

CHOIX AUTOMATIQUE DE LA MEILLEURE MÉTHODE DE SEGMENTATION STATISTIQUE NON SUPERVISÉE D'IMAGES

Salzenstein F.

Pieczynski W.

Institut National des Télécommunications, Département Signal et Image, 9 rue Charles Fourier
91011 Evry Cedex, FRANCE

RESUME

Nous avons effectués des tests de comparaison d'algorithmes de segmentation statistiques d'images, en vue de concevoir une méthode de choix automatique d'algorithme en fonction des images traitées. Nous utilisons les algorithmes les plus efficaces et les plus représentatifs des méthodes de traitement statistiques non supervisées d'images. Nos conclusions sont basées sur un ensemble d'images tests bruitées artificiellement. Le critère de comparaison des algorithmes est le taux d'erreur à la reconstruction entre les images "vérité-terrain" et l'image segmentée. Nous nous donnons également un ensemble de paramètres statistiques qui permettent de qualifier les images : facteur de corrélation du bruit, forme du bruit (à moyennes ou à variances discriminantes), homogénéité de l'image non bruitée (regroupement des classes de pixels). Ces facteurs définissent les zones frontières qui déterminent l'emploi de tel ou tel algorithme, ce qui permet le choix automatique de la méthode la mieux adaptée.

ABSTRACT

We compared statistical segmentations algorithms of image processing. Our purpose is to choose automatically the best procedure for each picture. We used the most efficient and representative algorithms of the unsupervised image processing. Our conclusions are based on a set of synthetical pictures. We added artificial noise to these pictures. As criteria of comparison, we choosed the rate of error between the segmented picture and the "true" picture. A set of others parameters will qualificate each picture and define the boundaries, which allows to choose the algorithm. These parameters are: the factor of correlation, the type of the noise (discrimination by the means or the variances), homogeneity of the picture (the size of the group of pixels wich belong to the same class).

1. Position du problème

Les études antérieures des algorithmes globaux (basés sur le modèle des champs de Markov ou des chaînes de Markov) et locaux de segmentation statistique d'images font apparaître des différences de comportements en fonction de paramètres statistiques de l'image tels que la forme du bruit, sa corrélation spatiale, l'homogénéité de l'image ([1],[8]).

L'objet de notre étude est de définir, à partir de simulations expérimentales, un algorithme de choix automatique de la méthode la mieux adaptée aux données en présence. Nous supposons les bruits gaussiens.

Le premier problème est le suivant : pour quels critères de décision doit on opter en "amont" (ensemble des paramètres estimés sur une image réelle et conditionnant le choix de tel ou tel algorithme) et en "aval" (critère de comparaison des images obtenues par différents traitements). En ce qui concerne le critère "amont", nous retenons trois facteurs déterminant :

i) le(s) coefficient(s) de corrélation spatiale du bruit de l'image.

ii) le type de bruit : les deux cas extrêmes de bruitage sont le bruit VD (discrimination par les variances) et le bruit MD (discrimination par les moyennes).

iii) l'homogénéité de l'image.

L'automatisation du choix des algorithmes nécessite en "aval" un critère de comparaison objectif, c'est à dire indépendant du point de vue de l'observateur. Dans le cas de l'approche statistique, le critère qui se présente le plus naturellement est le taux d'erreur à la reconstruction entre l'image "vérité-terrain" et l'image segmentée. Nous considérerons qu'un algorithme est plus efficace qu'un autre, s'agissant d'une même image, lorsque ce taux d'erreur pour le deuxième algorithme excède d'au moins 4 % le taux d'erreur du premier algorithme.

Notons également qu'il s'agit de comparer les algorithmes dans des conditions similaires de traitement, autrement dit d'évaluer les algorithmes sur la base d'un nombre minimum d'itérations de convergence de la phase d'estimation des paramètres propres à ces algorithmes. Nous optimisons le temps de calcul pour chacun d'eux.

2. Présentation des algorithmes utilisés.

Le deuxième problème est le choix proprement dit des méthodes à comparer. Nous nous intéressons aux trois grands types d'approche de la segmentation bayésienne. Nous disposons de méthodes dites "locales" (affectation d'une classe à chaque pixel en tenant compte de son voisinage : segmentation "aveugles" ou "contextuelles" [1], [2]), et de méthodes dites "globales" basées sur l'hypothèse des champs ou des chaînes de Markov [3], [4], [7], [8] (affectation d'une classe à chaque pixel, compte tenu de



l'ensemble de l'image : segmentation globale MPM [4]).

Pour chacune de ces approches nous avons retenu un algorithme représentatif particulier. Nous retenons trois modes de segmentation précédés chacun d'une étape d'estimation adaptée (qui estime les paramètres spécifiques à ce mode de segmentation non supervisée).

2.1 Approche globale champ de Markov.

Nous employons un algorithme MPM global [4] associé une phase d'estimation ICE [6]. La phase d'estimation évalue le paramètre de la loi a priori du champ de Markov non bruité (ce paramètre définit la fonction énergie du champ de Gibbs) et les paramètres de bruits (moyennes et variances de chaque classe). Nous supposons le champ stationnaire et de markoviannité spatiale relativement aux quatre plus proches voisins (voisins horizontaux et verticaux).

2.2 Approche locale : ICE aveugle non stationnaire.

Au sein du groupe d'algorithmes locaux, les méthodes EM, SEM et ICE se valent ([2]). Nous employons la méthode ICE aveugle adaptative [2], autrement dit un algorithme de segmentation aveugle associé à une méthode ICE [6] adaptative : lors de la phase estimation, la loi a priori des classes dépend de chaque site et sa ré-estimation par ICE se fait sur une fenêtre de stationnarité (on suppose que dans cette fenêtre, la loi a priori est indépendante des pixels).

2.3 Chaînes de Markov.

L'algorithme est fondé sur le modèle des chaînes de Markov cachés [8]. Nous considérons la suite cachée comme une chaîne de Markov stationnaire. Ceci permet de faire rapidement et facilement des simulations de réalisations de X selon sa distribution a posteriori, avec un gain de temps considérable par rapport aux champs de Markov [8]. Dans la méthode MPM des chaînes de Markov, le calcul de la probabilité a posteriori permettant la décision d'appartenance d'un pixel à une classe, est possible grâce aux procédures "forward-backward" simples à mettre en oeuvre. Lors de la phase estimation nous estimons les paramètres que sont la matrice de transition, les probabilités initiales ainsi que les moyennes et variances du bruit par la méthode EM ([8],[9]).

3. Description et estimation des paramètres "amont".

3.1 Facteur d'homogénéité h .

Nous avons remarqué que l'approche locale donnait en général de meilleurs résultats sur des images peu homogènes (ce qui ne saurait surprendre). Aussi faisons nous intervenir le facteur d'homogénéité. S étant l'ensemble des pixels, l'image "vérité-terrain" est la réalisation $X = x$ de la variable aléatoire $X = (x_i)_{i \in S}$. Le facteur h qui évalue l'homogénéité est calculé à partir des probabilités conjointes a priori, de deux pixels voisins x_i et x_j , par la moyenne de ces probabilités suivant les quatre directions de voisinage : horizontale, verticale, et les deux directions diagonales. Si chaque pixel est à valeur dans $\Omega = \{\omega_1, \dots, \omega_K\}$ l'ensemble des K classes, on a :

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

L'indice j indique la direction du voisinage. Ces probabilités sont estimées à partir de l'algorithme SEM contextuel à deux voisins.

Remarquons que si les pixels sont dispersés de manière totalement aléatoire dans l'image, nous pouvons écrire :

$$P_j[(X_i, X_j) = (\omega_i, \omega_j)] = 1/K^2, \forall i$$

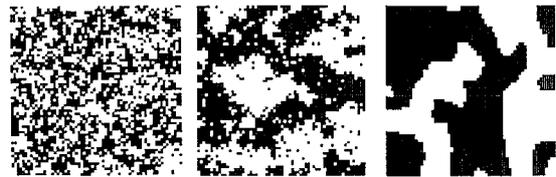
donc $H = 1/K$ qui est la valeur minimum de H . Soit :

$$1/K \leq H \leq 1$$

H est égal à 1 pour une image contenant une seule des K classes. Nous normalisons ce facteur afin de le rendre indépendant du nombre de classes et d'élargir la plage de valeurs d'homogénéité. En définissant le facteur d'homogénéité h par : $h = (K \cdot H - 1) / (K - 1)$, nous avons :

$$0 \leq h \leq 1$$

Exemples d'images de différentes homogénéités :



$h = 0,4$

$h = 0,7$

$h = 0,94$

3.1 Types de bruit.

L'image bruitée est la réalisation $Y = y$ de la variable aléatoire $Y = (Y_i)_{i \in S}$, à valeur dans R^N (N est le cardinal de S). Les probabilités conditionnelles $P[Y_i = y_i | X_i = x_i]$ sont supposées gaussiennes, ([2]) et sont définies par les moyennes et variances $(\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$ des classes. La phase de segmentation nécessite l'estimation de ces paramètres.

Les deux cas extrêmes de bruits sont les bruits à discrimination par les variances (VD) et à discrimination par les moyennes (MD). Nous choisissons des plages de valeurs dans lesquelles les algorithmes diffèrent par leur efficacité (valeurs au delà desquelles les méthodes de segmentation donnent des résultats comparables) et convergent (valeurs limites de convergence des algorithmes). Les bruits gaussiens réels sont des cas intermédiaires de ces bruits. Nous évalueront dans ce cas la part de bruit VD et la part de bruit MD.

3.2 Coefficient de corrélation spatiale ρ .

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 ($\rho_{\text{inter classe}} = \rho_{\text{intra classe}}$).

Dans les cas réels, les valeurs de ρ diffèrent dans les quatre directions : nous avons constaté que la valeur du coefficient le plus élevé avait une influence sur la taille optimale de F .



4. Estimation des paramètres "amont" par un algorithme contextuel.

Pour estimer les valeurs de $h, \rho, (\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$, nous utilisons la méthode SEM contextuelle ([2]). Cet algorithme évalue correctement le facteur $\rho_{\text{intra classe}}$ et les paramètres du bruit mais estime mal le paramètre h . Il apparaît ainsi pertinent, au vu des résultats expérimentaux sur différentes homogénéités, d'apporter un correctif à la valeur estimée. Nous utilisons l'algorithme SEM contextuel stationnaire étant donné que nous ne disposons pas au préalable d'informations sur les paramètres "amont" qui déterminent la taille de la fenêtre (un algorithme contextuel non stationnaire augmente d'autre part le temps de calcul). Le tableau ci-dessous compare les valeurs estimées du coefficient de corrélation avec ses vraies valeurs, calculées sur des images d'homogénéités diverses.

tab1 : estimation de ρ .

	$h=0,3$	$h=0,5$	$h=0,7$	$h=0,9$
$\rho=0$	0,02	0,01	0,03	0,05
$\rho=0,7$	0,71	0,70	0,6	0,8
$\rho=0,9$	0,90	0,89	0,91	0,98

Bruit VD : $(\mu_1, \sigma_1) = (1,1)$; $(\mu_2, \sigma_2) = (1,2)$

tab2 : estimation de ρ .

	$h=0,3$	$h=0,5$	$h=0,7$	$h=0,9$
$\rho=0$	0,03	0,08	0,15	0,20
$\rho=0,7$	0,60	0,60	0,61	0,70
$\rho=0,9$	0,80	0,81	0,82	0,90

Bruit MD : $(\mu_1, \sigma_1) = (1,1)$; $(\mu_2, \sigma_2) = (2,1)$

5. Etude de l'effet des paramètres $h, \rho, (\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$ sur la fenêtre de stationnarité de l'algorithme aveugle adaptatif.

Les dimensions de la fenêtre de stationnarité dépendent des valeurs de h, ρ et $(\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$. Nous avons déterminé la taille de la fenêtre qui assure la meilleure segmentation pour la méthode ICE aveugle non stationnaire. Les tests montrent que :

- i) lorsque la corrélation augmente, la taille de la fenêtre augmente.
- ii) lorsque l'homogénéité augmente, la taille de la fenêtre diminue.

Le tableau 3 indique, pour différentes valeurs de h, ρ et dans le cas du bruit MD, la dimension de F.

tab 3 : dimension de la fenêtre de stationnarité.

	$h=0,3$	$h=0,4$	$h=0,5$	$h=0,6$	$h=0,7$	$h=0,8$	$h=0,9$
$\rho=0$	2*2	2*2	2*2	2*2	2*2	2*2	2*2
$\rho=0,5$	4*4	4*4	4*4	4*4	4*4	4*4	4*4
$\rho=0,7$	5*5	5*5	5*5	5*5	5*5	5*5	5*5
$\rho=0,9$	15*	15*	15*	10*	10*	5*5	5*5

6. Expérimentations et résultats.

Nous effectuons les tests de comparaison sur des images de synthèse (images "vérité-terrain") auxquelles on ajoute des bruits différemment corrélés VD ou MD. Nous simulons des champs de Gibbs de facteur d'homogénéité diverses (ces différentes homogénéités sont obtenues en modifiant le coefficient d'énergie markovienne). Les résultats permettent de définir, dans l'ensemble des paramètres $h, \rho, (\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$ des zones de discrimination des algorithmes locaux et globaux. Les tableaux ci-dessous indiquent quel(s) algorithme(s) s'avère être le plus efficace suivant les valeurs des paramètres caractéristiques (études réalisées sur des images de synthèse à deux classes):

A1 : méthode ICE aveugle non stationnaire et segmentation aveugle.

A2 : méthode ICE globale des champs de Markov et segmentation MPM.

A3 : méthode EM globale des chaînes de Markov et segmentation MPM.

tab 4 : comparaison de A1, A2 et A3

	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0	A1 A2 A3	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3	A2 A3	A2 A3
0,4	A1 A2 A3	A1 A2 A3	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3	A2 A3
0,5	A1	A1	A1 A2 A3	A1 A2 A3	A1 A2	A2	A2
0,7	A1	A1	A1	A1	A1	A2	A2
0,9	A1	A1	A1	A1	A1	A1	A1

bruitage MD : $(\mu_1, \sigma_1) = (1,1)$; $(\mu_2, \sigma_2) = (2,1)$

tab 5 : comparaison de A1, A2 et A3

	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0	A1 A2 A3	A1 A2 A3	A1 A2 A3	A2 A3	A2 A3	A2 A3	A2 A3
0,4	A1 A2 A3	A1 A2	A1 A2 A3	A2	A2	A2	A2
0,5	A1	A1	A1	A1	A1	A2	A2
0,7	A1	A1	A1	A1	A1	A1	A1
0,9	A1	A1	A1	A1	A1	A1	A1

bruitage VD : $(\mu_1, \sigma_1) = (1,1)$; $(\mu_2, \sigma_2) = (1,2)$

Ces résultats nous permettent les commentaires suivants:

1) Ces algorithmes globaux et surtout ceux qui utilisent les chaînes de Markov sont plus sensibles à la corrélation que les algorithmes locaux.

2) Pour de fortes valeurs de corrélation, l'algorithme local adaptatif s'impose.

3) Pour de faibles valeurs de corrélation ($\rho < 0,4$), il y a concurrence entre A1, A2, A3 pour des images faiblement homogènes, les deux derniers s'avérant plus efficaces dans le cas d'image à fortes homogénéités ($h > 0,5$). Dans ce dernier cas, il est alors préférable d'utiliser les chaînes de Markov, en raison de l'extrême rapidité de ces algorithmes (l'échantillonneur de Gibbs



utilisé dans le cas des champs de Markov augmente considérablement le temps de calcul).

4) Pour les valeurs intermédiaires de corrélations ($0,4 \leq \rho \leq 0,7$), le choix se porte sur A2, en ce qui concerne les images fortement homogènes ($h \geq 0,7$), et sur A1 pour les images faiblement homogènes.

5) Nous notons d'autre part, la plus grande sensibilité des algorithmes globaux au bruit VD, dans les cas corrélés, et notamment de ceux fondés sur les chaînes de Markov.

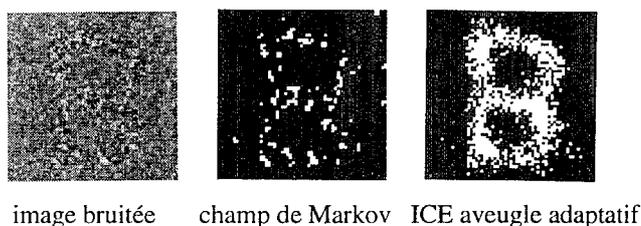
Remarquons qu'en cas d'indécision, le temps de calcul peut permettre de départager les méthodes. Par ordre de rapidité:

$$A1 < A2 < A3.$$

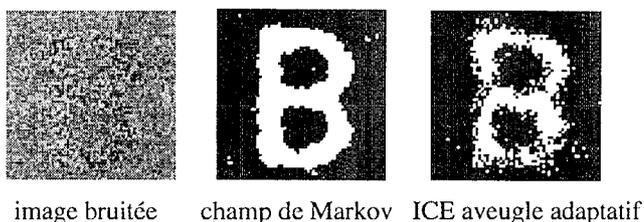
D'autre part, si nous diminuons le rapport signal à bruit, dans le cas MD, ($\mu_2 - \mu_1 = 0,5$), nous constatons une plus grande sensibilité des algorithmes globaux à la corrélation (pour $\rho \geq 0,5$ nous choisiront l'algorithme A1, quel que soit l'homogénéité de l'image).

Le problème reste néanmoins de déterminer avec exactitude, les zones frontières permettant le choix de tel ou tel algorithme, compte tenu de ces premières approches.

Exemples de segmentation d'une image très homogène par deux méthodes de segmentation, suivant différents paramètres caractéristiques :



$$\text{bruit VD : } h = 0,95 ; \rho = 0,67$$



$$\text{bruit VD : } h = 0,95 ; \rho = 0,4$$

7. Conclusions.

Les résultats présentés mettent en lumière la possibilité de discriminer les différents algorithmes selon les valeurs des paramètres caractéristiques, la difficulté étant de bien cerner les zones frontières. D'autre part, les tableaux précédents montrent que dans de nombreux cas, le type de bruit n'intervient pas dans le choix de l'algorithme. Pour les autres cas (forte homogénéité et facteur de corrélation de l'ordre de 0,7: A1 s'avère plus efficace dans le cas VD tandis que A2 est plus performant dans le cas MD), une étude plus fine permettrait d'identifier les valeurs des moyennes et des variances à partir desquels nous choisiront A1 ou A2.

La question est de savoir si on peut généraliser les remarques précédentes au cas de plusieurs classes. Nous pouvons prévoir qu'une augmentation du nombre de classes induit une diminution du facteur d'homogénéité : les algorithmes locaux adaptatifs pourraient alors s'avérer intéressants. Le principal problème qui se pose pour mener

cette étude correctement est le choix des valeurs des paramètres caractéristiques, en vue de définir les zones "frontières", notamment en ce qui concerne le type de bruitage.

Finalement, notre étude permet de proposer un premier algorithme de choix automatique de la méthode la plus efficace suivant :

(i) estimation de $h, \rho, (\mu_i)_{i=1..K}, (\sigma_i)_{i=1..K}$

(ii) décision si le bruit est VD ou MD à partir des valeurs des moyennes et variances.

(iii) choix parmi A1, A2, A3 à partir de h, ρ et selon tes tableaux tab 4 ou tab 5.

9. Références.

- [1] Braathen B. - Pieczynski W. - Masson P. (1993) - "Global and local methods of unsupervised Bayesian segmentation of images" - Machine Graphics & Vision - Vol. 2, n°1, pp 39-52.
- [2] Peng A. (1992) - "Segmentation statistique non supervisée d'images et détection de contours par filtrage" - Thèse de l'Université Technologique de Compiegne.
- [3] Geman S. - Geman D. (1984) - "Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images" - IEEE Trans. on PAMI - Vol. 6, pp. 721-741.
- [4] Marroquin J. - Mitter S. - Poggio T. (1987) - "Probabilistic solution of ill posed problems in computational vision" - Journal of the American Statistical Association - Vol. 82, pp 76-89.
- [5] Chalmond B. (1989) - "An iterative Gibbsian technique for reconstruction of m-ary images" - Pattern Recognition - Vol. 22, n°6, pp 747-761.
- [6] Pieczynski W. (1994) - "Champs de Markov cachés et Estimation Conditionnelle Itérative" - Traitement du Signal - Vol. 11, n°2, pp 141-153.
- [7] Benmiloud B. - Pieczynski W. (1994) - "Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images" - Soumis à Traitement du Signal.
- [8] Benmiloud B. (1994) - "Chaînes de Markov cachées et Segmentation Statistique Non Supervisée de Séquences d'Images" - Thèse de l'Université de Paris 7.
- [9] Devijver P.A. - Dekesel M. (1988) - "Champs aléatoires de Pickard et modélisation d'images digitales" - Traitement du Signal - Vol. 5, n°5.
- [10] Baum L.E. - Petrie T. - Soules G. - Weiss N. (1970) - "A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains" - Ann. Math. Statistic. - 41, pp. 164-171.