

# EXTRACTION D'UN INDICE DE TEXTURE PAR LE MODELE MARKOVIEN EN VUE D'UNE CARACTERISATION DU THEME BATI

L.CHAOUCHE RAMDANE<sup>1</sup>, T. IFTENE<sup>2</sup>, H. FIZAZI IZABATEN<sup>3</sup>

<sup>(1)</sup>Université de Tlemcen, Facultés des Sciences, Département Informatique

<sup>(2)</sup>Agence Spatiale Algérienne (ASAL), Alger

<sup>(3)</sup>Université des Sciences et de la Technologie d'Oran, Faculté des Sciences, Département Informatique  
[f.chaoucheramdan@mail.univ-tlemcen.dz](mailto:f.chaoucheramdan@mail.univ-tlemcen.dz)

## ABSTRACT

L'extraction des zones urbaines sur une image satellitaire à partir des seules informations spectrales est insuffisante. La plupart des méthodes font appel à une analyse de la texture de l'image pour intégrer l'aspect spatial qui peut s'avérer important dans ce cas. C'est à partir de cette méthode que nous essayons, de dégager les zones urbaines de celles de non urbaines. Comme les champs de Markov sont des outils très utilisés en traitement d'images surtout pour la modélisation des textures. Nous proposons, une approche de caractérisation du thème bâti pour l'extraction des indices texturaux reposant sur la modélisation markovienne qui sera utilisée dans un processus classificatoire.

## 1 INTRODUCTION

Les méthodes traditionnelles d'extraction d'informations, à partir d'images satellitaires, se basent généralement sur la réponse spectrale des capteurs, en considérant le pixel de façon individuelle. Ces approches sont dans certains cas insuffisantes, surtout avec l'apparition des images à haute et à très haute résolution. Ces images présentent un contenu spectral de plus en plus hétérogène. C'est le cas des zones urbaines, où cette haute résolution, permet de révéler tous les petits détails composant ce paysage, jusque là non accessibles, donnant ainsi des régions très contrastées composées de groupes de pixels de valeurs radiométriques très disparates.

Il est nécessaire donc que les méthodes d'extraction de l'information à partir de ces images soient plus performantes. Cela est possible en essayant de dépasser la simple analyse spectrale, pixel par pixel, en faisant intervenir le voisinage [1,10] c'est-à-dire la texture.

C'est à partir de l'analyse texturale que nous essayons dans ce travail, de dégager les zones urbaines de celles de non urbaines et de définir un masque urbain à partir d'une image à haute résolution. L'extraction des indices texturaux repose sur la modélisation markovienne qui sera utilisée dans un processus classificatoire.

## 2 CHAMPS DE MARKOV

Les champs de Markov sont des outils très utilisés en traitement d'image [4, 6, 7, 9, 11], notamment en restauration d'image, segmentation, classification d'images optique et radar, stéréovision et modélisation de textures, etc. Leur intérêt est de pouvoir modéliser des interactions entre pixels de façon simple, à travers un modèle

probabiliste. Autrement dit, dans un champ de Markov, la probabilité conditionnelle en un site, n'est fonction que de la configuration du voisinage de ce site. Donc, l'idée sous-jacente des champs de Markov est de rendre compte, via la formulation probabiliste, du fait que le niveau de gris d'un site donné sachant l'état de l'ensemble des autres sites du réseau ne dépend que de la connaissance des états des sites voisins de ce site (les champs que nous introduisons ici ont été proposés en physique, pour cette raison, nous altérons légèrement notre langage et appelons un site au lieu de pixel).

## 3 ANALYSE DE LA TEXTURE PAR APPROCHE MARKOVIENNE

Notre objectif est l'extraction des zones urbaines, du fait que, ces zones sont constituées de nombreux matériaux, elles possèdent une grande variabilité en terme de niveaux de gris (zones contrastés). De plus, ces matériaux en partie sont aussi caractéristiques de certains paysages naturels, donnant à certains pixels urbains les mêmes signatures spectrales que ces paysages non urbains.

## 4 LE MODELE ISOTROPE

Le modèle markovien gaussien isotrope proposé par Descombes dans [2, 3, 8] donne des résultats satisfaisants, d'où l'utilisation de ce modèle. L'approche sera validée sur des images Aster (2000) de l'ouest d'Oran (Algérie) de résolution 15m [1].

L'analyse de la texture par le modèle isotrope permet d'estimer les paramètres de texture sans la prise en compte de la direction, ce qui revient à considérer seulement le

voisinage classique isotrope (4 connexités, 8 connexités).

#### 4.1 Modèle markovien gaussien

L'image est modélisée par un modèle markovien gaussien 4 connexes.

$$P(X_S / X_r, r \in V(S)) = \frac{1}{Z_{V(S)}} (-\beta(X_S - X_r) + \lambda(X_S - \mu)^2)$$

$$P(X_S / X_r, r \in V(S)) = P(X_S / m_S)$$

Avec :

S l'ensemble des sites de l'image

$X_s$  un champ aléatoire

$\mu$  la moyenne locale

$\lambda$  et  $\beta$  les paramètres du modèle

$m_s$  la moyenne des 4 voisins de s.

$V(s)$  le voisinage de s

$Z_{V(S)}$  la constante de normalisation.

L'indice de texture donné par la variance conditionnelle locale  $\sigma_{P(X_S / m_S)}^2 = \frac{1}{2\beta(4 + \lambda)}$  est un bon indicateur de la présence ou non de l'urbain [3]. Elle est estimée par la méthode des queues de comètes.

#### 4.2 Estimation des paramètres par la méthode « queues de comètes »

Nous estimons les variances conditionnelles locales, en utilisant la méthode des queues de comètes fondée sur l'estimation des matrices des probabilités conditionnelles. Cette méthode a été proposée pour la première fois en 1993 par Descombes [2]. Le nom queues de comètes s'explique par la forme des matrices qui rappellent celles des comètes.

La méthode consiste à estimer la matrice des probabilités conditionnelles dans une fenêtre glissante. Le choix de la taille de la fenêtre est le résultat d'un compromis. Plus la fenêtre est large, plus les statistiques sont robustes. D'un autre côté, plus la fenêtre est étroite, moins il y a de risques de se trouver en présence d'un mélange de plusieurs textures [8].

Pour chaque position de la fenêtre, on estime la variance conditionnelle locale à partir de la matrice des probabilités conditionnelles. Ce paramètre est assigné au pixel central de la fenêtre. La matrice des probabilités conditionnelles est présentée sous forme d'image (voir figures 1 et 2). La forme du nuage de points rappelle celle de la queue de comète.




Figure 1: Queue de comète (résultat théorique)




Figure 2: Queue de comète (résultat pratique)

En pratique, pour chaque site  $s$  à l'intérieur de la fenêtre, on incrémente de 1 l'élément de la matrice dont les coordonnées correspondent à  $X_s$  et à la moyenne  $m_s$ .

#### 4.3 Résultats expérimentaux

Dans la suite, on va appliquer le modèle markovien isotrope pour extraire l'indice de texture donné par la variance conditionnelle locale sur des images Aster de l'ouest d'Oran (voir figures 3 et 4). Afin d'extraire au mieux les zones urbaines, nous avons choisi le canal 1 (vert) du fait que, ce dernier soit le plus contrasté visuellement par rapport aux autres canaux.




Figure 3: Zone urbaine



Figure 4 : Zone non urbaine

Pour montrer la qualité de l'indice de la variance conditionnelle locale, nous avons estimé cet indice sur une image où l'urbain ne figure pas (voir figure 4).

Nous avons aussi comparé la variance conditionnelle locale avec la variance classique [1].

#### 4.3.1 Choix des paramètres d'analyse

Pour les images présentées dans les figures 3 et 4, nous estimons le paramètre du modèle et la variance classique. La taille de la fenêtre d'analyse, doit satisfaire deux critères contradictoires à savoir, la plus petite possible pour réduire le risque de mélange de textures différentes et, en même temps, la plus grande possible pour pouvoir extraire des statistiques assez robustes et significatives [5].

Dans notre cas, après plusieurs tests sur la variabilité spatiale apportée par l'indice (Analyse visuelle), nous avons opté pour une fenêtre de taille 13 x 13.

Le voisinage considéré est le voisinage "4 connexe".

#### 4.3.2 Discussion et analyse de la qualité de l'indice de texture et comparaison avec une autre approche.

On remarque sur l'image de l'estimée (voir figure 5) que la variance conditionnelle locale privilégie les contours et les frontières d'une façon nette et précise, bords plus francs entre les classes, et une bonne limitation spatiale comme le montre l'image de la figure 7.

Par contre sur l'image où est représentée la variance classique (voir figure 6), les bords des régions sont flous.

Les résultats obtenus par le modèle markovien gaussien à quatre connexités sont satisfaisants. Sur l'image de la figure 5 l'urbain apparaît en sombre et le non urbain en clair et nous constatons que certaines confusions apparaissent aux niveaux de certaines zones (tels que les serres qui présente des variations d'intensités dans la direction NOn/SEs) qui ont une réponse similaire au thème bâti (voir figure 5) [1].

Urbain




Figure 5: Variance conditionnelle locale




Figure 6: Variance pour la zone urbaine




Figure 7: Superposition de l'image originale et celle de l'indice de texture

La figure 8 correspond au paramètre de texture estimé d'une région non urbaine. On remarque que toute l'image apparaît en clair, ce qui correspond à une zone non urbaine. Par contre, sur l'image de la figure 9 apparaissent certaines zones sombres.

Nous appliquons, par la suite l'algorithme « C-moyennes floues » non supervisé, nommé plus couramment FCM (Fuzzy C-means) pour faire la classification, sur les images obtenues par le modèle markovien. Nous obtenons les résultats représentés par les figures 10 et 11.

Sur l'image de la figure 11 un seul nuage de point est détecté lorsqu'il n'y a pas de zone urbaine, et deux dans le cas contraire (voir figure 10). Nous observons sur cette

dernière que certaines zones non urbaines - telles que les serres - apparaissent comme urbain à la classification.



Figure 8 : Variance conditionnelle locale




Figure 9 : Variance classique



Figure 10 : Masque urbain pour la zone urbaine




Figure 11 : Masque urbain pour la zone non urbaine

Nous avons comparé nos résultats avec un masque urbain extrait à partir de l'image de la variance classique (voir figure 12). On remarque l'existence de deux nuages de points, ce qui représente une confusion entre l'urbain et le

non urbain (Cette image présente le contour de l'urbain).




Figure 12 : Masque urbain à partir de la variance classique

L'estimation de la variance conditionnelle locale avec l'approche isotrope favorise tout ce qui est structure linéaire et génère par ce fait des confusions avec les zones urbaines. Ce constat nous a mené à intégrer l'approche anisotrope afin de mieux caractériser le milieu urbain par rapport aux objets linéaires obtenus par l'approche isotrope.

## 5 LE MODELE ANISOTROPE

Les images de zones urbaines contiennent des variations d'intensité des pixels quelque soit la direction, tandis que les images de champs sont constituées de régions d'intensité localement uniforme. Par ailleurs, certains objets tels que les serres, ayant une structure linéaire (figure 13) présentent des variations d'intensité, dans des directions privilégiées, semblables aux zones urbaines. Ainsi, sur l'image de l'estimée de la variance conditionnelle locale (figure 5), qui correspond à une analyse isotrope de la texture, les objets ayant une structure linéaire (serres, certaines cultures) ont un paramètre de texture proche de celui des villes (zones sombres sur la figure 5). C'est pour cette raison que nous nous proposons d'analyser la texture par une approche anisotrope afin de pouvoir mieux caractériser les zones urbaines sur des images où la structure des objets apparaît plus nettement.

L'anisotropie de certaines zones de l'image est de plus en plus visible avec la finesse de la résolution des images satellitaires.

Le modèle anisotrope permet de mieux caractériser les zones urbaines sur des images sur lesquelles la structure des objets apparaît plus nettement [8].



Figure 13 : Zoom sur la serre de l'image

## 5.1 Modèles markoviens gaussiens

On va prendre en compte l'anisotropie en considérant 8 modèles chacun selon une direction. Au lieu de considérer les voisinages classiques isotropes (4 connexité, 8 connexité), nous définissons dans la direction  $d$ , le voisinage du pixel  $s$  comme étant l'ensemble constitué des deux voisins les plus proches de  $s$  dans cette direction (Figure 14). Chaque modèle est défini dans une direction donnée.

Nous considérons des champs gaussiens de sorte que la probabilité conditionnelle pour le modèle dans la direction  $d$  est la suivante :

$$P(X_s / X_r, r \in V^d(S)) = \frac{1}{Z_{V^d(s)}} \exp(-\beta^{(d)} (\sum_{r \in V^d(s)} (X_s - X_r)^2 + \lambda^{(d)} (X_s - \mu)^2))$$

$V^d(s)$  est le voisinage de  $s$  défini dans la direction  $d$ .

$Z_{V^d(s)}$  est la constante de normalisation.

$\beta^{(d)}$  et  $\lambda^{(d)}$  sont les paramètres du modèle.

En réécrivant l'équation précédente, on montre que  $P(X_s / X_r, r \in V^d(S))$  ne dépend que de la moyenne  $m_s^d$  des deux voisins de  $s$  dans la direction  $d$  :

$$P(X_s / X_r, r \in V^d(S)) = \frac{1}{Z_{V^d(s)}} \exp(-\beta^{(d)} (2 + \lambda^{(d)}) (X_s - \frac{2m_s^d + \lambda^{(d)} \mu}{2 + \lambda^{(d)}})^2)$$

$$= P(X_s / m_s^d)$$

$P(X_s | X_r, r \in V_{d(s)})$  suit donc une loi normale définie par :

$$P(X_s / X_r, r \in V^d(S)) \equiv N\left(\frac{2m_s^d + \lambda^{(d)} \mu}{2 + \lambda^{(d)}}, \frac{1}{2\beta^{(d)} (2 + \lambda^{(d)})}\right)$$

Pour chaque modèle nous estimons, les variances conditionnelles par la méthode des queues de comète [8, 12, 13] :

$$\sigma_{d P(X_s / m_s)}^2 = \frac{1}{2\beta^{(d)} (2 + \lambda^{(d)})}$$

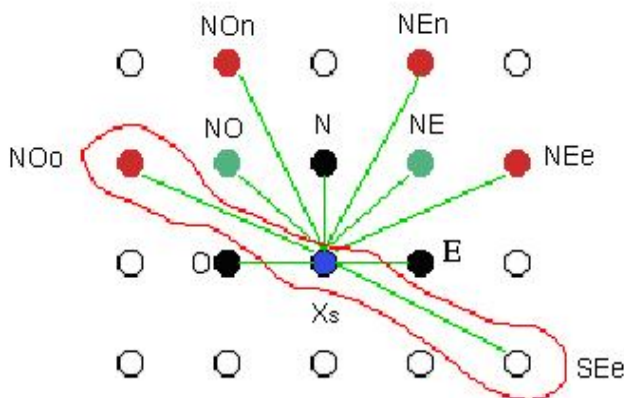


Figure 14 : Représentation des 8 directions considérées

On note :

**N** : Nord ; **S** : Sud ; **O** : Ouest ; **E** : Est.

**NE** : Nord – Est ; **SO** : Sud – Ouest ;

**NO** : Nord – Ouest ; **SE** : Sud – Est.

**NOo** : Nord – Ouest – ouest ; **SEe** : Sud – Est – est.

**NOn** : Nord – Ouest – nord.

**SEs** : Sud – Est – sud.

**NEn** : Nord – Est – nord.

**SOs** : Sud – Ouest – sud.

**NEe** : Nord – Est – est ; **SOo** : Sud – Ouest – ouest.

Le réseau ainsi constitué sur l'image n'est pas isotrope comme le montre la figure 14. En effet, si on considère la direction (Est - Ouest), les pixels voisins du pixel  $s$  sont situés à une distance 1 de  $s$ . En revanche, si l'on considère la direction (NOo / SEe), les pixels voisins de  $s$  sont situés à une distance  $\sqrt{5}$  du pixel  $s$ . En d'autres termes, l'estimation des paramètres se fera sur des distances différentes selon la direction considérée. Afin de corriger le biais introduit par l'anisotropie du réseau et de pouvoir comparer les paramètres estimés dans les huit directions, nous les normalisons (les ramener sur la même échelle).

## 5.2 Normalisation des paramètres

Les voisins d'un pixel  $X_s$  sur la figure 14, sont situés à des distances variées de celui-ci. En l'occurrence 1 pour les pixels en noir,  $\sqrt{2}$  pour les pixels en vert et enfin  $\sqrt{5}$  pour les pixels en rouge (figure 15).

Ces distances introduisent un biais dans les calculs, dans la mesure où elles sont supposées être égales (une distance d'un pixel). Une normalisation s'impose afin de corriger l'anisotropie du réseau. Ce qui revient en d'autres termes à rendre les paramètres estimés comparables (sur la même échelle). L'idée principale est toute simple. Elle se base sur l'introduction, sur l'image, d'un réseau fictif de pixels sur lequel toutes les distances précédentes seront exprimées.

### 5.2.1 Choix du pas du réseau de référence

Le choix du pas du réseau de référence est fait de telle façon que les trois distances seront exprimées comme des multiples entiers de celui-ci. Ainsi pour remonter aux grandeurs de départ à partir du réseau de référence, il suffit d'effectuer un ensemble de sommations.

Les pixels situés à une distance de 1  $\Rightarrow$  1 =  $x$  . [pas]

Les pixels situés à une distance de  $\sqrt{2}$   $\Rightarrow$   $\sqrt{2}$  =  $y$  . [pas]

Les pixels situés à une distance de  $\sqrt{5}$   $\Rightarrow$   $\sqrt{5}$  =  $z$  . [pas]

Pour approximer les deux racines, on opte pour des fractions rationnelles qui offrent le meilleur compromis

entre une approximation précise des racines et un nombre réduit de sommations. La valeur du pas qui répond au mieux aux critères d'exactitude et minimisant le nombre de sommations est :  $\varepsilon = 1/12$ . Ainsi, on aura :

$$1 = 12\varepsilon$$

$$\sqrt{2} \approx 17\varepsilon$$

$$\sqrt{5} \approx 28\varepsilon$$




Figure 15: Réseau de référence

Dans la suite, nous allons donc estimer les paramètres sur l'image, puis nous allons chercher les paramètres équivalents pour le réseau de référence.

L'expression de la variance conditionnelle locale, pour chaque direction, est donnée par [8] :

Distance  $\sqrt{5}$  (NOo/SEe, NOn/SEs, NEn/SOs, NEe/SOo) :

$$\sigma_d^2 = \frac{1}{2\beta_{27}(d)(2 + \lambda_{27}(d))}$$

$$= \frac{P_{27}(\lambda)}{2\beta(2 + \lambda_{27}(d))}$$

Distance  $\sqrt{2}$  (NE/SO, NO/SE) :

$$\sigma_d^2 = \frac{1}{2\beta_{16}(d)(2 + \lambda_{16}(d))}$$

Distance 1 (N/S, E/O) :

$$\sigma_d^2 = \frac{1}{2\beta_{11}(d)(2 + \lambda_{11}(d))}$$

$$= \frac{P_{11}(\lambda)}{2\beta(2 + \lambda_{11}(d))}$$

L'expression du paramètre  $\lambda$  pour chaque direction est donnée par :

$$\lambda_{11} = \lambda(\lambda+1)^2(\lambda+2)^2(\lambda+3)^2(\lambda+4)(\lambda^2+4\lambda+1)^2$$

$$\lambda_{16} = \lambda(\lambda^8+17\lambda^7+119\lambda^6+442\lambda^5+935\lambda^4+1122\lambda^3+714\lambda^2+204\lambda+17)^2$$

$$\lambda_{27} = \lambda(\lambda+2)^2(\lambda+4)(\lambda^3+7\lambda^2+14\lambda+7)^2(\lambda^3+5\lambda^2+6\lambda+1)^2$$

Nous remarquons que la moyenne de la loi  $P(X_s|m_s)$  est une fonction linéaire de  $m_s$  c.à.d  $\langle P(X_s/m_s) \rangle = a.m_s + b$ , où

$$a = \frac{4}{4+\lambda} \text{ et } b = \frac{\lambda \mu}{4+\lambda} \text{ [8].}$$

Nous estimons donc a et b par la méthode des moindres carrés [8]. Nous déduisons  $\lambda$  de a et b pour chaque direction d.

L'expression du paramètre  $\beta$  pour chaque direction est donnée par :

$$\beta_{11} = \frac{\beta}{P_{11}(\lambda)}, \quad \beta_{16} = \frac{\beta}{P_{16}(\lambda)}, \quad \beta_{27} = \frac{\beta}{P_{27}(\lambda)}$$

avec

$$P_{11}(\lambda) = (\lambda+1)(\lambda+2)(\lambda+3)(\lambda^2+4\lambda+1)(\lambda^2+4\lambda+2)(\lambda^4+8\lambda^3+20\lambda^2+16\lambda+1)$$

$$P_{16}(\lambda) = (\lambda^8+17\lambda^7+119\lambda^6+442\lambda^5+935\lambda^4+1122\lambda^3+714\lambda^2+204\lambda+17)(\lambda^8+15\lambda^7+91\lambda^6+286\lambda^5+495\lambda^4+462\lambda^3+210\lambda^2+36\lambda+1)$$

$$P_{27}(\lambda) = (\lambda+2)(\lambda^2+4\lambda+2)(\lambda^6+12\lambda^5+53\lambda^4+104\lambda^3+86\lambda^2+24\lambda+1)(\lambda^{12}+24\lambda^{11}+252\lambda^{10}+1520\lambda^9+5813\lambda^8+14672\lambda^7+24648\lambda^6+27104\lambda^5+18646\lambda^4+7344\lambda^3+1400\lambda^2+96\lambda+1)(\lambda^3+7\lambda^2+14\lambda+7)(\lambda^3+5\lambda^2+6\lambda+1)$$

Nous allons chercher, pour les distances  $\sqrt{2}$  et  $\sqrt{5}$ , la variance conditionnelle équivalente relativement au réseau de pas 1. Ainsi, nous conservons les estimées des variances conditionnelles dans les directions N/S et E/O et nous normalisons les estimées dans toutes les autres directions. Le réseau de référence (correspondant à  $\varepsilon$ ) n'est qu'un intermédiaire pour les calculs [8].

Pour la distance  $\sqrt{5}$  la variance conditionnelle normalisée (i.e. ramenée au réseau de pas 1) est :

$$\sigma_{dnorm}^2 = g(\lambda) \cdot \sigma_d^2$$

La fonction de normalisation  $g(\lambda)$  est donnée par :

$$g(\lambda) = \frac{\frac{P_{11}(\lambda)}{(2 + \lambda_{11}(d))}}{\frac{P_{27}(\lambda)}{(2 + \lambda_{27}(d))}}$$

Pour la distance  $\sqrt{2}$  la variance conditionnelle normalisée (i.e. ramenée au réseau de pas 1) est :

$$\sigma_{dnorm}^2 = h(\lambda) \cdot \sigma_d^2$$

La fonction de normalisation  $h(\lambda)$  est donnée par :

$$h(\lambda) = \frac{\frac{P_{11}(\lambda)}{(2 + \lambda_{11}(d))}}{\frac{P_{16}(\lambda)}{(2 + \lambda_{16}(d))}}$$

### 5.3 Résultats expérimentaux

Dans le paragraphe 4.3, nous avons appliqué une analyse isotrope. Dans cette partie, nous présentons des résultats complémentaires en prenant en charge l'aspect directionnel de l'analyse. Plus explicitement, on estimera sur l'image de la figure 13 les variances conditionnelles locales pour chacun des huit modèles.

Les résultats sont présentés sur les figures (16, 17, 18, 19, 20, 21, 22, 23).

Ces images présentent l'estimée du paramètre de texture du modèle défini, respectivement dans les directions E, N, NE, NO, NEe, NOo, NEen et NOen. Une analyse visuelle montre que l'indice calculé sur les huit images permet une bonne localisation des surfaces urbaines (zones sombres) comparativement à l'indice donné par le modèle isotrope figure 5.

On remarque que cet indice distingue entre les objets qui répandent fortement indépendamment de la direction (exemple les villes), les objets qui répandent faiblement ou moyennement en fonction de la direction (champs agricoles et serres).

Sur l'image 23, il est possible de distinguer la serre de l'urbain. Cette image représente l'estimée du paramètre de texture du modèle défini dans la direction NOen. C'est aussi la direction dans laquelle est orientée la serre. Par ailleurs, on aperçoit qu'elle a une réponse similaire à celle de la zone urbaine, dans les images (17 et 18) et les images (19 et 21). Ces dernières représentent l'estimé du paramètre dans les directions N, NE, NO, et NOo.

Le comportement de l'indice calculé en fonction de la direction va contribuer à la discrimination entre ces deux thèmes, chose qui n'a pas été possible avec le premier modèle [1].



Figure 16: Direction E



Figure 17: Direction N



Figure 18: Direction NE




Figure 19: Direction NO



Figure 20: Direction NEe



Figure 21: Direction NOo




Figure 22: Direction NEn



Figure 23: Direction NOn

#### 5.4 Génération de l'indice de texture

Notre but est d'utiliser l'information texturale dérivée, afin de mieux isoler les surfaces urbaines. L'utilisation des huit indices de texture à la fois, conduit au désagrément de la lourdeur du temps de calcul. On s'est donc penché sur la recherche d'une méthode de combinaison d'indice, afin de réduire, d'une part, la quantité de données et d'autre part, de préserver une bonne richesse texturale.

Nous avons, en premier lieu, essayé de travailler sur les valeurs maximales en générant un indice, dont la valeur pour chaque pixel, est celle du maximum des huit directions. L'idée derrière cela est de pouvoir isoler les valeurs maximales, ce qui revient à isoler l'urbain. Les tests réalisés ont montré que les valeurs maximales sont très peu caractéristiques de l'urbain (figure 24). Le même constat a été obtenu pour les valeurs minimales.

Les valeurs extrêmes étant éliminées, on a essayé de classer les valeurs de l'indice dans les huit directions dans l'ordre croissant afin de ne prendre que les deux valeurs centrales. Ceci revient, en quelque sorte, à appliquer un filtre médian. Le paramètre de texture global retenu est celui donné par la moyenne de ces deux valeurs centrales. L'indice ainsi généré est donné par la figure 25 [1].




Figure 24: Valeur maximale des 8 variances conditionnelles estimées




Figure 25 : Paramètre global (moyenne des valeurs centrales)

#### 5.5 Analyse de l'image de l'indice global

L'image de l'indice donné par la moyenne des deux valeurs centrales calculée sur l'image test est donnée par la figure 25. Sur cette image, on peut remarquer que la différence entre l'urbain et le non urbain est beaucoup plus accentuée. Les limites de la zone urbaine sont très nettes. L'indice calculé donne des régions beaucoup plus homogènes que le paramètre isotrope (figure 5). En effet, la zone urbaine est beaucoup plus lisse que sur l'image du paramètre isotrope qui présente des trous.

Comme on peut le constater, les valeurs de l'indice calculé, sur la surface de la serre, se trouvent beaucoup plus proches de celles des zones non urbaines. Le risque de confusion signalée dans le paragraphe 5.3 causée par l'anisotropie de certaines régions (serres) est donc réduit.

Ce paramètre permet donc de bien cerner les zones urbaines. Cela confirme l'intérêt d'une analyse directionnelle [1].

#### 5.6 Génération du masque urbain

Notre but est de pouvoir séparer les zones urbaines des non urbaines d'une façon automatique en générant une image binaire, qui nous renseigne de la présence ou non, de l'urbain. Pour cela, l'image d'indice de texture calculée, sera utilisée comme donnée, en entrée, dans un processus classificatoire. La finalité étant de regrouper les thèmes



contenus dans l'image en deux classes urbain/non-urbain.

L'algorithme FCM non supervisé a été appliqué sur l'image de l'indice global obtenu par le modèle markovien gaussien anisotrope de la figure 13. Le résultat est représenté par la figure 26.




Figure 26: Classification avec FCM

La première constatation qu'on peut faire, c'est que la confusion due à la serre a été complètement éliminée. L'approche développée a permis donc une meilleure distinction des deux thèmes. Ce qui prouve la force et la qualité du modèle markovien anisotrope [1].

## 6 CONCLUSION

Dans le travail présenté dans ce document, on a appliqué le modèle markovien gaussien isotrope sur des images satellitales Aster de l'ouest d'Oran (Algérie). Les résultats obtenus sont de meilleures qualités : paramètre plus discriminant, bords plus francs entre les classes. Le paramètre extrait à savoir la variance conditionnelle locale est un bon indicateur de la présence de l'urbain. Toutefois, certaines confusions aux niveaux de quelques zones non urbaines (telles que les serres) apparaissent avec une réponse très voisine des surfaces bâties.

Ce constat nous a poussé à affiner l'analyse en prenant en compte l'anisotropie locale de l'image, afin de mieux caractériser le milieu urbain par rapport aux objets sources

de confusion. Cela – la prise en charge de l'anisotropie – est en parfaite concordance avec la thématique urbaine de notre étude, puisque l'aspect anisotrope est très rehaussé dans les images à haute et très haute résolution adaptées à l'analyse urbaine. A partir de ce modèle, un nouveau paramètre de texture a été calculé à partir de la variance conditionnelle locale dans les huit directions sur l'image Aster. Comme il a été expliqué précédemment. Les nouvelles orientations introduites par ce nouveau paramètre sont en mesure de les différencier. Le modèle anisotrope a permis donc, de mieux caractériser le thème urbain en éliminant la plupart des cas de confusion, générés par le modèle isotrope. L'indice proposé a aussi permis d'obtenir des bords nets entre les différentes zones.

## REFERENCES

- [1] L. Chaouche Ramdane. Analyse Texturale par Approche Markovienne : Application à l'Analyse Urbaine. Thèse de Magister, Centre National des Techniques Spatiales (CNTS), Arzew, 2006.
- [2] X. Descombes. Champs de Markoviens en analyse d'images. Thèse de Doctorat, ENST, 1993.
- [3] X. Descombes, M. Sigelle & F. Preteux. "Estimating Gaussian Markov random field parameters in a nonstationary framework: Application to remote sensing imaging". IEEE Trans. on image processing, vol.8, no.4, avril 1999, pp.490-503.
- [4] H. Fizazi, R. Rabahi et I. Khireddine. Application des champs aléatoires de Markov approche multi échelle pour la classification des images satellitaires. Projet d'Ingénieur, Université USTO, Oran, 2003.
- [5] T. Iftene & A. Safia. "Comparaison entre la matrice de cooccurrence et la transformation en ondelettes pour la classification texturale des images HRV(XS) de Spot". Télédétection, Vol.4, n°1, p.39-49, 2004.
- [6] Z. Kato. Modélisations Markoviennes Multirésolutions en vision par ordinateur. Application à la segmentation d'images SPOT. Thèse de Doctorat, Université Nice-Sophia Antipolis, 1994.
- [7] J. Laferté. Contribution à l'analyse d'images par modèles markoviens sur des graphes hiérarchiques : Application à la fusion de données multirésolutions. Thèse de Doctorat