

REVUE DES APPROCHES DE SEGMENTATION D'IMAGES TEXTUREES : EXEMPLE DES IMAGES METEOROLOGIQUE

S.AMEUR *, ZAMEUR *

***Laboratoire d'analyse et de modélisation des phénomènes aléatoires (LAMPA), Département d'électronique, Faculté Génie Electrique et Informatique, Université Mouloud Mammeri, BP no 17 RP 15000 Tizi-Ouzou, Algérie*

soltaneameur@yahoo.com

amzohra@yahoo.fr

Résumé: Cet article présente une revue des approches en segmentation d'images. Nous montrerons que l'approche région est la mieux adaptée pour la segmentation des images texturées. Nous passerons en revue les principales méthodes d'analyse des images texturées et nous donnerons les résultats obtenus par application de méthodes statistiques développées au laboratoire sur des images météo-sat en vue de l'identification des nuages.

Mots clés: images, segmentation, texture,

1 Introduction

Pour segmenter une image en régions homogènes au sens de la texture, il est nécessaire de classer les pixels de l'image. Depuis les travaux de Haralick & al. [HAR73] de nombreux auteurs ont traité le problème de classification en proposant diverses méthodes de caractérisations locales de la texture, notamment Chu & al. [CHU *et al.* 90]. Ces travaux et bien d'autres étudient les moyens de caractériser localement l'image en décrivant les interactions entre un pixel à classer et un ou plusieurs de ses voisins. Les paramètres extraits de matrices de cooccurrence ou les coefficients de corrélations multiples entre groupes de voisins de pixels ont notamment été utilisés. Ces méthodes ont été suffisamment développées sous l'angle de la recherche pour que l'on pense maintenant les exploiter et les comparer sur des données réelles, dans un contexte d'application. Quelques études comparatives ont été menées (PPOhania & al. 1992); (J.P. Cocquerez & S. Philipp 95). Cependant ces travaux n'ont été menés, en général, que sur des textures de l'album de Boadatz. Nous présentons dans cet article deux nouvelles méthodes que nous appliquerons à des images météorologiques. L'une est une version améliorée des cooccurrences qui tient compte de l'anisotropie de la texture et l'autre est une

segmentation multi échelle, basée sur une approche bayésienne et qui utilise un réseau multi échelle du champ markovien.

2 Approches de segmentation d'images

La segmentation fait référence aux notions de différence et de similarités perçues par le système visuel humain. Ces notions ont donné naissance à deux approches principales : l'approche frontière et l'approche région. Remarquons qu'il existe aussi d'autres approches moins utilisées telles que les contours actifs, les templates, les modèles pyramidaux et les modèles mixtes.

2.1 Approches 'frontière'

Ce sont parmi les plus classiques en segmentation d'images. Ces méthodes supposent généralement un modèle à priori des discontinuités recherchées et opèrent de manière très localisée. Les approches frontière peuvent aussi être classées en plusieurs catégories [Cocq95], à savoir : les approches dérivatives [Deriche87], surfaciques [HAR84], morphologiques, markoviennes [CHO90] et variationnelles [MCI96]. Toutes ces approches sont bien adaptées aux images qui présentent des régions

uniformes au sens des niveaux de gris et offrent une bonne localisation spatiale. Mais, elles restent très sensibles aux bruits et aux contours mal définis. Elles sont donc utiles pour détecter les frontières entre les objets mais ne s'appliquent pas aux frontières séparant des régions de textures différentes.

2.2 Approches 'régions'

Contrairement aux approches frontières qui recherchent les dissimilarités, les approches région recherchent plutôt la similarité. Ces approches fournissent une carte de régions fermées. Cependant la localisation des frontières reste généralement peu précise. Parmi les approches région, on distingue les méthodes de classification, la croissance de régions et la division fusion.

2.2.1 Les méthodes de classification

Les classes sont construites à partir des attributs des pixels. Chaque pixel est affecté à une classe unique. Les méthodes de classification les plus classiques en segmentation région sont essentiellement les méthodes de seuillage et la méthode des nuées dynamiques (ou des K-moyennes). On retrouve également toutes les méthodes de classification floue [HER97], les méthodes de classification bayésienne [PAP92][VEM95][ASH95a] et les méthodes neuronales [pal94][HUI98](koho88). Les résultats obtenus par ces techniques sont liés au problème du choix du nombre de classes (approches non supervisées) et au problème du choix des attributs.

2.2.2 Les méthodes de type croissance de régions

Développée initialement par Muerle et Allen en 1968 [MuAl68], ce type d'approche consiste à choisir, d'abord, des germes de régions, puis à faire croître chaque germe en intégrant progressivement des pixels voisins à ces germes. Cette méthode présente des analogies avec le système de vision humaine puisque quand on regarde une image, on commence toujours par un point particulier, puis on cherche ensuite à reconnaître l'objet autour de ce point. Ici, l'image est d'abord divisée en cellules de $k \times k$ pixels ($k=2,4$, ou 8). Ensuite, on balaye l'image de gauche à droite et de haut en bas. Dès qu'on rencontre une cellule comme le germe d'une nouvelle région, on teste la similitude entre la cellule en cours et la cellule-germe pour chaque cellule adjacente à cette région. Le test utilisé est le test d'homogénéité de Kormognov-Smirnov sur les histogrammes de niveaux de gris des deux cellules. Si le résultat du test est nul (c'est-à-dire que les deux cellules sont similaires), alors la cellule en cours sera intégrée à la région, et la forme de celle-ci sera recalculée. La croissance ultérieure de cette région se fera en utilisant sa nouvelle forme. Cette procédure est répétée jusqu'à ce que l'on ne trouve plus de cellules pouvant être ajoutées à la région en cours. La région trouvée est enregistrée et on commence une nouvelle itération de l'algorithme. La segmentation est terminée lorsque toutes les cellules sont traitées. Dans cette méthode, deux facteurs agissent sur le résultat de

la segmentation : l'un est le choix des germes initiaux, l'autre est la condition d'arrêt de la croissance de régions. Notons que la croissance de région est une méthode particulière de segmentation d'images. Elle exploite correctement les informations contextuelles et les informations topologiques de l'image. L'inconvénient de cette méthode est que le temps de calcul est très important et qu'elle produit toujours des régions trop nombreuses par rapport au nombre d'objets dans l'image. De plus, le résultat obtenu dépend aussi de l'ordre dans lequel on opère la fusion et la division des régions.

2.2.3. Les méthodes de type division fusion

Après une étape d'initialisation, le processus de segmentation est itératif et alterne deux phases : une phase de division de toutes les régions non homogènes et une phase de fusion de toutes les régions adjacentes de sorte que la région résultante respecte toujours le critère d'homogénéité. Ces méthodes font appel à la théorie des graphes. Ainsi, elles peuvent être classées selon la structure du graphe utilisé. On retrouve alors le partitionnement de Voronoï [COCQ95], l'arbre quaternaire [STR91][MUZ93][MUZ96] [ROU7] et les approches pyramidales.

2.3 Autres approches

2.3.1. Les modèles pyramidaux

Ces modèles consistent à utiliser des images réduites par deux à chaque fois par rapport à l'image initiale. On peut donc choisir la hauteur de la pyramide en fixant le nombre de divisions que l'on autorise (demi image, quart d'image, huitième d'image, ...). Un trop petit nombre de division revient à n'opérer que sur l'image initiale et n'est pas intéressant en pratique. Trop de divisions donnent une image microscopique sur laquelle on ne peut plus trouver le contour. Les méthodes pyramidales peuvent être utilisées pour placer des templates. Pour effectuer la segmentation, on recherche tout d'abord le contour dans une image au 1/8ème par exemple, où le traitement est extrêmement rapide vu la faible taille de l'image. Ensuite, dans l'image au 1/4, on recherche le contour en initialisant ce dernier à partir de l'image au 1/8ème. Puis, on affine au fur et à mesure le tracé du contour pour finalement obtenir une segmentation de l'image à sa taille initiale. La structure la plus connue celle de l'algorithme des quad-tree, en raison de sa simplicité et son efficacité. Cependant, son inconvénient majeur est son caractère rigide et son incapacité à s'adapter à la structure fondamentale des données de l'image.

2.3.2. Les modèles mixtes

Ils résultent de la combinaison des approches contour et région.

3 Etude comparative : (Choix de la méthode de segmentation)

Il s'agit de montrer que les méthodes texturales semblent bien adaptées au traitement d'images naturelles. Rappelons que le but principal de toute méthode de segmentation est de construire une partition optimale au sens d'un critère donné. Ceci nécessite alors la définition de ce critère ainsi qu'une règle d'affectation de chaque point image à la région ou à la classe la plus appropriée.

L'approche région s'attache à faire apparaître des régions homogènes selon un critère (niveau de gris ou texture), alors que l'approche frontière tente de trouver des contours ou frontières de régions présentant une variation rapide du même critère

Parmi les approches de segmentation décrites ci-dessus, il ressort que l'approche région qui est la mieux adaptée pour la segmentation d'images texturées. Les méthodes de segmentation par classification sont les plus utilisées car elles sont capables de traiter un nombre important de données.

4 Analyse d'images texturées

En pratique, on distingue deux grandes classes de textures, qui correspondent à deux niveaux de perception: Les macro textures et les micro textures. Les macro textures présentent un aspect régulier, sous formes de motifs répétitifs spatialement placés selon une règle précise (ex: peau de lézard, mur de brique) donc une approche structurelle déterministe; les micro textures présentent des primitives "microscopiques" distribuées de manière aléatoire (ex: sable, laine tissée, herbe) d'où une approche probabiliste cherchant à caractériser l'aspect anarchique et homogène.

4.1. Méthodes d'analyse de la texture

Le but de l'analyse de texture est de formaliser les descriptifs de la texture par des paramètres mathématiques qui serviraient à l'identifier.

L'absence d'une définition formelle et précise de la texture a conduit à l'élaboration d'une multitude de méthodes d'analyse de textures. Le choix d'une méthode de caractérisation de textures est étroitement lié à l'application visée et à la nature de la texture à discriminer

Une multitude de méthodes, de variantes et de combinaisons de méthodes ont déjà été proposées dans la littérature [JAIN82]. On distingue cinq types de méthodes :

4.1.1. Les méthodes structurelles

Ces méthodes tiennent compte de l'information structurelle et contextuelle d'une forme et sont particulièrement bien adaptées aux textures macroscopiques. Les étapes d'analyse sont d'abord l'identification des éléments constitutifs, puis la définition des règles de placement. Les deux structures

les plus importantes sont les structures de graphe et les structures syntaxiques.

4.1.2. Les méthodes statistiques

Dans ces méthodes, la texture est considérée comme la réalisation d'un processus stochastique stationnaire. Des paramètres statistiques sont estimés pour chaque pixel de l'image. Suivant la modalité des images à étudier, la signature la plus discriminante de la texture est à rechercher soit dans des méthodes qui exploitent directement les propriétés statistiques de la texture (matrices de cooccurrences, matrice de longueurs de plages, matrice de voisinage, fonction d'autocorrelation, modèle de Markov, modèle autorégressif, modèles issues de la morphologie mathématique), soit dans des méthodes qui exploitent les propriétés statistiques à partir d'un plan transformé dans lequel on réécrit l'image de texture (densité spectrale, méthode des extremas locaux, méthodes de transformation de Fourier, Karhunen Loeve, Walsh Hadamard, Slant ou avec des filtres numériques).

4.1.3. Les méthodes basées sur l'étude des formes

se trouvent au croisement de la reconnaissance des formes, de la caractérisation de défauts et de l'analyse macro textural. Les régions texturales de l'image épousent des formes particulières et peuvent être caractérisées par des paramètres dits de formes.

4.1.4. Les méthodes spatio-fréquentielles

Ces méthodes, préservent à la fois les informations globales et locales. Elles sont bien adaptées aux signaux quasi périodiques, en effet, les textures sont des signaux quasi périodiques qui ont une énergie fréquentielle localisée. Ces méthodes permettent de caractériser la texture à différentes échelles.

4.1.5. Les méthodes fractales

Ces méthodes permettent de synthétiser des images très proches de la réalité. En analyse de texture, la dimension fractale, qui est une mesure du degré d'irrégularité d'un objet, décrit une certaine propriété de la texture. Le modèle fractal est basé essentiellement sur l'estimation par des méthodes spatiales de la dimension fractale de la surface représentant les niveaux de gris de l'image.

5 Choix de la méthode d'analyse

Différentes études comparatives ont été déjà réalisées et ont porté sur divers types d'images où chaque base avantageait une famille par rapport à une autre. Les résultats obtenus ont montré la supériorité des caractéristiques extraites à partir des méthodes basées sur les deux approches : spatio-fréquentielle et statistique. En effet, les méthodes, basées sur l'approche spatio-fréquentielle, offrent l'avantage de déterminer les caractéristiques en fréquence et en orientation des points de l'image. Toutefois, les

résultats obtenus par ces dernières semblent plus liés à la nature des textures. Par contre, les méthodes basées sur l'approche statistique, ont de bonnes performances sur toute la base de données choisies. Néanmoins, l'utilisation conjointe des attributs provenant de familles différentes a permis d'aboutir à des résultats robustes sur une large gamme de types d'images.

Chacune de ces deux approches regroupent plusieurs méthodes, celles essentiellement utilisées sont :

L'approche spatio- fréquentielle qui consiste à caractériser la texture par filtrage fréquentiel on trouve essentiellement les Filtres de Laws spectre de puissance....,

Ces méthode, basée sur le domaine de Fourier, présente un inconvénient majeur qui est principalement dû à la perte de l'information de localité spatiale dans l'image. En outre, cette position est une information très importante pour la segmentation de l'image.

L'approche statistique qui part de l'hypothèse selon laquelle une texture est une réalisation d'un processus stochastique à deux dimensions possédant la propriété de stationnarité. Dans cette approche, on cherche à caractériser la distribution spatiale des niveaux de gris par une approche statistique. Parmi les principales méthodes nous pouvons citer : la méthode du maximum de vraisemblance, les matrices de cooccurrences, les différences statistiques et les vecteurs de rang.

6 Discussion

Choisir l'une ou l'autre des méthodes d'extraction de caractéristiques de la texture dépend des images à segmenter. Devant la diversité des images, il semble raisonnable de dire qu'il n'existe pas une famille d'attributs universelle ou une méthode d'extraction optimale.

Les méthodes basées sur l'approche structurelle sont particulièrement appliquées à la description et à la synthèse de textures ayant une organisation régulière (textures périodiques). Ce type de textures ne représente qu'une faible proportion des textures que l'on rencontre dans les scènes naturelles. De plus, une texture comporte toujours un caractère aléatoire dans les primitives qui la constituent comme dans les règles de placement. L'approche purement structurelle s'avère insuffisante à cause de sa rigidité car elle trouve beaucoup de contraintes dans les applications réelles où des textures présentant des structures périodiques idéales n'existent pratiquement jamais.

En évaluant les avantages et inconvénients de chaque approche, nous remarquons que l'approche statistique est la plus adéquate en vu du type de données utilisées.

Dans les prochains paragraphes, nous appliquerons la technique du maximum de vraisemblance à la

segmentation des images Météosat. Puis, nous présenterons une amélioration que nous avons apportée à la méthode d'analyse de la texture des images par les matrices de cooccurrence. Nous donnerons aussi les résultats obtenus par approche markovienne.

7 Segmentation d'images météosat

7.1. Présentation des données

Les images satellitaires que nous avons utilisées sont des images prises par le satellite Météosat. La base de données Météosat disponible pour notre étude, se compose d'une série d'images Wefax représentant toute l'Afrique du Nord, transmises à travers les canaux visible (VIS : 0.4 - 1.14 μm) et infrarouge (IR : 10.5 - 12.5 μm) de Meteosat 4 et collectées toutes les trois heures pendant le mois de Décembre 1994 par la station météorologique de Dar El Beida (Algérie). Chaque image forme une fenêtre de 512 x 512 pixels, pour laquelle les valeurs possibles des niveaux de gris vont de 0 à 255 et la taille de chaque pixel est 5 x 5 km² au point sub-satellite. Les prétraitements que doivent subir ces images sont le rehaussement de leur contraste et l'élimination des bruits impulsionsnels. Ainsi, les images visible et infrarouge du 19.12.1994, ont été rehaussées par égalisation d'histogrammes. Les résultats de ce rehaussement sont données par les figures 1 et 2. afin de faciliter l'interprétation des résultats une composition colorée a été effectuée (voir figure 3).




Fig. 1. Image visible du 19.12.1994 rehaussée par égalisation d'histogramme.




Fig. 2. Image infrarouge du 19.12.1994 rehaussée par égalisation d'histogramme

7.2. Méthode du maximum de vraisemblance

Supposons que les classes d'une image soient $C_1, \dots, C_k, \dots, C_K$, où K est le nombre total de classes. La probabilité d'avoir la classe à laquelle un pixel X appartient, est donnée par la probabilité conditionnelle $P(C_k / X)$, à savoir la probabilité à postériori que la classe C_k soit bien celle à laquelle appartient le pixel X . Le principe du maximum de vraisemblance repose sur le théorème de Bayes qui stipule que :

$$P(X) P(C_k / X) = P(C_k) P(X / C_k) \quad (1)$$

La technique du maximum de vraisemblance a pour but de réaliser une classification des pixels de l'image de manière à minimiser le risque d'erreur de classification de ces pixels. La recherche du minimum de cette erreur revient à comparer les probabilités à priori obtenues successivement au cours de la classification grâce à la règle de décision de Bayes dont la formulation est la suivante :

Un pixel X de l'image de valeur x sera considéré comme appartenant à la classe C_k si $P(C_k) > P(C_l)$ pour tout k différent de l .

Pour segmenter une image en K classes C_k , il suffit donc connaître la probabilité à priori $P(C_k)$ de chacune de ces classes. On peut alors écrire que :




Fig. 3. Composition coréée des images visible et infrarouge prises par le satellite Meteosat le 19.12.1994.

$$P(X) = \sum_{k=1}^K P(X / C_k) P(C_k) \quad (2)$$

Compte tenu des expressions (1) et (2), la règle de décision de Bayes peut encore s'exprimer comme étant :

$$x \in C_k \text{ si } P(C_k / X) > P(C_l / X) \quad \forall k \neq l \quad (3)$$

En pratique, la méthode du maximum de vraisemblance est mise en œuvre en réalisant une partition de l'histogramme bidimensionnel visible – infrarouge en classes d'après des caractéristiques

moyennes. Ces dernières qui peuvent être le centre de gravité et la matrice de covariance, sont des classes caractéristiques données à priori. Les caractéristiques moyennes données pour initialiser l'algorithme du maximum de vraisemblance sont obtenues à partir d'un ensemble d'apprentissage. Cet algorithme comporte très sommairement les étapes suivantes :

- Pour déterminer l'ensemble d'apprentissage, une première partition arbitraire de l'histogramme bidimensionnel est effectuée.

- La réflectance la plus brillante et la température la plus froide déterminent la classe des nuages les plus hauts et les plus épais.

- La détermination des seuils pour la classe de surface est effectuée en repérant le minimum de réflectance pour une température de brillance forte.

- Plusieurs couches de nuages épais et d'altitudes différentes sont déterminées à partir de cet histogramme.

- Des courbes d'évolution visible/infrarouge sont associées à ces différentes couches de nuages, de la surface terrestre jusqu'au nuage épais.

- Les classes résultent d'une partition régulière le long des courbes d'évolution visible/infrarouge reliant la partie de ciel clair à la partie la plus épaisse et la plus froide de la couverture nuageuse.

- A partir des valeurs moyennes associées à chaque classe déterminée dans

L'histogramme, l'algorithme ainsi décrit, retourne aux images d'origine pour trouver

Les points les plus proches des centres de gravité de chaque classe et définit ainsi un ensemble d'apprentissage.

- A partir de chaque groupe de points et du voisinage 3x3 de chacun de ces points, un centre de gravité et une matrice de covariance sont calculés à nouveau.

- Après plusieurs itérations, on obtient une partition optimum

Cette méthode qui a été mise en œuvre dans notre laboratoire, a été appliquée à l'ensemble des images Météosat de notre base de données. Pour ce faire, nous avons construit l'histogramme bi-dimensionnel visible – infrarouge en cumulant toutes les images Météosat du mois de Décembre 1994. Cet histogramme est donné par la figure 1 dans laquelle l'axe des abscisses représente les niveaux de gris des pixels composant les images visibles et l'axe des ordonnées est relatif aux images infrarouges. Il donne la probabilité qu'un point de l'image ait, à la fois, un niveau de gris (i) dans le visible et un niveau de gris (j) dans l'infrarouge. Cette probabilité qui est aussi la fréquence d'apparition du couple (i, j), est représenté par l'échelle des couleurs de la figure 1. A partir de l'histogramme 2D ainsi établi, on construit le diagramme de partition de cet histogramme et celui permettant l'identification des classes de pixels. Ces

deux diagrammes sont donnés par la figure 4. Ces diagrammes permettent ensuite la segmentation de n'importe quelle image de notre banque de données. La figure 5 montre le résultat de la segmentation de l'image visible prise le 19 Décembre 1994 à 14 H (voir fig. 1).


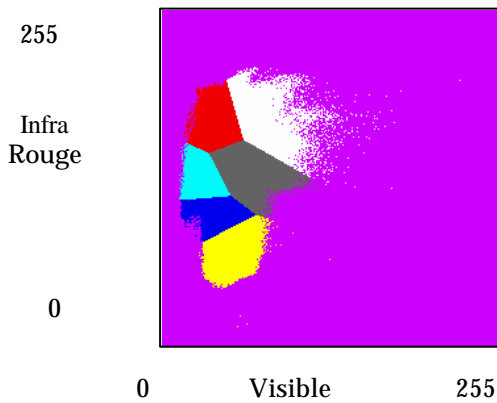
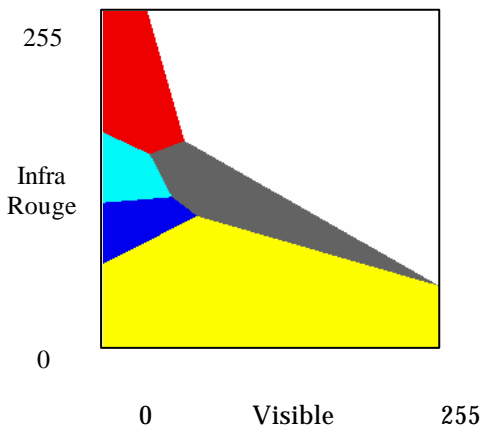


Fig. 4. Histogramme bidimensionnel des images Météosat du mois de Décembre 1994 (rappelons que ces images ont été collectées simultanément dans le visible et l'infrarouge, toutes les trois heures, pendant une période de trente jours).



a-Partition de l'histogramme 2D



(a) Identification des classes.

Fig.5. Diagrammes de partitionnement et d'identification des classes.




Fig.6 . Résultats de la segmentation par maximum de vraisemblance.

L'image de la figure 6 se compose de six classes repérées par les couleurs jaune, vert, bleu, blanc, marron et rouge respectivement. Pour trouver à quoi correspondent ces classes, nous avons comparé cette image à la composition colorée des images visible et infrarouge donnée par la figure 3. On constate que les surfaces blanches qui apparaissent sur la figure6, correspondent grossièrement aux nuages blancs figurant sur l'image de la figure 3. Ce sont des nuages élevés. La région en jaune peut globalement être attribuée aux sols chauds et arides de la partie basse de l'Afrique du Nord. Les régions rouges et marron semblent correspondre à des nuages plus bas. Les régions bleues peuvent être associées aux mers et aux terres froides et humides et les régions vertes peuvent être attribuées aux mers et aux terres plus humides et beaucoup plus froides. Dans l'ensemble, cette classification donne des indications sur les différents constituants de l'image mais elle laisse subsister beaucoup de zones de confusion. En effet, les éclaircies qui existent au dessus de l'océan Atlantique et de l'Europe, n'apparaissent pas dans les classes rouges, marrons et vertes. L'identification de la classe bleue nous semble incorrecte car elle comporte des zones où existent normalement des nuages moyens ou élevés et des parties chaudes à l'est de l'Algérie ; En outre, il est impossible de distinguer les contours de l'Afrique du Nord et de la mer Méditerranée dans cette classe. Plus généralement, on peut dire que les méthodes multispectrales n'offrent pas toujours des résultats satisfaisants du fait qu'elles laissent subsister des zones de confusion de certaines classes qui restent spectralement confondues. C'est le cas des nuages observés au dessus de surfaces couvertes de neige et de glace. Etant donné que l'utilisation de l'information spectrale telle que celle découlant de l'application de la méthode du maximum de vraisemblance, ne suffit pas, à elle seule, à atteindre une bonne classification, on est donc amené à considérer d'autres types d'information. Dans le souci d'une amélioration de la classification, nous avons pensé à extraire les propriétés de texture de l'image car celles – ci apportent des informations pouvant compléter celles contenues dans les signatures spectrales. Dans ce contexte, deux voies nous sont offertes : l'approche

markovienne et la technique des matrices de cooccurrence.

7.3. Méthode des matrices de cooccurrences

Pour les images météosat, la méthode des cooccurrences a été utilisée pour extraire les propriétés texturales des images utilisées pour différentes orientations. Rappelons que ces orientations sont 0° , 45° , 90° et 135° (S.AMEUR & al, 2001). Les paramètres texturaux ainsi obtenus, sont le contraste, l'énergie, l'entropie, la corrélation et l'homogénéité locale. Le nombre de composantes représentant ces paramètres ont été réduits au moyen de la TKL. On a déduit alors que la première composante des propriétés texturales joue un rôle important dans la classification des images. A l'étape suivante, les propriétés texturales les plus représentatives ont été sélectionnées en utilisant l'algorithme pas à pas. On trouve alors que l'utilisation du contraste conduit à la meilleure classification. Dans la plupart des cas, la combinaison du contraste avec les trois autres propriétés texturales améliore le taux de classification. Finalement, l'algorithme des K-means a été appliqué à la segmentation des images Météosat. la fenêtre d'analyse doit être convenablement choisie, car le taux de classification dépend de la taille de la fenêtre. En outre, le vecteur déplacement choisi, décrit très bien l'anisotropie de la texture.

7.3.1. Résultats de la classification en utilisant la méthode des matrices de cooccurrences

Pour segmenter l'image multi spectrale Météosat, nous avons intégré dans la procédure de classification le paramètre contraste et le paramètre énergie et ce, en plus de l'information radio métrique des deux composantes visible et infrarouge. A partir de l'image contraste, on constate déjà une première segmentation texturale (voir fig. 7). Sur l'image du paramètre énergie, on reconnaît les zones homogènes avec les couleurs rose et bleu, et on distingue une zone très hétérogène correspondant aux nuages bas (voir fig.8). les résultats de la segmentation sont donnés par les figures 9 et 10.




Fig. 7 : Image représentant le paramètre contraste




Fig. 8 : Image représentant le paramètre énergie




Fig. 9 : Résultat de la segmentation en utilisant la T.K.L, $T_c=893(s)$




Fig. 10: Résultat de la segmentation en utilisant les paramètres moyens, $T_c=1436(s)$

Légende :

Vert foncé: Sol humide et mer, **Bleu:** Sol chaud, **Jaune:** Nuages moyens, **Orange:** Nuages élevés, **Vert clair:** Nuages bas.

7.4. Segmentation par analyse Multi-échelle associée à une approche markovienne

7.4.1. Principe de l'approche multi-échelle de la segmentation

La méthode de segmentation que nous allons présenter est une nouvelle approche de segmentation bayésienne de l'image. Elle remplace le modèle MRF en utilisant le réseau multi-échelle du champ markovien (Multi Scale Random Field ou MSRF) et elle remplace aussi l'estimateur M.A.P par un estimateur séquentiel par maximum à posteriori ou SMAP dérivé d'un critère d'estimation. A la

différence du MRF, la méthode de segmentation obtenue est un algorithme non itératif ayant un temps de calcul proportionnel à MN où M est le nombre de classes et N le nombre de pixels. Le modèle MSRF possède un certain nombre d'avantages par rapport au modèle MRF à échelle fixe. La structure en chaînes de Markov facilite l'estimation des paramètres du modèle MSRF. L'estimateur SMAP permet de minimiser la dimension des régions non classées en assignant progressivement les erreurs dues au mauvais classement des pixels aux échelles grossières. Cet estimateur se compose d'une série d'étapes d'optimisation partant d'une échelle grossière vers une échelle plus fine.

7.4.2. Résultats

Le résultat obtenu par l'application de la méthode de segmentation par analyse multiéchelle à l'image de la figure 6 est donné par la figure 11. On constate que deux classes supplémentaires ont été identifiées. En effet, cela s'explique par le fait que l'analyse sur plusieurs échelles permet de discerner des nuages différents mais pouvant avoir des caractéristiques de textures proches




Fig. 11 : Résultat de la segmentation par analyse multi-échelle

Les caractéristiques statistiques de chaque classe sont données ci-dessous :

Multi-échelle pour 10 classes

Clusters	Pixels	Moy. Statistique de chaque classe
1	5612	241.5
2	5537	215.5
3	4516	192.0
4	6021	167.5
5	5301	139.4
6	4568	115.1
7	5254	91.1
8	5082	66.0
9	5356	39.7
10	5182	14.3

Conclusion

L'utilisation de l'information spatiale et spectrale a permis une bonne segmentation des images considérées. La segmentation des images Météosat a mis en évidence huit classes homogènes. Toutes ces classes ont respectivement été identifiées à des régions de même texture exprimant la nature de la surface terrestre pour les régions étudiées et la présence de nuages dans ces régions. Deux principales sortes de nuages ont été trouvées dans l'image de la figure 9. Ce sont des nuages bas et des nuages d'altitude représentés respectivement par les classes bleu et jaune. Pour l'Afrique du Nord, ces nuages sont respectivement identifiés à des stratocumulus et des altocumulus. Les bords limitant les surfaces occupées par de tels nuages, sont bien définis, prouvant l'efficacité des deux méthodes de segmentation présentée dans cet article et permettant d'utiles applications dans les domaines de l'hydrologie et de la conversion d'énergie solaire. Cependant, les classes bleu et jaune sont indiquées dans la figure 11 comme étant des surfaces uniformes alors que des nuages situés aux différentes altitudes, se superposent probablement dans les régions représentées par ces classes. Ceci signifie que l'image de la figure 11 ne peut pas nous informer complètement sur le type de nuages ainsi observés. De façon similaire, il y a une ambiguïté pour la classe vert sombre puisque l'océan Atlantique et le continent européen sont confondus dans une telle classe. Une telle ambiguïté peut s'expliquer par la limitation de la précision de classification due à la résolution de l'image [Welch et al.; 1989]. En dépit de cette limitation, des investigations supplémentaires peuvent être faites pour améliorer la classification des images. Par exemple, les propriétés texturales pourraient être calculées pour les images infrarouges et combinées avec les propriétés texturales des images visibles pour doubler les classes où des ambiguïtés sont observées et obtenir ainsi d'autres classes représentatives.

La segmentation a pu être affinée grâce à la nouvelle approche basée sur le multi-échelle. Nous avons présenté un nouveau critère et un modèle de segmentation statistique. L'estimateur SMAP est proposé pour sa capacité à minimiser la largeur des régions non classées; et donne un algorithme de segmentation facile à implémenter. Le modèle MSRF utilise une structure pyramidale pour calculer à différentes échelles les caractéristiques des paramètres de l'image à segmenter. La structure en chaîne de Markov du modèle MSRF permet d'estimer avec précision les paramètres de l'image durant le processus de segmentation.

Appliquée à l'image Météosat nous avons pu confirmé les classes identifiées par l'approche texturale tout en levant quelques ambiguïtés. Nous avons pu ainsi discriminer les classes confondues.

Références

Ameur, S ; K. Bara; A. Adane and N. Zerhouni, 2001: Effect of the texture anisotropy in the classification of remote sensing images, *Systems Analysis-Modelling Simulation-SAMS,2001, Vol.40, pp. 309-327.*

Chehikian,A., Recursive filters for gradient estimation and contour extraction using B-spline interpolation, *Traitement du signal,1997,vol.4,p.29.*

Deriche R. Using Canny's criteria to derive a recursively implemented optimal edge detector , *Int. Journal of Computer Vision,1987, vol.1,N°2,pp167-187.*

DIAS, J.M. and J.M.N. Leitao , Wall position and thickness estimation from sequences of echocardiographic images, *IEEE Trans. On Medical imaging,1996,Vol.15,N°1 PP.25-38.*

Diday, E., Lemaire, J., Pouquet, J. et Testu, F. 1982 : *Éléments d'analyse de données, Ed. Dunod, Paris, France.*

Cocquerez, J.P et S.Philipp, 1995 : Analyse d'images : filtrage et segmentation, *Ed. Masson, Paris.*

Haralick, R.M., Shanmugam, K., and Dinstein, I. 1973 : Textural features for image classification, *IEEE trans. on systems, man, and cybernetics, 6, pp. 610-621.*

Welch, R. M. ; M.S. Navar and S.K. Sengupta, 1989 : The effect of spatial resolution upon feature - based cloud field classification, *J. geophys. Res., 94(D12), 767 – 781.*

Ohanian P.P and Dubes R.C, 1992 : Performance evaluation for four classes of textural features, *Pattern Recognition, Vol.25.N°8,pp819-833.*