

Sur le choix de méthode de segmentation statistique d'images

On the Choice of Statistical Image Segmentation Method

par Fabien SALZENSTEIN et Wojciech PIECZYNSKI

Département Signal et Image
Institut National des Télécommunications
9, rue Charles Fourier 91011 Evry Cedex
e-mail. Wojciech.Pieczynski@int-evry.fr

résumé et mots clés

Nous traitons dans cet article du problème de la segmentation d'images à partir de niveaux de gris et sans prise en compte de la notion de texture. Les méthodes statistiques de telle segmentation peuvent être divisées en deux familles : méthodes locales, où l'on classe chaque pixel à partir de l'information contenue dans son voisinage de petite taille, et méthodes globales, qui font appel aux modélisations markoviennes et permettent d'effectuer des classifications bayésiennes en tenant compte de toute l'information disponible. Toutes les méthodes peuvent être rendues automatiques, ou non supervisées, en leur adjoignant une méthode d'estimation de mélanges. Des études antérieures ont montré que le choix de la méthode d'estimation a, dans le cas gaussien, peu d'influence sur le résultat final. Cependant, les comportements généraux des méthodes locales et globales sont très différents et aucune famille n'est supérieure à l'autre dans toutes les situations. Nous proposons dans cet article un algorithme de choix automatique, à savoir fonctionnant sans intervention humaine et à partir de la seule image à segmenter, entre les méthodes locales et les méthodes globales. Le choix de l'algorithme est fait à partir de l'homogénéité de l'image des classes et de la corrélation spatiale du bruit. La pertinence des choix est montrée via simulations et segmentations des images réelles.

Segmentation statistique d'images, champs de Markov, chaînes de Markov.

abstract and key words

In this paper we deal with the statistical grey-level segmentation, without any reference to texture. These methods can be divided in two families: local methods and global ones. Local methods classify each pixel, using tools of Bayesian classification, from the information contained in its neighbourhood of a small size. Global methods are based on hidden Markov models and allow one to apply Bayesian techniques taking into account the entire information available. Adding a previous model parameter estimation step, which is a mixture estimation, all these methods can be rendered automated, or unsupervised. On the one hand, results obtained with unsupervised methods differ little from results obtained with true parameter based methods. On the other hand, for a given segmentation method, the choice of the parameter estimation method has little influence on the final result. However, the general behaviour of local and global methods are different. Although global methods can give excellent results when data are well suited to the underlying model, in other situations local methods can ensure clearly better performance. The aim of the present work is to propose a method for choosing between local and global methods. The choice we propose is automated, i.e., independent from any human intervention and only depending on the image to be segmented. We deduce the choice from two factors: class image homogeneity and spatial correlation of the noise. The good behaviour of our algorithm is validated with simulations and real-world image segmentation results.

Statistical image segmentation, Markov Fields, Markov Chains.

1. introduction

Notre étude traite du problème de la segmentation d'images, à partir de niveaux de gris et sans prise en compte de la notion de texture, par des méthodes statistiques. Dans ce contexte, les méthodes statistiques peuvent être divisées en deux familles : méthodes locales et méthodes globales. Dans les premières, chaque pixel est classé à partir de l'observation limitée à son voisinage de petite taille, ce qui rend possible l'application directe de diverses stratégies bayésiennes. Le principe des méthodes globales requiert la classification de chaque pixel à partir de toute l'image, soit en exploitant entièrement l'information disponible. Les stratégies bayésiennes ne sont plus calculables directement dans ce contexte, cependant, l'introduction des modélisations par champs markoviens a permis la conception de méthodes itératives permettant la définition des suites convergeant vers les solutions bayésiennes. Les avancées décisives dans ce domaine sont dues à Geman et al. [GeG84] et Marroquin et al. [MMP87]. Citons également l'algorithme Iterated Conditional Modes (ICM) de Besag [Bes86] lequel, bien que ne garantissant pas la convergence, est très rapide et donne des résultats satisfaisants dans un certain nombre de situations. Les méthodes "non supervisées", à savoir incluant en amont une phase d'estimation des paramètres du modèle utilisé à partir des seules images à segmenter, ont ensuite été proposées. Le problème statistique correspondant étant celui de l'estimation de mélange de lois, il est possible d'envisager l'application des méthodes générales comme Expectation-Maximization [DLR77, ReW84], Gradient Stochastique [You89], Iterative Conditional Estimation [Pie94], ou encore Stochastic EM [BCD83, CeD86]. En couplant ces méthodes générales avec les différentes méthodes de segmentation, il est ainsi possible de proposer un grand nombre d'algorithmes de segmentation non supervisée. Citons quelques exemples de couplage des méthodes locales avec EM [PeP95], SEM [PeP95], ICE [PeP95] et quelques autres de couplage des méthodes globales avec EM [Cha89, ChJ93, Zec93], GS [You89], ou ICE [BPM93, Pie94, BoL94, MCP97]. Il existe également des méthodes originales, ne faisant appel à aucune méthode générale citée ci-dessus [GGG90, KeF95, LaD89]. Différentes études montrent que l'efficacité des méthodes non supervisées est assez peu différente de celle des méthodes utilisant les vrais paramètres. On peut ainsi considérer, en première approximation, que lorsque le modèle statistique utilisé correspond aux données traitées la méconnaissance éventuelle des paramètres ne pose pas de problème majeur.

Cependant les études antérieures des algorithmes globaux et locaux de segmentation statistique non supervisée d'images ont fait apparaître des différences de leurs comportements en fonction de paramètres statistiques de l'image tels que la corrélation spatiale du bruit ou l'homogénéité de l'image [BPM93]. Les différences de l'efficacité pouvant être significatives, le problème du choix de la méthode la mieux adaptée aux données en présence peut revêtir une importance considérable.

Dans cet article nous considérons trois algorithmes de segmentation : deux globaux, fondés respectivement sur les champs et les chaînes de Markov cachés, et un local. Nous présentons ensuite un algorithme permettant de choisir, uniquement à partir de l'image

à segmenter, la méthode la mieux adaptée. Notons que les méthodes de segmentation choisies sont très simples : notre objectif est de les comparer entre elles et non de les améliorer.

L'organisation de l'article est la suivante :

Dans le paragraphe 2 nous décrivons très succinctement les principes des trois types de démarches considérés dans cet article. Le paragraphe 3 est consacré à la formalisation des facteurs de choix retenus. Le choix de la meilleure méthode de segmentation devant être automatique, nous proposons dans le paragraphe 4 une méthode d'estimation des facteurs de choix à partir de la seule image à segmenter et présentons quelques exemples de résultats numériques. L'algorithme du choix automatique dans le cas de deux classes, ainsi que quelques résultats numériques et visuels, sont présentés dans le paragraphe 5. Le cas de trois classes est traité dans le paragraphe 6 et le paragraphe 7 est consacré aux conclusions.

2. présentation des algorithmes utilisés

2.1. approche globale par champs de Markov

Considérons S l'ensemble des pixels de l'image, $\Omega = \{\omega_1, \dots, \omega_K\}$ l'ensemble des classes, N le cardinal de S . Dans le cadre considéré, l'image inobservable des classes $x = (x_s)_{s \in S}$ est une réalisation d'une variable aléatoire $X = (X_s)_{s \in S}$ à valeurs dans Ω^N . En supposant la probabilité de chaque réalisation non nulle, nous pouvons écrire :

$$P[X = x] = ce^{-U(x)} \quad (2.1)$$

$U(x)$, dite énergie de Gibbs, est donnée par la somme de fonctions définies sur les cliques associées au voisinage de la markovianité. Nous considérerons le cas le plus simple d'un champ de Markov relativement aux quatre plus proches voisins, avec l'énergie donnée par (2.2).

$$U(x) = \sum_{x_s, x_t \text{ voisins}} \varphi(x_s, x_t) \text{ avec } \varphi(x_s, x_t) = \begin{cases} -\alpha & \text{si } x_s = x_t \\ \alpha & \text{si } x_s \neq x_t \end{cases} \quad (2.2)$$

Le champ X étant classiquement bruité par un bruit blanc Gaussien, les paramètres définissant le modèle sont le paramètre α définissant l'énergie de Gibbs et l'ensemble des moyennes et des variances du bruit de chacune des classes, que l'on désignera par β .

Ainsi que nous l'avons signalé dans l'introduction, l'estimation des paramètres peut être effectuée par plusieurs méthodes différentes, et chacune d'entre elles peut être couplée avec l'une des méthodes de segmentation MAP [GeG84], MPM [MMP87] ou ICM [Bes86]. Nous retenons ICE pour l'estimation des paramètres et MPM pour la segmentation.

2.2. approche globale par chaînes de Markov

Nous adoptons le modèle étudié dans [BeP95]. Il consiste en la définition d'un parcours de type Hilbert-Peano [Ska92] dans l'ensemble des pixels, ce qui permet de transformer les processus bi-dimensionnels (champs aléatoires) en un processus mono-dimensionnel. Le champ X est alors modélisé par une chaîne de Markov et l'image observée est la réalisation $Y = y$ de la variable aléatoire Y , qui est une version bruitée de X . La chaîne de Markov $(X_s)_{s \in N}$ étant supposée homogène et stationnaire, sa loi est définie par (2.3).

$$P[(X_n, X_{n+1}) = (\omega_i, \omega_j)] = c_{ij} \quad (2.3)$$

Notons que (2.3) donne, en particulier, la loi initiale et la matrice de transition de la chaîne. Fixons N , le nombre de pixels, et notons $X = (X_1, \dots, X_N)$, $Y = (Y_1, \dots, Y_N)$. Le processus Y est obtenu à partir de X par une procédure de bruitage analogue à celle utilisée dans le cas des champs de Markov. Finalement, la loi de (X, Y) est déterminée par les paramètres $(c_{ij})_{1 \leq i, j \leq K}$ et les moyennes et variances du bruit en chaque classe. Ces paramètres peuvent alors être estimés par des méthodes de type EM, SEM, ou ICE [BeP95]. Les performances de ces méthodes étant pratiquement équivalentes, nous optons pour l'algorithme EM, le plus rapide.

Finalement, nous retenons dans la suite l'algorithme EM pour la phase d'estimation des paramètres et l'algorithme MPM pour la segmentation.

2.3. approche locale : ICE aveugle adaptative

Soit $Y = (y_s)_{s \in S}$ le champ bruité, A et B deux sous-ensembles de S de petite taille. La segmentation bayésienne locale associée à la fonction de perte $(0,1)$ conduit à affecter à chaque sous-ensemble A l'élément $\hat{x}_A = \hat{s}(y_B) \in \Omega^{\text{card } A}$ qui maximise la probabilité conditionnelle :

$$\hat{x}_A(y_B) = \arg \max_{x_A \in \Omega^{\text{card } A}} P[X_A = x_A | Y_B = y_B] \quad (2.4)$$

On choisit généralement $A = \{s\}$, ce que nous ferons dans la suite. Il est alors possible de prendre en compte l'information contenue dans les observations sur un voisinage $V = B$ de deux manières :

- une segmentation « contextuelle » : on utilise (2.4) avec $A = \{s\}$ et $B = V$ en supposant que les lois de probabilité figurant dans (2.4) ne dépendent pas de s . L'information contenue dans les observations sur $V = B$ est ainsi exploitée au niveau de la segmentation proprement dite.

- une segmentation « aveugle adaptative » : on utilise (2.4) avec $A = \{s\}$ et $B = \{s\}$ en supposant que la loi *a priori* de X_s , qui figure implicitement dans (2.4), dépend de s . On tient alors compte de l'information contenue dans les observations sur le voisinage $V = B$ au niveau de l'estimation des paramètres, par le biais des fenêtres centrées sur s et utilisées pour l'estimation des lois *a priori*.

Finalement, nous retenons la méthode « aveugle adaptative » avec la phase « estimation des paramètres » traitée par ICE. Le problème du choix de la taille optimale de la fenêtre d'estimation, qui dépend de l'homogénéité de l'image, est abordé dans la sous-section 4.2.

3. paramètres de choix d'une méthode de segmentation non supervisée

3.1. facteur d'homogénéité h

Des études antérieures ont permis de constater que « l'homogénéité » de l'image est importante relativement à l'efficacité des algorithmes de type local et global [BPM93]. Intuitivement, l'image est d'autant plus homogène que la taille des zones homogènes est grande. L'objectif de cette sous-section est de définir un facteur de mesure de l'homogénéité pouvant être calculé automatiquement à partir de l'image bruitée.

Le facteur h que nous proposons évalue l'homogénéité à partir des lois conjointes a priori, de deux pixels voisins s, t , par la moyenne de ces probabilités suivant les quatre directions de voisinage : horizontale, verticale, et les deux directions diagonales. Chaque X_s étant à valeurs dans $\Omega = \{\omega_1, \dots, \omega_K\}$, on considère H défini par (3.1), où l'indice j indique la direction du voisinage.

$$H = \frac{1}{4} \left\{ \sum_{j=1}^4 \sum_{i=1}^K P_j[(X_s, X_t) = (\omega_i, \omega_j)] \right\} \quad (3.1)$$

Il est alors possible d'estimer les probabilités figurant dans (3.1) à partir de l'image bruitée par l'algorithme SEM contextuel à deux voisins, dont le principe est rappelé dans le paragraphe 4. Remarquons que si les pixels sont dispersés de manière totalement aléatoire dans l'image, nous pouvons écrire :

$$\forall 1 \leq i \leq K \quad P_j[(X_s, X_t) = (\omega_i, \omega_i)] = \frac{1}{K^2} \quad (3.2)$$

ce qui correspond à $H = 1/K$. Bien que H puisse prendre toute valeur entre 0 et $1/K$, supposons temporairement, uniquement pour des raisons de concision de présentation qui apparaîtront ultérieurement, que $1/K \leq H$. Étant donné que $H \leq 1$, nous avons :

$$\frac{1}{K} \leq H \leq 1 \quad (3.3)$$

Nous normalisons alors le facteur H afin de le rendre indépendant du nombre de classes et d'élargir la plage de valeurs d'homogénéité. En posant :

$$h = (KH - 1)/(K - 1) \quad (3.4)$$

nous avons :

$$0 \leq h \leq 1 \quad (3.5)$$




Figure 1. – Estimation des corrélations spatiales du bruit.

Nous retenons donc comme facteur mesurant l'homogénéité d'une image le nombre défini par (3.1), (3.4). Son estimée sera alors calculée par les mêmes formules à partir des lois conjointes, elles-mêmes estimées à partir de l'image bruitée par le SEM contextuel.

Notons que les cas où $H \leq 1/K$ seraient également pris en compte en donnant un h négatif. Une telle situation ne s'est cependant jamais produite dans les différents cas étudiés, h minimal obtenu étant de 0.3.

3.2. coefficient de corrélation spatiale ρ

Les corrélations spatiales du bruit jouent également un rôle important dans le comportement des diverses méthodes de segmentation statistique non supervisée.

Dans nos simulations, nous construisons des images bruitées en introduisant le même facteur de corrélation spatiale pour les quatre directions de voisinage et sans tenir compte de l'appartenance d'un pixel à une classe ($\rho_{inter\ classe} = \rho_{intra\ classe}$). Ainsi que nous le verrons par la suite, c'est le facteur de corrélation qui déterminera notamment la taille de la fenêtre F utilisée pour l'estimation des lois a priori dans la méthode ICE aveugle adaptative.

Bien que les valeurs de ρ puissent théoriquement différer dans les quatre directions du voisinage (voir Figure 1), les tests sur des images réelles montrent que le coefficient est généralement le même dans les quatre directions. Nous conjecturons que l'estimation de ce facteur dans une seule direction de voisinage est suffisante (nous choisirons deux voisins horizontaux).

4. estimation des paramètres de choix

4.1. estimation de h et ρ

Pour estimer les valeurs de h et ρ , nous proposons l'utilisation de l'algorithme SEM.

Considérons une suite $\nu_1 = (s_1, t_1), \dots, \nu_n = (s_n, t_n)$ de couples de pixels voisins fixée dans l'ensemble des pixels S et notons $X_{\nu_i} = X_{(s_i, t_i)} = (X_{s_i}, X_{t_i})$, $Y_{\nu_i} = Y_{(s_i, t_i)} = (Y_{s_i}, Y_{t_i})$ les restrictions des champs X, Y à ν_i . La connaissance de la loi de (X_{ν_i}, Y_{ν_i}) , indépendante de ν_i selon l'hypothèse de stationnarité, implique la connaissance des paramètres h et ρ . En effet, d'une part cette loi donne la loi de $X_{\nu_i} = (X_{s_i}, X_{t_i})$, ce qui permet de

déterminer h par (3.1) et (3.4). D'autre part, elle donne les lois de $Y_{\nu_i} = (Y_{s_i}, Y_{t_i})$ conditionnelles à $X_{\nu_i} = (X_{s_i}, X_{t_i})$, lesquelles lois sont des lois gaussiennes sur R^2 et dont la connaissance donne les paramètres $\rho, (\mu_i)_{i=1 \dots K}, (\sigma_i)_{i=1 \dots K}$. Le problème est donc d'estimer la loi de (X_{ν_i}, Y_{ν_i}) à partir de $Y_{\nu_1}, \dots, Y_{\nu_n}$. La loi de chaque Y_{ν_i} étant un mélange de K^2 lois gaussiennes sur R^2 , on peut appliquer l'algorithme SEM [BCD83, CeD86].

Quelques résultats d'estimation de h et ρ par cette méthode sont présentés dans le Tableau 1. De nombreux résultats des estimations de ces facteurs dans des conditions très diverses sont donnés dans [Sal96]. Ces résultats permettent de conclure à la qualité suffisante, en ce qui concerne leur utilisation pour le choix automatique de la meilleure méthode de segmentation, des estimées de ces facteurs.

Notons que le niveau de corrélation du bruit ne dégrade pas, selon les résultats du Tableau 1, la qualité de l'estimation de l'homogénéité, ce qui montre une bonne robustesse de la méthode choisie par rapport à ce paramètre. Ce fait est à relever car, de façon générale, l'augmentation de la corrélation des données implique la dégradation de l'efficacité des estimations.

Tableau 1. – Estimation de h et ρ pour le bruit $\mu_2 - \mu_1 = 1, \sigma_1 = \sigma_2 = 1$.

	\hat{h}			$\hat{\rho}$		
	$h = 0,4$	$h = 0,7$	$h = 0,9$	$h = 0,4$	$h = 0,7$	$h = 0,9$
$\rho = 0$	0,22	0,32	0,52	0,05	0,05	0,1
$\rho = 0,5$	0,32	0,5	0,66	0,45	0,40	0,5
$\rho = 0,7$	0,38	0,48	0,7	0,71	0,67	0,67
$\rho = 0,8$	0,46	0,64	0,78	0,79	0,81	0,8
$\rho = 0,9$	0,48	0,74	0,82	0,85	0,84	0,86

4.2. choix de la taille de la fenêtre d'estimation dans les méthodes adaptatives

Diverses simulations montrent que la dimension de la meilleure fenêtre d'estimation utilisée dans les méthodes adaptatives dépend des valeurs de h, ρ et $(\mu_i)_{i=1 \dots K}, (\sigma_i)_{i=1 \dots K}$ [Sal96]. Ainsi se pose, de façon subalterne, le problème du choix automatique de la taille la plus adéquate. Cependant, l'influence de la forme des bruits (discrimination par les moyennes ou les variances), ainsi que l'influence de h , peuvent être considérées comme négligeables [Sal96]. Seul ρ est important : le choix de la taille la mieux adaptée en fonction de ρ est précisé dans le Tableau 2.

Tableau 2. – Choix de la meilleure fenêtre d'estimation des méthodes locales adaptatives à partir de la corrélation spatiale du bruit.

	$\rho = 0$	$\rho = 0,4$	$\rho = 0,5$	$\rho = 0,7$	$\rho = 0,8$	$\rho = 0,9$
Taille	5 * 5	6 * 6	8 * 8	10 * 10	15 * 15	20 * 20

5. expérimentations et résultats dans le cas de deux classes

5.1. algorithmes de choix

Nous avons utilisé quatorze images différentes, chacune d'entre elles étant bruitée par des bruits de différent type et de différente intensité. Les résultats complets de simulations, présentés dans [Sal 96], permettent de définir, dans l'ensemble des paramètres $(h, \rho) \in [0, 1]^2$, des zones de discrimination des algorithmes locaux et globaux. Nous présentons dans le Tableau 3 une synthèse de plusieurs tableaux du même type.

Tableau 3. – Choix du meilleur algorithme en fonction de l'homogénéité et de la corrélation pour le bruit MD (discriminant par la moyenne). A1 : méthode locale, A2 : méthode globale fondée sur les champs de Markov, A3 : méthode globale fondée sur les chaînes de Markov.

	$h = 0,3$	$h = 0,4$	$h = 0,5$	$h = 0,6$	$h = 0,7$	$h = 0,8$	$h = 0,9$
$\rho = 0$	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3	A2 A3	A2 A3	A2 A3
$\rho = 0,4$	A1 A2 A3	A1 A2 A3	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3	A2 A3
$\rho = 0,5$	A1	A1	A1 A2	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3
$\rho = 0,7$	A1	A1	A1	A1	A1	A2	A2
$\rho = 0,8$	A1	A1	A1	A1	A1	A1	A2
$\rho = 0,9$	A1	A1	A1	A1	A1	A1	A1

Le résultat le plus immédiat est la constatation que la deuxième bissectrice est la ligne de partage entre les algorithmes locaux et les algorithmes globaux. Étant donné que l'équation de la diagonale s'écrit $h = \frac{2}{3}\rho + \frac{3}{10}$, les résultats du Tableau 3 permettent de proposer l'algorithme de choix automatique suivant :

- (i) Estimer ρ, h par le SEM;
- (ii) Si $h \leq \frac{2}{3}\rho + \frac{3}{10}$, opter pour la méthode locale avec la fenêtre déterminée à partir de ρ par le Tableau 2;
- (iii) Si $h \geq \frac{2}{3}\rho + \frac{3}{10}$, opter pour
 - A2 si $\rho \geq 0,5$
 - A3 si $\rho \leq 0,5$

L'algorithme est également présenté sur la Figure 2.

Notons que l'algorithme fondé sur les chaînes de Markov est le plus rapide et l'algorithme local adaptatif le plus lent.

5.2. données utilisées et résultats visuels

Nous donnons sur la Figure 3 six images parmi les quatorze, d'homogénéités différentes, utilisées dans les simulations. Les




Figure 2. – Choix de la méthode statistique non supervisée en fonction de la corrélation spatiale du bruit et de l'homogénéité de l'image des classes.




Figure 3. – Exemples des images de synthèse utilisées dans les simulations.

versions bruitées et les segmentées de ces versions par les trois méthodes en présence sont présentées sur la Figure 4. Les résultats de segmentations, aussi bien visuels que numériques, confirment la pertinence du choix défini plus haut. Notons que nous avons choisi deux cas « extrêmes » et, dans la pratique, cette pertinence sera, en moyenne, moins saisissante. Ces exemples ont cependant l'avantage de montrer l'existence de tels cas extrêmes.

6. généralisation à plusieurs classes

Lorsque le nombre de classes est supérieur à deux, il devient difficile d'effectuer une étude aussi complète que celle faite dans le cas de deux classes. En particulier, l'homogénéité est moins aisée à appréhender intuitivement (on peut imaginer des images de trois classes très homogènes par rapport à l'une d'entre elles et très peu homogènes par rapport aux autres). De même, la corrélation moyenne du bruit traduit un grand nombre de corrélations : dans le cas de trois classes, on peut considérer quatre directions et, pour chacune d'entre elles, trois corrélations interclasses et trois autres intraclasses. Enfin, la distinction entre les bruitages de type « discrimination par les moyennes » et ceux de type « discrimination par les variances » est malaisée à définir.

Cependant, un certain nombre de simulations présentées dans [Sal 96] permet d'affirmer qu'en première approximation l'intérêt de l'algorithme du choix est préservé. Nous reproduisons ci-dessous quelques exemples de résultats dans le cas de trois classes.

6.1. images de synthèse

Nous présentons sur la Figure 5 deux images de synthèse, leurs versions bruitées, et les segmentations par les trois méthodes en présence.

Les résultats visuels et les taux d'erreur confirment l'intérêt de l'algorithme du choix. Dans le cas d'une image très homogène (Im 15) bruitée par un bruit blanc important (Im 17) on constate une forte différence entre l'efficacité de l'algorithme A2 et l'algorithme A1. Concernant le comportement de l'algorithme A3, on observe un phénomène analogue à celui constaté dans le cas de deux classes : moins efficace que A2, il reste cependant acceptable et pourrait être choisi en cas de contraintes de temps de calcul. Dans le cas d'une image très peu homogène (Im 16) bruitée par un bruit fortement corrélé, on constate toujours une forte différence entre l'efficacité de l'algorithme A2 et A1, mais la qualité de leurs performances respectives est inversée. L'algorithme A2 s'avère parfaitement inefficace et l'algorithme A1 semble acceptable. On observe par ailleurs une nette supériorité de l'algorithme A3 sur l'algorithme A2, ce qui confirme sa meilleure robustesse par rapport à l'homogénéité de l'image de classes constatée dans le cas de deux classes.




Figure 4. – Exemples d'efficacité des trois méthodes en présence. Bruitages $\mu_2 - \mu_1 = 2, \sigma_1 = \sigma_2 = 1$.

6.2. images réelles

Nous présentons sur la Figure 6 les résultats de segmentation de deux images réelles. La première (Im 25) est une image de faible homogénéité et de corrélation plutôt forte (il s'agit d'une vue aérienne d'une partie de Grenoble). La deuxième est une image




Figure 5. – Segmentation des images de synthèse. MD1 : $\rho = 0, \mu_3 - \mu_2 = \mu_2 - \mu_1 = 1$, MD2 : $\rho = 0,9, \mu_3 - \mu_2 = \mu_2 - \mu_1 = 2\rho = 0,9, \mu_3 - \mu_2 = \mu_2 - \mu_1 = 2$.

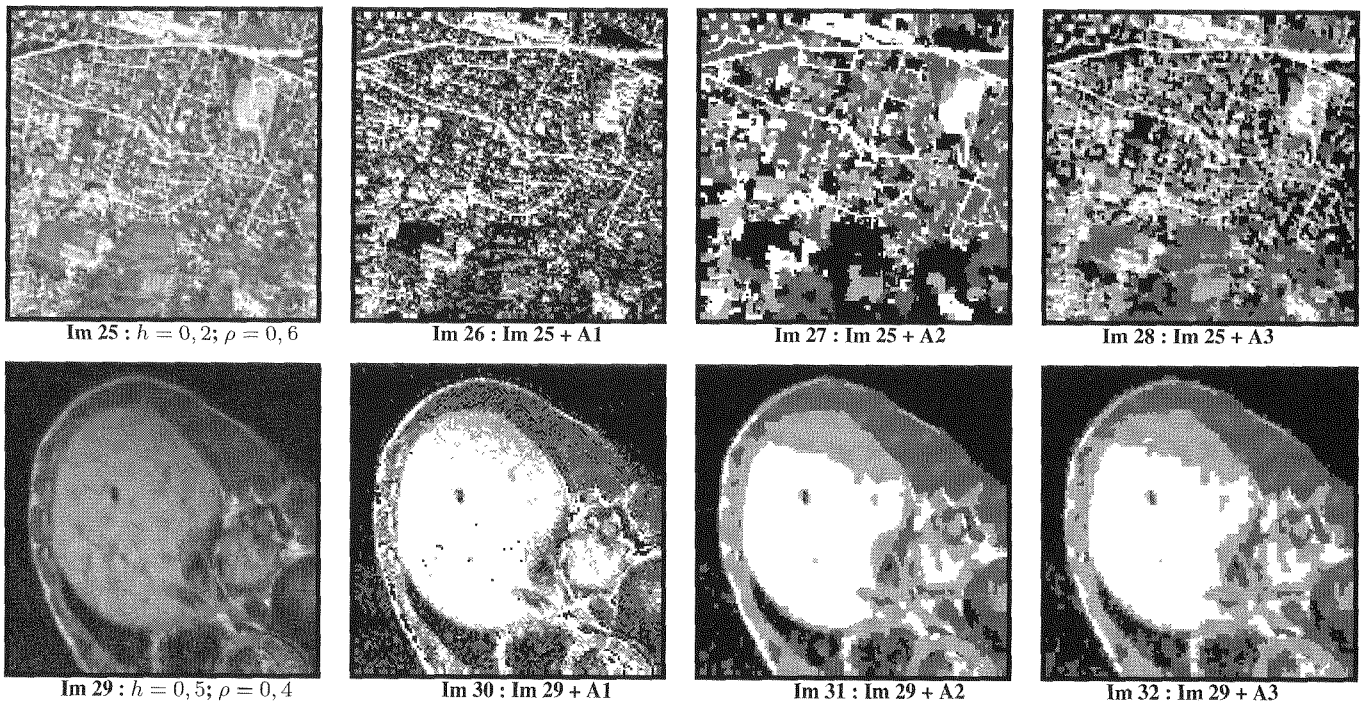


Figure 6. – Segmentations d'images réelles.

d'homogénéité et de corrélation plutôt faibles. Les corrélations et les homogénéités sont estimées par le SEM contextuel.

Étant donné les coefficients de corrélation et d'homogénéité de l'image Im 25, nous devons, conformément à notre algorithme de choix, opter pour une méthode locale adaptative. L'examen visuel des trois segmentées (Im 26-28) confirme la pertinence de

ce choix, en effet, la segmentée par A1 semble la plus proche de l'image originale.

Conformément aux valeurs des coefficients de corrélation et d'homogénéité estimés à partir de l'image Im 29, nous devons la segmenter par une méthode globale. Ces dernières semblent en effet donner des résultats plus probants, cependant une telle

conclusion ne s'impose pas de façon évidente. Les résultats de segmentation par une méthode locale et une méthode globale sont très différents et il n'est pas impossible que les deux présentent un intérêt. Cette constatation est en accord avec le fait que le point $(h, \rho) = (0.5, 0.4)$ n'est pas très éloigné de la diagonale (Figure 2). Notons également la grande ressemblance entre les segmentées par A2 et A3, ce qui est en accord avec l'algorithme de choix proposé (en prolongeant vers les valeurs plus faibles de l'homogénéité la ligne, qui est à $\rho = 0.5$, départageant A2 et A3).

7. conclusions

Nous avons considéré dans cet article le problème de la segmentation statistique non supervisée des images non texturées. L'objectif de notre travail était de présenter un algorithme de choix automatique entre une méthode de type global et une méthode de type local. Sa motivation est fondée sur les deux constatations suivantes :

(i) Le comportement des diverses méthodes est globalement similaire au sein de chacune des trois familles (méthodes locales, celles fondées sur les champs de Markov cachés, et celles fondées sur les chaînes de Markov cachés)

(ii) Le comportement des représentants des trois familles peut être très différent et leurs efficacités peuvent être complémentaires.

Nous avons choisi trois représentants de trois familles et les avons considérés, en vertu de (i) et en première approximation, comme représentatifs au plan du comportement général. Leur comportement a ensuite été étudié en fonction de quatre facteurs : l'homogénéité de l'image des classes, la corrélation spatiale du bruit, le type de bruit et l'importance du bruitage. Les résultats présentés dans [Sal 96] permettent de négliger les deux derniers facteurs et de ne considérer que l'homogénéité de l'image des classes et la corrélation spatiale du bruit. Ces mêmes résultats, dont nous avons reproduit une partie dans le présent article, montrent par ailleurs la pertinence de l'utilisation de l'algorithme de choix proposé.

Nous avons utilisé des modélisations très simples et, en complexifiant l'énergie des champs de Markov ou la matrice de transition des chaînes de Markov, la hiérarchie des efficacités des méthodes pourrait éventuellement être modifiée. Cependant, il existe des cas où cette hiérarchie est si prononcée qu'elle serait, très probablement, respectée par des modèles plus complexes. En tout état de cause, les modèles simples considérés dans cet article sont déjà assez largement utilisés dans la pratique.

Le travail présenté pourrait être continué dans deux directions. D'une part, il existe des méthodes d'estimation du nombre de classes [LJC92] et l'implémentation de l'algorithme correspondant en amont contribuerait à l'automatisation de l'ensemble de la démarche. D'autre part, nous avons proposé dans [CPH97, SaP97] des modélisations par champs aléatoires flous cachés et des méthodes de segmentation statistique floue non supervisée locales et globales. Les modèles flous proposés étant des généralisations « continues » des modèles utilisés dans le présent travail, dans le sens où l'on retrouve ces derniers lorsque la quantité de flou

dans l'image des classes tend vers zéro, on pourrait conjecturer la validité de l'algorithme de choix dans le cas flou. La proportion de flou pouvant être par ailleurs aisément estimée de façon automatique, l'ensemble de la démarche pourrait être : (1) estimation du nombre des classes, (2) estimation de la quantité de flou dans l'image des classes, (3) choix entre les segmentations classique et floue, (4) choix entre les méthodes globales et locales de segmentation. Notons également qu'il est possible de remplacer, dans cette démarche, les mélanges gaussiens classiques par les mélanges généralisés [GiP 97, DMP 97], ce qui constituerait une nouvelle extension.

BIBLIOGRAPHIE

- [BeP95] B. Benmiloud, W. Pieczynski, Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images, *Traitement du Signal*, Vol. 12, No. 5, pp.433-454, 1995.
- [Bes86] J. Besag, On the statistical analysis of dirty pictures, *Journal of the Royal Statistical Society*, Series B, 48, pp. 259-302, 1986.
- [BoL94] J. M. Boucher and P. Lena, Unsupervised Bayesian classification, application to the forest of Paimpont (Brittany), *Photo Interprétation*, Vol. 32, No. 1994/4, 1995/1-2, 1995, pp. 79-81.
- [BPM93] B. Braathen, W. Pieczynski, P. Masson, Global and local methods of unsupervised Bayesian segmentation of images, *Machine Graphics & Vision*, Vol. 2, No. 1, pp. 39-52, 1993.
- [BCD83] M. Broniatowski, G. Celeux, J. Diebolt, Reconnaissance de mélanges de densités par un algorithme d'apprentissage probabiliste, *Data Analysis in Informatics 3*, E. Diday (Ed.), North Holland, Amsterdam, 1983.
- [CPH97] H. Caillol, W. Pieczynski, and A. Hillon, Estimation of Fuzzy Gaussian Mixture and Unsupervised Statistical Image Segmentation, *IEEE Transactions on Image Processing*, Vol. 6, No. 3, pp. 425-440, 1997.
- [CeD86] G. Celeux, J. Diebolt, L'algorithme SEM : un algorithme d'apprentissage probabiliste pour la reconnaissance de mélanges de densités, *Revue de Statistique Appliquée*, Vol. 34, No. 2, pp. 35-52, 1986.
- [Cha89] B. Chalmond, An iterative Gibbsian technique for reconstruction of m-ary images, *Pattern Recognition*, Vol. 22, No. 6, pp. 747-761, 1989.
- [ChJ93] R. Chellapa, A. Jain Ed., *Markov Random Fields, Theory and Application*, Academic Press, San Diego, 1993.
- [DMP97] Y. Delignon, A. Marzouki, W. Pieczynski, Estimation of Generalized Mixture and Its Application in Image Segmentation, *IEEE Transactions on Image Processing*, Vol. 6, No. 10, pp. 1364-1375, 1997.
- [DLR77] M.M. Dempster, N.M. Laird, and D.B. Rubin, Maximum likelihood from incomplete data via the EM algorithm, *Journal of the Royal Statistical Society*, Series B, 39, pp. 1-38, 1977.
- [DuJ89] R.C. Dubes, A.K. Jain, Random field models in image analysis, *Journal of Applied Statistics*, Vol. 16, No. 2, pp. 131-164, 1989.
- [GeG84] S. Geman, G. Geman, Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images, *IEEE Transactions on PAMI*, Vol. 6, No. 6, pp. 721-741, 1984.
- [GGG90] S. Geman, D. Geman, C. Graffigne, et P. Dong, Boundary detection by constrained optimization, *IEEE Transactions on PAMI*, Vol. 12, No. 7, pp. 609-627, 1990.
- [GiP97] N. Giordana and W. Pieczynski, Estimation of Generalized Multisensor Hidden Markov Chains and Unsupervised Image Segmentation, *IEEE Transactions on PAMI*, Vol. 19, No. 5, pp. 465-475, 1997.

- [Guy93] X. Guyon, Champs aléatoires sur un réseau, Collection Techniques Stochastiques, Masson, Paris, 1993.
- [HaH86] R. Haralick, J. Hyonam, A context classifier, *IEEE Transactions on GRS*, Vol. GE-24, No. 6, pp. 997-1007, 1986.
- [Hi192] A. Hillion, Les approches statistiques pour la reconnaissance des images de télédétection, Atti della XXXVI Riunione Scientifica, SIS, Vol. 1, pp. 287-297, 1992.
- [KeF95] C. Kervrann et F. Heitz, A Markov random field model based approach to unsupervised texture segmentation using local and global spatial statistics, *IEEE Transactions on Image Processing*, Vol. 4, No. 6, pp. 856-862, 1997.
- [LaD89] S. Lakshmanan, H. Derin, Simultaneous parameter estimation and segmentation of Gibbs random fields, *IEEE Transactions on PAMI*, Vol. 11, pp. 799-813, 1989.
- [LJC92] Z. Liang, R.J. Jaszczak, R.E. Coleman, Parameter Estimation of Finite Mixture Using the EM Algorithm and Information Criteria with Application to Medical Image Processing, *IEEE Transactions on Nuclear Science*, No. 4, Vol. 39, pp. 1126-1133, 1992.
- [MMP87] J. Marroquin, S. Mitter, T. Poggio, Probabilistic solution of ill-posed problems in computational vision, *Journal of the American Statistical Association*, 82, pp. 76-89, 1987.
- [MCP97] M. Mignotte, C. Collet, P. Pérez, et P. Bouthemy, Unsupervised segmentation applied on sonar images, *Energy Minimization Methods in Computer Vision and Pattern Recognition*, Lecture Notes in Computer Science : 1223, Springer-Verlag, Berlin, pp.491-506, 1997.
- [PeP95] A. Peng, W. Pieczynski, Adaptive Mixture Estimation and Unsupervised Local Bayesian Image Segmentation, *Graphical Models and Image Processing*, Vol. 57, No. 5, pp. 389-399, 1995.
- [Pie94] W. Pieczynski, Champs de Markov cachés et estimation conditionnelle itérative, *Traitement du Signal*, Vol. 11, No. 2, pp. 141-153, 1994.
- [QiT89] W. Qian and D.M. Titterton, On the use of Gibbs Markov chain models in the analysis of images based on second-order pairwise interactive distributions, *Journal of Applied Statistics*, Vol. 16, No. 2, pp. 267-282, 1989.
- [ReW84] R.A. Redner, H.F. Walker, Mixture densities, maximum likelihood and the EM algorithm, *SIAM Review*, 26, pp. 195-239, 1984.
- [Sal96] F. Salzenstein, Modèles Markoviens Flous et Segmentation non Supervisée d'Images, thèse de l'Université Rennes I, 1996.
- [SaP97] F. Salzenstein and W. Pieczynski, Parameter Estimation in Hidden Fuzzy Markov Random Fields and Image Segmentation, *Graphical Models and Image Processing*, Vol. 59, No. 4, pp. 205-220, 1997.
- [Ska92] W. Skarbek, Generalized Hilbert scan in image printing, *Theoretical Foundations of Computer Vision*, R. Klette et W. G. Kropetsh Ed., Akademik Verlag, pp. 45-57, 1992.
- [Yao89] J.F. Yao, Segmentation bayésienne d'images : comparaisons de méthodes contextuelles et globales, *Cahier du Centre d'Etudes et de Recherches*, Op.30 (4), pp. 269-290, 1989.
- [You88] L. Younes, Estimation and annealing for Gibbsian fields, *Annales de l'Institut Henri Poincaré*, 24, pp. 269-294, 1988.
- [You89] L. Younes, Parametric inference for imperfectly observed Gibbsian fields, *Probability Theory and Related Fields*, 82, pp. 625-645, 1989.
- [Zec93] J. Zerubia, and R. Chellapa, Mean field annealing using Compound Gauss-Markov Random Fields for edge detection and image estimation, *IEEE Transactions on Neural Networks*, 8(4), pp. 703-709, 1993.

Manuscrit reçu le 26 novembre 1996.

LES AUTEURS

Fabien SALZENSTEIN

Diplômé de l'École Nationale Supérieure des Télécommunications de Bretagne en 1990, Fabien Salzenstein a collaboré à la conception des logiciels de poursuite de piste pour les aiguilleurs du ciel à la Société Thomson-CSF, branche SDC, de 1991 à 1993. Il a préparé ensuite un doctorat à l'Institut National des Télécommunications, Évry, à partir de 1993. Ses travaux de thèse, qui ont porté sur les modélisations floues et la segmentation non supervisée d'images, ont été couronnés par le titre de docteur de l'Université de Rennes I en 1996. Actuellement post doctorant au département Image, École Nationale Supérieure des Télécommunications, Paris.

Wojciech PIECZYNSKI

Titulaire de Doctorat d'État en Statistique Mathématique obtenu à l'Université Paris VI en 1996, Wojciech Pieczynski a enseigné à l'Université de Tiaret, Algérie, à l'Université de Brazzaville, Congo, et à l'École Nationale Supérieure des Télécommunications de Bretagne, Brest. Actuellement Professeur et responsable du Groupe de Traitements Statistiques d'Images à l'Institut National des Télécommunications, Évry. Ses travaux de recherche portent sur les modélisations probabilistes et traitements statistiques d'images.