



## UNE NOUVELLE METHODE DE SEGMENTATION D'IMAGES DE TEXTURES MULTIREOLUTION

(A New Method for Multiresolution Texture Image Segmentation)

K. KPALMA et V. HAESE-COAT

Laboratoire d'Automatique, Equipe Image  
Institut National des Sciences Appliquées  
35043 RENNES Cedex (France)

### RÉSUMÉ

La segmentation d'images de textures est un problème qui a fait l'objet de nombreuses études. Diverses méthodes, comme celles utilisant plusieurs images de résolutions différentes (ou niveaux de pyramide) sont ainsi proposées. Dans des travaux antérieurs, nous avons présenté une méthode d'analyse multirésolution aboutissant à un algorithme de segmentation (ASM) qui s'est révélé performant mais complexe dans sa mise en oeuvre. Pour simplifier le processus, nous avons proposé un algorithme hiérarchique (ASH) qui segmente les différentes résolutions, l'une après l'autre. Par cette simplification, le système s'est alors trouvé pénalisé par une perte de performances. Dans cet article, nous proposons une méthode qui allie les avantages des deux algorithmes. Si les performances du nouvel algorithme sont inférieures à celles de l'ASM, elles sont meilleures que celles de l'ASH tout en préservant la simplicité de mise en oeuvre.

### ABSTRACT

Texture image segmentation is an important problem that is considered in many research works. Some methods like those using different resolution images (or pyramid levels) are then proposed. In former works, we have presented a method for multiresolution texture analysis that led to a multiresolution image segmentation algorithm (ASM). This algorithm is found to be accurate but complex in its implementation. To alleviate the ASM's complexity, we proposed a hierarchical algorithm (ASH) that segments different resolution images one after another and combines the results. The simplicity gain is then penalized by performances loss. To maintain ASM's performances and ASH's simplicity, we propose, in this paper, an algorithm that combines the both methods by performing ASH first and ASM last for misclassified pixels. This algorithm is found to be efficient enough with a little loss of performances but with computing time gain regarding to ASM.

### 1 Introduction

La segmentation d'images par la classification de pixels est un processus lourd en temps calcul. En utilisant la classification bayésienne, le nombre de calculs varie comme  $n^2$  si  $n$  est la longueur du vecteur attribut. Dans des travaux antérieurs [1, 2, 3], nous avons proposé une méthode (ASM : Algorithme de Segmentation Multirésolution [3]) de segmentation d'images de textures dans un contexte multirésolution. Les différents tests effectués sur diverses mosaïques de textures ont révélé l'efficacité de la méthode. Mais compte-tenu de la lourdeur de cette méthode il s'est avéré nécessaire de trouver une méthode permettant de réduire le temps calcul de l'algorithme tout en préservant ses performances de segmentation.

Un algorithme de segmentation hiérarchique (ASH [3]) fut ainsi mis au point. Mais une fois le processus simplifié, la qualité de la segmentation s'est trouvée réduite.

Dans cette étude, nous proposons une nouvelle méthode basée sur les deux algorithmes précédents.

### 2 Le principe de l'ASM

Dans le cas de l'ASM [3], les paramètres caractéristiques sont extraits à différentes résolutions pour construire le vecteur attribut. Si  $p$  est le nombre de paramètres extraits par image et si  $r$  est le nombre d'images disponibles, alors la longueur du vecteur attribut ainsi constitué est donnée par  $n=rp$ . Il est évident alors que le nombre de calculs qui varie comme  $n^2$ , est proportionnel à  $r^2$ . Les résultats de segmentation obtenus à l'aide de cet algorithme sont assez satisfaisants (de l'ordre de 99% de bonne segmentation), mais le temps calcul devient important si l'on augmente le nombre d'images de résolutions différentes. L'obtention de telles performances nous conduit alors à la recherche d'un algorithme semblable mais plus simple de mise en oeuvre.

Afin de réduire le temps calcul de cet algorithme, nous avons développé une méthode (ASH : Algorithme de Segmentation Hiérarchique [3]) qui traite une résolution à la fois en tenant compte des résultats de segmentation de l'image précédente et en observant pour chaque pixel une mesure de la qualité de sa classification. Cette mesure donne le taux de confiance que l'on peut accorder à la classification d'un point après qu'il a été classifié en tenant compte de sa position par



rapport aux différentes classes dans l'espace d'observation. Les points dont la *mesure de la qualité de classification* est en dessous d'un seuil prédéfini sont alors rejetés pour une classification ultérieure.

### 3 Le principe de l'ASH

Considérons un problème de classification bayésienne à deux classes  $\omega_1$  et  $\omega_2$  et à deux caractéristiques  $a_1$  et  $a_2$ . La règle de décision est définie par :

décider  $\omega_s$  si  $d_s(x) < d_t(x)$ ,  $s, t=1, 2$  ( $s \neq t$ )

où  $d_s(x)$  est une fonction de discrimination, en l'occurrence la distance de Mahalanobis et où  $x$  est l'observation.

Supposons que pour une observation  $x_0$ ,  $d_1(x_0) < d_2(x_0)$ . Si  $\bar{x}_1$  et  $\bar{x}_2$  sont les moyennes respectives des échantillons prélevés dans les classes  $\omega_1$  et  $\omega_2$ , alors comme le montre la figure 1, on obtient un triangle de sommets  $x_0$ ,  $\bar{x}_1$  et  $\bar{x}_2$ .




Fig. 1 : Illustration du principe de calcul de l'indice de classification.

La frontière entre les deux classes est une courbe (droite) qui coupe le segment de droite  $(\bar{x}_1, \bar{x}_2)$  et qui est définie par l'ensemble des points  $x$  du plan  $(a_1, a_2)$  tels que  $d_1(x) = d_2(x)$ . Dans le cas où les deux classes sont bien séparées, cette frontière passe entre les nuages des deux classes. Malheureusement, en pratique, il arrive souvent que les deux nuages se recouvrent. En effet, si les attributs choisis pour caractériser les deux classes ne sont pas suffisamment discriminants, les nuages des deux classes peuvent être très proches voire même se recouvrir. On retrouve alors une zone d'incertitude autour de cette frontière. Cette zone qui correspond au domaine de recouvrement des deux nuages et qui rend difficile la classification est à la base de la probabilité d'erreur. En effet, pour des observations appartenant à ce domaine, il est impossible de décider sans risque d'erreur. C'est pourquoi Weber a introduit le taux de confiance qui lui permettait, pour les fenêtres d'analyse de grande taille, de déterminer les points sur lesquels règne un *doute de classification*. Pour ces points qui sont généralement localisés dans les zones de frontières, il a utilisé des fenêtres d'analyse de petite taille réduisant ainsi les erreurs de classification [4]. La figure 2 illustre ce phénomène de recouvrement de nuages : les points de l'ensemble  $E_1$  qui sont de la classe  $\omega_1$  seront classés dans la classe  $\omega_2$  avec la règle de décision définie plus haut. De même, les points appartenant à l'ensemble  $E_2$  seront classés dans  $\omega_1$ .

On peut alors définir une troisième classe,  $\omega_R$ , qui regroupe les points de la zone de recouvrement. Elle correspond à la classe des points rejetés temporairement. Pour définir cette classe de rejet, nous devons définir une mesure de la qualité de classification d'un point. Pour cela, nous proposons une fonction utilisant les distances (dans le plan d'observation) entre le point classifié d'une part et les centres  $\bar{x}_1$  et  $\bar{x}_2$  de l'autre part.

#### 3.1 Mesure de la qualité de classification

Pour cette mesure nous proposons la fonction *indice de classification* (IC) définie par :

$$IC(x_0) = 1 - \frac{d_1}{d_2} \quad (2)$$

Cet indice varie entre 1 pour le cas d'une classification parfaite ( $d_1=0$ ) et 0 pour le cas le plus litigieux à savoir  $d_1=d_2$  (points situés sur la frontière). L'IC est donc la mesure de la fiabilité de la classification d'un point.

On peut alors définir la classe de rejet en fixant un seuil ICS en dessous duquel l'indice de classification des points bien classifiés ne doit pas se trouver. On peut alors établir une règle de décision modifiée à deux niveaux : une classification temporaire suivie d'une confirmation (ou d'un rejet) de cette classification selon que l'IC du point concerné est supérieur (ou non) au seuil.

décider temporairement  $x_0 \in \omega_s$  si  $d_s(x_0) < d_t(x_0)$

et confirmer  $x_0 \in \omega_s$   $\begin{cases} \text{si } IC(x_0) > ICS \\ \text{sinon rejeter } x_0 \end{cases}$

La classe de rejet est alors définie par l'ensemble des points  $x$  de l'espace d'observation tels que  $IC(x) < ICS$ .

Dans son étude, Weber fixait le seuil du taux de confiance de façon arbitraire et globale sans tenir compte de la valeur de ce taux au sein des classes en présence. Comme l'ont montré les tests sur les images de textures, la valeur moyenne de l'IC dépend de la classe en présence : classe à laquelle appartient le point considéré [3]. Le choix d'un seuil trop élevé risque de rejeter tous les points d'une classe entière alors que s'il est trop faible, tous les points seront confirmés.

L'image de la figure 4.c qui représente une carte de l'indice de classification (quantifié sur 256 niveaux de gris) obtenu pour une mosaïque de textures montre bien que la valeur moyenne de cette fonction dépend de la classe considérée. Prise conjointement avec l'image de la figure 4.d, on peut remarquer que les zones bien segmentées correspondent bien aux fortes valeurs de l'IC (zones claires de 4.c). Nous proposons donc une détermination automatique du seuil de l'IC et cela relativement à la classe en présence.

Considérons les deux classes  $\omega_1$  et  $\omega_2$  de la figure 2. Le choix des seuils pour les deux classes est motivé par l'existence du recouvrement ( $E_1$  et  $E_2$ ) des nuages de points. Soit  $\hat{x}_s$  le point extrême du nuage de  $\omega_s$  qui est le plus proche de  $\omega_t$ . Soient  $\delta_{ts}$  la distance, dans la métrique  $d_t$ , entre  $\hat{x}_s$  et le centre

$\bar{x}_t$  de  $\omega_t$  ( $\delta_{ts}=d_t(\hat{x}_s)$ ,  $s \neq t$ ) et  $\Delta_{ss}$  la distance, dans la métrique  $d_s$ , entre  $\hat{x}_s$  et le centre  $\bar{x}_s$  de  $\omega_s$  ( $\Delta_{ss}=d_s(\hat{x}_s)$ ).




Fig.2 : Configuration de recouvrement de deux nuages.

Dans le cas de  $\omega_1$ , c'est  $\hat{x}_2$  qui détermine le seuil puisqu'il est le point de la classe  $\omega_2$  qui a la plus forte probabilité d'être classé dans  $\omega_1$ . Ainsi, connaissant  $IC(\hat{x}_2)$  par rapport à la classe  $\omega_1$ , et en fixant le seuil de IC pour la classe  $\omega_1$  à cette valeur, on pourra obtenir une confirmation pour les points de  $\omega_1$  dont l'IC est supérieur à ce seuil. Soit

$$IC_{st} = 1 - \frac{d_{st}}{\Delta_{ss}} \text{ avec } s \neq t.$$

Cette valeur de l'IC mesurée en  $\hat{x}_s$ , vis-à-vis de  $\omega_s$ , est celle que nous prendrons donc pour être le seuil  $ICS_s$  de l'indice de classification en présence de la classe  $\omega_s$ . Comme le montre la figure 2 ci-dessus, si  $IC(\hat{x}_2) > ICS_1$ , alors des points de  $\omega_2$  seront classés dans la classe  $\omega_1$ . Par contre si l'on prend  $ICS_1 > IC(\hat{x}_2)$ , alors on peut rejeter les points de  $E_2$  appartenant à  $\omega_2$  et quelques points de  $\omega_1$  pour une classification ultérieure.

### 3.2 Cas général multiclasse

Dans le cas général où l'on dispose de plus de deux classes, on peut se ramener à un système à deux classes après l'étape de décision pour procéder à la mesure de l'IC. On prendra comme classe 1, la classe à laquelle est associé le point, après sa classification. La seconde classe sera alors celle constituée par les N-1 classes autres que la plus proche.

Soient  $\omega_s$  ( $s = 1, 2, \dots, N$ ) les N classes et soient  $\omega'_1$  et  $\omega'_2$  les deux classes définies pour le calcul de l'indice de classification. Supposons que la classe  $\omega_s$  soit celle qui a été retenue après la décision. Elle sera alors la classe  $\omega'_1$  et la moyenne des N-1 classes restantes la classe  $\omega'_2$ . Les paramètres statistiques des deux classes  $\omega'_1$  et  $\omega'_2$  sont donc donnés par les deux équations suivantes :

$$\bar{x}'_1 = \bar{x}_s \text{ et } \Sigma'_1 = \Sigma_s \quad (3)$$

$$\bar{x}'_2 = \frac{1}{N-1} \sum_{j=1, j \neq s}^N \bar{x}_j \text{ et } \Sigma'_2 = \frac{1}{N-1} \sum_{j=1, j \neq s}^N \Sigma_j \quad (4)$$

$\bar{x}_s$  ( $s=1, 2, \dots, N$ ) étant la moyenne de la classe  $\omega_s$  et  $\Sigma_s$ , la matrice de covariance de cette classe.

*Remarque : de par sa définition, il peut arriver que l'IC prenne des valeurs négatives. Le point concerné doit alors être rejeté et pour cela, on lui assigne la valeur 0.*

Les classes  $\omega'_1$  et  $\omega'_2$  étant définies, on peut calculer l'indice de classification et ainsi passer à l'étape suivante de la segmentation qui est l'étape de confirmation.

Cette technique est très utile dans un système de segmentation hiérarchique des images multirésolution. Considérons un système de segmentation à r images de résolutions différentes notées  $I_0, I_1, \dots, I_{r-1}$ . La segmentation image par image est moins lourde que celle effectuée à l'aide de l'ASM (dans le premier cas, le vecteur attribut est de longueur p alors que dans le second cas, il est de longueur rp). Si  $I'_i$  est la classe de rejet après la segmentation de l'image  $I_i$  avec l'ASH, alors à l'étape i+1, on n'a plus que cette classe de rejet à segmenter. Le volume de données diminue donc d'une étape à l'autre réduisant ainsi le temps calcul. A l'étape finale, après la segmentation de  $I_{r-1}$ , si la classe de rejet  $I'_{r-1}$  n'est pas vide, alors on effectue une segmentation supplémentaire basée alors sur l'ASM.

A cette étape, on considère dans chaque image  $I_i$  de départ ( $i=0, 1, \dots, r-2$ ), l'ensemble  $I''_i$  des points correspondant à la classe de rejet  $I'_{r-1}$  ( $I''_{r-1}=I'_{r-1}$ ). Les images  $I''_i$  sont alors combinées dans la segmentation par ASM. Le volume de donnée ayant beaucoup diminué (il ne reste plus que 14.56% pour l'image présentée à la figure 4) par rapport au volume initial, l'utilisation de l'ASM, en conséquence, reste peu coûteuse en temps calcul. La fusion des résultats de segmentation obtenus aux différentes étapes donne alors l'image segmentée finale  $I_s$ . Cet algorithme de segmentation hiérarchique d'images multirésolution (ASHIM) est représenté par le diagramme de la figure 3.




Fig.3 : Algorithme ASHIM

### 4 Résultats expérimentaux

Les résultats de segmentations effectuées sur diverses mosaïques d'images de textures montrent l'efficacité de cette méthode. La figure 4 ci-dessous représente en b, l'image originale (T1=laine, T2=paille, T3=herbe et T4=raphia), en c la carte de l'IC (niveau 0), en d la classe de rejet  $I'_{r-1}$  (représentée en noir) et en e l'image segmentée dans un contexte de p=4 et r=3 (niveaux 0, 1 et 2). Les textures utilisées dans cette étude sont celles de l'album de Brodatz [6]. Après leur saisie, nous leur avons appliqué une normalisation afin que toutes les textures aient une même valeur moyenne et une même variance. Les images de résolutions différentes sont données par les niveaux de la pyramide gaussienne [3] de la mosaïque considérée.

La figure 4.a représente la configuration d'une mosaïque de quatre textures dans une image.



Les attributs utilisés pour la segmentation sont les paramètres H du modèle fractal brownien. Les quatre attributs



sont les valeurs du paramètre extraites dans quatre orientations différentes.


T1	T2
T3	T4

a



b

c



d

e

Fig.4 : Image test et segmentation par ASHIM.

Les tableaux ci-après présentent les taux de segmentation obtenus avec l'ASM (Tableau 1) d'une part et avec l'ASHIM (Tableau 2) d'autre part. Ces tableaux montrent les résultats pour différentes combinaisons de niveaux de pyramide. Pour cette étude comparative, les tests ont été effectués dans les mêmes conditions ; pour une mosaïque de textures, nous avons pris les mêmes valeurs de p et de r.

Dans chaque tableau, les résultats sont présentés, par ligne suivant le nombre r d'images mises en jeu. Dans les colonnes, l'on peut lire le taux de bonne classification obtenu par classe (ou texture) et pour une combinaison de niveaux donnée. La dernière colonne (*global*) donne le taux de bonne segmentation pour toute l'image. Les résultats présentés correspondent aux zones intérieures des textures.

r	Niveaux	T1	T2	T3	T4	Global
2	0, 1	99.92	99.91	100.00	100.00	99.96
	0, 2	99.98	100.00	100.00	99.80	99.94
	1, 2	98.15	100.00	98.48	99.30	98.98
3	0, 1, 2	99.95	100.00	100.00	99.94	99.97

Tableau 1 : Résultats de segmentation avec l'ASM (p = 4)

r	Niveaux	T1	T2	T3	T4	Global
2	0, 1	99.97	99.94	99.98	100.00	99.97
	0, 2	99.97	99.54	98.85	99.57	99.48
	1, 2	99.30	86.35	25.55	97.48	77.17
3	0, 1, 2	99.97	99.54	98.85	99.57	99.48

Tableau 2 : Résultats de segmentation avec l'ASHIM (p=4)

### 5 Conclusion

Dans cette étude, nous avons proposé une méthode de segmentation d'images de textures multirésolution permettant d'obtenir des résultats satisfaisants tout en préservant le temps calcul vis-à-vis de l'algorithme ASM. On peut ainsi réduire le temps calcul de plus de la moitié par rapport à l'ASM. Mais il faut noter que le gain en temps calcul dépend de la population de la classe de rejet  $I'_{r-1}$ .

La comparaison des résultats obtenus sur des mosaïques de textures (Tableaux 1 et 2) nous permettent de conclure que cet nouvel algorithme est très efficace dans la segmentation d'images de textures dans un contexte de la multirésolution. En effet, en dehors de la combinaison des niveaux 1 et 2 de la pyramide, les résultats de segmentation sont globalement comparables (colonne *global*).

Par une association d'un algorithme efficace mais complexe, l'ASM, et d'un algorithme moins performant mais plus simple, l'ASH, nous avons pu dégager un algorithme de segmentation d'images assez simple de mise en oeuvre et néanmoins suffisamment robuste.

### Références

- [1] K. Kpalma, V. Haese-Coat and A. Bruno, "Analyse Pyramidale de Textures Naturelles à Travers la Dimension Fractale", 13<sup>ème</sup> Colloque GRETI, 16-20 sept. 1991, Juans-les-Pins, France, pp 1053-1056.
- [2] K. Kpalma, A. Bruno and V. Haese-Coat, "Natural Texture Analysis in Multiscale Context Using Fractal Dimension", Proc. SPIE-Visual Commun. and Image Processing, Nov. 1991, Boston, USA, Vol. 1606, pp 55-66
- [3] K. Kpalma, "Analyse Fractale de Textures Naturelles dans un Contexte Multirésolution : Application à la Segmentation d'Images Multirésolution", thèse de Doctorat à l'INSA de Rennes, France, fév. 1992.
- [4] A. G. Weber and A. A. Sawchuk, "Multiple Resolution Image Texture Segmentation", pp 108-120.
- [5] J.-C Simon, "La Reconnaissance des Formes par Algorithmes", Masson, Paris, 1985
- [6] P. Brodatz, "Textures", A photographic Album for Artists and Designers, Dover, New York, 1966.