

Segmentation d'images : recherche d'une mise en œuvre automatique par coopération de méthodes

Image Segmentation : Toward an Automatic Framework Through Methods Cooperation

par Chafik Djilal KERMAD et Kacem CHEHDI

LASTI-Groupe Image, ENSSAT, 6, rue de Kerampont, 22305 Lannion, France.
Tel : (33) 02 96 46 50 30 / E-mail : kermad@enssat.fr, chehdi@enssat.fr

résumé et mots clés

Dans cet article, nous proposons un système de segmentation adapté à l'analyse de plusieurs types d'images, riches en détails et dont les régions peuvent être de nature uniforme et/ou texturée. Un intérêt tout particulier a été accordé à l'aspect automatique et non-supervisé du dispositif.

Le système proposé combine deux concepts. Le premier, fondé sur un procédé d'intégration d'informations issues de différentes méthodes de segmentation, permet de tirer parti des avantages de chacune d'elles. Le second concept s'inspire de la perception active par l'introduction d'une boucle de retour dans le système afin de corriger et d'ajuster les paramètres de contrôle de l'ensemble des méthodes employées. Le principe de la coopération proposée introduit un mécanisme de vérification de la cohérence par comparaison des résultats des méthodes impliquées dans la coopération. Ce dernier aspect fait défaut à un bon nombre d'approches coopératives.

Le système développé est composé de deux modules. Le premier est dédié à l'extraction de régions uniformes ou faiblement texturées. Le principe est fondé sur une coopération itérative entre une méthode de détection de contours et une méthode d'agrégation de points. Ces deux méthodes sont itérées avec des critères de plus en plus tolérants jusqu'à la convergence vers des résultats cohérents et stables. La cohérence est réalisée en minimisant une mesure de dissimilarité entre les contours et les régions. Le but est ainsi de fournir une solution optimale au sens de la compatibilité entre les résultats des deux segmentations. Le second module localise les régions texturées et contribue à la réactualisation et à la correction des contours extraits à chaque itération du premier module. Cette localisation s'appuie sur une classification automatique par multi-seuillage exploitant certains mécanismes de la perception visuelle, et sur une fusion des régions multi-seuillées minimisant un critère de similarité.

Segmentation d'images, coopération de méthodes, perception du contraste, dissimilarité entre images de contours, mesure de cohérence.

abstract and key words

This paper focuses on the problem of image segmentation. It addresses the inherent deficiencies occurring when extracting low-level features (primitives) and when dealing with the complexity of real scenes. To solve such a problem we propose a framework which integrates several types of primitives formed progressively from complementary image transformations in an iterative and cooperative way. A particular interest has been given to the automatic and unsupervised aspect of the device.

The proposed system combines two concepts. The first one is based on the integration of the information resulting from different segmentation methods. This allows us to take into account the advantages from each of them. The second concept draws itself from active perception by the introduction of a feedback in the system in order to correct and adjust the control parameters of different segmentation methods. The principle of the proposed cooperation introduces a mechanism to check the coherence by making a comparison of the results obtained by the cooperative methods. This last aspect is lacking to most of cooperative approaches that can be found in the literature.

The developed system is composed of two modules. The first is dedicated to the extraction of uniform or weakly textured regions. Its principle is based on an iterative cooperation between two methods : edge detection and region growing. Both methods are iterated with more and more tolerance criteria until they converge towards coherent and stable results. The coherence is achieved by minimising a dissimilarity measure between the contours and the regions. The objective is therefore to provide an optimal solution in the sense of the compatibility between the results of the two segmentations. The second module localises textured regions in order to update and correct the contours extracted at each iteration by the first module. This localisation is based on an automatic classification through multi-thresholding exploiting some mechanisms of visual perception, and on a fusion of multi-thresholded regions minimising a similarity criterion.

Image segmentation, cooperative methods, contrast perception, dissimilarity between edge maps, coherence measure.

1. position du problème

L'objectif de la segmentation est de décrire l'importante quantité d'informations contenues dans l'image en recherchant des indices visuels pertinents et discriminants permettant de la représenter sous une forme plus condensée et facilement exploitable. La segmentation constitue un des problèmes les plus importants en analyse d'images car le résultat obtenu à l'issue de cette étape conditionne fortement la qualité finale de l'interprétation. Bien que le sujet ait déjà fait l'objet d'une vaste littérature [39] [41], il n'existe pas de méthode générale de segmentation [14], les techniques employées restent généralement dépendantes :

- des spécificités de l'image à traiter : richesse en textures d'orientations et d'échelles différentes ; transitions floues entre régions ; contours occultés ; ...;
- du type d'indices visuels à extraire : contours ; régions uniformes au sens des niveaux de gris ; textures ; points caractéristiques ; formes : segments de droite, angles ; ...;
- de la nature du problème à résoudre en aval de la segmentation : reconstruction 3D ; reconnaissance de formes ; interprétation ; contrôle de qualité ; suivi automatique d'objets ; ...;
- de contraintes d'exploitation : complexité algorithmique ; fonctionnement en temps réel ; contraintes matérielles liées aux systèmes d'acquisition, capacité de stockage ; ...

De plus, la segmentation d'images demeure un problème mal posé au sens de Hadamard [45] à cause de la non unicité, de l'incertitude et de l'instabilité des solutions par rapport aux données d'entrée :

- l'application de différents algorithmes à une même image donne souvent des résultats différents, avec une redondance parfois très variable.
- de faibles modifications des données initiales et des paramètres de la méthode (seuils, facteurs d'échelles, tailles de fenêtres d'analyse, sens de parcours des points, ...) peuvent impliquer des changements remarquables sur les résultats.

Le problème de la segmentation reste donc ouvert, surtout dans le cadre de l'analyse d'images réelles riches en détails et contenant

une grande variété de régions de nature uniforme et/ou texturée. Notre propos dans cet article est de contribuer à la recherche d'une mise en œuvre automatique de la segmentation d'images fixes par coopération entre méthodes. Une attention particulière a été accordée à l'aspect générique et non supervisé de l'approche. Notre objectif consiste ainsi à développer un système de segmentation demandant un minimum de connaissance *a priori* sur le nombre de classes présentes dans l'image ou sur les modèles d'objets à identifier et opérant sans hypothèse sur la distribution des niveaux de gris. Le système doit aussi être capable d'adapter les paramètres des méthodes aux spécificités des images à analyser afin de couvrir plusieurs catégories d'images.

Avant de présenter la démarche adoptée pour atteindre ces objectifs, nous allons exposer succinctement les différentes méthodes de segmentation rencontrées dans la littérature en mettant plutôt l'accent sur leurs points faibles.

2. état de l'art et motivations

Malgré la diversité des techniques de segmentation, il est possible de les classer en deux grandes catégories : **les approches non coopératives** et **les approches coopératives**.

Dans la première catégorie, nous pouvons distinguer trois types de méthodes [27] : celles destinées à la détection des transitions locales (*contours*) [33]; celles adaptées à l'extraction des *régions uniformes* au sens des niveaux de gris [36]; et celles dédiées à l'extraction des régions homogènes au sens de la *texture* [41]. Pour ces méthodes, nous avons principalement dégagé les remarques suivantes :

- Les méthodes de détection de *contours* supposent généralement une connaissance *a priori* d'un modèle à détecter et opèrent d'une façon très localisée. Elles fournissent souvent des frontières de régions discontinues. De plus, elles sont sensibles aux variations spatiales brusques de l'image, qu'il s'agisse de bruit ou de texture,

ce qui engendre la production de faux contours à l'intérieur des régions.

- Les méthodes d'extraction de *régions uniformes* introduisent principalement des erreurs liées à la localisation des frontières des régions.
- Concernant les méthodes d'extraction de *régions texturées*, les résultats peu satisfaisants sont essentiellement dus à la difficulté d'extraire des informations caractéristiques permettant d'augmenter la séparation entre les différents modèles de texture. En outre, la localisation des frontières des régions reste généralement non précise. Elles présentent enfin le défaut d'altérer les structures fines dans l'image qui sont souvent soit fusionnées aux régions voisines, soit sur-segmentées.

L'ensemble de ces remarques montre bien qu'il est difficile d'aboutir à un résultat satisfaisant en appliquant une seule méthode. Aussi, pour espérer une segmentation fiable et suffisamment corrélée avec les entités qui composent la scène réelle, de nombreux travaux ont eu recours à la coopération de plusieurs des méthodes de la première catégorie, en particulier celles de détection de contours et celles d'extraction de régions uniformes. Trois types de coopération sont distingués : la *coopération « série »* [6] [19] [26] [30] [35] [40] [46] [47] [48], la *coopération « parallèle »* [1] [5] [7] [20] [34] et la *coopération « hybride »* [3] [4] [12] [10] [25] [38] [43] [44] [49].

- Les différentes approches de la *coopération série* conduisent à la conception d'algorithmes de segmentation puissants. Cependant, elles souffrent de l'ordonnancement imposé dans la coopération qui peut dans certains cas altérer les résultats.

- En ce qui concerne les approches de la *coopération parallèle*, l'accent est selon les cas plutôt mis sur les mécanismes de fusion, d'adaptation, ou de correction. La notion de coopération active qui implique l'introduction simultanée de ces trois mécanismes n'intervient pas explicitement, ce qui ne contribue pas de manière générale à des résultats probants.

- Les approches de la *coopération hybride* permettent de pallier quelques lacunes des méthodes des deux précédentes catégories. Par contre elles ne valident pas la cohérence des primitives extraites.

En résumé, l'automatisation de la tâche de segmentation et son adaptation à un large éventail de types d'images impliquent d'une part, la multiplication des traitements et d'autre part, l'adoption d'une démarche progressive où la formation des primitives s'opère de manière coopérative et guidée. L'efficacité de la coopération peut aussi être améliorée en introduisant, en plus des mécanismes de correction et d'adaptation aux contextes examinés, des critères d'évaluation du degré de robustesse des primitives extraites par les différentes techniques impliquées dans la coopération. Le système de segmentation que nous proposons entre dans ce cadre.

3. approche développée

Dans le but d'intégrer différents types d'informations issues de transformations complémentaires, le système développé est constitué de deux modules.

Le *premier*, dont le principe est basé sur un procédé de coopération itérative entre méthodes, permet l'extraction de régions uniformes ou faiblement texturées. L'idée employée dans ce module repose d'une part, sur le fait qu'un résultat commun à plusieurs techniques de segmentation peut être considéré comme significatif, et d'autre part, sur la complémentarité des résultats pour combler les faiblesses de chacune des différentes méthodes de segmentation. En outre, afin d'engendrer une représentation cohérente et stable de l'image, un mécanisme pour vérifier la cohérence des primitives extraites est utilisé. Enfin, pour permettre la remise en cause des résultats obtenus et l'ajustement des paramètres de contrôle des différentes techniques de segmentation, le procédé de rétroaction est introduit. L'originalité de la coopération proposée réside ainsi dans l'introduction de mécanismes de vérification de la cohérence par comparaison des résultats des méthodes qui coopèrent [29].

Le *second module* localise les régions texturées afin de réactualiser et corriger à chaque itération les contours extraits par le premier module. Cette localisation s'appuie sur une classification automatique par multi-seuillage exploitant certaines propriétés de la perception visuelle et sur une fusion des régions multi-seuillées minimisant un critère de similarité [28].

Le synoptique de la figure 1 donne une représentation globale du système.

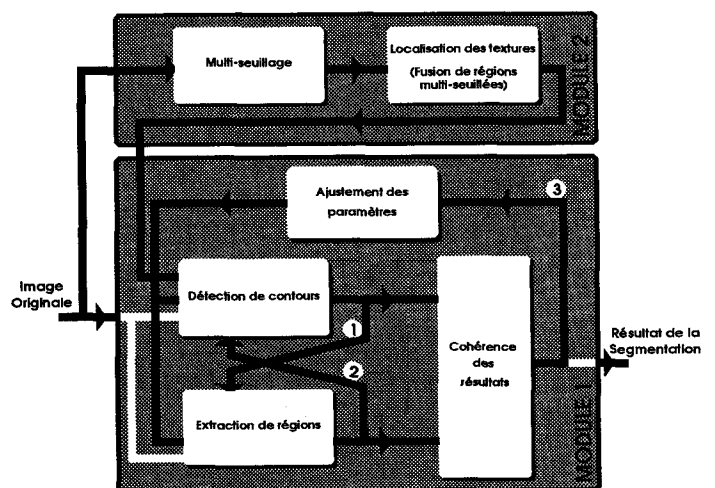


Figure 1. – Synoptique du système de segmentation..

3.1. module 1 : extraction de régions uniformes ou faiblement texturées

Dans l'état actuel de son implémentation, ce module fait intervenir uniquement deux méthodes : détection de contours et extraction de régions uniformes. Le principe du module dans ce cas de figure consiste à faire évoluer la formation des contours et des régions, à partir d'une sur-détection de contours et d'une sur-segmentation en régions, en relâchant les critères de formation des régions qui sont contrôlés par les contours (boucle (1) sur la figure 1). Ceux-ci seront par la suite réactualisés et corrigés en s'aidant des régions extraites au fur et à mesure des différentes itérations (boucle (2) sur la figure 1). Pour avoir un même mode de représentation, à la fin de chaque itération, la carte des régions est transformée en une carte de contours. Une mesure de dissimilarité entre celle-ci et le résultat de la détection de contours est effectuée pour évaluer la cohérence des deux résultats et décider de la continuation ou de l'arrêt de la procédure globale de segmentation. Cette mesure tient à la fois compte de la détection et de la localisation des contours. Dans le cas où le critère d'arrêt n'est pas vérifié, les paramètres qui contrôlent la formation des différentes primitives sont réactualisés et la procédure est itérée (boucle de retour (3) sur la figure 1). Le résultat de segmentation retenu est celui qui minimise la dissimilarité entre ces deux résultats (maximise la cohérence).

Nous présentons d'abord les deux méthodes qui sont utilisées par ce premier module. Ensuite, nous étudions l'interaction entre ces deux méthodes. Enfin, des résultats sur deux types d'images sont présentés et permettront alors de tirer quelques conclusions.

3.1.1. méthode adoptée pour la détection des contours

A l'issue d'une étude préliminaire faite dans [27] et vu les remarques sur les différents détecteurs de contours [14], nous avons choisi d'utiliser le filtre de Deriche [18]. En effet, en plus de son optimalité au sens des critères de Canny [9], ce filtre présente la propriété d'être paramétrable par un facteur d'échelle α qui contrôle le degré de lissage. L'étude du comportement du filtre à différentes échelles montre que son application pour des valeurs élevées de α (basses échelles) permet une meilleure localisation de contours au détriment d'une forte sensibilité aux bruits. En moyenne α varie entre 0.5 et 2. Le choix d'une échelle optimale reste un problème ouvert et une sur-segmentation étant préférable à une sous-segmentation, une détection de contours avec une valeur élevée s'est avérée préférable.

Après l'opération de filtrage, la détection de contours peut s'opérer de deux manières : soit par une extraction des maxima locaux de la dérivée première, soit par l'extraction des passages par zéro de la dérivée seconde. Dans notre cas, les points candidats aux contours retenus sont ceux correspondant aux maxima locaux de l'image des gradients. Cette opération est généralement suivie par un seuillage de type hystérésis. L'avantage de ce type de seuillage est qu'il permet d'obtenir des ensembles de points connexes,

ce qui facilite les étapes de chaînage et d'approximation prévues généralement en aval de cette étape. Il nécessite toutefois la détermination de deux paramètres S_h et S_b . Pour cette opération, un compromis est souvent difficile à obtenir pour conserver les contours correspondant aux frontières significatives entre les différentes régions de la scène et pour éliminer les « faux contours » dus aux bruits. Afin de s'affranchir du seuillage par hystérésis qui impose le choix de deux seuils et une classification binaire, et pour favoriser un seuillage adaptatif au niveau de gris et au contexte du voisinage examiné, nous effectuons une classification des maxima des gradients en trois catégories (contraste faible, moyen et fort), selon des critères liés à la perception visuelle. Pour cela, une fonction de Sensibilité de l'Oeil au Contraste (SOC) intégrant trois zones de décision : contraste fort, moyen, faible, a été utilisée [17]. Nous rappelons le principe de la construction de cette fonction (plus de détails sont donnés dans [31]).

Pour mesurer la sensibilité de l'œil au contraste, une série d'images a été créée. Chaque image est composée de bandes verticales où chacune d'elles correspond à un niveau de luminance constant. Partant du niveau de luminance faible (0) vers le niveau élevé (255), la différence des niveaux de gris entre deux bandes successives est égale à une valeur du contraste CT . Pour un ensemble de valeurs de contraste, une série d'images est obtenue. L'observation de l'ensemble de cette série montre que trois zones sont généralement distinguées. Les zones extrêmes, correspondant aux bandes de luminances faible et élevée, sont pratiquement homogènes, c'est-à-dire que les frontières entre les bandes de la zone sont invisibles par un observateur humain. Par contre, les bandes de la zone centrale se distinguent facilement. Les valeurs limites de celle-ci et la valeur du contraste CT permettent l'obtention d'une courbe de décision (en blanc sur la figure 2) séparant les contrastes visibles et les contrastes invisibles ou faibles. Une analyse plus fine a été effectuée pour diviser le contraste visible en deux secteurs : contraste fort et contraste moyen [31], comme le montre la figure 2.

La perception du contraste entre un point et son voisinage est dépendante de son niveau de luminance et de la différence des luminances de ses voisins proches. L'œil est moins sensible aux transitions dans les luminances élevées (zones très claires de




Figure 2. – Fonction de Sensibilité de l'Œil au Contraste (SOC).

l'image) et les luminances faibles (zones sombres). Par exemple, un point ayant un niveau de gris égal à 10 doit avoir un contraste de 8 par rapport à son voisin pour que ce contraste soit visible, alors qu'il aurait fallu seulement un contraste de 2 si ce point avait eu un niveau de gris égal à 80. La fonction SOC permet de répertorier les points de contours en leur associant le qualificatif fort, moyen ou faible en fonction du positionnement du niveau de gris et du gradient du point dans les trois zones de la fonction. Pour illustrer le comportement de l'opérateur de Deriche et l'intérêt de l'utilisation de la fonction SOC, nous présentons quelques résultats obtenus sur une image SPOT (image de la région Aquitaine, figure 3 (a)) issue de la banque d'images du GdR PRC-ISIS. Les images (b) et (c) de la figure 3 montrent des exemples de contours extraits à partir de l'image « Aquitaine » pour deux valeurs de α . Tous les maxima locaux non nuls sont mis à zéro (noir) et le reste à 255 (blanc). Nous pouvons constater que la diminution de la valeur de α favorise la bonne détection au détriment de la localisation et vice versa. L'image (d) de la figure 3 illustre le résultat de classification de l'image des maxima locaux correspondant à un α de 2 (les points foncés correspondant aux gradients forts). Ce résultat montre que la fonction SOC permet de bien distinguer les points de contours correspondant aux fluctuations des niveaux de gris dans les régions uniformes (faibles contrastes), ainsi que les points de contours liés aux transitions franches entre ces régions. Ce résultat sera exploité lors du




Figure 3. – Détection des maxima locaux suivant le filtrage de Deriche : (a) Image SPOT «Aquitaine» après rehaussement. (b) Le facteur d'échelle $\alpha = 0.5$. (c) Le facteur d'échelle $\alpha = 2$. Les maxima des gradients non nuls correspondent aux points noirs. (d) Classification des maxima locaux selon la fonction SOC.

processus de formation des régions uniformes. Celles-ci serviront par la suite à valider les contours significatifs (paragraphe 3.1.3).

3.1.2. méthode adoptée pour l'extraction des régions

La formation de régions peut être réalisée de deux manières : par fusion et/ou division d'ensemble de points fondée sur des critères globaux ou par agrégation de points basée sur des critères de similarité locaux. Il nous semble que l'appartenance d'un pixel à une région nécessite la prise en compte d'informations sur la région et d'informations locales relatives au pixel. Or, dans un procédé de fusion, puisque l'étude se fait au niveau des régions, l'information locale est non considérée. L'approche de formation de régions par agrégation de points, utilisant des critères qui tiennent compte à la fois du contexte local et des informations sur la région constituée, a donc été retenue. Cette approche permet une meilleure efficacité quant à la rapidité et à la taille mémoire nécessaire à la structure des données relatives aux régions et à leurs attributs.

Des régions-noyaux sont d'abord déterminées, puis des modèles des régions sont définis. Les points voisins aux noyaux sont ensuite repérés. Seuls, parmi ces points, ceux qui vérifient un critère de similarité sont agrégés aux noyaux. Si un point est adjacent à plus d'un noyau, il sera annexé à celui avec lequel il a le plus fort degré d'appartenance (au sens du critère de similarité employé). Ce procédé permet ainsi une croissance parallèle des régions même si les noyaux sont examinés de manière séquentielle.

Les noyaux des régions sont généralement introduits manuellement par un utilisateur. Dans le cas non supervisé, les régions fiables de l'image peuvent être déterminées en effectuant des opérations logiques entre plusieurs cartes de régions différentes pour la même image [26]. Les noyaux des régions sont alors obtenus par intersection de résultats de plusieurs segmentations, réalisées par la même procédure de croissance de régions, mais en utilisant différentes directions de parcours des pixels et en appliquant des seuils de segmentation faibles pour garantir la stationnarité de l'homogénéité des régions. C'est cette approche que nous avons utilisée.

Le vecteur de caractéristiques du noyau ou de la région est composé de son intensité moyenne, de son écart-type et du nombre de ses pixels noté N_R . Lors du démarrage de la croissance de régions, le modèle de la région courante est initialisé en fonction des paramètres du noyau. Au cours de la croissance de régions, lorsqu'un pixel est agrégé à une région, le modèle de la région est mis à jour d'une façon incrémentale [22] : la moyenne et la variance pour les $n + 1$ premières observations x_k sont respectivement estimées par :

$$\hat{\mu}_{x(n+1)} = \frac{n}{n+1} \hat{\mu}_{x(n)} + \frac{1}{n+1} x_{(n+1)} \quad (1)$$

$$\hat{\sigma}_{x(n+1)}^2 = \hat{\sigma}_{x(n)}^2 - (\hat{\mu}_{x(n+1)})^2 \quad (2)$$

avec

$$\hat{\sigma}_{x(n+1)}^2 = \frac{n}{n+1} \hat{\sigma}_{x(n)}^2 + \frac{1}{n+1} x_{(n+1)}^2 \quad (3)$$

Pour mesurer le degré de ressemblance de l'attribut (l'intensité $I(i, j)$) du pixel examiné avec le modèle de la région en cours de formation R_c , le critère de similarité correspondant au test de Fisher est employé. Un pixel examiné p_c d'intensité $I(i, j)$ est agrégé à la région R_c de moyenne μ_{R_c} et d'écart-type σ_{R_c} si :

$$\frac{|\mu_{R_c} - I(i, j)|}{\sigma_{R_c}} \leq S_k \quad (4)$$

où S_k est un seuil initialisé avec une faible valeur et incrémenté à la fin de chaque itération k du module 1.

Les régions-noyaux ou les régions extraites ainsi à chaque itération k , doivent en plus avoir un nombre de points supérieur à un seuil N_{R_k} . Ce paramètre est également réactualisé à la fin de chaque itération du module 1.

Notons que dans le procédé d'agrégation, il peut exister des ensembles de pixels qui ne vérifient aucun critère de groupement. De tels pixels, souvent situés sur une discontinuité ou même en bordure de celle-ci, ont souvent des caractéristiques locales qui ne sont plus celles de la région voisine. L'annexion de tels pixels entraînerait alors une variation arbitraire de la moyenne et de l'écart-type des niveaux de gris de la région. Il est alors souhaitable de les classer dans une catégorie de pixels problématiques et de retarder la décision de leur annexion à telle ou telle région jusqu'à ce que l'on puisse obtenir des informations issues d'autres traitements (contours, textures,...).

Les images de la figure 4 montrent des exemples de régions issues de l'image de la figure 4 (a). Les régions-noyaux sont obtenues par intersection de résultats de segmentations réalisées dans quatre directions (balayage de l'image ligne par ligne du haut en bas puis du bas vers le haut, et balayage colonne par colonne de gauche à droite puis de droite à gauche) en appliquant le seuil S_k pour chacune des segmentations.

Les résultats montrent que malgré l'utilisation de faibles seuils de similarité (cas où $S_k=5$), certaines régions de l'image sont sous-segmentées. On peut également remarquer la mauvaise localisation de la plupart des frontières des régions extraites.

Le but des différentes techniques de segmentation par extraction de régions est souvent de partitionner l'image en respectant au mieux une ou plusieurs propriétés fortement liées à l'uniformité des régions. Cette hypothèse, un peu restrictive, est à la base d'un des principaux défauts de ces algorithmes : difficulté à positionner correctement les frontières des régions. Ainsi, une région à l'intérieur de laquelle la luminosité varie linéairement peut être divisée en deux sous régions, et deux régions distinctes ayant des contrastes faibles le long de leurs frontières peuvent être fusionnées en une seule. C'est une des raisons qui rendent nécessaire le recours à une information tirée de la détection de contours pour assister la technique de détection de régions.




Figure 4. – Extraction de régions par agrégation récursive de points pour différentes valeurs de S_k . (a) Image SPOT de la région Aquitaine rehaussée. (b) Noyaux ayant servi à la formation des régions avec $S_k = 5$ et $N_{R_k} = 32$. (c) $S_k = 5$. (d) $S_k = 6$. (e) $S_k = 7$. (f) $S_k = 8$.

3.1.3. coopération et interaction contours-régions uniformes

La description d'une image à partir des primitives contours et régions devrait être identique (un contour fermé définit une région et une région définit un contour fermé) mais ce n'est pas toujours le cas en pratique.

Typiquement, le principal avantage des contours est qu'ils sont localisés de manière précise. Néanmoins, l'application d'une approche contours se heurte souvent au problème de sous-détection de certaines discontinuités, ce qui engendre des contours ouverts. Le point fort de l'approche par extraction de régions est juste-

ment la fermeture des frontières. Leur localisation exacte reste cependant difficile à obtenir. La méthodologie adoptée dans ce premier module du système tend à tirer un meilleur profit de la complémentarité et de la dualité entre les régions uniformes et les contours dans l'image. Cette complémentarité et cette dualité peuvent être exprimées de quatre manières différentes [7] [26] [40] [48] :

- les régions sont situées à l'intérieur des contours, par conséquent il n'y a pas de points de contours à l'intérieur d'une région.
- un point contour réel est situé sur ou à proximité d'une frontière de région.
- une frontière de région est fermée par nature et un contour doit l'être également.
- un contour ne peut pas être situé à l'intérieur d'une région et un contour doit être situé sur la totalité de la frontière commune entre deux régions.

Sur la base de ces règles de dualité, un certain nombre de critères décisionnels sont utilisés pour corriger les contours et régions obtenus à l'issue des différentes itérations. La coopération se concrétise par l'extraction d'un type d'information guidée et/ou corrigée par l'information duale.

Pour éliminer les faux contours liés à la présence du bruit et pour confirmer ceux qui sont significatifs, le processus de détection de contours exploite les informations sur les régions. Si le gradient du point de contour appartient à la classe des gradients à faible contraste, le contour est rejeté si les régions qui le bordent possèdent la même étiquette. Si le gradient appartient à la classe des gradients à fort contraste, le contour est validé. En revanche, s'il appartient à la classe des gradients à contraste moyen, le point contour est validé lorsque les régions situées de part et d'autre du contour possèdent des étiquettes différentes et au moins un de ses points voisins a un gradient à fort contraste.

Par ailleurs, comme il a été souligné précédemment, en plus d'une localisation imprécise des frontières, la procédure de formation des régions peut engendrer des sous-segmentations malgré l'utilisation de faibles seuils d'agrégation. Les erreurs relatives à ce type de problème sont principalement dues aux bruits qui sont superposés sur les frontières et qui ont des niveaux de gris similaires à la région en cours de formation. Aussi, pour corriger en partie ce défaut, un second critère faisant intervenir le gradient du point examiné a été introduit dans la procédure d'agrégation de points. En plus du critère de similarité employé, le point doit avoir un gradient qui appartient à la classe des gradients à faible contraste pour être agrégé à la région.

Un autre aspect de l'interaction contours-régions est celui lié à la fermeture de contours. Celle-ci consiste à combler les discontinuités entre des suites de points représentant le même contour. La fermeture de contours est souvent initialisée par un regroupement perceptuel. Une première étape consiste à examiner les chaînes de contours à l'aide des critères de Gestalt [32]. Généralement, ces critères de regroupement sont donnés par :

- la proximité : deux chaînes peuvent être fusionnées si leur distance est inférieure à un seuil;
- la continuité : le contour étant souvent rectiligne, deux chaînes ont une forte probabilité de se fusionner si elles sont dans le prolongement l'une de l'autre.

La courbe reliant deux chaînes de points de contours est définie soit en utilisant un modèle de la courbe (arc de cercle, polynômes, parabole, segment de droite,...), soit en minimisant une fonction d'énergie de courbure. La fermeture est fondée sur des critères purement locaux aux deux chaînes concernées [37] ou sur une stratégie globale d'optimisation [2] [13]. Une fois la fermeture décidée, chaque paire de chaînes de points de contours concernée est connectée. Notre implantation actuelle de la fermeture est simple. Deux chaînes de points de contours, situées sur ou à proximité d'une frontière de région, sont reliées si la distance qui les sépare ne dépasse pas 3 points et si leurs extrémités possèdent la même direction du gradient.

Si un contour n'est pas fermé, ou s'il est inclus dans une même région, celui-ci est conservé s'il appartient à la classe des gradients à contraste fort. Ce type de contours reflète entre autres des défauts relatifs à l'état de surface des objets (textures à motifs fortement contrastés) ou à la présence d'ombres et de reflets. Il peut donc arriver qu'un contour reste présent au milieu d'une région. Ce problème sera en partie traité dans la section 3.3.

Rappelons que l'objectif recherché dans le premier module du système est de fournir des résultats mutuellement compatibles. Les deux méthodes employées sont ainsi itérées jusqu'à la convergence vers des résultats cohérents. La cohérence est réalisée en minimisant une mesure de dissimilarité entre les contours et les frontières des régions.

3.1.4. mesure de la dissimilarité contours-régions

Etant données plusieurs segmentations de la même scène, le problème est de trouver une mesure qui permet de donner une estimation de la similarité ou de la corrélation entre les éléments des différentes segmentations, en considérant à la fois la détection et la localisation des différentes primitives extraites.

Une transformation des différents résultats afin de définir un mode de représentation commun des informations à mettre en correspondance est d'abord réalisée, puis la mesure de dissimilarité entre les résultats transformés est effectuée. Pour des raisons de simplicité et de temps de calcul, une représentation sous forme de contours a été adoptée. Notons qu'une modélisation de plus haut niveau (basée sur l'utilisation de primitives géométriques de type segment de droite ou autre) serait beaucoup plus fiable et plus significative et permettrait d'obtenir de meilleurs résultats dans un environnement peu texturé et présentant de fortes discontinuités. Elle nécessiterait cependant l'utilisation de techniques d'interpolation et de méthodes de mesures de similarité plus complexes, ce qui engendrerait un coût algorithmique beaucoup plus important.

Parmi les mesures permettant de donner une indication sur la dissimilarité entre cartes de contours, nous pouvons citer la distance de Hausdorff [24]. La distance de Hausdorff entre deux sous ensembles A et B appartenant à un ensemble de points X est définie par :

$$D_H(A, B) = \max\{\sup_{x \in A} d_E(x, B), \sup_{x \in B} d_E(x, A)\} \quad (5)$$

où si d est une distance entre deux pixels, alors la distance $d_E(x, A)$ entre un pixel x et un ensemble de pixels A est définie par [11] :

$$d_E(x, A) = \inf\{d(x, a) : a \in A\} \quad (6)$$

Bien que la distance de Hausdorff soit théoriquement intéressante puisqu'elle possède des propriétés liées avec les opérations de base de la morphologie mathématique [24], elle est peu utilisée en pratique comme mesure d'erreur entre images binaires. Le problème inhérent à cette distance est surtout dû à sa grande sensibilité aux bruits (de contours). Un simple pixel mal localisé augmente la valeur de D_H à cause de la présence de l'opérateur « sup » dans sa définition. Afin d'éviter cette sensibilité de D_H au bruit et compte tenu de ses propriétés topologiques intéressantes, nous proposons une nouvelle mesure inspirée de la distance de Hausdorff. Nous décrivons ci-après la procédure utilisée pour mesurer la dissimilarité entre contours et régions. Soit C la carte des contours et soit F celle des frontières des régions. L'approche adoptée consiste à calculer pour chaque point de contour (resp. frontière) dans l'image C (resp. F) l'écart minimal qui le sépare d'un point frontière (resp. contour) dans l'image F (resp. C). On calcule, ensuite, les moyennes des écarts minimaux des deux cartes. La dissimilarité finale est donnée par la moyenne des deux moyennes.

Pour tout point contour c de C :

Se positionner au point c' de F ayant les mêmes coordonnées que celles de c .

Rechercher dans F le point contour v' qui minimise une distance $d_e(c', v')$ telle que si c' et v' ont pour coordonnées respectives (i, j) et (k, l) :

$$d_e(c', v') = \sqrt{(i - k)^2 + (j - l)^2}$$

On note $d_E(c, F)$ l'écart minimal.

Pour tous les points contour f de F :

Projeter le point f sur la carte C . Soit f' ce point.

Rechercher dans C le point contour le plus proche du point f' au sens de la distance euclidienne $d_e(\cdot, \cdot)$.

On note $d_E(f, C)$ cet écart minimal.

La dissimilarité entre les deux cartes C et F est donnée par $Dissim(C, F) \equiv 1/2\{\langle d_E(c, F) \rangle_C + \langle d_E(f, C) \rangle_F\}$ où $\langle d_E(c, F) \rangle_C$ (resp. $\langle d_E(f, C) \rangle_F$) représente la

moyenne des écarts $d_E(c, F)$ (resp. $d_E(f, C)$)

$$\langle d_E(c, F) \rangle_C = 1/N_c \sum_{c \in C} d_E(c, F) P(d_E(c, F))$$

$$\langle d_E(f, C) \rangle_F = 1/N_f \sum_{f \in F} d_E(f, C) P(d_E(f, C))$$

$P(x)$ désigne la population de x .

N_c (resp. N_f) correspond au nombre de points de contours dans C (resp. F).

Cet algorithme donne de bons résultats : il présente une forte robustesse au bruit comparativement à la distance de Hausdorff, et ne nécessite aucun seuil empirique. La complexité algorithmique de cette mesure dépend du nombre de points de contours et du nombre de points de frontières des régions dans l'image. Cette complexité s'avère ainsi importante dans le cas des images riches en détails. Pour contourner en partie ce problème, l'espace de recherche des points les plus proches de p dans M ($p = c'$ ou f' et $M = F$ ou C) est réduit à des voisinages limités et centrés en p .

3.1.5. module 1 : résultats expérimentaux

Afin d'évaluer le premier module, nous présenterons des résultats obtenus sur une image faiblement texturée et une image fortement texturée. Dans ces expérimentations ainsi que dans l'ensemble des expérimentations suivantes, le paramètre de croissance de région S_k est initialisé à la valeur 1 et croît par pas de 1 à chaque itération. Le paramètre de surface N_{R_k} initialisé à 32 décroît avec un pas de 1. Le facteur d'échelle de la détection de contours α a été fixé à 2. Les images de la figure 5 représentent les résultats de segmentation de l'image « Aquitaine » et l'évolution du critère de dissimilarité.

Ne disposant pas de vérité de terrain, nous pouvons remarquer que pour cette image, de bons résultats de segmentation sont obtenus. La plupart des régions de l'image originale visibles à l'œil sont détectées de manière satisfaisante. Les contours fins correspondent bien aux discontinuités visibles dans l'image originale et la majorité d'entre eux sont extraits. On peut également noter leur bonne localisation et la préservation des détails et des structures fines. L'évolution de la mesure de dissimilarité montre que le résultat de segmentation commence à se stabiliser à partir de la 6^{ème} itération.

Nous avons testé l'approche développée dans ce premier module sur une autre image, issue de la banque d'images de l'EPFL, riche en textures d'orientations différentes et présentant des inhomogénéités importantes des régions (figure 6 (a)).

En examinant le résultat de la segmentation (figure 6 (b)), nous pouvons constater qu'au sens des niveaux de gris, les différentes régions qui composent cette image sont bien détectées. Il présente toutefois une multitude de petites régions difficilement exploitables. La méthode de segmentation nécessite l'intégration d'autres types d'informations basées sur la texture, d'où l'intérêt de l'introduction du second module dans le système.

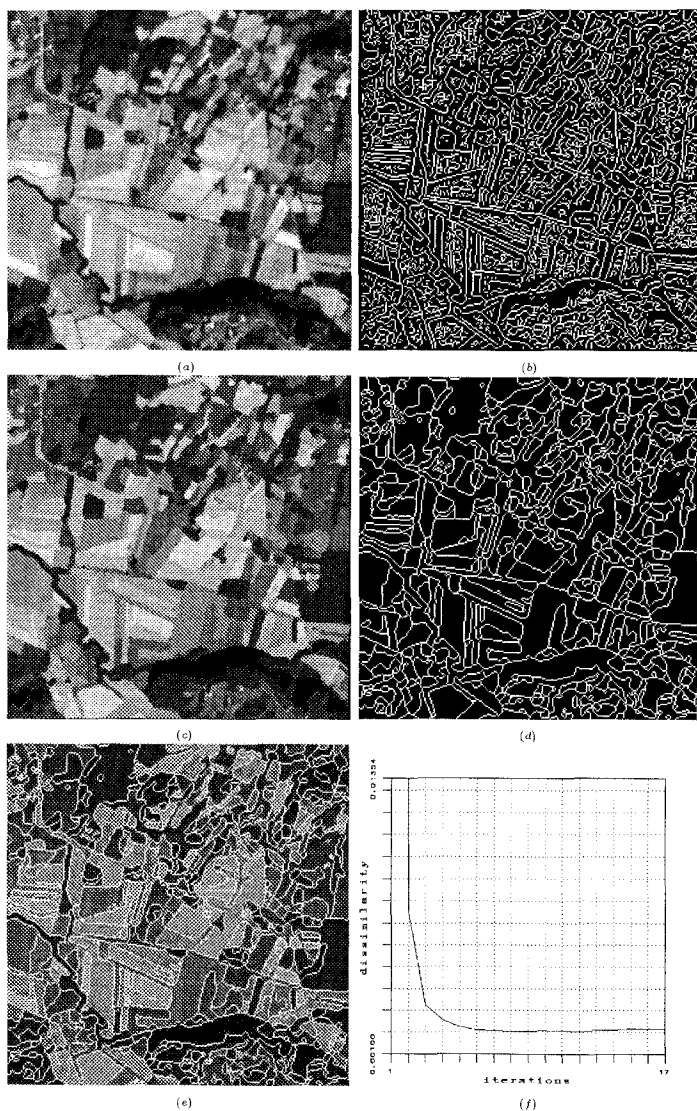


Figure 5. – Segmentation coopérative contours-régions. Image faiblement texturée. (a) Image Aquitaine. (b) Carte de contours de départ. (c) Résultat final de la segmentation région. (d) Frontières finales de la segmentation région. (e) Frontières finales de la segmentation superposées à l'image originale. (f) Evolution de la dissimilarité entre la carte des contours et la carte des frontières de régions en fonction des itérations.

3.2. module 2 : extraction de régions texturées

Une amélioration, permettant de prendre en compte la localisation des régions texturées, est apportée en intégrant un second module. Celui-ci permet de corriger les primitives contours et régions non significatives issues de la coopération contours-régions uniformes.

La construction de la carte des régions texturées s'effectue à l'aide d'un algorithme de segmentation de textures opérant suivant deux niveaux : *division* et *fusion*.




Figure 6. – Segmentation coopérative contours-régions. Image texturée. (a) Image aérienne. (b) Frontières finales de la segmentation superposées sur les régions.

L'objectif de la *division* est de fournir une représentation cohérente et simplifiée au sens des niveaux de gris et suffisamment représentative pour la caractérisation des textures de l'image. Elle est fondée sur une technique de multi-seuillage [28] [42].

La *fusion* a pour objectif de détecter de manière grossière les régions texturées de l'image. Elle est basée sur les co-occurrences [21] de niveaux de gris issus de la division. Dans les paragraphes suivants, nous décrivons avec plus de détails ces deux procédures.

3.2.1. simplification par multi-seuillage

L'approche proposée consiste à classer les points de l'image en comparant leurs niveaux de gris aux seuils déterminés par l'analyse d'un histogramme global [15]. Celui-ci est construit à partir de pics significatifs issus d'histogrammes locaux. Cette procédure élimine l'information non pertinente afin d'homogénéiser les régions et de mettre en évidence les éléments les plus caractéristiques des textures. Ceci permettra ultérieurement une simplification des procédures de segmentation ou de modélisation.

La méthode est effectuée en deux phases : *construction de l'histogramme global des maxima locaux* et *classification des niveaux de gris de l'image à partir de cet histogramme*. Dans ce qui suit, nous décrivons ces deux phases.

Phase 1) Construction de l'histogramme global

Cette première phase s'appuie sur une transformation des histogrammes locaux et sur des critères de décision simples pour déterminer les pics significatifs locaux qui serviront pour la construction de l'histogramme global. L'image originale notée I , de dimension $N \times N$ est divisée en fenêtres carrées sans chevauchement, chacune de taille $d \times d$. Soit $h_c(l)$ la fréquence d'occurrence du niveau de gris l dans une fenêtre notée B_c .

a. Transformation des histogrammes locaux :

La procédure de transformation est nécessaire car la plupart des histogrammes locaux multi-modaux présentent des modes aux

limites mal définies. Le calcul des maxima est alors délicat. Cette transformation a donc pour but de mettre en évidence les différents modes de chaque histogramme [16]. Pour cela nous avons utilisé quatre critères basés sur la mesure des fluctuations des niveaux de gris. Ces critères notés C_1, C_2, C_3 et C_4 , donnent une indication sur l'homogénéité d'un point par rapport à ses quatre voisins les plus proches. Ils sont respectivement définis par :

$$\begin{aligned} C_1 &= |I(i, j) - I(i - 1, j)| < \Delta[I(i, j)] \\ C_2 &= |I(i, j) - I(i, j - 1)| < \Delta[I(i, j)] \\ C_3 &= |I(i, j) - I(i, j + 1)| < \Delta[I(i, j)] \\ C_4 &= |I(i, j) - I(i + 1, j)| < \Delta[I(i, j)] \end{aligned}$$

où $I(i, j)$ représente le niveau de gris du point (i, j) appartenant à B_c . $\Delta[\cdot]$ est la valeur de la fonction donnée par la courbe qui sépare le contraste visible (regroupement des contrastes fort et moyen) et le contraste faible (la courbe en blanc sur la figure 2 - paragraphe 3.1.1). L'introduction de cette fonction permet de tenir compte de la visibilité d'un point par rapport à ses voisins. Elle favorise le regroupement des points de luminances visuellement proches. En fonction du nombre de critères vérifiés, les fréquences d'apparition $h_c(l)$ des niveaux de gris $I(i, j)$ sont modifiées de la manière suivante :

$$\begin{aligned} h_c(l) &= h_c(l) + p_4 \text{ si les 4 critères sont vérifiés ;} \\ h_c(l) &= h_c(l) + p_3 \text{ si 3 critères sont vérifiés ;} \\ h_c(l) &= h_c(l) + p_2 \text{ si 2 critères sont vérifiés ;} \\ h_c(l) &= h_c(l) + p_1 \text{ si 1 seul critère est vérifié ;} \\ h_c(l) &= h_c(l) \text{ sinon.} \end{aligned}$$

p_1, p_2, p_3 et p_4 sont des constantes telles que $p_1 < p_2 < p_3 < p_4$ (par exemple $p_1 = 1, p_2 = 2, p_3 = 3$ et $p_4 = 4$). En tenant compte à la fois des relations spatiales entre points et de leur visibilité, cette transformation permet de mettre en évidence les principaux modes de l'histogramme. Avant de déterminer les principaux pics de l'histogramme, une opération de lissage lui est appliquée. Celle-ci est nécessaire pour éliminer les irrégularités de l'histogramme. On utilise à cet effet un noyau gaussien de taille 5 et de variance 1.

b. Recherche des pics significatifs :

Les pics significatifs des histogrammes résultant des traitements précédents doivent vérifier les trois critères suivants :

- Un niveau de gris est un pic de l'histogramme s'il présente une fréquence d'occurrence locale maximale.
- La distance séparant deux pics significatifs doit être supérieure à un seuil S_d ; sinon on retient comme pic significatif celui dont la fréquence d'occurrence est la plus grande.
- La hauteur d'un pic doit être supérieure à une fraction S_l du maximum de l'histogramme. Ceci permet d'éliminer les pics de taille relativement faible.

Les valeurs de seuils S_d et S_l sont calculées de manière automatique et représentent respectivement la moyenne des distances des couples de pics successifs et la moyenne des fréquences d'apparition des pics.

Les fréquences d'occurrence des pics valides sont cumulées dans un histogramme global. Celui-ci, noté H_{glob} , présente une forme multi-modale bien prononcée.

Cette première phase est effectuée en utilisant plusieurs tailles de fenêtres ($16 \times 16, 32 \times 32, 64 \times 64$) afin de tenir compte de la résolution spatiale de l'image. Les fréquences d'occurrence des pics déterminés en appliquant les différentes tailles sont cumulées dans le même histogramme.

Phase 2) Classification des niveaux de gris

La classification est réalisée moyennant une procédure itérative de regroupement des masses de l'histogramme global H_{glob} en masses ponctuelles significatives caractérisant les régions qui composent l'image. Le but est de détecter les seuils s_g les plus significatifs en déplaçant itérativement les valeurs de niveaux de gris vers leurs centres de masse jusqu'à idempotence de l'histogramme. Cette procédure est décrite ci-après.

Soient $H^{(0)}(i) = H_{glob}(i)$, $i \in [i_{min}, i_{max}]$, l'histogramme initial à traiter, et $H^{(k)}$, l'histogramme obtenu à l'itération k .

Les fréquences d'occurrence des niveaux de gris à l'itération $k+1$ sont déterminées selon les relations suivantes :

$$H^{(k+1)}(i) = \sum_{s \in V_i} H^{(k)}(s) \delta(i - \mu_k(s)) \quad (7)$$

où $\delta(\cdot)$ représente le symbole de Kronecker et $\mu_k(s)$ désigne la moyenne glissante à l'itération k .

$$\mu_k(s) = \frac{\sum_{s \in V_i} s H^{(k)}(s)}{\sum_{s \in V_i} H^{(k)}(s)} \quad (8)$$

V_i représente l'ensemble des $2m + 1$ niveaux de gris voisins de i , il est défini par :

$$V_i = \{\max((i - m), i_{min}) \dots \min((i + m), i_{max})\}$$

La relation (7) traduit le déplacement d'une partie des masses de $H^{(k)}(i)$ vers leurs centres de gravité locaux. Dans le cas supervisé, le paramètre m doit être choisi assez petit (de l'ordre de 3 à 10) si on veut obtenir un nombre important de classes. Pour rendre la procédure de regroupement automatique et non supervisée, on fait varier m graduellement jusqu'à ce que des tailles successives fournissent les mêmes résultats. L'histogramme final obtenu est constitué de masses ponctuelles. A chaque masse correspond une classe et la position de chaque masse indique le niveau de gris qui sera affecté en tant qu'étiquette à chaque classe. Les valeurs des seuils s_g sont alors données par les moyennes des niveaux de gris déterminées par la position de ces masses. Elles permettent de définir les intervalles de luminance de chacune des classes et d'associer à chaque point de l'image une étiquette.

La technique de multi-seuillage tient donc compte des propriétés locales de chaque histogramme et ne demande aucune connaissance *a priori* sur l'image à segmenter. Les résultats issus de

cette technique (images des étiquettes) se révèlent corrects dans le cas des images composées d'un certain nombre de régions bien contrastées, avec une faible variation des luminances à l'intérieur d'une même région. Mais les résultats s'avèrent peu intéressants dans le cas où il y a présence de zones fortement texturées. Dans ce dernier cas, l'intérêt de cette première analyse réside dans l'extraction de l'information dont l'influence est la plus significative pour la caractérisation des différentes régions de l'image. Ceci permet une première simplification des données avant de procéder au traitement complémentaire présenté dans le paragraphe suivant.

3.2.2. extraction des textures par fusion des régions multi-seuillées

En considérant qu'une texture est une structure disposant de certaines propriétés spatiales homogènes et invariantes par translation, nous avons utilisé pour la caractériser les étiquettes issues de la procédure de multi-seuillage et leurs fréquences d'occurrence. Le problème de segmentation est ainsi ramené à la localisation des différentes régions de l'image des étiquettes ayant un comportement semblable au sens des étiquettes et de leurs fréquences d'apparition.

Pour localiser les textures dans l'image nous avons expérimenté plusieurs méthodes basées sur l'utilisation des histogrammes généralisés [31] des niveaux de gris issus de la procédure du multi-seuillage. Nous décrivons, ci-dessous, celle qui introduit les histogrammes d'ordre deux (matrice de co-occurrence). Nous présentons ensuite quelques résultats obtenus sur l'image aérienne de la figure 6(a). La localisation des zones texturées s'effectue selon l'algorithme de fusion suivant :

- **Phase 1)** l'image des étiquettes est découpée en blocs rectangulaires qui se chevauchent;
- **Phase 2)** les statistiques locales sont, ensuite, calculées à l'intérieur de chacun des blocs de l'image des étiquettes;
- **Phase 3)** une fusion des blocs minimisant un critère de similarité est effectuée.

Nous détaillons chacune de ces phases dans les paragraphes suivants.

Phase 1) découpage de l'image

Pour le découpage de l'image, le choix de la taille du bloc est inhérent à tous les problèmes d'analyse d'images. Il dépend de la résolution de la texture à analyser. La taille des blocs doit être assez grande pour que le calcul des statistiques soit significatif. Cette taille doit malgré tout rester raisonnable afin de calculer les caractéristiques de façon locale. Les tests effectués sur des images aériennes et sur des images de scènes d'extérieur montrent qu'une taille de 8 x 8 pixels amène à un trop grand nombre de blocs sans une amélioration sensible de la qualité des résultats de fusion. Les résultats obtenus avec des blocs de 32 x 32 pixels ne sont pas suffisamment précis. Dans le cas des images de télédétection, un bon compromis peut être obtenu avec des blocs de taille de 16 x 16 pixels qui se chevauchent.

Phase 2) extraction des paramètres

Pour chaque bloc du découpage initial, nous déterminons l'histogramme d'ordre deux. Afin de réduire le coût calculatoire, cet histogramme est calculé seulement pour les vecteurs de déplacement $\vec{\delta} = (0, 1)$ (déplacement horizontal), et $(1, 0)$ (déplacement vertical). Pour l'extraction des paramètres, deux possibilités ont été expérimentées : l'utilisation des matrices de co-occurrence des étiquettes et l'extraction d'attributs sur celles-ci. Dans ce dernier cas, un grand nombre de mesures peut être défini à partir de la matrice de co-occurrence pour caractériser les régions texturées de l'image [21]. En raison du coût de calcul élevé, seuls quelques uns de ces attributs sont souvent utilisés (uniformité de l'énergie, inertie, corrélation, homogénéité locale, et entropie). Les attributs extraits pour les vecteurs de déplacement $(0, 1)$ et $(1, 0)$ forment les vecteurs de paramètres qui caractérisent chacun des blocs issus du découpage.

Phase 3) fusion des régions minimisant le critère de similarité

Le problème de la distance de similarité entre deux textures n'est toujours pas résolu en théorie. Dans notre cas, pour mesurer le degré de similarité entre le bloc examiné, noté B^c , et un de ses blocs voisins, noté B^v , suivant les deux approches de caractérisation de la phase 2, nous avons expérimenté deux critères. Le premier utilise la distance de Kolmogorov entre les matrices de co-occurrence des étiquettes et le deuxième fait intervenir l'indice de similarité cosinus calculé à partir des attributs qui caractérisent chacune des matrices.

Pour deux histogrammes du second ordre d'étiquettes h_c et h_v , la distance de Kolmogorov est donnée par :

$$D_{(h_c, h_v)}^K = \sum_{p=0}^{N_E-1} \sum_{q=0}^{N_E-1} |h_c(p, q) - h_v(p, q)| \quad (9)$$

N_E représente le nombre des étiquettes. Une propriété remarquable de cette distance est son invariance par toute transformation strictement monotone des données. Le critère de similarité entre deux blocs voisins B^c et B^v est alors donné par

$$C_h = (D_{(h_c, h_v)}^K < s_{h1}) \quad (10)$$

où s_{h1} est un seuil réglé empiriquement et choisi de l'ordre de 30% à 50% de la surface du bloc.

Dans le second cas de figure, si V_c représente le vecteur d'attributs de la matrice de co-occurrence du bloc analysé B^c et V_v celui d'un bloc voisin B^v , la similarité des deux blocs est évaluée par le cosinus de l'angle entre ces deux vecteurs :

$$\delta_{h2}(B^c, B^v) = \frac{\langle V_c, V_v \rangle}{\|V_c\| \|V_v\|} \quad (11)$$

$\langle u, v \rangle$ désigne l'opération du produit scalaire des vecteurs u et v .

Pour chaque bloc B^c on cherche dans son voisinage le bloc B^v avec lequel la similarité est maximale. Les deux blocs seront

considérés comme similaires si leur indice de similarité est inférieur à un seuil s_{h2} . Dans le cas où aucun bloc adjacent n'est similaire au bloc courant, on entreprend la construction d'une nouvelle région dont celui-ci est le premier élément. Ce processus est itéré pour toute l'image des étiquettes.

Les tests effectués sur des images de textures naturelles de Brodatz [8] montrent qu'il n'y a pas de différence notable entre les résultats obtenus par cette méthode en utilisant les deux indices de similarité.

3.2.3. module 2 : résultats expérimentaux

Dans cette expérimentation ainsi que dans les expérimentations suivantes, l'indice de similarité employé est celui de la distance de Kolmogorov entre histogrammes d'ordre deux d'étiquettes, la taille des blocs est de 16, le seuil de fusion s_{h1} est égal à 40% la surface du bloc. L'analyse est faite avec un chevauchement entre blocs de 8 pixels.

Les images de la figure 7 présentent respectivement l'image aérienne, son histogramme, l'histogramme global construit à partir des histogrammes locaux, l'histogramme global après la procédure de regroupement des masses ponctuelles (7 pics ont été déterminés, ceux qui ont des fréquences d'occurrence relativement faibles n'apparaissent pas sur l'histogramme), le résultat de multi-seuillage obtenu et le résultat de la localisation des textures. Les étiquettes de ce dernier résultat ont été affectées de manière arbitraire.

Au vu des différents histogrammes de l'image test considérée dans cette expérimentation, deux remarques peuvent être faites. Tout d'abord, l'histogramme global construit met bien en évidence les principaux modes constituant l'histogramme de l'image originale qui est pratiquement unimodal. Ensuite, les regroupements des masses ponctuelles de l'histogramme global convergent correctement vers ses modes les plus significatifs.

Nous pouvons visuellement constater que pour cette image, une bonne simplification a été effectuée : les transitions perceptibles par l'œil sont pratiquement toutes mises en évidence et la plupart des éléments représentatifs de la texture sont détectés de manière satisfaisante.

3.3. interaction contours-régions uniformes et textures

L'interaction de la détection de textures avec la procédure contours-régions est simple. A la fin de chaque itération du module 1, une correction du résultat de la détection des contours est effectuée afin de valider ou rejeter les contours situés à l'intérieur des zones texturées déterminées par le module 2. L'information issue de ce module n'évolue pas au cours des itérations du premier module.

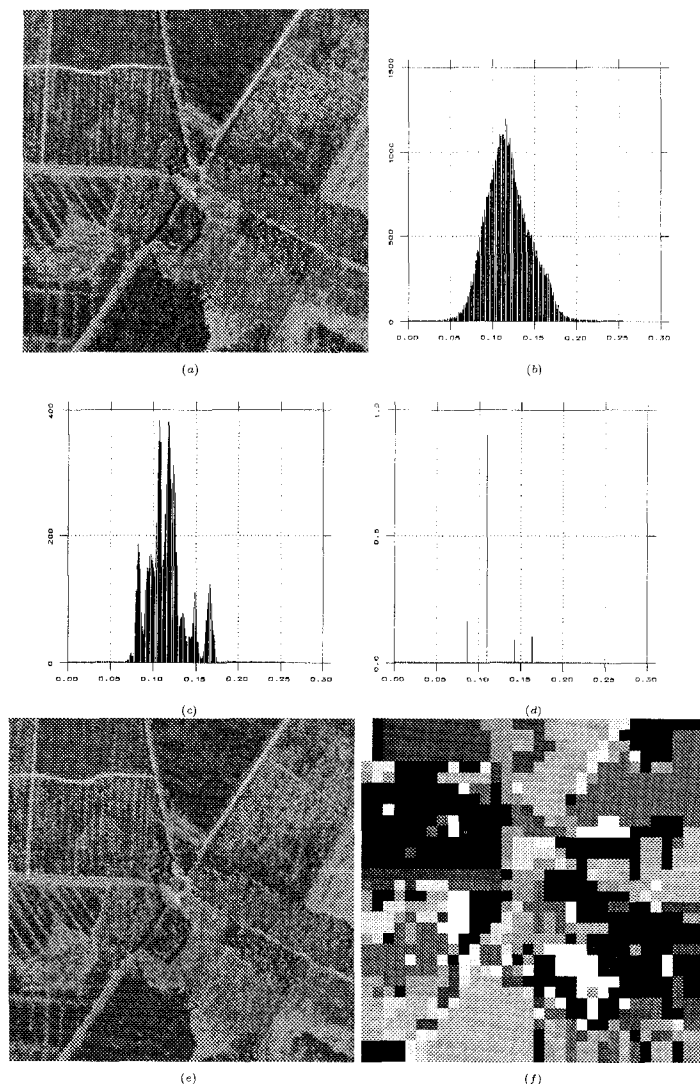


Figure 7. – Localisation de la texture. (a) L'image aérienne. (b) Son histogramme. (c) Son histogramme global H_{glob} . (d) Son histogramme global après regroupement de ses masses ponctuelles. (e) Résultat du multi-seuillage (seuils : 98, 119, 135, 153, 176, 201). (f) Résultat de la fusion des régions multi-seuillées.

Le critère de validation des contours prend en compte sa régularité et son contraste. Pour estimer la régularité de la facette (état de surface) centrée sur le point candidat à examiner, un indice de confiance a été défini, pour chaque point de contour, en fonction de la distribution des niveaux de gris de son voisinage local [23]. Soit $I(i, j)$ le niveau de gris du point examiné. Le calcul de l'indice de confiance se fait de la manière suivante : on fait intervenir les gradients G_p et leur moyenne μ_{g_p} sur un voisinage 3×3 . L'inverse de la moyenne des écarts normalisée définit la régularité :

$$Z = 1/Q \tag{12}$$

où

$$Q = \frac{1/3 \sum_{k=-1}^1 |G_p(k) - \mu_{g_p}|}{\mu_{g_p}} \quad (13)$$

et

$$\mu_{g_p} = 1/3 \sum_{k=-1}^1 G_p(k) \quad (14)$$

Pour une facette qui représente une variation homogène dans la direction du contour, Q tend vers zéro et par conséquent Z est grande. Par contre, si la présence d'un candidat est due à la texture, les fluctuations provoquées par celle-ci augmentent la valeur de Q et Z devient faible. L'indice de confiance du point candidat est donné par

$$C_f = \beta \cdot Z + \Delta[(I(i, j))] \quad (15)$$

où β est un facteur correcteur (dans notre cas il a été fixé à 1) et $\Delta[.]$ correspond, ici, à la valeur de la fonction SOC définie dans le paragraphe 3.1.1 (figure 2).

Dans la définition de C_f , lorsque Z augmente et/ou $\Delta[.]$ est élevée (située dans la zone des contrastes forts), la valeur de C_f augmente aussi. Ceci est engendré pour une variation constante des points voisins du point candidat et par le fait que la variation locale est importante pour les contours bien contrastés. Quand la valeur de $\Delta[.]$ n'est pas dans la zone des contrastes faibles, le candidat doit être retenu même si Z est faible. L'indice de confiance doit préserver les détails évidents dans l'image originale.

Un point de contour est validé si cet indice est intérieur à un seuil.

3.4. Module 1 et Module 2 : résultats expérimentaux

La figure 8 donne un résultat de cette expérimentation sur l'image aérienne avec un seuil de l'indice de confiance C_f fixé à 9. L'introduction de la texture au niveau de la fusion permet d'obtenir




Figure 8. – Segmentation obtenue après intégration de la texture dans la coopération contours-régions. (a) Image aérienne originale. (b) Résultat de la segmentation.

des résultats de qualité correcte. Nous pouvons toutefois remarquer une légère altération des structures fines se situant entre des régions ayant des textures similaires.

Afin d'évaluer la méthode développée, nous avons utilisé une autre image pour laquelle nous disposons d'une carte de vérité de terrain (figure 10). Cette image a été prise par le satellite SPOT en mai 1987 et représente la forêt de Paimpont.

La vérité de terrain nous a été fournie par l'équipe COSTEL (Climat et Occupation du Sol par TELédétection) de l'université de Rennes II. Comme la carte de vérité de terrain ne couvre pas entièrement l'image satellitale, celle-ci a été masquée de sorte que toutes les deux aient le même support (figure 9).

Pour mettre en évidence les régions de l'image originale, nous avons superposé à celle-ci les contours de parcelles de la carte de vérité de terrain (figure 11).

L'image de la figure 12 (a) (resp. 12 (b)) représente le résultat de la segmentation de l'image Paimpont obtenu par la méthode du module 1 (coopération contours-régions : CR) (resp. la méthode intégrant le module 1 et le module 2 (coopération contours-régions-textures : CRT)) superposée à l'image originale. Nous pouvons constater que les frontières des régions visibles dans l'image sont bien détectées et permettent donc d'envisager un processus d'interprétation de manière quasi-directe.




Figure 9. – Image SPOT de la forêt de Paimpont masquée.




Figure 10. – Carte de la vérité de terrain de la forêt de Paimpont VT (12 classes). (a) En contours. (b) En régions.




Figure 11. – Vérité de terrain superposée à l'image originale.




Figure 12. – Résultats de segmentation superposée à l'image originale Paimpont. (a) Méthode contours-régions (CR). (b) Méthode contours-régions-textures (CRT).




Figure 13. – Contours du résultat de segmentation de l'image Paimpont. (a) Méthode contours-régions (CR); (b) Méthode contours-régions-textures (CRT).

Pour mesurer objectivement la qualité des résultats, le tableau ci-après donne la dissimilarité normalisée (paragraphe 3.1.4) entre la carte des frontières finales (figure 13 (a)) (resp. (figure 13 (b))) issue de la coopération contours-régions (CR) (resp. coopération contours-régions-texture (CRT)) et la vérité de terrain en contours VT de la figure 10 (a). Cette comparaison montre que la segmentation issue de la coopération CRT est plus proche de la vérité de terrain.

Tableau 1. – Dissimilarités entre les résultats de segmentation RS_i obtenus par le système (cas contour-région CR et cas contour-région-texture CRT) et la carte vérité de terrain VT .

Méthodes	$D_M(VT, RS_i)$	$D_M(RS_i, VT)$	Dissimilarité
CR	0.004541	0.004617	0.004579
CRT	0.004341	0.004411	0.004376

4. conclusion

L'approche coopérative du système de segmentation que nous avons proposée se situe dans le cadre des méthodes hybrides relatives à la résolution de problèmes de la vision artificielle en utilisant des concepts de la « fusion de données » et de la « perception active ». Le but global du système n'est pas défini explicitement pour une application donnée, ce qui nous permet l'exploration de données images dont on ne dispose pas de connaissances *a priori*. Les deux modules composant le système ont été présentés.

L'approche développée dans le **premier module** permet d'obtenir de façon automatique une segmentation de l'image à la fois en primitives de type régions et de type contours. Elle se distingue des autres approches par l'introduction d'un mécanisme de correction et d'ajustement par le biais de boucles de retour et l'inclusion d'une mesure de cohérence des résultats intermédiaires. La coopération entre les deux méthodes (détecteur de contours et extracteur de régions) est effectuée par une communication bidirectionnelle. Elle est initialisée par des sur-segmentations. Chaque méthode produit un résultat approprié. Une évaluation de la cohérence des résultats intermédiaires est réalisée à la fin de chaque cycle à l'aide d'une mesure de dissimilarité prenant en compte à la fois la détection et la topologie des contours et des frontières des régions.

Le **second module** fait intervenir l'aspect textural des régions afin de réactualiser et corriger les contours non significatifs extraits au fur et à mesure des différentes itérations du premier module. La localisation des zones texturées dans l'image est fondée sur une combinaison de deux techniques que nous avons développées : une division et une fusion. La fusion s'appuie sur une méthode de co-occurrence des niveaux de gris. Celle-ci présente dans son implantation classique, l'inconvénient de conduire à des temps de calcul élevés. Pour pallier ce problème, le nombre de niveaux de gris initial est réduit par une étape de division. Cette étape est réalisée à l'aide d'une technique de classification automatique utilisant des critères d'homogénéité locale prenant en compte des propriétés du système visuel humain liées à la sensibilité de l'œil aux contrastes.

L'approche développée opère avec un minimum de connaissance *a priori*. Elle est quasi automatique (la taille des blocs pour la caractérisation des textures de l'image et leur seuil de fusion ont été fixés). Le système combinant les deux modules a été

appliqué sur plusieurs types d'images réelles et les résultats obtenus sont concluants. L'efficacité de notre approche s'est traduite, dans la plupart des cas examinés, par une détection cohérente des éléments représentatifs de l'image. Elle a été particulièrement constatée par les bons résultats expérimentaux obtenus sur les images de télédétection dans le domaine du visible. Cette approche démontre ainsi l'importance de :

- l'intégration de primitives complémentaires (contours, régions, textures),
- l'adoption d'une démarche progressive dans la formation des primitives,
- la validation de chaque primitive avec l'aide d'autres primitives et la mesure de sa cohérence, ce qui conduit à l'extraction de primitives fiables et pertinentes,
- et enfin, l'ajustement itératif des paramètres, qui permet leur adaptation à la spécificité de l'image analysée.

Les efforts futurs devront porter sur l'introduction d'une correction à partir du premier module vers le second (régions-uniformes vers textures) pour affiner les résultats de la localisation des frontières des textures. Nous pouvons également envisager l'intégration d'autres méthodes tenant compte de façon adaptative de la résolution et des échelles des textures des images ainsi que des critères ou méthodes permettant de prendre en considération l'aspect géométrique et structurel des primitives extraites au fur et à mesure des différentes itérations.

BIBLIOGRAPHIE

- [1] N. Ahuja, A transform for multiscale image segmentation by integrated edge and region detection, *IEEE PAMI-18(12)* pp. 1211-1235, 1996.
- [2] N. Ahuja et M. Tuceryan, Extractions of early perceptual structure in dot patterns : integrating region, boundary and component Gestalt. *Pattern Recognition*, vol. 48, pp. 304-356, 1989.
- [3] R. Bajcsy, Active Perception. *Proceedings of The IEEE*, 76(8) pp. 996-1005, Aug. 1988.
- [4] O. Baujard et C. Garbay, KISS : un système de vision multi-agents. Actes du 8ième congrès de Reconnaissance des Formes et Intelligence Artificielle, pp. 89-98, Lyon-Villeurbanne, Nov. 1991.
- [5] F. Bellet, M. Salotti et C. Garbay, Une approche opportuniste et coopérative pour la vision bas niveau, *Revue Traitement du Signal*, Vol.12(5) pp. 479-493, 1995.
- [6] J. Benois et D. Barba, Image segmentation by region-contour cooperation as basis for efficient coding scheme, *Proc. of ICPR,92*, The Hague Nd. Sept. 1992.
- [7] P. Bonnin et B. Zavidovique, La segmentation coopérative : Comment combiner détection de contours et croissance de régions? 14ième colloque GRETSI, pp. 755-758, Juan-les-Pins, Sept. 1993.
- [8] P. Brodatz, Textures- A Photographic album for artists and designers, Dover NY 1966.
- [9] J. Canny, A computational approach to edge detection, *IEEE PAMI-8(6)* pp. 679-698, Nov. 1986.
- [10] J.M. Chassery et Y. Elomary, Coopération contours actifs et multi-résolution en segmentation d'images, 15ième colloque GRETSI, Juan-les-pins, Septembre 1995.
- [11] J.M. Chassery et A. Montanvert, Géométrie discrète en analyse d'images. Eds. Hermès, Paris 1991.
- [12] C.C. Chu et J.K. Aggarwal, The Integration of image segmentation maps using region and edge information, *IEEE PAMI-15(12)* :1241-1255, Dec. 1993.
- [13] M.G. Cox, J.M. Rehg et S. Hingorani, A Bayesian multiple-hypothesis approach to edge grouping and contour segmentation. *International Journal of Computer Vision*, vol. 11, no 1, pp. 5-24, 1993.
- [14] J.P. Cocquerez et S. Philipp, Analyse d'images : filtrage et segmentation. Collection Enseignement de la physique. Masson, Paris, 1995.
- [15] K. Chehdi, C. Cariou et C.D. Kermad, Image segmentation and texture classification using local thresholds and 2D AR modelling, in *Proc. EUSIPCO'94*, pp30-33, Sept. 1994.
- [16] K. Chehdi et D. Coquin, Binarisation de plusieurs classes d'images par seuillage local optimal maximisant un critère d'homogénéité, 13ième colloque GRETSI, Juan-les-pins, Sept. 1991.
- [17] K. Chehdi et Q.M. Liao, Détection de contours basée sur la perception visuelle en vue de la segmentation d'images, 14ième colloque GRETSI, pp. 739-742, Juan-les-Pins, Sept. 1993.
- [18] R. Deriche, Fast algorithms for low-level vision, *IEEE PAMI-18(1)* :679-683, 1990.
- [19] J.P. Gombotto, A new approach to combining region growing and edge detection, *Pattern Recognition Letters*, 14 pp. 869-875, 1993.
- [20] J.F. Haddon et J.F. Boyce, Image segmentation unifying region and boundary information, *IEEE PAMI-12(10)* pp. 929-948, 1990.
- [21] R.M. Haralick, Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5) pp. 786-803, 1979.
- [22] R.M. Haralick et L.G. Shapiro, Survey, image segmentation techniques, *Computer Vision, Graphics and Image Processing*, Vol 29, pp. 100-132, 1985.
- [23] R.M. Haralick et L.T. Watson, A facet model for image data, *Computer Graphics and Image Processing*, Vol 15 pp. 113-126, 1981.
- [24] D.P. Huttenlocher, G. Klanderma et J. Rucklidge, Comparating images using the Hausdorff distance, *IEEE PAMI-15(9)* :850-863, 1993.
- [25] R. Kara-Falah et P. Bolon, Une technique d'intégration des résultats en segmentation d'images, 15ième colloque GRETSI, pp. 573-576, Juan-les-pins, Sept. 1995.
- [26] R. Kara-Falah, P. Bolon, et J.P. Cocquerez, A region-region and region-edge cooperative approach of image segmentation, in *Proc. of IEEE ICIP'94*, Vol.3 pp. 470-474, 1994.
- [27] C.D. Kermad, Segmentation d'Images : Recherche d'une Mise en œuvre Automatique par Coopération de Méthodes. Thèse de doctorat de l'université de Rennes I, 1997.
- [28] C.D. Kermad, K. Chehdi et C. Cariou, Segmentation d'images par multi-seuillage d'histogramme et fusion de régions minimisant un critère de similarité, 15ième colloque GRETSI, pp. 641-644, Juan-les-Pins, Sept. 1995.
- [29] C.D. Kermad, K. Chehdi et C. Cariou, Image segmentation by an iterative region-contour control minimizing a convergence criterion, in *Proc. of IEEE ICSP'96*, Pekin, Oct. 1996.
- [30] V. Koivunen et M. Pietikainen, Combined edge and region based method for range image segmentation, *Proc. of SPIE Intl. robotics and computer vision conf. IX*, pp. 501-512, Boston Nov. 1990.


Segmentation d'images : recherche d'une mise en œuvre automatique

- [31] Q.M. Liao, Detection de contours et segmentation d'images, application à la télédétection et à la biologie marine. Thèse de doctorat de l'université de Rennes I, 1995.
- [32] D.G. Lowe, Perceptual organization and visual recognition. Kluwer Academic Publishers, Hingham, 1985.
- [33] D. Marr et E. Hildreth, Theory of edge detection, Proc. of the Royal Society of London, Series B 207 pp. 187-217, 1980.
- [34] I. Matalas, R. Benjamin, et R. Kitney, An edge detection technique using the facet model and parameterized relaxation labeling, IEEE PAMI-19(4) :328-341, 1997.
- [35] M. Melkemi et J.M. Chassery, Edge-region segmentation processing based on generalized voronoï diagram representation, Proc. of the ICPR, The Hague Nd. Sept. 1992.
- [36] O. Monga et B. Wrobel, Segmentation d'image : vers une méthodologie, Revue Traitement du Signal, Vol.4(3) pp. 169-193, 1987.
- [37] V.S. Nalwa et E. Pauchon, Edge aggregation and edge description. Computer Vision, Graphics and Image Processing, vol. 40, pp. 79-94, 1987.
- [38] A. Nazif et M.D. Levine, Low level segmentation : An expert system, IEEE PAMI-6(5), 1984.
- [39] N.R. Pal et S.K. Pal, A review on image segmentation techniques, Pattern Recognition, 26 :1277-1294, 1993.
- [40] T. Pavlidis et Y.T. Liow, Integration region growing and edge detection, IEEE PAMI-12(3) pp. 225-233, 1990.
- [41] T.R. Reed et J.M.H. Du Buf, A review of recent texture segmentation and feature extraction techniques. Computer Vision, Graphics and Image Processing : Image Understanding, 57 :359-372, Mai 1993.
- [42] P.K. Sahoo, S. Soltani, A.K.C. Wong et Y.C. Chen, A survey of thresholding techniques, Computer Vision, Graphics and Image Processing, vol 41, pp. 233-260, 1988.
- [43] C. Spinu, C. Garbay et J.M. Chassery, Une approche coopérative et adaptative pour la segmentation d'images, 15ième colloque GRETSI, pp. 609-612, Juan-les-Pins, Sept. 1995.
- [44] M. Tabb et N. Abuja, Multiscale image segmentation by integrated edge and region detection, IEEE Transactions of Image Processing, vol. 6, no. 5, pp. 642-655, 1997.
- [45] A.N. Tikhonov et V.Y. Arsenin, Méthodes de résolution de problèmes mal posés, MIR Moscou 1974.
- [46] L. Vinet et al. Cooperative segmentation and stereo matching, Image Topical Meeting on IU and Machine Vision, Massachusetts, June 1989.
- [47] B. Wrobel et O. Monga, Segmentation d'images naturelles : Coopération entre un détecteur de contour et un détecteur de région, Proc. of Cong. COGNITIVA MARI, pp. 181-188, Paris Mai 1987.
- [48] Y. Xiaohan et al. Image segmentation combining region growing and edge detection, Proc. of ICPR'92, The Hague Nd. Sept. 1992.
- [49] S.C. Zhu et A. Yuille, Region competition : unifying snakes, region growing and bayes/mrf for multiband image segmentation, IEEE PAMI-18(9), Sept. 1996.

Manuscrit reçu le 2 février 1998.


LES AUTEURS

Chafik Djalad KERMAD



Ingénieur diplômé de l'Institut National d'Informatique d'Alger, il a soutenu une thèse de doctorat en traitement du signal et télécommunication en 1997 sur la segmentation d'images. Il est actuellement attaché temporaire d'enseignement et de recherche à l'ENSSAT et à l'IUT de Lannion (Université de Rennes I). Ses activités de recherche portent essentiellement sur la conception de méthodes coopératives et adaptatives de segmentation en vue de développer des systèmes automatiques d'interprétation d'images.

Kacem CHEHDI



Professeur à l'ENSSAT (Université de Rennes I) en traitement du signal et de l'image. Il est directeur du Laboratoire d'Analyse des Systèmes de Traitement de l'Information (LASTI). Ses activités de recherche portent sur l'adaptativité des traitements à tous les niveaux de la chaîne de reconnaissance de formes par vision. Dans le cadre de la restauration et du filtrage, il s'intéresse à l'identification de la nature des dégradations en vue d'appliquer les algorithmes appropriés. En segmentation, ses travaux concernent la mise en œuvre de systèmes coopératifs et automatiques.

Segmentation d'images : recherche d'une mise en œuvre automatique par coopération de méthodes

ERRATUM

Image Segmentation: Toward an Automatic Framework Through Methods Cooperation

par Chafik Djalal KERMAD et Kacem CHEHDI

LASTI-Groupe Image, ENSSAT, 6, rue de Kerampont, 22305 Lannion, France.
Tel : {33} 02 96 46 50 30 / E-mail : kermad@enssat.fr, chehdi@enssat.fr

résumé et mots clés

Dans cet article, nous proposons un système de segmentation adapté à l'analyse de plusieurs types d'images, riches en détails et dont les régions peuvent être de nature uniforme et/ou texturée. Un intérêt tout particulier a été accordé à l'aspect automatique et non-supervisé du dispositif.

Le système proposé combine deux concepts. Le premier, fondé sur un procédé d'intégration d'informations issues de différentes méthodes de segmentation, permet de tirer parti des avantages de chacune d'elles. Le second concept s'inspire de la perception active par l'introduction d'une boucle de retour dans le système afin de corriger et d'ajuster les paramètres de contrôle de l'ensemble des méthodes employées. Le principe de la coopération proposée introduit un mécanisme de vérification de la cohérence par comparaison des résultats des méthodes impliquées dans la coopération. Ce dernier aspect fait défaut à un bon nombre d'approches coopératives.


Le système développé est composé de deux modules. Le premier est dédié à l'extraction de régions uniformes ou faiblement texturées. Le principe est fondé sur une coopération itérative entre une méthode de détection de contours et une méthode d'agrégation de points. Ces deux méthodes sont itérées avec des critères de plus en plus tolérants jusqu'à la convergence vers des résultats cohérents et stables. La cohérence est réalisée en minimisant une mesure de dissimilarité entre les contours et les régions. Le but est ainsi de fournir une solution optimale au sens de la compatibilité entre les résultats des deux segmentations. Le second module localise les régions texturées et contribue à la réactualisation et à la correction des contours extraits à chaque itération du premier module. Cette localisation s'appuie sur une classification automatique par multi-seuillage exploitant certains mécanismes de la perception visuelle, et sur une fusion des régions multi-seuillées minimisant un critère de similarité.

Segmentation d'images, coopération de méthodes, perception du contraste, dissimilarité entre images de contours, mesure de cohérence.

LES AUTEURS

Chafik Djalal KERMAD

Kacem CHEHDI



Ingénieur diplômé de l'Institut National d'Informatique d'Alger, il a soutenu une thèse de doctorat en traitement du signal et télécommunication en 1997 sur la segmentation d'images. Il est actuellement attaché temporaire d'enseignement et de recherche à l'ENSSAT et à l'IUT de Lannion (Université de Rennes I). Ses activités de recherche portent essentiellement sur la conception de méthodes coopératives et adaptatives de segmentation en vue de développer des systèmes automatiques d'interprétation d'images.



Professeur à l'ENSSAT (Université de Rennes I) en traitement du signal et de l'image. Il est directeur du Laboratoire d'Analyse des Systèmes de Traitement de l'Information (LASTI). Ses activités de recherche portent sur l'adaptativité des traitements à tous les niveaux de la chaîne de reconnaissance de formes par vision. Dans le cadre de la restauration et du filtrage, il s'intéresse à l'identification de la nature des dégradations en vue d'appliquer les algorithmes appropriés. En segmentation, ses travaux concernent la mise en œuvre de systèmes coopératifs et automatiques.

Article publié dans le volume 15 numéro 4 en page 336, les photos des auteurs ont été interverties. Elles sont ici rétablies en bonne place.