

# Segmentation non-supervisée d'images multispectrales SPOT : application à la cartographie maritime.

J.-N. Provost<sup>(1)</sup>, C. Collet<sup>(1)</sup>, P. Pérez<sup>(2)</sup>, P. Bouthemy<sup>(2)</sup>

(1) Laboratoire GTS (Groupe de Traitement du Signal),

Ecole Navale, Lanvéoc-Poulmic,  
BP 600 - 29240 Brest-Naval France.

email: nom@ecole-navale.fr

(2) IRISA/INRIA, Campus Universitaire de Beaulieu,

35042 Rennes cedex, France.

email: nom@irisa.fr

**Résumé :** Cet article présente une méthode non-supervisée de segmentation d'image SPOT appliquée à la cartographie marine. L'utilisation d'images satellites en zones cotières peut permettre la réalisation automatique de cartes bathymétriques, grâce aux caractéristiques radiométriques de l'onde rétrodiffusée par la mer et/ou le fond marin. L'application visée concerne la cartographie automatique des profondeurs d'eau en zones littorales, pour l'établissement des cartes marines. Les images SPOT multispectrales présentent des corrélations inter-canaux qui dépendent de la classe considérée : cette corrélation sera explicitement modélisée dans l'algorithme de segmentation. Nous nous plaçons dans le cadre d'une modélisation markovienne hiérarchique sur quadarbre, l'estimation des paramètres constituant une étape préalable à l'opération de classification. Des résultats sont présentés sur des images de synthèse et réelles afin de montrer l'efficacité de cette démarche. L'originalité de la méthode proposée réside dans l'estimation non-supervisée des paramètres du modèle, en particulier les paramètres de corrélation inter-canaux pour chaque classe, sur les données multispectrales observées.

**Mots clés :** cartographie, modélisation markovienne, quadarbre, segmentation d'images multispectrales, corrélation.

**Abstract :** *This paper presents an unsupervised image segmentation method applied to maritime cartography. The use of satellite images over coastal areas can improve the automatic production of bathymetric charts, thanks to the radiometric properties of the electromagnetic wave backscattered by the sea or the sea floor. The application of this work concerns the automatic cartography of sea depth in littoral areas, in order to obtain maritime charts. SPOT images present correlations between channels, depending on each considered class: this correlation is explicitly modeled in the segmentation algorithm we propose. We adopt a hierarchical Markovian modeling on a quad-tree, the estimation of the model parameters being a preliminary step of the classification. Results are reported on synthetic and real images: they demonstrate the efficiency of the method. The contribution of this paper relies on the non-supervised estimation of parameters in the case of multispectral correlated data, including the estimation of the correlation coefficients for each considered class.*

**Keywords :** *cartography, Markovian modeling, quad-tree, multispectral image segmentation, correlation.*

## 1 Introduction

Cet article<sup>1</sup> présente une méthode de segmentation non supervisée d'images satellitaires multispectrales appliquée à la cartographie marine. La mise à jour des cartes marines est en effet un problème important pour la navigation. Les méthodes classiques de relevé bathymétrique nécessitent des moyens importants (bâtiments océanographiques), et aboutissent à des mesures fiables mais dont l'acquisition est lente. La méthode proposée dans cet article permet de réduire ces coûts par l'exploitation d'informations fournies par le satellite SPOT. Les données SPOT sont disponibles dans trois bandes spectrales : le canal XS1 (longueurs d'onde de 0,50 à 0,59  $\mu m$ , vert), le canal XS2 (de 0,61 à 0,68  $\mu m$ , rouge), et le canal XS3 (de 0,79 à 0,89  $\mu m$ , proche infrarouge)[1]. Les différents capteurs du satellite mesurent la radiométrie diffusée, c'est-à-dire l'intensité réfléchie par le sol, les nuages, la mer... Plus précisément, pour le problème qui nous intéresse, la mesure radiométrique correspond à une pénétration dans l'eau allant de 25 mètres à quelques centimètres selon la bande passant e du capteur, pour des eaux peu turbides. Nous disposons d'un modèle paramétrique heuristique permettant de déduire, de la radiométrie observée dans les canaux XS1 et XS2, la profondeur d'eau[1].

La plupart des images que nous traitons proviennent de zones isolées (les atolls de l'océan Pacifique), où les campagnes hydrographiques s'avèrent particulièrement coûteuses. Nous avons dans un premier temps développé un algorithme de segmentation permettant d'associer à chaque pixel une classe (nuage, terre, ou mer, cette dernière pouvant être de plus subdivisée en plusieurs classes selon la profondeur d'eau).

La suite de cet article est divisée en quatre sections. La section 2 décrit le modèle de segmentation basé sur la structure du quadarbre, appliquée au cas monospectral. La section 3 étend cet algorithme au cas multispectral, avec une prise en compte de la corrélation inter-canaux. Des résultats de segmentation sont ensuite présentés sur

---

<sup>1</sup> Les auteurs remercient l'EPHOM (Etablissement Principal des Services Hydrographique et Océanographique de la Marine) pour le soutien financier concernant cette étude et la fourniture des images.

des images réelles et de synthèse dans la section 4. La section 5 contient quelques commentaires de conclusion.

## 2 Segmentation monospectrale

De nombreux travaux ont été réalisés depuis une dizaine d'années sur la segmentation d'images en s'appuyant sur une modélisation markovienne. Des modèles de champs de Markov 2D ont été principalement introduits. Afin d'augmenter la robustesse de la segmentation et surtout de diminuer le temps de calcul induit par les algorithmes itératifs d'optimisation associés, des alternatives ont été étudiées. Pour réaliser une segmentation non-supervisée, Giordana *et al.*[2] proposent ainsi une approche basée sur les chaînes de Markov, mais perdent la richesse d'une modélisation 2D. D'autres approches introduisant une modélisation markovienne hiérarchique ont été définies [3][4][5][6], mais leurs coûts calculatoires demeurent élevés dans le cas d'une segmentation impliquant un grand nombre de classes. L'approche développée par Laferté[7] fournit une modélisation markovienne hiérarchique sur un quadarbre, qui permet une remise à jour non-itérative des paramètres du modèle et une segmentation au sens du critère MPM à l'aide d'un algorithme exact non itératif.

Considérons deux ensembles de variables aléatoires :  $X = (X_s)_{s \in S}$  correspond aux classes et  $Y = (Y_s)_{s \in S}$  aux données observées.  $X_s$  prend des valeurs dans l'ensemble des classes :  $\Lambda_e = \{\omega_1, \dots, \omega_K\}$ , tandis que  $Y_s$  est à valeur dans  $\Lambda_o = \{0, \dots, 255\}$  pour notre application.  $X_s$  est localisée sur  $S$ , un ensemble hiérarchique de sites définis sur le quadarbre[7] (voir Figure 1) :  $S = \{S^n\}_{n=0, \dots, R} = \{S^0, \dots, S^R\}$  où  $R + 1$  représente le nombre de niveaux et  $S^R = \{r\}$  est la racine du quadarbre.  $Y$  est défini sur la grille bidimensionnelle de pleine résolution  $S^0$ . Chaque site  $s$  possède un unique parent noté  $s^-$ , et les quatre fils d'un site  $s$  seront notés  $s^+ = \{t : s = t^-\}$  (cf. Figure 1). Par la suite,  $X^n$  désignera pour simplifier  $(X_s)_{s \in S^n}$ .

On suppose que le champ  $X$  est markovien en échelle, *i.e.*,  $P(X^n | X^k, k > n) = P(X^n | X^{n+1})$ , que les probabilités de transition se factorisent selon  $P(X^n | X^{n+1}) = \prod_{s \in S^n} P(X_s | X_{s^-})$ , et que les mesures sont mutuellement indépendantes conditionnellement à l'étiquetage, *i.e.*,  $P(Y | X) = \prod_{s \in S} P(Y_s | X_s)$ .

Donc,  $(X, Y)$  est markovien sur le quadarbre[7] avec  $P(X, Y) = P(X_r) \prod_{s \in S} P(Y_s | X_s) \prod_{s \neq r} P(X_s | X_{s^-})$ . On suppose que les vraisemblances conditionnelles des observations sont des lois Gaussiennes :  $P(Y_s | X_s = \omega_i) = \mathcal{N}(\mu_i, \sigma_i^2)$ .

Afin de réaliser une segmentation non-supervisée, il faut déterminer le nombre de classes  $K$ . Nous proposons d'initialiser l'algorithme avec un majorant du nombre de classes, et ensuite, nous fusionnons les classes qui sont proches (les classes  $i$  et  $j$  sont regroupées si  $\left(\frac{\sigma_i + \sigma_j}{\sigma_i \sigma_j}\right) |\mu_i - \mu_j| < T$  où  $\mu_j$  et  $\sigma_j$  correspondent à la moyenne et l'écart type de la classe  $j$ ). Le seuil  $T$  est choisi empiriquement.

La description du champ markovien nécessite la connaissance des probabilités initiales *a priori*  $\pi_i$  et

des probabilités de transition *a priori* père-fils  $a_{ij}$  :  $\pi_i = P(X_r = \omega_i)$  et  $a_{ij} = P(X_s = \omega_j | X_{s^-} = \omega_i)$ . Le terme d'attache aux données nécessite la connaissance des paramètres  $(\mu_i, \sigma_i^2) \forall i \in \{1, \dots, K\}$ .

Plusieurs itérations sont effectuées en réalisant une passe montante et descendante à chaque itération  $[q]$  sur l'arbre afin de remettre à jour les paramètres :

$$\Phi^{[q]} = \left\{ \left\{ \pi_i^{[q]} \right\}, \left\{ a_{ij}^{[q]} \right\}, \left\{ \mu_i^{[q]} \right\}, \left\{ \sigma_i^{[q]2} \right\} \right\}_{i,j \in \{1, \dots, K\}} \quad (1)$$

Cette remise à jour peut être déterministe (algorithme EM [8]), stochastique (algorithme SEM [9]), hybride (algorithme ECI [10] où l'estimation de  $\{a_{ij}, \pi_i\}$  est déterministe tandis que celle de  $\{\mu_i, \sigma_i\}$  est stochastique). Dans le cas déterministe, la passe descendante permet de calculer  $\xi_s(i) = P[X_s = \omega_i | Y]$ . Dans le cas stochastique, cette passe permet de simuler une réalisation du champ des étiquettes  $X$ . Les résultats obtenus sur des images de synthèse ont permis d'observer le bon comportement de l'étape d'estimation. L'intérêt du SEM [9] sur l'EM [8] est l'étape de simulation qui autorise une initialisation des paramètres moins précise. Le nombre d'itérations (une dizaine) est fixé empiriquement.

La segmentation finale est effectuée selon le critère MPM :

$$\hat{x}_s = \arg \max_{i=1 \dots K} P[X_s = \omega_i | Y] \quad (2)$$

Pour d'autres approches markoviennes [3][5][6], la segmentation MPM est difficile à mettre en œuvre, c'est pourquoi le critère du MAP (Maximum *A Posteriori*) est généralement utilisé. Ce dernier critère est toutefois moins pertinent.

## 3 Segmentation multispectrale

Nous considérons maintenant des images multispectrales :  $\mathbf{Y}_s = (Y_s^{(R)}, Y_s^{(G)}, Y_s^{(B)})$ , où  $R, G$  et  $B$  correspondent aux trois canaux disponibles sur des données SPOT, représentées en fausses couleurs. Nous supposons que la vraisemblance conditionnelle des données est une loi normale vectorielle de la forme :

$$P(\mathbf{Y}_s | X_s = \omega_i) = \frac{1}{(2\pi)^{3/2} \sqrt{\det(\Sigma_i)}} \times \exp \left[ -\frac{1}{2} (\mathbf{Y}_s - M_i)^t \Sigma_i^{-1} (\mathbf{Y}_s - M_i) \right] \quad (3)$$

avec  $M_i$  le vecteur des moyennes et  $\Sigma_i$  la matrice  $3 \times 3$  de covariance de la classe  $i$ .

$$M_i = \begin{bmatrix} \mu_i^{(R)} & \mu_i^{(G)} & \mu_i^{(B)} \end{bmatrix}^t \quad (4)$$

$$\Sigma_i = \begin{bmatrix} \sigma_i^{R2} & \rho_i^{RG} \sigma_i^R \sigma_i^G & \rho_i^{RB} \sigma_i^R \sigma_i^B \\ \rho_i^{RG} \sigma_i^R \sigma_i^G & \sigma_i^{G2} & \rho_i^{GB} \sigma_i^G \sigma_i^B \\ \rho_i^{RB} \sigma_i^R \sigma_i^B & \rho_i^{GB} \sigma_i^G \sigma_i^B & \sigma_i^{B2} \end{bmatrix} \quad (5)$$

La segmentation multispectrale que nous proposons inclut l'estimation des coefficients de corrélation inter-canaux, et ce pour chaque classe. Nous supposons donc

que  $\Sigma_i$  n'est pas diagonale. Dans l'approche stochastique (SEM), qui permet la simulation d'une réalisation selon  $P(X|\mathbf{Y} = \mathbf{y})$ , les coefficients de corrélation sont mis à jour grâce à l'expression suivante :

$$\rho_i^{(C_1, C_2)} = \frac{n_i \sum_{s|\hat{x}_s=\omega_i} y_s^{(C_1)} y_s^{(C_2)} - \prod_{c=C_1, C_2} \sum_{s|\hat{x}_s=\omega_i} y_s^{(c)}}{\sqrt{\left[ n_i \sum_{s|\hat{x}_s=\omega_i} y_s^{(C_1)2} - \left( \sum_{s|\hat{x}_s=\omega_i} y_s^{(C_1)} \right)^2 \right]}} \times \frac{1}{\sqrt{\left[ n_i \sum_{s|\hat{x}_s=\omega_i} y_s^{(C_2)2} - \left( \sum_{s|\hat{x}_s=\omega_i} y_s^{(C_2)} \right)^2 \right]}} \quad (6)$$

avec  $n_i$  le nombre de pixels dans la classe  $i$ , et  $(C_1, C_2) \in \{R, G, B\}^2$  représente un couple de canaux.

L'initialisation des paramètres  $\Phi^{[0]}$  dans le cas multispectral, s'effectue de la manière suivante :

- Les probabilités initiales  $\pi_i^{[0]}$  sont supposées uniformes, donc  $\pi_i^{[0]} = \frac{1}{K}$ .
- Les probabilités de transitions  $a_{ij}^{[0]}$  sont obtenues par  $a_{ii}^{[0]} = \frac{1}{2}$  et  $a_{ij}^{[0]} = \frac{1}{2(K-1)}$  pour  $i \neq j$ .
- Les coefficients de corrélation initiaux sont supposés nuls ( $\Sigma_i$  diagonale) et les moyennes et écart-types sont obtenus par un algorithme des K-moyennes flou [11] (on définit une fonction d'appartenance floue de chaque paramètre à toute classe  $i$  parmi  $K$  pour le calcul des barycentres).

## 4 Résultats

### 4.1 Images de synthèse

Nous avons d'abord testé cet algorithme de segmentation multispectrale sur des images de synthèse de taille  $64 \times 64$  pixels (Figure 2) afin de valider la méthode. Le résultat de la segmentation est de très bonne qualité, et l'estimation des paramètres (y compris les coefficients de corrélation) est robuste (cf. Table 1). L'algorithme a été initialisé avec 10 classes, et 5 classes sont obtenues finalement. La mise à jour des paramètres s'est fait de manière stochastique, tant pour les termes d'attache aux données (estimateur MV) que pour ceux du modèle markovien.

### 4.2 Images réelles

Nous avons validé l'algorithme sur des images réelles SPOT. Les tests (Figure 3) ont porté sur des images multispectrales de taille  $256 \times 256$  pixels. Le nombre initial de classes est 10, et le nombre résultant est 6. La mise à jour des paramètres est faite de manière stochastique (SEM). Nous n'avons pas pour cette image de vérité terrain, seule la vérité "expert" est disponible et est conforme à la segmentation obtenue.

## 5 Conclusion

Cet article s'intéresse au délicat problème de la segmentation non-supervisée d'images multispectrales corrélées. Un algorithme de segmentation basé sur une modélisation markovienne hiérarchique (quadarbre) a été présenté et fournit des résultats très encourageants. Cette méthode conserve le caractère spatial (2D) de l'information (ce qui n'est pas le cas d'une modélisation par chaîne de Markov [2]) et est plus rapide que des techniques classiques basées sur les champs de Markov spatiaux, mais plus lent et nécessitant d'avantage d'espace mémoire que celui introduit dans [2]. L'approche proposée ne nécessite pas de procédé itératif pour la mise à jour des paramètres. Dans notre application, la modélisation par quadarbre est particulièrement intéressante, car elle permet de travailler sur une partie seulement de l'image, alors que la technique des chaînes de Markov [2] requiert la considération de l'image entière (observations sans trous). Cela permettra ultérieurement d'isoler les zones de terre afin d'estimer la bathymétrie uniquement sur les zones de mer.

La contribution de ce travail a consisté à étendre au cas multispectral les algorithmes existants, en prenant en compte la corrélation entre canaux pour chaque classe sur des images réelles.

## References

- [1] L. LOUBERSAC, P.Y. BURBAN, O. LEMAIRE, H. VARET, and F. CHENON. Integrated study of Aitutaki's lagoon (Cook islands) using Spot satellite data in situ measurements: bathymetric modelling. *Geocarto International* (2), pages 31–37, 1991.
- [2] N. GIORDANA and W. PIECZYNSKI. Estimation of generalized multisensor hidden Markov chains and unsupervised image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5):465–475, 1997.
- [3] P. PÉREZ. *Champs markoviens et analyse multirésolution de l'image : application à l'analyse du mouvement*. Thèse, Université de Rennes I, juillet 1993.
- [4] F. HEITZ, P. PÉREZ, and P. BOUTHEMY. Multiscale minimisation of global energy functions in some visual recovery problems. In *Computer Vision Graph. and Image Proces. : Image Understanding*, volume 59, pages 125–134, January 1994.
- [5] Z. KATO, M. BERTHOD, and J. ZERUBIA. A hierarchical Markov random field model and multitemperature annealing for parallel image classification. *Graphical Models and Image Processing*, 58(1):18–37, 1996.
- [6] M. MIGNOTTE, C. COLLET, P. PÉREZ, and P. BOUTHEMY. Unsupervised Markovian segmentation of sonar images. In *Proc. ICASSP*, volume 4, pages 2781–2785, Munchen, May 1997.
- [7] J.M. LAFERTÉ, F. HEITZ, and P. PÉREZ. Modèles markoviens d'images et algorithmes d'estimation non linéaire sur le quadarbre. *Traitement du signal*, 15(3):213–230, 1998.
- [8] G. CELEUX and J. DIEBOLT. A random imputation principle: the stochastic EM algorithm. *Rapport de recherche INRIA*, (901):1–19, septembre 1988.
- [9] G. CELEUX and J. DIEBOLT. L'algorithme SEM : un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités. *Revue de statistiques appliquées*, 34(2):35–52, 1986.
- [10] W. PIECZYNSKI. Champs de markov cachés et estimation conditionnelle itérative. *Traitement du signal*, 11(numéro 2):141–153, 1994.
- [11] P. ROSTAING, J.N. PROVOST, and C. COLLET. Unsupervised multispectral image segmentation using generalized gaussian

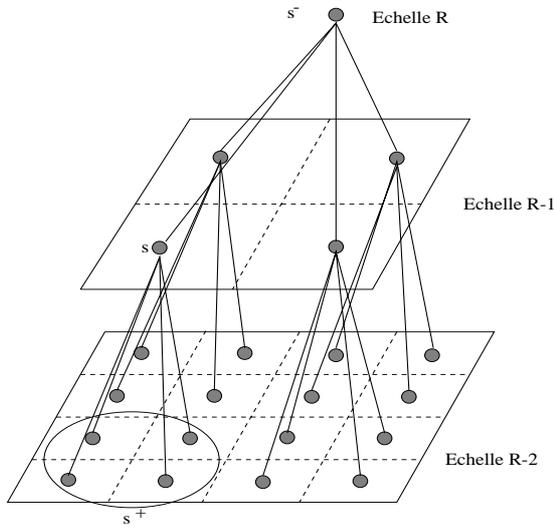


Figure 1: La structure du quadarbre et ses notations.

Classe		1	2	3	4	5
moyenne théorique	R	210	40	50	100	170
moyenne estimée	R	210,4	40,0	49,9	100,1	169,8
moyenne théorique	G	110	90	60	100	200
moyenne estimée	G	109,3	90,1	60,4	99,9	198,1
moyenne théorique	B	210	100	150	30	70
moyenne estimée	B	208,6	99,2	149,3	29,1	68,5
écart type théorique	R	12	5	10	10	20
écart type estimée	R	11,0	5,0	10,0	10,8	18,9
écart type théorique	G	18	9	11	20	15
écart type estimée	G	16,4	9,0	11,1	19,2	14,0
écart type théorique	B	10	15	12	7	9
écart type estimée	B	10,6	14,9	12,1	7,2	8,6
corrélacion théorique	RG	0,4	-0,1	0,2	0	0,5
corrélacion estimée	RG	0,31	-0,16	0,22	-0,05	0,44
corrélacion théorique	RB	-0,3	0,5	0,4	-0,5	0,6
corrélacion estimée	RB	-0,44	0,48	0,31	-0,6	0,53
corrélacion théorique	GB	0,2	0,7	0,8	0,7	0,7
corrélacion estimée	GB	0,12	0,68	0,80	0,66	0,66

Table 1: Paramètres réels et estimés pour l'image de synthèse multispectrale de la figure 2.

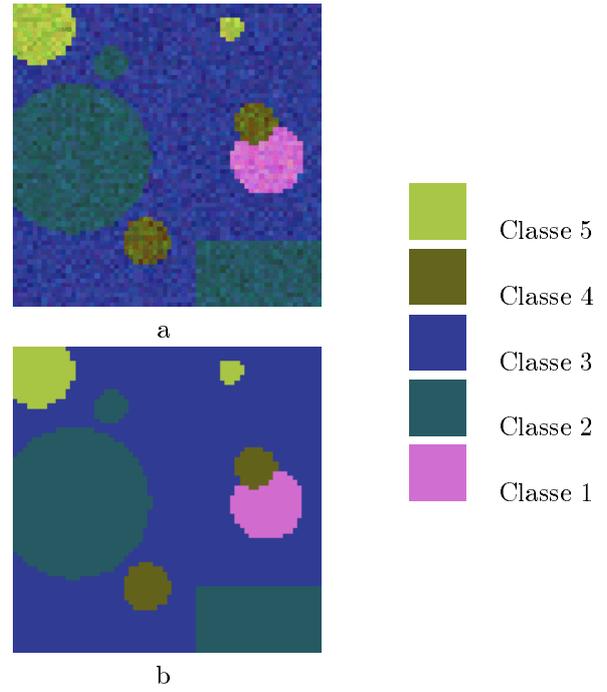


Figure 2: Segmentation sur une image synthétique 64x64, comprenant 5 classes. (a) image bruitée (b) classification obtenue

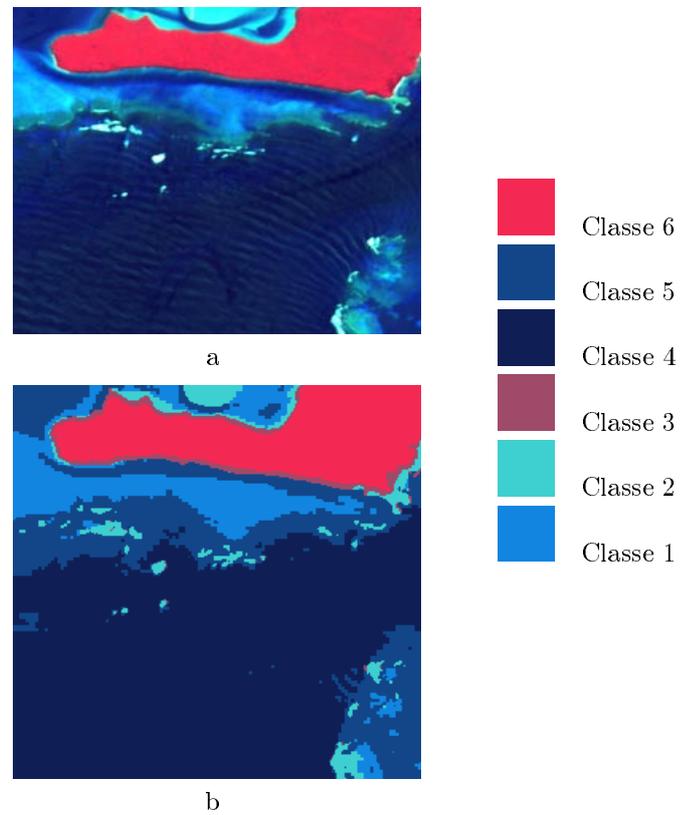


Figure 3: a: Image SPOT (256x256 pixels) b: Image Segmentée. L'algorithme a bien isolé la zone de terre (classe 6). Différentes zones de mer sont obtenues et la classe 4 a gommé l'effet des vagues.