au niveau de la parcelle, par exemple en utilisant la valeur médiane.

Nous espérons obtenir ces résultats dans un avenir proche.

Chapitre 7

Conclusion et Perspectives

7.1 Conclusion

L'objectif de ce stage était de détecter automatiquement les vergers dans une image satellite panchromatique à Très Haute Résolution Spatiale. L'approche proposée ici est la classification par réseau de neurones sur la base d'un vecteur d'indices texturaux. Neuf classes de textures correspondant à des types d'occupation agricole ont été retenues, dont des vergers jeunes et vieux.

Tous les indices de texture ont été calculés : nous avons utilisé ENVI pour les indices d'Haralick et développé un algorithme pour le calcul des longueurs de plages. Nous avons donc un fichier image de 35 couches (une par indice) de plus de 10 giga-octets.

Ensuite, la base d'apprentissage et de validation a été numérisée sous la forme d'un calque vecteur qui contient le géoréférencement et les informations acquises sur le terrain. Cette base contient 1042 parcelles dont on retire 239 parcelles qui constituent notre base d'apprentissage. Elle se présente sous la forme de fichiers images (extractions de l'image d'indices), qui contiennent 35 couches correspondant au vecteur d'indices de texture (soit une base d'environ 1 giga-octet).

Pour le réseau de neurone, un algorithme de traitement de type perceptron multicouche a été développé mais celui-ci n'est pas encore totalement opérationnel.

7.2 Perspectives

Le projet de perceptron doit d'abord être débuggé pour obtenir les images de classification. Nous procéderons ensuite à la validation de la méthode et analyserons la pertinence des résultats et l'apport général de ce travail. Ensuite, il serait intéressant de mettre en place un algorithme d'extraction des parcelles classifiées par le réseau de neurones, afin de procéder à la caractérisation intra-parcellaire des vergers.

On pourra s'appliquer par la suite à optimiser la démarche présentée ici. Par exemple, on pourra s'intéresser à la mise en place d'un pré- et/ou post-traitement, basé sur l'image de gradient. En effet suite à l'étude de l'image de gradient de la zone, nous nous sommes aperçu que l'on peut en extraire un pseudo-parcellaire, ce qui nous permettrait d'augmenter la fiabilité de l'information extraite. Cela est dû principalement à la présence de chemins ou de haies (principalement des cyprès et peupliers sur la zone d'étude) bordant les parcelles agricoles. Mais avant il faudra bien entendu vérifier que cela sera utilisable sur d'autres zones d'agro-foresterie, car il est fort probable que cette analyse basée sur le gradient ne sera pas utilisable partout. Par exemple, dans les pays tropicaux les chemins sont souvent invisibles sur les images (THRS ou aéroportées) car ils sont cachés par le couvert végétal.

Evaluer et tester l'analyse en ondelettes semble aussi être un complément ou une alternative évidents à la méthode proposée. Il nous faudra vérifier d'une part si elle peut suffire pour faire la classification, et d'autre part s'il est opportun d'intégrer un indice basé sur une analyse en ondelettes à notre méthode actuelle. Je pense qu'il est important d'approfondir les ondelettes car elles peuvent

nous apporter une information pertinente, comme le montrent Voorons et al (2003 [12]).

Un autre type de réseau de neurones devrait aussi être testé, notamment un réseau de type Kohonen car celui-ci nous permettrait de ne pas avoir de phase d'apprentissage et nous ferait gagner un temps non négligeable.

Enfin, à plus long terme il nous paraît important d'évaluer l'apport de l'information multi spectrale. En effet l'intégration d'une information reliée à la densité de végétation (indices tels que le NDVI ¹) pourrait discriminer certains types de vergers.

D'une manière générale une analyse approfondie de la problématique devrait nous permettre de développer un algorithme plus performant.

¹NDVI : Normalized Difference Vegetation Index

Bibliographie

- [1] R. Adams and L. Bischof. Seeded region growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, volume 16(6) :pages 641–647, June 1994. 8
- [2] A. Witkin M. Kass and D. Terzopoulos. Snakes : Active contour models. *International Journal of Computer Vision*, pages pages 321–331, 1988. 8
- [3] F. Meyer and S. Beucher. Morphological segmentation. *Journal of Visual Communication and Image Representation*, Volume 1(Issue 1) :Pages 21–46, September 1990. 8
- [4] S. Mallat. *A wavelet tour of signal processing*. Academic Press, 1998. 8, 9
- [5] I. Dinstein R. M. Haralick, K. Shanmugam. Textural features for image classification. *IEEE Trans. on System Man and Cybernetic*, Volume 3(6) :pages 610–621, 1973. 8, 11, 12, 13
- [6] Runmei Hu and Moustafa M. Fahmy. Texture segmentation based on a hierarchical markov random field model. *Signal Processing*, Volume 26(Issue 3) :Pages 285–305, March 1992. 8
- [7] S. Beucher and F. Meyer. The morphological approach to segmentation : the watersheds transformation in e.r. doughterty (ed.). *Mathematical Morphology in Image Processing*, pages pages 433–481, 1992. 8
- [8] A. Rosenfeld. Fuzzy digital topology. *Inform. Control*, pages pages 76–87, 1979. 9
- [9] F. Fontana S.G. Dellepiane and G.L. Vernazza. Non linear image labeling for multivalued segmentation. *IEEE Transaction on Image Processing*, pages pages 429–446, 1996. 9
- [10] J.K. Udupa and S. Samarasekera. Fuzzy connectedness and object definition : Theory, algorithms and applications in image segmentation. *GMIP*, pages pages 246–261, 1996. 9
- [11] J. Cutrona and N. Bonnet. Two methods for semi-automatic segmentation based on fuzzy connectedness and watersheds. In *Imaging and Image Processing VIIIP*. IASTED International Conference on Visualisation, 2001. 9
- [12] Voorons M. Germain M. Béné G. B. Fung k. Segmentation of high resolution images based on the multifractal analysis. In *IGARSS*. IGARSS Toulouse, juillet 2003. 9, 10, 23
- [13] S. Arivazhagan and L. Ganesan. Texture segmentation using wavelet transform. *Pattern Recognition Letters*, Volume 24(Issue 16) :3197–3203, December 2003. 9
- [14] Edgar Gil Rizzatti Daniela Mayumi Ushizima Sabino, Luciano da Fontoura Costa and Marco Antonio Zago. A texture approach to leukocyte recognition. *Real-Time Imaging*, Volume 10(4) :205–216, August 2004. 11
- [15] Arvis V. Deguy S. Debain C. Benassi A. Generalization of the cooccurrence matrix of image segmentation results. *Image Anal. Stereol.*, Volume 23, 2004. 12
- [16] D. Boukerroui O. Basset N. Guérin A. Baskurt. Multiresolution texture based adaptive clustering algorithm for breast lesion segmentation,. *European Journal of Ultrasound*, vol. 8(n° 2) :p. 135–144., 1998. 12
- [17] R.C. Gonzalez and P. Wintz. *Digital Image Processing (2nd Ed.)*. Addison-Wesley, 1987. 12
- [18] M. M. Galloway. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, Volume 4 :pages 172–179, 1975. 12

- [19] A. Rosenfeld J. S. Weszka, C. R. Dyer. A comparative study of texture measures for terrain classification. *IEEE Trans. System Man and Cybernetics*, vol. 6(n° 4) :p. 269–285, 1976. [12](#)
- [20] Bo Tao and Bradley W. Dickinson. Texture recognition and image retrieval using gradient indexing. *Journal of Visual Communication and Image Representation*, Volume 11(Issue 3) :Pages 327–342, September 2000. [13](#)
- [21] J.A. Richards. *Remote Sensing Digital Image Analysis*. Springer Verlag, 1994. [16](#)
- [22] J.T. Tou and R.C. Gonzalez. *Pattern Recognition Principles*. Addison-Wesley Publishing Company, 1974. [16](#)
- [23] W.S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5 :115–133, 1943. [17](#)
- [24] Franck Rosenblatt. The perceptron : probabilistic model for information storage and organization in the brain. *Psychological Review*, 65 :386–408, 1958. [18](#)
- [25] Le Cun and al. Handwritten zip code recognition with multilayer networks. In *the 10th International conference on Pattern Recognition*, 1990. [19](#)
- [26] Bennani and Gallinari. Connectionist approaches for automatic speaker recognition. In *ESCA Workshop on Automatic Speaker Recognition, Identification and Verification.*, 1994. [19](#)

Annexes

Chapitre 1

Glossaire

CIRAD : Centre de Coopération Internationale en Recherche Agronomique pour le Développement, 3

ENVI : Environnement for Vizualing Images Research Systems <http://www.researchsystems.com>, 5

MTD : Maison de la Télédétection, 3

NDVI : Normalized Difference Vegetation Index, 21

PNTS : Programme National de Télédétection Spatiale, 3

QuickBird : Capteur multispectral américain, développé par Digitalglobe. <http://www.digitalglobe.com>, 4

SERFEL : Station Expérimentale de Recherches en Fruits et Légumes. <http://www.serfel.fr>, 4

SIG : Système d'Information Géographique, 5

THRS : Très Haute Résolution Spatiale, 3

Chapitre 2

Localisation de la zone d'étude




FIG. 2.1 – Zone de l'étude : en rouge les parcelles visitées sur le terrain

Chapitre 3

Tableau recapitulatif des indices de texture

Nom de l'indice	Ordre	Forumule	Caracteristique	Illustration	Article
Moyenne	1	$MOY = \frac{1}{N} \sum_{i,j} g(i,j)$		illustration	article
Variance	1	$VAR = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^2$	distribution autour de la moyenne	illustration	article
Skewness	1	$SKE = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^3$	indicateur de symetrie	illustration	article
Kurtosis	1	$KUR = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^4$	si KUR faible les transition sont douce sinon transition rapide	illustration	article
Holder	1	formule	dimenstion factal de l'image	illustration	article
Méthode à basée sur la Matrice de cooccurrence					
Moyenne	2	$MOY = \sum_i \sum_j ip(i,j)$		illustration	article
Variance	2	$VAR = \sum_i \sum_j (i - MOY)^2 p(i,j)$	mesure la distribution des niveaux de gris autour de la moyenne	illustration	article
Energie	2	$E = \sum_{i,j} (p(i,j))^2$	homogénéité de la texture si faible image fortement texturer	illustration	article
Contraste	2	$CON = \sum_i \sum_j (i - j)^2 p(i,j)$	homogénéité local de la région (valeur faible donne de grande region homogène)	illustration	article
Homogénéité	2	$HOM = \sum_{i,j} \frac{1}{1+(i-j)^2} p(i,j)$	liée au contaste elle a un comportement inverse	illustration	article
Corrélation	2	$COR = \sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i,j)$	uniformité de la distribution des niveaux de gris	illustration	article
Corrélation Normalisée	2	$COR_N = \sum_{i,j} \frac{ijp(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$	uniformité normalisé de la distribution des niveaux de gris	illustration	article
Entropie	2	$ENT = - \sum_i \sum_j p(i,j) \log p(i,j)$	granularité de l'image forte valeur donne gros grain	illustration	article
Moment diagonal	2	$DIAG = \sum_i \sum_j (\frac{1}{2} i - j p(i,j))^{1/2}$	caracteristique	illustration	article
Cluster Shade	2	$CSHADE = \sum_i \sum_j (i + j - 2MOY)^3 p(i,j)$	proche de la variance mais avec une capacité de discrimination élevée à l'ordre 3	illustration	article
Cluster prominence	2	$CPROM = \sum_i \sum_j (i + j - 2MOY)^4 p(i,j)$	proche de la variance mais avec une plus grande capacité de discrimination (ordre 4)	illustration	article
Méthode des différences des niveaux de gris					
Moyenne	2	$MOY = \sum_{i=1}^M if(i/\beta)$	équivalent de la moyenne de cooccurrence	illustration	article
Contraste	2	$CONT = \sum_{i=1}^M i^2 f(i/\beta)$	équivalent du contraste de cooccurrence	illustration	article
Uniformité	2	$ASM = \sum_{i=1}^M [f(i/\beta)]^2$	équivalent de l'énergie de cooccurrence	illustration	article
Entropie	2	$ENT = \sum_{i=1}^M -f(i/\beta) \log f(i/\beta)$	équivalent de l'entropie de cooccurrence	illustration	article
IDM	2	$CONT = \sum_{i=1}^M \frac{f(i/\beta)}{i^2 + 1}$	équivalent de l'homogénéité de cooccurrence	illustration	article
Méthode basé sur les gradients					
on peut calculer de nouveaux indice (tel que la moyenne ou variance) a partir d'une image de gradients ce qui permet de introduire une information sur le contour					
Méthode des longueurs de plages de niveaux de gris					
Poids de plages courtes	2	$SRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{r(i,j)}{j^2}$	un fort SRE indique que l'image et fortement texturé	illustration	article
Poids de plages longues	2	$LRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N j^2 r(i,j)$	un fort LRE indique la presence de zone homogène	illustration	article
Distribution des niveaux de gris	2	$GDIST = \frac{1}{nr} \sum_{i=1}^M \left[\sum_{j=1}^N r(i,j) \right]^2$	un fort GDIST indique une faible variabilité des niveau de gris	illustration	article
Distribution des longueurs de plages	2	$RLDIST = \frac{1}{nr} \sum_{j=1}^N \left[\sum_{i=1}^M r(i,j) \right]^2$	un forte RLDIST indique qu'il y a des grand regroupement de pixel	illustration	article
Pourcentage de plages	2	$RPC = \frac{\sum_{i=1}^M \sum_{j=1}^N r(i,j)}{\sum_{i=1}^M \sum_{j=1}^N jr(i,j)}$	homogénéité de la texture	illustration	article
Poids des longueurs de plage de faible niveau de gris	2	$LGRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{r(i,j)}{i^2}$	repere les grandes zone foncé	illustration	article
Poids des longueurs de plage de fort niveau de gris	2	$HGRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N i^2 r(i,j)$	inverse du LGRE	illustration	article
Poids des petites plages de faible niveau de gris	2	$LGSRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{r(i,j)}{i^2 j^2}$	repere les petite zone foncé	illustration	article
Poids des longues plages de fort niveau de gris	2	$HGLRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N i^2 j^2 r(i,j)$	inverse du LGSRE	illustration	article
Poids des petites plages de fort niveau de gris	2	$HGSRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{i^2 r(i,j)}{j^2}$	repere les petite zone claire	illustration	article
Poids des longues plages de faible niveau de gris	2	$LGHRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{j^2 r(i,j)}{i^2}$	inverse du HGSRE	illustration	article