

Segmentation non supervisée d'images par chaîne de Markov couple

Stéphane Derrode¹ et Wojciech Pieczynski²

¹ École Nationale Supérieure de Physique de Marseille,
Groupe Signaux Multidimensionnels, laboratoire Fresnel (UMR 6133),
Domaine universitaire de Saint Jérôme, 13013 Marseille cedex 20, France.
Tél : int+ 33 4 91 28 28 49, Fax : int+ 33 4 91 28 88 13
stephane.derrode@enspm.u-3mrs.fr

² Institut National des Télécommunications,
Département Communications, Images et Traitement de l'Information,
9, rue Charles Fourier, 91011 Evry cedex, France.
Tél : int+ 33 1 60 76 44 25, Fax : int+ 33 1 60 76 44 33
wojciech.pieczynski@int-evry.fr

Résumé Dans ce travail, nous utilisons le modèle récent de « chaîne de Markov couple » pour la segmentation non supervisée d'images. Ce modèle est strictement plus général que le modèle classique de chaîne de Markov cachée. Il permet notamment de mieux prendre en compte les frontières entre les classes, ce qui peut s'avérer d'un grand intérêt pour la segmentation d'images radar. En contre partie, la complexité du modèle est supérieure à celle du modèle classique. La méthode est illustrée et analysée par des résultats comparatifs de segmentation non supervisée obtenus sur des images synthétique et réelle.

Mots clés Chaîne de Markov cachées, Chaîne de Markov couple, Estimation Conditionnelle Iterative, Segmentation non supervisée, Mélanges généralisés, Système de Pearson, Image radar.

1 Introduction

Le champs d'application des modèles de Markov cachés est extrêmement vaste. Dans le domaine du traitement du signal et de l'image, ces modèles ont été exploités sous de nombreuses formes et avec différentes structures spatiales comme des chaînes, des champs ou des arbres [10]. En particulier, les chaînes de Markov cachées ont été utilisées avec succès pour la reconnaissance de caractères manuscrits, la détection de véhicules, ou la segmentation d'images [1,8,6]. Dans ce dernier cas, les images 2D sont préalablement transformées en vecteur 1D grâce au parcours de Hilbert-Peano [14], pour s'adapter à la structure monodimensionnelle d'une chaîne.

Dans ce travail, nous nous intéressons au modèle récent appelé « chaîne de Markov couple » (CMcouple), qui est strictement plus général que le modèle classique de chaîne de Markov cachée (CMC) [11]. Cependant, ce modèle est plus complexe, notamment à cause du plus grand nombre de paramètres nécessaires pour le décrire. Il est donc intéressant de tester et d'analyser son apport par rapport au CMC dans le contexte de la segmentation non supervisée d'images. Ce papier est organisé de la manière suivante. Dans la section 2, nous proposons une présentation synthétique du modèle couple. Par manque d'espace, les algorithmes d'estimation des paramètres ne sont pas détaillés ici¹. Les sections 3 et 4 illustrent le modèle en présentant des résultats comparatifs de segmentation non supervisée d'une image artificielle et d'une image JERS de rizière. Enfin, la conclusion dresse le bilan théorique et expérimental de ce travail et propose quelques perspectives.

2 Présentation du modèle couple

Le succès des CMC est principalement dû au fait que, lorsque le processus caché² \mathbf{X} peut être représenté par une chaîne de Markov finie et lorsque la structure du bruit n'est pas trop complexe, alors \mathbf{X} peut être reconstruit à partir du processus observé³ \mathbf{Y} à l'aide de différents critères bayésiens de classification tels que le MAP (« Maximum A Posteriori ») ou le MPM (« Maximal Posterior Mode »). Ces méthodes de restauration utilisent la distribution du processus caché conditionnellement au processus observé,

$$P(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y}) = \frac{P(\mathbf{X} = \mathbf{x}, \mathbf{Y} = \mathbf{y})}{P(\mathbf{Y} = \mathbf{y})} = \frac{P(\mathbf{Y} = \mathbf{y} | \mathbf{X} = \mathbf{x}) P(\mathbf{X} = \mathbf{x})}{P(\mathbf{Y} = \mathbf{y})} \quad (1)$$

et il est important de noter que $\mathbf{X} | \mathbf{Y}$ doit impérativement être une chaîne de Markov. Or, il existe des distributions simples $P(\mathbf{Y} = \mathbf{y} | \mathbf{X} = \mathbf{x})$ pour lesquelles $P(\mathbf{X} = \mathbf{x})$ est une distribution de Markov et $P(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y})$ n'en est pas une. C'est la raison pour laquelle on introduit généralement l'hypothèse $H_1 : P(Y_n | \mathbf{X} = \mathbf{x}) = P(Y_n | X_n = x_n)$ permettant de conserver la markovianité de $\mathbf{X} | \mathbf{Y}$.

Cette hypothèse peut, dans certains cas, apparaître comme limitative. En effet, l'intérêt des modèles de Markov en segmentation d'images repose principalement sur la prise en compte des dépendances spatiales. Dans la plupart des scènes réelles, il est plus probable que deux pixels

¹ L'estimation des paramètres dans le cadre de la méthode ICE (« Iterative Conditional Estimation ») est présentée dans [11,4,5].

² $\mathbf{X} = (X_1, X_2, \dots, X_N)$, $X_n \in \Omega = \{1, 2, \dots, K\}$ et N représente la longueur de la chaîne.

³ $\mathbf{Y} = (Y_1, Y_2, \dots, Y_N)$, $Y_n \in \mathbb{R}$.




Fig. 1. (a) Image originale et (b) version bruitée (256×256). Le tableau (c) présente les paramètres du bruit. Le bruit est si important qu'il est difficile de distinguer les deux classes dans l'image (b).

voisins appartiennent à la même classe que deux pixels éloignés l'un de l'autre. Cependant, un pixel situé proche d'une frontière entre deux classes peut avoir un aspect visuel différent d'un autre pixel de la même classe mais éloigné de toute frontière. Étant donnée l'hypothèse H_1 , cette situation ne peut pas être prise en compte. C'est la raison essentielle de l'introduction du modèle couple pour lequel on considère directement la markovianité de $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$ (cf. Eq. 1). Dans ce cas, $\mathbf{X}|\mathbf{Y}$ est encore une chaîne de Markov et les critères de restauration bayésiens restent applicables [10]. Le modèle couple permet donc de s'affranchir de l'hypothèse limitative H_1 .

3 Résultats de segmentation sur une image artificielle

Nous présentons maintenant des résultats de segmentation sur une image synthétique avec pour principal objectif de fournir des éléments quantitatifs de comparaison entre les modèles classique et couple. Il s'agit plus spécifiquement de déterminer si le modèle couple peut s'avérer intéressant lorsque le processus observé n'est ni une CMC, ni une CMcouple.

Pour les expériences, nous avons utilisé l'image artificielle de la figure 1(a) qui représente un champ de Gibbs à deux classes. La version dégradée de l'image a été obtenue en appliquant un bruit non Gaussien corrélé, cf. figure 1(b). Plus précisément, nous avons bruité indépendamment les deux classes de l'image originale avec des bruits issus d'une loi gamma et d'une loi gamma inverse ; les paramètres des distributions sont reportés dans le tableau 1(c). Nous avons ensuite appliqué un filtre moyenneur sur l'image de manière à corréliser les deux bruits⁴.

L'image ainsi obtenue a été segmentée en considérant les modèles par chaînes de Markov classique et couple, selon le critère bayésien du MPM. Pour chacun de ces deux modèles, nous avons soit calculé les paramètres à l'aide des données complètes, i.e. la « vérité-terrain » représentée par l'image 1(a), soit estimé les paramètres avec la méthode ICE correspondant au modèle. Le nombre d'itérations ICE a été fixé à 100 et le nombre de réalisations par itération à 1. Pour tous les cas de figure, le mélange a été estimé dans le système de Pearson [9]. Ce système est constitué essentiellement de huit familles de lois mono-modales parmi lesquelles figurent les deux familles dont sont issus les bruits (avant filtrage). Ce système compte également les lois bêta de 1^{re} et de 2^e espèce ainsi que la famille des lois gaussiennes. Il offre ainsi une très large

⁴ Le noyau du filtre utilisé dans cette expérience est : $\frac{1}{5,8} \begin{pmatrix} 0,4 & 0,8 & 0,4 \\ 0,8 & 1 & 0,8 \\ 0,4 & 0,8 & 0,4 \end{pmatrix}$.




Fig. 2. Résultats de segmentation sur l'image de la figure 1. Les courbes blanches représentent les « vraies » frontières de séparation entre les deux classes. Les deux premières images ont été obtenues avec le modèle classique, les deux suivantes avec le modèle couple. Les images (a) et (c) ont été obtenues avec les paramètres calculés à partir de la « vérité-terrain » alors que les images (b) et (d) ont été obtenues avec les paramètres estimés à l'aide de ICE.

variété de formes (lois symétriques ou non, lois à support borné, semi-borné ou infini), et s'est avéré très bien adapté pour la segmentation d'images satellites [2,3].

Les résultats de segmentation sont reportés dans la figure 2. En comparant les taux d'erreur de classification, nous pouvons faire deux remarques. D'une part, les taux d'erreur sont toujours plus importants lorsque les paramètres sont estimés [images (b) et (d)] que lorsqu'ils sont calculés [images (a) et (c)], ce qui est parfaitement justifié en soi. Cependant, pour chaque modèle, nous pouvons constater que les deux taux sont relativement proches, ce qui illustre la très bonne robustesse de ICE dans les deux modèles. D'autre part, il est intéressant de noter que les résultats concernant les CMcouple sont sensiblement meilleurs que ceux correspondants au CMC.

À titre d'exemple, le tableau 1 rapporte les paramètres estimés par ICE dans le cas du modèle couple. Outre les probabilités initiales et la matrice de transition de la chaîne de Markov \mathbf{Z} , nous avons reporté les paramètres des lois sélectionnées pour estimer le mélange. Chacune des $K^2 = 4$ lois bidimensionnelles a été estimées à l'aide de deux lois mono-dimensionnelles par decorrélation (procédé d'orthogonalisation de Gram-Schmidt). On peut remarquer la grande diversité des formes sélectionnées par ICE, à l'intérieur du système de Pearson, pour estimer le mélange.

4 Segmentation d'une image radar

La figure 3 présente les résultats de segmentation d'une image JERS de rizière (Île de Java, Indonésie ; taille : 512×512). L'image originale est principalement caractérisée par deux stades de maturation du riz et par d'autres cultures. Nous avons décidé de segmenter l'image en $K = 4$ classes avec 100 itérations ICE pour chacun des deux modèles. En comparant les résultats de segmentation, il apparaît clairement que le modèle couple offre une segmentation beaucoup plus régulière et que les zones segmentées sont plus homogènes. Le tableau ci-dessous rapporte les coefficients de corrélation des 16 lois 2D. La plupart d'entre eux sont très éloignés de zéro, ce qui est de nature à justifier l'apport du modèle couple par rapport au modèle classique.

Pour terminer la comparaison, il est important de noter que les temps de calcul entre les deux modèles sont assez différents. Le programme basé sur le modèle classique a segmenté

Tab. 1. Paramètres estimés par l'algorithme ICE-couple avec un mélange issu du système de Pearson. $p(i, j)$: probabilités conjointe *a priori* de \mathbf{X} ; $\mu_i, i = 1..4$: moments; β_1 : « skewness » au carré; β_2 : « kurtosis ».

$$p(i, j) = \begin{pmatrix} 0.49 & 0.01 \\ 0.01 & 0.48 \end{pmatrix}$$

$f_{i,j}$	Paramètres du mélange							
	ρ	Distribution	μ_1	μ_2	μ_3	μ_4	β_1	β_2
$f_{0,0}$	0,68	$g_1^{0,0}$ Student't	30,9	1,0	0,2	3,5	0,03	3,54
		$g_2^{0,0}$ Student't	30,2	1,0	0,2	3,5	0,04	3,50
$f_{0,1}$	0,66	$g_1^{0,1}$ Type II	17,2	1,0	0,1	1,8	0,01	1,80
		$g_2^{0,1}$ Beta 1	18,1	1,0	-0,4	2,3	0,15	2,27
$f_{1,0}$	0,65	$g_1^{1,0}$ Beta 1	17,2	1,0	-0,5	2,6	0,25	2,62
		$g_2^{1,0}$ Type II	18,5	1,0	0,0	1,9	0,00	1,94
$f_{1,1}$	0,68	$g_1^{1,1}$ Type IV	37,3	1,0	0,4	3,6	0,19	3,59
		$g_2^{1,1}$ Gamma	37,9	1,0	0,4	3,2	0,13	3,20




Fig. 3. Résultats de segmentation de l'image JERS de rizière (a) à l'aide du modèle classique (b) et du modèle couple (c). Les labels de classe (1, ..., 4) ont été modifiés par la valeur moyenne des niveaux de gris de la classe pour faciliter la comparaison visuelle avec l'image originale.

l'image en 35 minutes, alors que le programme basé sur le modèle couple a pris 2 heures et 40 minutes. Cette différence importante provient essentiellement du fait qu'il est nécessaire d'estimer non pas $K = 4$ lois monodimensionnelles comme dans le modèle classique, mais $2K^2 = 32$ lois à chaque itération ICE.

$\rho(., .)$	ω_1	ω_2	ω_3	ω_4
ω_1	0.36	0.58	0.32	0.57
ω_2	0.53	0.83	0.20	0.19
ω_3	0.41	0.70	0.31	0.45
ω_4	0.37	0.24	0.35	0.33

5 Conclusion

Dans ce travail, nous avons présenté l'application du modèle de « chaîne de Markov couple » pour la segmentation non supervisée d'images. L'originalité du modèle réside dans le fait que le

processus $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$ est directement considéré de Markov, et non plus uniquement le processus \mathbf{X} . Étant donné sa plus grande complexité, il est intéressant d'analyser l'apport du modèle dans le cadre de la segmentation non supervisée d'images radar. De nombreuses expériences, toutes conduites dans le cadre de mélanges généralisés issus du système de Pearson et dont certaines sont présentées dans ce travail, montrent que l'utilisation du modèle couple peut être d'un grand intérêt et améliorer sensiblement les résultats de segmentation. Le modèle couple constitue une alternative intéressante notamment à cause du fait que l'on peut mieux modéliser les lois aux frontières. Cela procure généralement des classes plus homogènes dans l'image segmentée et réduit considérablement le nombre de pixels isolés.

Comme perspective à ce travail, nous pouvons citer l'extension du modèle au cas d'images multi-composantes telles que les images multi-senseurs, multi-temporelles ou multi-fréquences. Ainsi, la corrélation spatiale et la corrélation inter-composantes pourraient être prises en compte en même temps. Une autre direction de recherche concerne le nouveau modèle appelé « chaîne de Markov triplet » [12], lui-même strictement plus général que le modèle couple, et son application à la segmentation non supervisée d'images. Enfin, notons que le modèle de chaînes de Markov cachée a été utilisé comme initialisation au modèle de champs de Markov caché [7]. Nous pouvons envisager d'adapter la même démarche entre les chaînes et les champs couple [13].

Références

1. B. Benmiloud and W. Pieczynski. Estimation des paramètres dans les CMC et segmentation d'images. *Traitement du Signal*, 12(5) :433–454, 1995.
2. Y. Delignon, A. Marzouki, and W. Pieczynski. Estimation of generalized mixture and its application in image segmentation. *IEEE trans. on Image Processing*, 6(10) :1364–1375, 1997.
3. S. Derrode, G. Mercier, and J.M. Lecaillec et R. Garelo. Estimation of sea-ice SAR clutter statistics from Pearson's system of distributions. In *Proc. of the IGARSS'01*, Sydney, Australia, 9-13 July 2001.
4. S. Derrode and W. Pieczynski. SAR image segmentation using generalized pairwise Markov chains. In *Proc. of the SPIE-RS'02*, Crete, Greece, 22-27 September 2002.
5. S. Derrode and W. Pieczynski. Signal and image segmentation using pairwise Markov chains. To appear in *IEEE trans. on Signal Processing*, 2004.
6. A. El-Jacoubi, M. Gilloux, R. Sabourin, and C.Y. Suen. An HMM-based approach for off-line unconstrained handwritten word modeling and recognition. *IEEE trans. on PAMI*, 21(8) :752–760, 1999.
7. R. Fjørtoft, Y. Delignon, W. Pieczynski, M. Sigelle, and F. Tupin. Unsupervised segmentation of radar images using HMC and HMRF. 41(3) :675–686, 2002. *IEEE trans. on Geoscience and Remote Sensing*.
8. N. Giordana and W. Pieczynski. Estimation of generalized multisensor HMC and unsupervised image segmentation. *IEEE trans. on PAMI*, 19(5) :465–475, 1997.
9. N.L. Johnson and S. Kotz. *Continuous univariate distributions, Vol. 1 and 2*. Wiley and Sons, 1994.
10. W. Pieczynski. Modèles de Markov en traitement d'images. *Traitement du Signal*, 2003.
11. W. Pieczynski. Pairwise Markov chains. *IEEE trans. on PAMI*, 25(5) :634–639, 2003.
12. W. Pieczynski, C. Hulard, and T. Veit. Triplet Markov chains in hidden signal restoration. In *Proc. of the SPIE-RS'02*, Crete, Greece, 22-27 September 2002.
13. W. Pieczynski and A.-N. Tebbache. Pairwise Markov random fields and segmentation of textured images. *Machine Graphics & Vision*, 9(3) :705–718, 2000.
14. W. Skarbek. Generalized Hilbert scan in image printing. In R. Klette and W. G. Kropetsh, editors, *Theoretical Foundations of Computer Vision*. Akademie Verlag, Berlin, 1992.