

Segmentation bathymétrique d'images multispectrales SPOT

Bathymetric segmentation of multispectral SPOT images

par C. COLLET[‡], J.N. PROVOST[‡], P. ROSTAING[‡], P. PÉREZ^{*}, P. BOUTHEMY^{*}

■ École navale/Irenav – BP 600 – 29240 Brest Navale provost@ecole-navale.fr

‡ Université de Bretagne Occidentale, 6 av le Gorgeu – BP 809 – 29285 Brest Cedex. christophe.collet@univ-brest.fr

* IRISA/INRIA, Campus Universitaire de Beaulieu, 35042 Rennes, France, nom@irisa.fr

résumé et mots clés

Cet article présente la segmentation des images multispectrales SPOT pour la mise à jour des cartes marines et le contrôle d'informations nautiques. La segmentation des images multispectrales est réalisée en deux étapes grâce à une première modélisation par chaîne de Markov, puis une seconde par champ de Markov hiérarchique. Elle inclut l'estimation automatique des paramètres du modèle ainsi que l'identification des paramètres du bruit dans le contexte de l'estimation de mélange de lois généralisé. Un modèle d'inversion bathymétrique adaptatif est ensuite proposé et validé sur des images réelles, pour lesquelles on dispose de points de contrôle correspondant à des mesures bathymétriques réalisées *in situ* dans le cadre de campagnes hydrographiques.

Mots-clés : images multispectrales SPOT, segmentation, estimation, bathymétrie, modèle markovien

abstract and key words

This paper addresses the analysis of multispectral SPOT images in order to update nautical charts and to control nautical data. We have developed a segmentation approach based on two Markovian modeling steps. The first one is based on Markov chain (1D) modeling, whereas the second step involves a hierarchical process, Markovian in scale. Each of them includes the unsupervised estimation of the parameters. The model parameters are automatically calibrated whereas the noise parameters are estimated in the context of generalized distribution mixtures. An adaptive bathymetric inversion model is then derived in order to recover the water depth near the coasts. This bathymetric estimation has been validated on real data, for which control points are available that correspond to bathymetric measures supplied by previous hydrographic campaigns.

Key-words : multispectral SPOT images, segmentation, estimation, hydrography, Markovian modeling

1. introduction

L'hydrographie peut être définie par ses objectifs qui sont la détermination de la topographie du fond de la mer, son rattachement géodésique aux masses émergées, la caractérisation physique et dynamique de l'eau de mer. L'extraction de la topographie sous-marine et l'identification des dangers pour la navigation font l'objet de campagnes hydrographiques au cours desquelles sont réalisés des levés bathymétriques (profondeur d'eau) permettant l'élaboration de cartes marines. La génération automatique de spatiocartes (cartes de bathymétrie obtenues à partir d'images satellitales) est particulièrement intéressante dans les zones où il n'existe pas ou peu de levés bathymétriques. Depuis les années 80 avec les programmes LANDSAT puis SPOT, les informations spatiales sont considérées comme un complément aux données d'autres origines [23,24,18] et reportées après interprétation avec le graphisme de la cartographie classique.

Que ce soit pour compléter un levé partiel, contrôler une information ponctuelle ou actualiser un renseignement ancien, le traitement des images SPOT peut fournir des éléments de mise à jour. En particulier dans l'océan Indien ou sur les atolls polynésiens de l'océan Pacifique, l'éloignement de ces zones ainsi que le coût de campagnes hydrographiques n'autorisent que des mesures trop parcellaires ou trop ponctuelles pour permettre la publication de cartes marines et invitent le scientifique à rechercher des méthodes plus rapides, plus complètes et moins coûteuses. Dans ce contexte, l'utilisation des images multispectrales fournies par le satellite héliosynchrone SPOT est envisagée afin de réaliser rapidement une couverture cartographique complète de la Polynésie française.

Le satellite SPOT fournit une information dans trois bandes optiques : le canal **XS1** (longueurs d'onde de 0,50 à 0,59 μm , vert), le canal **XS2** (de 0,61 à 0,68 μm , rouge), et le canal **XS3** (de 0,79 à 0,89 μm , proche infrarouge) [22]. Les différents capteurs du satellite mesurent la radiométrie diffusée, c'est-à-dire l'intensité réfléchie par le sol, les nuages, la mer,... Les informations de radiométrie recueillies dans les canaux **XS1** et **XS2** permettent d'identifier des profondeurs d'eau allant respectivement jusqu'à 25-30 mètres et 7-9 mètres dans le cas d'une colonne d'eau non turbide. Le canal **XS3** quant à lui ne pénètre quasiment pas dans l'eau : il fournit néanmoins une information pertinente sur le trait de côte en fonction de la marée. La résolution offerte par le satellite SPOT en mode **XS**, de 20 mètres, permet l'observation de pinacles coralliens (gênants pour la navigation dans l'atoll) affleurant à quelques mètres sous la surface de la mer, les courants dus aux marées (vidange de l'atoll), les phénomènes de houle. Il est donc possible, avec les données SPOT, d'atteindre des échelles de restitution de l'ordre du 1/50.000 compatibles avec la plupart des besoins de navigation.

A la fin des années 80, une étape a été franchie avec l'élaboration de spatiocartes [14, 22] réalisées en particulier par le SHOM, Service Hydrographique et Océanographique de la Marine, faisant explicitement apparaître l'information d'origine spatiale parmi les données provenant de levés hydrographiques classiques, selon le formalisme usuel de la cartographie marine. Depuis le début des années 90, on réalise la production de cartes pour lesquelles l'essentiel de l'information provient de l'interprétation d'images spatiales. C'est en effet l'unique solution possible lorsque les levés classiques sont inexistantes ou trop fragmentaires et que des impératifs économiques ou militaires nécessitent d'hydrographier de vastes zones rapidement. Le géoréférencement des données radiométriques s'effectue sur des points de calage fournis grâce aux infrastructures géodésiques et/ou au système GPS (Global Positioning System), et permet de positionner chaque pixel dans un référentiel terrestre.

Il est tentant d'aller plus loin et, grâce aux progrès du traitement d'images numériques, de proposer des algorithmes de segmentation automatique d'images satellitales sur de vastes zones à hydrographier, pour lesquelles seuls quelques points de levés sont disponibles. Cet aspect est d'autant plus important que la résolution des images allant croissante (programme SPOT 5), il est nécessaire de traiter des quantités de données de plus en plus grandes (échelle 1/25.000). Le traitement automatique de la majeure partie de ces données constitue donc un enjeu important. Trois conditions sont néanmoins à respecter pour la viabilité d'un tel objectif : la transparence de l'eau qui conditionne la pénétration du rayonnement solaire (pratiquement nulle pour des eaux turbides, allant jusqu'à 30 mètres pour des eaux très claires et une mer calme) doit être bonne; la profondeur des fonds doit en conséquence se situer dans l'intervalle 0 – 30 mètres, les zones géographiques ne doivent pas être recouvertes de nuages (comme par exemple la Guyane pour laquelle l'imagerie RADAR à ouverture synthétique [25] est mieux adaptée) puisque le satellite SPOT ne dispose que de capteurs passifs.

Ces conditions sont réalisées dans les atolls du Pacifique où la cartographie de ces vastes lagons est rudimentaire et serait très longue et très coûteuse à réaliser avec des moyens traditionnels en raison de l'éloignement entre ces îles, leur difficulté d'accès, leur nombre et leur superficie¹.

On souhaite donc réaliser une segmentation automatique non supervisée des zones de mer en fonction de la radiométrie observée, puis obtenir une estimation de la bathymétrie en chaque pixel avec un modèle d'inversion paramétrique adaptatif [30].

La deuxième partie de cet article présente la méthode de segmentation retenue pour segmenter l'image en trois zones : mer, terre et nuage. En effet, la présence de nuages sur des zones maritimes occulte certaines portions de l'image pour lesquelles il sera dès lors impossible d'estimer la bathymétrie. Cette pre-

1. Le coût d'un relevé à l'échelle 1/10.000 par deux bâtiments hydrographiques couvrant 1000 km² est *grosso modo* équivalent au traitement de 20.000 km² en analysant une dizaine de scènes SPOT (Sources : SHOM).

mière étape de segmentation s'appuie sur une modélisation statistique de l'image par chaîne de Markov.

La troisième partie concerne la segmentation des zones de mer obtenues à l'étape précédente. On utilise à cet effet une modélisation markovienne sur un graphe hiérarchique de type quadarbre qui présente l'intérêt de permettre une segmentation de zones de mer au sens du critère statistique MPM (Maximum of Posterior Marginals) de manière non-itérative, et donc particulièrement rapide.

Enfin, dans une quatrième partie, nous présenterons le modèle d'inversion bathymétrique adaptatif utilisé et l'estimation des paramètres de ce modèle grâce à une technique de moindres carrés robustes, permettant de ne pas contaminer l'estimation des paramètres du modèle par des mesures aberrantes.

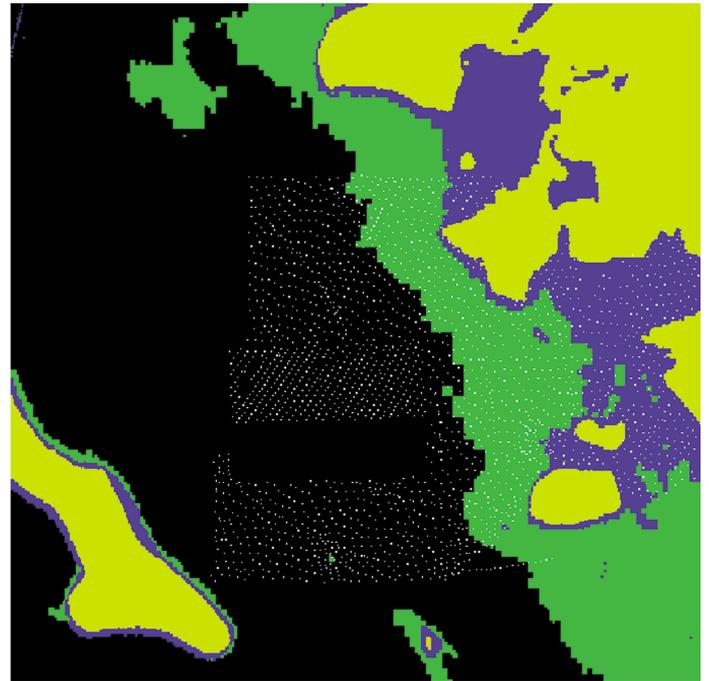
Une cinquième partie présentera les résultats obtenus sur des images réelles et les perspectives de ce travail de recherche.

2. extraction des zones de mer

Il convient de séparer les zones de mer des zones de terre et de nuages afin de pouvoir ultérieurement estimer les paramètres du modèle bathymétrique sur les zones de mer (*cf.* Fig.1a). Cette partie expose la méthode visant à obtenir un masque permettant d'occulter les zones autres que les zones de mer.



(a)



(b)

Figure 1. – (a) Image SPOT originale (512 par 512 pixels) représentée en fausses couleurs. Cette zone se situe en Nouvelle-Calédonie, au nord de la Grande Terre (île de Paaba). (b) Masque (en jaune) occultant les zones de terre et de nuages. Les zones de mer sont regroupées en trois classes représentées en vert, bleu et noir. Les points blancs représentent les mesures de profondeur d'eau réalisées *in situ* par un navire hydrographique. La disposition des mesures est liée au type de navigation du bâtiment (suivi d'un rail sur lequel des mesures sont régulièrement effectuées). L'estimation des paramètres est réalisée ici à l'aide de l'algorithme déterministe EM. Des résultats similaires sont obtenus avec des algorithmes stochastiques SEM et ECI : toutefois ces derniers requièrent une étape de simulation augmentant le temps de calcul et l'espace mémoire nécessaire.

2.1. modélisation par chaîne de Markov

Nous utilisons à cet effet un algorithme de segmentation basé sur un modèle statistique de type « chaîne de Markov » [6, 12, 16, 5]. On considère deux ensembles de variables aléatoires : $X = (X_n)_{n \in S}$ le vecteur des étiquettes, inconnu, à valeur dans $\Delta_{\text{étiquettes}} = \{e_1, e_2\}$ où e_1 désigne l'étiquette « mer » et e_2 correspond à l'étiquette « autre que mer » (*i.e.*, terre, nuage...). $Y = (Y_n)_{n \in S}$ correspond aux observations sur la grille bidimensionnelle régulière S de l'image (radiométrie mesurée en chaque pixel de l'image).

Dans le cas des images SPOT, Y_n est un vecteur (observation multispectrale) de dimension 3 : on notera par convention $Y^{(C)}$ l'image observée sur le canal $C \in \{XS1, XS2, XS3\}$. L'image est transformée en un vecteur grâce à un parcours géométrique de l'image de type fractal, à l'aide d'un scan d'Hilbert-Peano [16],

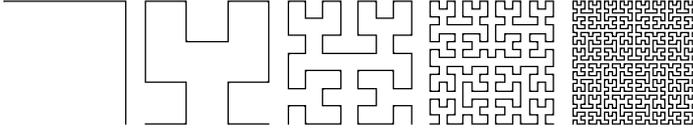


Figure 2. – Parcours fractal d'Hilbert Peano [16] pour des images de taille 2×2 à 32×32 pixels.

présenté sur la figure 2. Ceci permet de conserver partiellement dans le vecteur ainsi formé la notion de voisinage : deux points successifs dans le vecteur correspondent à des pixels voisins dans l'image. Bien évidemment, l'inverse n'est pas vrai. On modélise X comme étant une chaîne de Markov homogène d'ordre 1 :

$$P(X_{n+1} | X_n, \dots, X_1) = P(X_{n+1} | X_n) \quad \forall n \quad (1)$$

La loi de X est alors entièrement définie par la donnée de la probabilité initiale $\pi_{x_1} = P(X_1 = e_i)_{i=\{1,2\}}$ et de la probabilité de transition $a_{x_n x_{n+1}} = P(X_{n+1} = e_j | X_n = e_i)$ qui est indépendante de n dans le cas d'une chaîne de Markov homogène : $a_{x_n x_{n+1}} = a_{ij}$.

On suppose généralement l'indépendance de la probabilité des observations conditionnellement aux étiquettes :

$$\begin{aligned} P(\mathbf{Y} = \mathbf{y} | X = x) &= \prod_{n \in S} P(\mathbf{Y}_n = \mathbf{y}_n | X_n = x_n) \\ &= \prod_{n \in S} f_i(\mathbf{y}_n | X_n = e_i) \end{aligned} \quad (2)$$

Notons que $f_i(\cdot)$ est une loi multidimensionnelle associée à la classe i . Nous avons montré [8] qu'il était possible de segmenter les images multispectrales en utilisant un modèle de bruit gaussien multidimensionnel pour la loi conditionnelle $P(\mathbf{Y}_n | X_n)$ prenant compte explicitement la corrélation existant entre les trois capteurs. La loi jointe de (X, \mathbf{Y}) est donc donnée par :

$$\begin{aligned} P(X_1 = x_1, \dots, X_N = x_N, \mathbf{Y}_1 = \mathbf{y}_1, \dots, \mathbf{Y}_N = \mathbf{y}_N) \\ = \pi_{x_1} \prod_{n=1}^{N-1} a_{x_n x_{n+1}} \prod_{n=1}^N f_i(\mathbf{y}_n | X_n = e_i) \end{aligned} \quad (3)$$

avec $N = \text{Card}(S)$. Nous considérons donc f_i gaussienne, en prenant explicitement en compte la corrélation entre capteurs. L'estimation au sens du critère statistique MPM (Maximum of Posterior Marginals) du vecteur X s'effectue en utilisant l'algorithme de Baum-Devijver [11], qui permet une estimation de la marginale *a posteriori*

$$\xi_n(i) = P(X_n = e_i | \mathbf{Y} = \mathbf{y}) \quad (4)$$

en chaque point. L'estimation \hat{x} de X au sens du MPM s'exprime alors facilement à partir de l'évaluation de la probabilité *a posteriori* de chaque X_n :

$$\begin{aligned} \forall n \in S, \hat{x}_n = e_i &\Leftrightarrow P(X_n = e_i | \mathbf{Y} = \mathbf{y}) \\ &= \max_{e_j \in \Delta_{\text{étiquettes}}} P(X_n = e_j | \mathbf{Y} = \mathbf{y}) \end{aligned} \quad (5)$$

Cette expression est évaluée grâce aux équations (2,3) et (12) et nécessite donc l'estimation des états de la chaîne : la connaissance (et donc l'estimation) des probabilités initiales π_{x_1} notées π_i (Eq. 3 et Eq. 9 ou 13), des matrices de transition $a_{x_n x_{n+1}}$ (Eq. 3 et Eq. 9 ou 13) notées a_{ij} , ainsi que des probabilités d'observation $P(\mathbf{Y}_n | X_n)$ (Eq.2).

2.2. estimation des paramètres

Nous considérons l'estimation non supervisée des paramètres du modèle $\Phi_1 = (\pi_i, a_{ij})$ et du bruit $\Phi_2 = \{\boldsymbol{\mu}_i, \Gamma_i\}$ où $\boldsymbol{\mu}_i$ est la moyenne et Γ_i la matrice de covariance de la loi gaussienne associée à chaque classe i . Plusieurs algorithmes peuvent réaliser une telle estimation :

– L'algorithme EM (« Expectation-Maximization ») proposé par Dempster *et al.* [4], fournit une solution pertinente au délicat problème d'estimation des paramètres au sens du Maximum de Vraisemblance (MV) : $\hat{\Phi} = \arg \max_{\Phi} P(\mathbf{Y} = \mathbf{y} | \Phi)$. Le champ des étiquettes X étant caché, l'algorithme EM considère la maximisation itérative de l'espérance conditionnelle $Q(\Phi | \Phi^{[k]}) = E_{X|\mathbf{Y},\Phi} [\log P(X, \mathbf{Y} | \Phi) | \mathbf{Y} = \mathbf{y}, \Phi^{[k]}]$. On aboutit alors aux formules de réestimation déterministe de l'équation (9).

– On peut utiliser un algorithme de type MCEM [34] (Monte Carlo EM) qui estime l'espérance de Q par une procédure de Monte Carlo en générant p échantillons selon la loi $P(X | \mathbf{Y} = \mathbf{y}, \Phi^{[k]})$: on peut noter que si $p \rightarrow \infty$, alors, en vertu de la loi des grands nombres, on retrouve l'algorithme EM. En introduisant une approximation stochastique, on autorise une descente temporaire de la vraisemblance : il est ainsi possible de s'affranchir des maxima locaux et de l'initialisation. L'algorithme SEM proposé par Céleux et Diebolt [10] peut être vu comme un cas particulier de l'algorithme MCEM où $p = 1$. Comparé à l'algorithme EM, il comporte d'avantage d'aléas dans la mesure où **une** réalisation unique de X est utilisée à l'itération $[k]$. Le principe est de remplacer les espérances Q par $\log P(x^{[k]}, \mathbf{Y} = \mathbf{y} | \Phi^{[k]})$ avec $x^{[k]}$ tiré selon la loi $P(X | \mathbf{Y} = \mathbf{y}, \Phi^{[k]})$ et de remettre à jour les paramètres à partir de cet échantillon (*cf.* équations (7), (8) et (13)). En revanche, l'algorithme SEM ne converge pas et il est nécessaire de choisir un critère d'arrêt [10] : on peut choisir d'arrêter l'algorithme lorsque les paramètres estimés varient peu sur plusieurs itérations, mais on peut également préférer fixer un nombre maximum, assez grand, d'itérations.

– L'algorithme ECI (« Estimation Conditionnelle Itérative ») proposé par Pieczynski [28] permet une estimation de Φ opti-

male au sens de l'erreur quadratique moyenne. Comme les données sont incomplètes, l'estimation directe de Φ est impossible et doit être approchée à l'aide d'un estimateur $\widehat{\Phi}(\mathbf{Y}, X)$ sur données complètes. La meilleure approximation au sens de la minimisation de l'erreur quadratique moyenne est l'estimation conditionnelle par rapport à Y , i.e., $E[\widehat{\Phi}(\mathbf{Y}, x) | \mathbf{Y}]$. Lorsque cette expression n'est pas explicitement calculable, on simule p réalisations de X selon sa loi conditionnelle à $\mathbf{Y} = \mathbf{y}$ afin d'approcher l'espérance conditionnelle par la moyenne empirique en vertu de la loi des grands nombres :

$$\Phi^{[k+1]} = E[\widehat{\Phi}(\mathbf{Y}, X) | \mathbf{Y} = \mathbf{y}, \Phi^{[k]}] \approx \frac{1}{p} \sum_{i=1}^p \Phi^{[k]}(\mathbf{y}, \widehat{x}^i) \quad (6)$$

avec \widehat{x}^i tiré selon $P(X | \mathbf{Y} = \mathbf{y}, \Phi^{[k]})$. On aboutit alors aux formules de réestimation déterministe des équations (7), (8) et (9). Les algorithmes SEM et ECI peuvent être comparés si l'on utilise les mêmes données complètes ($\mathbf{Y} = \mathbf{y}, X = x$) et si l'estimateur choisi dans le cas de l'ECI est l'estimateur MV. Delmas [3] donne des conditions suffisantes pour que les deux algorithmes soient semblables.

Rappelons que le cadre de la procédure ECI est plus général que la procédure EM ou sa version stochastique SEM, et ne nécessite pas d'hypothèse particulière concernant les densités conditionnelles. Il n'existe pas de résultat théorique sur la convergence de la procédure ECI, néanmoins les expériences réalisées montrent son bon comportement asymptotique en général. Si l'on retient l'algorithme ECI en choisissant un seul tirage i.e., $p = 1$ dans l'Eq. 6, on obtient les formules de réestimation suivantes dans le cas gaussien (l'indice d'itération $[k]$ est omis par souci de lisibilité) :

$$\begin{aligned} \mu_i^{[C]} &= \frac{\sum_{n=1}^N \delta(x_n, i) y_n^{(C)}}{\sum_{n=1}^N \delta(x_n, i)} \\ (\sigma_i^{[C]})^2 &= \frac{\sum_{n=1}^N \delta(x_n, i) (y_n^{(C)} - \mu_i^{[C]})^2}{\sum_{n=1}^N \delta(x_n, i)} \end{aligned} \quad (7)$$

où $\delta(\cdot)$ désigne la fonction de Kronecker ; x est un échantillon tiré selon les lois initiales et de transition *a posteriori* (Eq. 11 et Eq. 12). Enfin, le coefficient de corrélation entre deux canaux C_1 et C_2 pour la classe i s'écrit :

$$\begin{aligned} \rho_i^{[C_1, C_2]} &= \frac{\left(\sum_{n=1}^N \delta(x_n, i) \right) \sum_{n=1}^N (\delta(x_n, i) y_n^{(C_1)} y_n^{(C_2)}) - \sum_{n=1}^N (\delta(x_n, i) y_n^{(C_1)}) \sum_{n=1}^N (\delta(x_n, i) y_n^{(C_2)})}{\prod_{c=C_1, C_2} \sqrt{\left[\left(\sum_{n=1}^N \delta(x_n, i) \right) \sum_{n=1}^N (\delta(x_n, i) y_n^{(C)})^2 - \left(\sum_{n=1}^N (\delta(x_n, i) y_n^{(C)}) \right)^2 \right]} \end{aligned} \quad (8)$$

On peut noter que ces expressions sont semblables à celles obtenues dans le cadre de l'algorithme SEM [10]. L'estimation des paramètres $\Phi_1 = (\pi_i, a_{ij})$ de la chaîne s'obtient selon les mêmes expressions que celles de l'algorithme EM [32, 30] :

$$\pi_i^{[k+1]} = \xi_1^{[k]}(i) \quad a_{ij}^{[q+1]} = \frac{\sum_{n=1}^{N-1} \Psi_n^{[k]}(i, j)}{\sum_{n=1}^{N-1} \xi_n^{[k]}(i)} \quad (9)$$

avec $\Psi_n^{[k]}(i, j)$ la probabilité conjointe *a posteriori*

$P[X_n = e_i, X_{n+1} = e_j | \mathbf{Y} = \mathbf{y}, \Phi^{[k]}]$ définie par (en omettant $[k]$)

$$\Psi_n(i, j) = \frac{\alpha_n(i) a_{ij} f_j(y_{n+1}) \beta_{n+1}(j)}{\sum_{l=1}^K \sum_{m=1}^K \alpha_n(l) a_{lm} f_m(y_{n+1}) \beta_{n+1}(m)} \quad (10)$$

où

– K désigne le nombre de classes : dans notre cas $K = 2$;

– $\alpha_n(i) = P[X_n = e_i | \mathbf{Y}_1 = \mathbf{y}_1 \dots \mathbf{Y}_n = \mathbf{y}_n]$ désigne la probabilité « forward » [11] obtenue lors du parcours aller ($X_1 \rightarrow X_N$) sur la chaîne ;

– $\beta_n(i) = \frac{P[\mathbf{Y}_{n+1} = \mathbf{y}_{n+1} \dots \mathbf{Y}_N = \mathbf{y}_N | X_n = e_i]}{P[\mathbf{Y}_{n+1} = \mathbf{y}_{n+1} \dots \mathbf{Y}_N = \mathbf{y}_N | \mathbf{Y}_1 = \mathbf{y}_1 \dots \mathbf{Y}_n = \mathbf{y}_n]}$ désigne la probabilité « backward » [11] obtenue lors du parcours retour ($X_N \rightarrow X_1$) sur la chaîne.

– où $\xi_1(i)$ désigne les probabilités initiales *a posteriori* $P[X_1 = e_i | \mathbf{Y}_1 = \mathbf{y}_1 \dots \mathbf{Y}_N = \mathbf{y}_N]$ qui s'expriment par

$$\xi_n(i) = \alpha_n(i) \beta_n(i) \text{ avec } n = 1. \quad (11)$$

Les probabilités de transition *a posteriori* sont quant à elles définies par

$$\begin{aligned} P[X_{n+1} = e_j | X_n = e_i, \mathbf{Y}_{n+1} = \mathbf{y}_{n+1} \dots \mathbf{Y}_N = \mathbf{y}_N] \\ = \frac{a_{ij} f_j(\mathbf{y}_{n+1} | X_{n+1} = e_j) \beta_{n+1}(j)}{\sum_{k=1}^{K-2} a_{ik} f_k(\mathbf{y}_{n+1} | X_{n+1} = e_k) \beta_{n+1}(k)} \end{aligned} \quad (12)$$

On peut préférer à l'estimation déterministe des paramètres *a priori* (équation (9)) utilisée par les algorithmes ECI et EM, les formules d'estimation stochastique de l'algorithme SEM :

$$\pi_i^{[k+1]} = \delta(x_1, i) \quad a_{ij}^{[k+1]} = \frac{\sum_{n=2}^N \delta(x_{n-1}, i) \delta(x_n, j)}{\sum_{n=2}^N \delta(x_{n-1}, i)} \quad (13)$$

On obtient alors, après plusieurs itérations nécessaires à la stabilisation des paramètres, la loi *a posteriori* $P(X_n | \mathbf{Y} = \mathbf{y}) \forall n$. Enfin, si l'on utilise l'algorithme EM, les formules de réestimation des paramètres *a priori* sont données par l'équation (9) et celles des paramètres du bruit sont obtenues en remplaçant $\delta(x_n, i)$ par $\xi_n(i)$ dans les équations (7) et (8).

2.3. algorithme MPM

On maximise en chaque point de la chaîne la probabilité *a posteriori* (cf. Eq. 5 et 11) :

$$\begin{aligned} \hat{x}_n &= \arg \max_{e_i \in \Delta_{\text{étiquettes}}} P(X_n = e_i | \mathbf{Y} = \mathbf{y}) \\ &= \arg \max_{i \in \{1,2\}} \xi_n(i) = \arg \max_{i \in \{1,2\}} \alpha_n(i) \beta_n(i) \end{aligned} \quad (14)$$

et, par une opération de balayage inverse, on génère l'image segmentée \hat{x} . Cette image constitue le masque permettant de ne travailler désormais que sur les zones de mer pour y extraire l'information bathymétrique (cf. Fig.1b). La modélisation par chaîne de Markov est un modèle *ad hoc* pour extraire les zones de mer. En ce qui concerne la segmentation bathymétrique des zones de mer retenues lors de cette première étape, nous proposons au paragraphe suivant une approche markovienne en échelle qui permettra en outre de s'affranchir de l'absence d'observations sur les sites précédemment masqués.

3. segmentation des zones de mer

On s'intéresse désormais aux sites $s \in S$ tels que $x_s = e_1$. Sur chacun d'eux, on observe une radiométrie \mathbf{y}_s dans les trois bandes spectrales **XS1**, **XS2** et **XS3**. L'exploitation du canal infrarouge **XS3**, qui a permis d'isoler les terres émergées et de déterminer le trait de côte, n'est plus utile à ce stade car sa pénétration dans la colonne d'eau est quasi-nulle. En revanche, le rayonnement solaire est absorbé sélectivement pour les deux autres canaux :

– pour le canal **XS1**, la pénétration dans la colonne d'eau atteint 25 à 30 mètres dans le cas d'une mer calme et d'eau très peu turbide (atoll de la Polynésie française par exemple) ;

– pour le canal **XS2** et sous les mêmes hypothèses, la pénétration du rayonnement solaire atteint 7 à 9 mètres. L'amplitude radiométrique observée dépend bien évidemment de la nature des fonds lorsque ceux-ci sont inférieurs à la profondeur de pénétration du rayonnement solaire dans la colonne d'eau. Le problème est alors délicat car la composition du fond marin influence la radiométrie observée.

Notre approche consiste à segmenter l'image radiométrique bi-spectrale (canaux **XS1** et **XS2**) en classes homogènes, à l'aide d'une modélisation markovienne. Devant la complexité et la généralité du problème, plusieurs alternatives [17] sont possibles pour modéliser la loi conjointe $P(X, \mathbf{Y})$: des modélisations par chaîne (cf. paragraphe 2.1 et [12, 28, 16]), par champ de Markov [15, 29, 33] ou arbres de Markov [21, 9, 2, 31]. Les algorithmes utilisant les modèles markoviens classiques (champs de Markov) sont non causaux, ce qui implique des algorithmes d'estimation itératifs. Cela augmente le temps de calcul de manière très importante, surtout lorsque le nombre de classes est grand. Nous avons considéré la prise en compte de graphes hiérarchiques tels les graphes pyramidaux de Bouman [1] ou Kato [20]. Ce dernier modèle appartient à la classe des modèles markoviens 3D où le champ markovien est défini sur une pyramide de sites comprenant des interactions inter et intra-niveaux. Ces approches augmentent généralement la robustesse de la segmentation, au prix d'un coût calculatoire élevé. Un autre modèle hiérarchique est la structure d'arbre dans laquelle le graphe adopté est un graphe connexe sans cycle [21] dont le représentant le plus simple est le quadarbre. Son absence de cycle conduit à des algorithmes d'estimation non itératifs et donc particulièrement rapides. Elle s'adapte par ailleurs naturellement aux « trous » générés par le masque de segmentation « mer » / « autre que mer ». C'est donc cette dernière approche que nous avons retenue pour les zones de mer.

3.1. modélisation markovienne sur graphe hiérarchique

Un graphe $G = (S, L)$ est formé par un ensemble S de sommets (ou nœuds) et un ensemble L d'arêtes reliant les sommets entre eux. On considère le processus X indicé par les sommets du graphe G markovien. Le quadarbre est un type particulier de graphe ne contenant pas de cycles, partitionné en échelles, dans lequel chaque nœud fils possède un et un seul nœud père :

$$X = \{X^n\}_{n=0}^R \text{ avec } X^n = \{X_s, s \in S^n\} \quad (15)$$

où X_s est à valeur dans $\Delta_{\text{étiquettes}} = \{\omega_1, \dots, \omega_K\}$, K désignant le nombre de classes, et S^n désigne les sommets de l'arbre à l'échelle n ($n = 0$ désigne l'échelle la plus fine $S^0 = S$, et $n = R$ la racine). Le nombre de classes peut être fixé arbitraire-

ment ou estimé à partir d'un majorant fourni par l'application [13, 7]. L'hypothèse fondamentale consiste à supposer le processus markovien en échelle, *i.e.*,

$$P(X^n | X^k, k > n) = P(X^n | X^{n+1}) \quad (16)$$

On fait généralement l'hypothèse que les probabilités de transition inter-échelles se factorisent de la façon suivante (s^- désigne l'unique père d'un site s comme illustré à la Fig. 3) :

$$P(X^n | X^{n+1}) = \prod_{s \in S^n} P(X_s | X_{s^-}) \quad (17)$$

et que d'autre part la dépendance ponctuelle du champ des observations \mathbf{Y} par rapport à X s'écrit

$$P(\mathbf{Y} | X) = \prod_{n=0}^R P(\mathbf{Y}^n | X^n) = \prod_{n=0}^R \prod_{s \in S^n} f_i^n(\mathbf{Y}_s | X_s = \omega_i) \quad (18)$$

où f_i^n décrit la vraisemblance des observations à l'échelle n . A partir de ces hypothèses, on en déduit facilement que la loi jointe $P(X, \mathbf{Y})$ suit une loi gibbsienne d'expression générale

$$P(X, \mathbf{Y}) = \prod_{s \in S} P(\mathbf{Y}_s | X_s) P(X_r) \prod_{s \in >r} P(X_s | X_{s^-}) \\ = \exp \left\{ \sum_{n=0}^R \sum_{s \in S^n} \log f_i^n(\mathbf{Y}_s | X_s) + \log P(X_r) + \sum_{s \in >r} \log P(X_s | X_{s^-}) \right\} \quad (19)$$

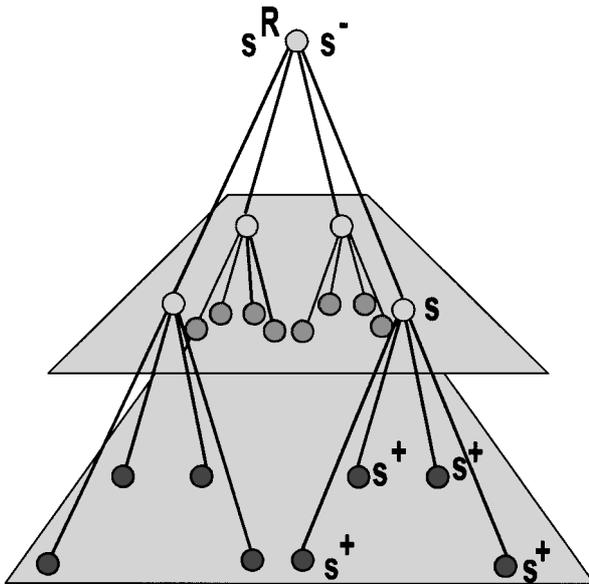


Figure 3. – Graphique hiérarchique de type quadarbre. s^r désigne la racine de l'arbre, s^+ désigne les fils de s tandis que s^- désigne l'unique père de s . On note $>r$ tous les descendants de la racine.

où l'expression $>r$ désigne les descendants de la racine r . L'intérêt de cette modélisation réside dans la possibilité de calculer analytiquement les marginales *a posteriori* $P(X_s | \mathbf{Y} = \mathbf{y})$ en chaque nœud s . Dans le cadre de notre application, les seules données observables sont disponibles au niveau le plus fin ($n = 0$) : lorsqu'aucune observation n'existe ($n > 0$) ou lorsque la radiométrie ne correspond pas à une zone classée « mer » ($s \in S^0$ et $x_s = e_2$ (cf. paragraphe 2.1.)) on prendra une vraisemblance aux observations égale à un. L'algorithme consiste en deux passes (montante puis descendante) et permet d'obtenir de manière exacte et non itérative le mode de la marginale *a posteriori* sur le quadarbre [21, 30].

$$\hat{x}_s = \arg \max_{\omega_i \in \Delta_{\text{étiquettes}}} P(X_s = \omega_i | \mathbf{Y} = \mathbf{y}) \quad (20)$$

3.2. estimation des paramètres

La modélisation markovienne sur le quadarbre nécessite l'estimation des paramètres du modèle : $a_{ij} = P(X_s = \omega_j | X_{s^-} = \omega_i)$ et $\pi_i = P(X_r = \omega_i)$. La vraisemblance des observations est exprimée par $f_i^0(\mathbf{Y}_s = \mathbf{y}_s | X_s = \omega_i)$ puisque les seules observations disponibles sont sur les feuilles de l'arbre dans notre cas. Différents modèles de bruit peuvent être utilisés [16, 31] : nous retenons le modèle gaussien. L'estimation des paramètres peut s'effectuer à nouveau en utilisant l'algorithme EM.

La maximisation de l'espérance conditionnelle

$$E[\log P(X, \mathbf{Y} | \Phi) | \mathbf{Y}, \Phi^{[k]}]$$

aboutit alors aux relations déterministes suivantes :

$$\mu_i^{[k](C)} = \frac{\sum_{s \in S^0} y_s^{(C)} \times \xi_s^{[k]}(i)}{\sum_{s \in S^0} \xi_s^{[k]}(i)} \quad (21) \\ \sigma_i^{[k](C)^2} = \frac{\sum_{s \in S^0} (y_s^{(C)} - \mu_i^{[k](C)})^2 \times \xi_s^{[k]}(i)}{\sum_{s \in S^0} \xi_s^{[k]}(i)}$$

$\forall C \in \{\text{XS1}, \text{XS2}\}$ et

$$\rho_i^{[k]} = \frac{\left(\sum_{s \in S^0} \xi_s^{[k]}(i) \sum_{s \in S^0} (\xi_s^{[k]}(i) y_s^{(\text{XS1})} y_s^{(\text{XS2})}) - \sum_{s \in S^0} (\xi_s^{[k]}(i) y_s^{(\text{XS1})}) \sum_{s \in S^0} (\xi_s^{[k]}(i) y_s^{(\text{XS2})}) \right)}{\prod_{C=\text{XS1}, \text{XS2}} \sqrt{\left[\left(\sum_{s \in S^0} \xi_s^{[k]}(i) \right) \sum_{s \in S^0} (\xi_s^{[k]}(i) y_s^{(C)^2}) - \left(\sum_{s \in S^0} (\xi_s^{[k]}(i) y_s^{(C)}) \right)^2 \right]}}$$

avec

$$\xi_s^{[k]}(i) = P(X_s = \omega_i | \mathbf{Y} = \mathbf{y}, \Phi^{[k]})$$

et $\Psi_s^{[k]}(i, j) = P(X_s = \omega_j, X_{s^-} = \omega_i | \mathbf{Y} = \mathbf{y}, \Phi^{[k]})$.

Enfin,

$$a_{ij}^{[k]} = \frac{\sum_{s \in >r} \Psi_s^{[k]}(i, j)}{\sum_{s \in >r} \xi_{s^-}^{[k]}(i)} \quad \pi_i^{[k]} = \xi_r^{[k]}(i) \quad (23)$$

L'algorithme SEM réalise une simulation x de X selon la loi $P[X|\mathbf{Y} = \mathbf{y}, \Phi^{[k]}]$ dans la passe descendante. On démontre [30] les formules suivantes pour la remise à jour stochastique des paramètres des lois conditionnelles :

$$\mu_i^{[k](C)} = \frac{\sum_{s \in S^0} \left(y_s^{(C)} \times \delta(x_s, i) \right)}{\sum_{s \in S^0} \delta(x_s, i)} \quad (24)$$

$$\sigma_i^{[k](C)^2} = \frac{\sum_{s \in S^0} \left[\left(y_s^{(C)} - \mu_i^{[k](C)} \right)^2 \times \delta(x_s, i) \right]}{\sum_{s \in S^0} \delta(x_s, i)}$$

$\forall C \in \{\mathbf{XS1}, \mathbf{XS2}\}$ et l'estimation de $\rho_i^{[k]}$ s'effectue en utilisant l'équation (22) dans laquelle on substitue $\xi_s^{[k]}(i)$ par $\delta(x_s, i)$. Les formules de réestimation stochastique des paramètres du modèle ont pour expression dans ce cas :

$$a_{ij}^{[k]} = \frac{\sum_{s \in >r} \delta(x_{s^-}, i) \delta(x_s, j)}{\sum_{s \in >r} \delta(x_{s^-}, i)} \quad \pi_i^{[k]} = \delta(x_r, i). \quad (25)$$

L'algorithme ECI effectue quant à lui une estimation déterministe des paramètres *a priori* : les formules de réestimation sont donc semblables à celles obtenues avec l'algorithme EM (équation (23)). Les paramètres du bruit sont estimés de manière stochastique en moyennant les expressions de l'équation (24) sur les p champs simulés.

La segmentation obtenue sur la figure 1b est issue d'un algorithme d'estimation EM sur le quadarbre. Des résultats similaires sont obtenus avec les algorithmes stochastiques SEM et ECI ; toutefois, ces derniers requièrent une étape de simulation augmentant le temps de calcul et l'espace mémoire nécessaire.

4. modèle d'inversion bathymétrique adaptatif

Il existe différents modèles permettant de relier la radiométrie observée et l'information bathymétrique ; on peut néanmoins les

regrouper en deux approches. Une première approche consiste, à l'aide de la connaissance de l'ensemble des paramètres régissant le modèle de diffusion radiométrique (réflexion spéculaire de surface, turbidité, coefficient de réflexion du fond, transmittance de l'atmosphère,...), à définir le modèle de propagation des ondes radiométriques dans les canaux **XS1** et **XS2**. Cette approche présente néanmoins deux défauts : le modèle comporte près d'une vingtaine de paramètres et ces paramètres sont généralement inconnus, ce qui conduit à les postuler constants sur des zones supposées homogènes.

Une seconde approche, basée sur le modèle de réflectance empirique proposé par Lyzenga [23, 24] permet de relier directement l'intensité du signal radiométrique mesuré par le satellite à la profondeur d'eau à partir de l'exploitation simultanée des canaux **XS1** et **XS2**. C'est cette approche que nous avons adoptée.

La radiométrie observée sur les canaux **XS1** et **XS2** au site s peut être empiriquement reliée à la bathymétrie $\hat{z}(s)$ [23, 24, 14, 18] selon l'expression :

$$\hat{z}(s) = A \times \ln(y_s^{(XS1)} - XS1_\infty) + B \times \ln(y_s^{(XS2)} - XS2_\infty) + C \quad (26)$$

où XS_{i_∞} représente la radiométrie des eaux très profondes pour le capteur i . Cette expression contient trois paramètres A , B et C , variables selon les zones observées (condition de propagation atmosphérique, température,...) qui seront estimés à partir d'un recalage entre des relevés *in situ* et la radiométrie mesurée. Ces variables seront supposées constantes pour une classe donnée sur l'image segmentée. Si K est le nombre de classes, nous estimons $\{A(i), B(i), C(i)\}_{i=1, \dots, K}$ par la méthode des moindres carrés robustes.

4.1. estimation des paramètres du modèle bathymétrique

Le recours à des M-estimateurs, qui a fait son apparition depuis quelques années en traitement d'image [27, 26], permet de rendre plus robuste l'estimation de paramètres utilisant le critère des moindres carrés. Les propriétés importantes d'une estimation robuste sont le point de rupture (*i.e.*, le plus faible pourcentage de contamination des données qui peut faire prendre à l'estimation une valeur arbitrairement élevée), la complexité algorithmique et la robustesse [19]. Dans notre cas, nous considérons à cette étape l'ensemble des pixels d'une zone de mer appartenant à une même classe. On dispose de relevés bathymétriques ponctuels épars fournis par d'anciennes campagnes hydrographiques. Ils fourniront les n points de calage d'une part

et les m points de contrôle d'autre part. L'estimation consiste à minimiser une somme de résiduels correspondant aux points $z(i)_{i \in [1, n]}$ de calage disponibles (profondeur mesurée *in situ*) :

$$\begin{aligned} \varepsilon &= \sum_{i=1}^n \rho(r_i) \quad \text{avec } r_i = z(i) - \hat{z}(i) \\ &= \sum_{i=1}^n \rho(z(i) - A\tilde{y}_1(i) - B\tilde{y}_2(i) - C) \end{aligned} \quad (27)$$

en posant $\tilde{y}_k(i) = \ln(y^{(XSk)}(i) - XS_{k\infty})$ et $\rho(\cdot)$ une fonction paire croissante sur \mathbb{R}^+ . Nous avons comparé la méthode des moindres carrés (MC) avec une méthode d'estimation robuste utilisant un M-estimateur (MCR). Pour la méthode MCR, l'estimateur retenu est celui proposé par Andrews [19] avec un paramètre de forme α pris égal à 2 :

$$\rho(x) = \begin{cases} 4 \sin^2\left(\frac{x}{2\alpha}\right) & \text{si } |x| < \pi\alpha \\ 4 \sin\alpha & \text{sinon} \end{cases} \quad (28)$$

D'autres estimateurs [19] (Geman ($\alpha = 3$), Tukey ($\alpha = 6$),...) ont également été testés et ont fournis des résultats similaires. La fonction d'influence associée $\Psi(x) = \frac{d}{dx}\rho(x)$ est représentée sur le graphe Fig. 4. Le problème de minimisation de

$$\begin{aligned} \arg \min_{A, B, C} \sum_{i=1}^n \rho(z(i) - A\tilde{y}_1(i) - B\tilde{y}_2(i) - C) \\ = \arg \min_{A, B, C} \sum_{i=1}^n \rho(r_i(A, B, C)) \end{aligned} \quad (29)$$

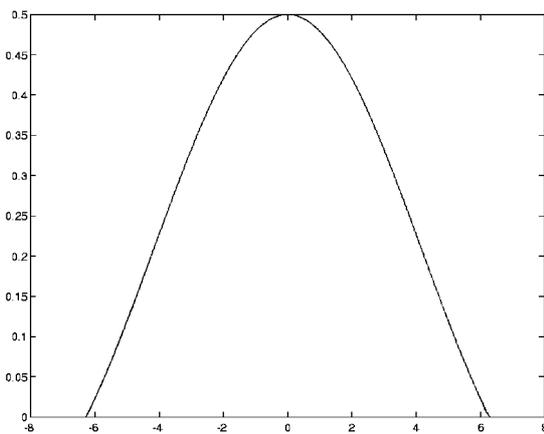


Figure 4. – Tracé de $\frac{1}{x}\Psi(x)$ ou $\Psi(x)$ désigne la fonction d'influence associée à l'estimateur robuste d'Andrews :

$$\Psi(x) = \begin{cases} \frac{2}{\alpha} \sin\frac{x}{\alpha} & \text{si } |x| < \pi\alpha \quad (\text{ici } \alpha = 2). \\ 0 & \text{sinon} \end{cases}$$

peut être ramené à une méthode des moindres carrés pondérés itérés alternant

– l'estimation des poids $\omega_i = \frac{\Psi(r_i)}{r_i}$ où r_i , fonction de (A, B, C) selon l'équation 27, est fixé ;

– l'estimation des paramètres (A, B, C) d'après $\arg \min_{A, B, C} \sum_i \omega_i r_i^2(A, B, C)$ pour ω_i fixé.

L'estimation des paramètres A, B, C pour une classe donnée se fera donc selon le synoptique suivant :

- 1) Initialisation des poids ω_i à 1 ;
- 2) On réalise plusieurs itérations alternées :
 - a) Résolution du problème des moindres carrés selon :

$$\begin{aligned} &\begin{bmatrix} \sum_i \omega_i \tilde{y}_1^2(i) & \sum_i \omega_i \tilde{y}_1(i) \tilde{y}_2(i) & \sum_i \omega_i \tilde{y}_1(i) \\ \sum_i \omega_i \tilde{y}_1(i) \tilde{y}_2(i) & \sum_i \omega_i \tilde{y}_2^2(i) & \sum_i \omega_i \tilde{y}_2(i) \\ \sum_i \omega_i \tilde{y}_1(i) & \sum_i \omega_i \tilde{y}_2(i) & \sum_i \omega_i \end{bmatrix} \begin{bmatrix} A \\ B \\ C \end{bmatrix} \\ &= \begin{bmatrix} \sum_i \omega_i \tilde{y}_1(i) z(i) \\ \sum_i \omega_i \tilde{y}_2(i) z(i) \\ \sum_i \omega_i z(i) \end{bmatrix} \end{aligned} \quad (30)$$

- b) Remise à jour des poids

$$\omega_i = \frac{\Psi(r_i)}{r_i} \quad (31)$$

- c) Arrêt lorsque la convergence des paramètres (A, B, C) est réalisée.

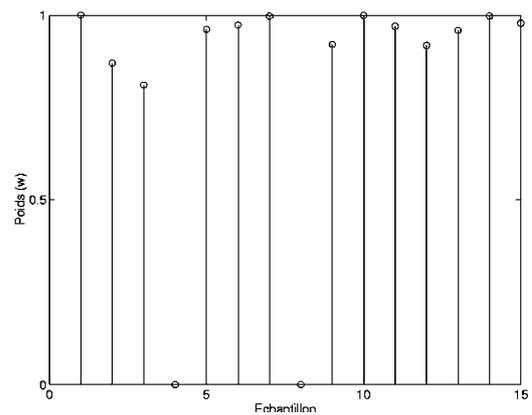


Figure 5. – Cette figure représente les poids associés aux 15 mesures « *in situ* » par l'algorithme MCR. On observe la présence de deux sondes fournissant vraisemblablement des mesures aberrantes (4^{ème} et 8^{ème} échantillons). Les poids sont à valeurs dans $\left[0, \frac{2}{\alpha^2}\right]$. Pour faciliter leur interprétation, cette dynamique a été ramenée sur $[0, 1]$.

En quelques itérations, on obtient la convergence de l'estimation des paramètres A , B et C . Le recours à un estimateur robuste permet d'éviter qu'une mesure aberrante (« outlier » en anglais, *i.e.*, mesure bathymétrique insolite ou atypique...) ne vienne contaminer l'estimation des paramètres du modèle d'inversion, surtout lorsque le nombre de points de calage n est faible. La figure 5 représente les poids ω_i et indique clairement la présence de deux mesures aberrantes.

4.2. base d'apprentissage et base de test

Cette partie montre les résultats obtenus sur des données SPOT réelles. Les résultats présentés (image SPOT de taille 512 pixels par 512 pixels soit une couverture d'une centaine de km²) ont été obtenus en une quinzaine de minutes sur un PC Pentium III cadencé à 500 MHz, disposant de 256 Ko de RAM. L'image traitée est celle de la figure 1a. Cette image a été segmentée dans un premier temps selon la méthode décrite au paragraphe 2.1., en s'appuyant sur un modèle de chaîne de Markov générant un masque occultant les zones « autres que mer ». La segmentation sur un quadarbre, paragraphe 3, permet alors d'identifier trois classes dans les zones de mer comme cela est montré à la figure 1b. Sur la région correspondant à cette image, l'île de Paaba au large de la Nouvelle-Calédonie, nous disposons d'un ensemble \mathcal{E} d'environ 2200 relevés bathymétriques effectués antérieurement par un bâtiment océanographique. Nous pouvons les positionner sur l'image SPOT grâce à quelques points géodésiques caractéristiques, dont la localisation est fournie grâce au système GPS. La procédure retenue consiste à regrouper ces relevés bathymétriques en deux bases distinctes :

- une base d'apprentissage \mathcal{A} qui permettra le calibrage des paramètres du modèle d'inversion bathymétrique (*i.e.*, trois coefficients A , B , C pour chacune des trois classes de mer segmentées à l'étape précédente) ;

- une base de test \mathcal{T} qui formera l'ensemble des points de contrôle (*i.e.*, mesures de profondeur d'eau).

Nous avons $\mathcal{E} = \mathcal{A} \cup \mathcal{T}$ et $\mathcal{A} \cap \mathcal{T} = \emptyset$, ce qui permettra d'évaluer la qualité et la précision de la carte de bathymétrie obtenue. En prenant $m = 100$ points pour la base de test \mathcal{T} et $n = 15$ points pour la base d'apprentissage \mathcal{A} , dans chacune des trois classes (*cf.* Fig.7), on obtient les paramètres estimés rassemblés dans le tableau 2 et la quantification associée des erreurs (*cf.* Tab.3). Les cartes de bathymétrie résultantes sont présentées aux figures 8a et 8b. Pour la carte de bathymétrie de la figure 8a, nous avons retenu un seul modèle de bathymétrie pour toutes les zones de mer. Les résultats obtenus dans ce cas de figure confirment l'intérêt d'une segmentation préalable des zones de mer (*cf.* Fig. 9). Par ailleurs, l'utilisation d'un estimateur robuste (*cf.* Tab. 1) évite qu'une mesure aberrante (mesure bathymé-

trique erronée, mesure radiométrique aberrante,...) ne contamine l'estimation des paramètres du modèle d'inversion et ne biaise la carte bathymétrique (*cf.* Fig. 6a (critère des moindres carré) et 6b (critère des moindres carrés robustes)). On montre (*cf.* Tab. 1) que les meilleurs résultats sont obtenus en utilisant un estimateur MCR diminuant l'influence des sondes défailtantes (Fig. 5).

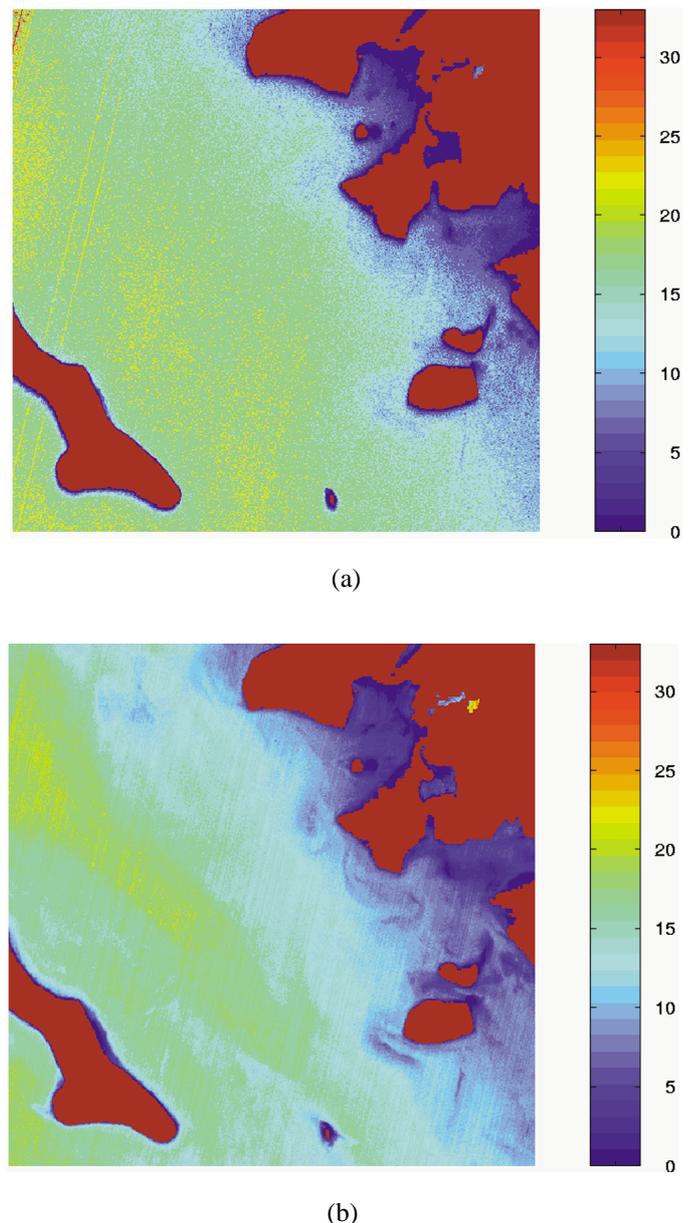


Figure 6. – Cartes bathymétriques obtenues avec la méthode MC (a) et la méthode MCR (b). Un unique modèle d'inversion bathymétrique a été estimé pour toute la zone de mer.

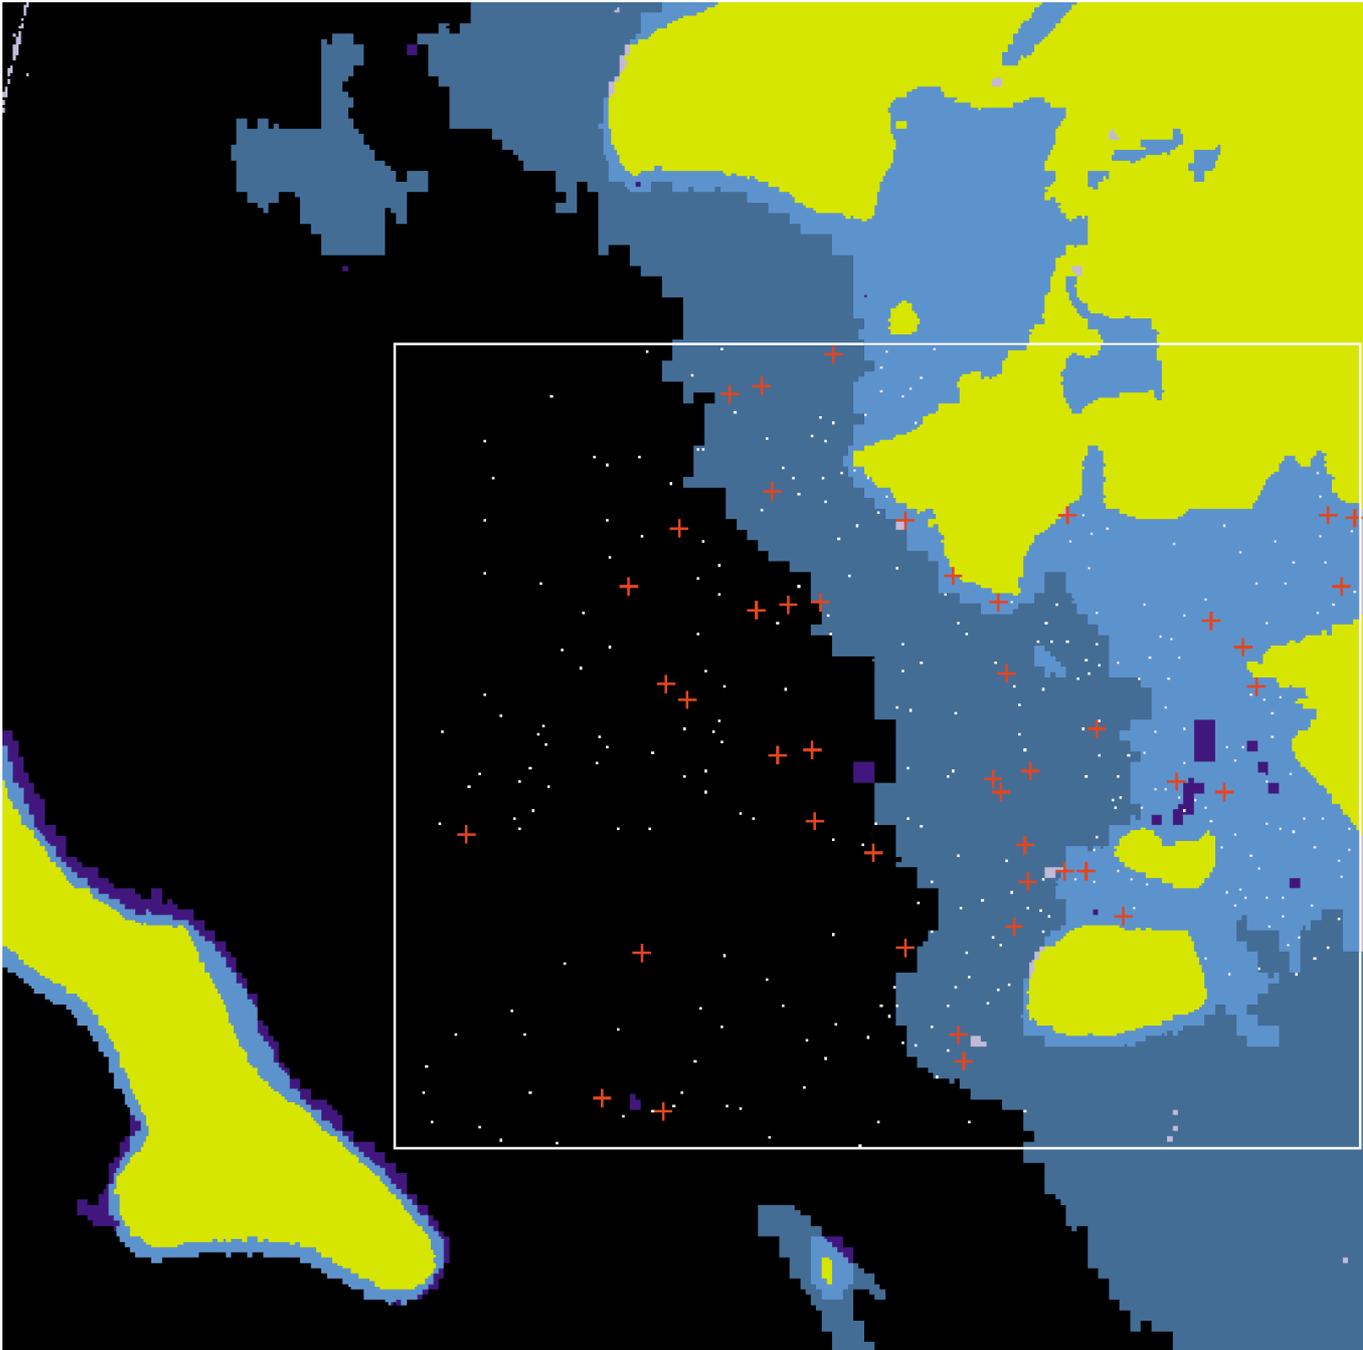


Figure 7 – Les croix rouges désignent les 45 points de calage et les points blancs, les 300 points de contrôle. Toutes les mesures « *in situ* » disponibles sont contenues dans le cadre blanc.

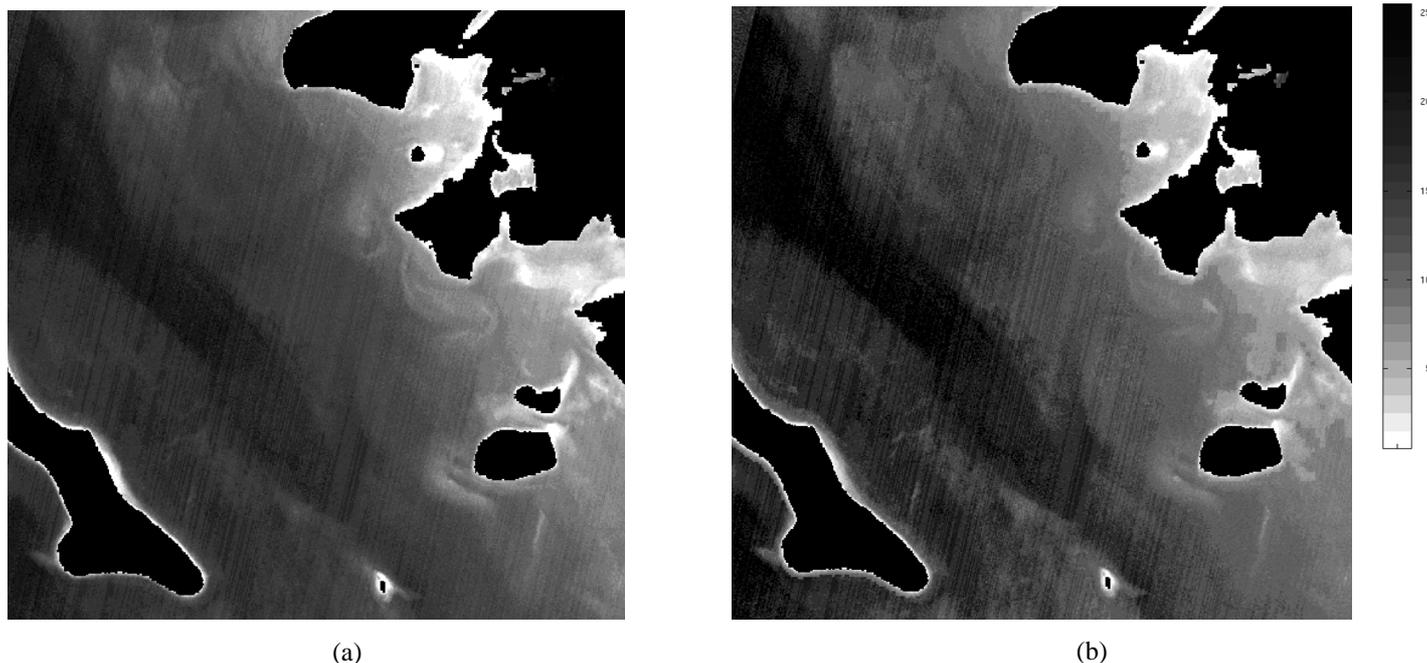


Figure 8. – Cartes bathymétriques (en mètres) obtenues avec la méthode MCR 1 classe (a) et la méthode MCR avec pré-segmentation en 3 classes utilisant un modèle markovien hiérarchique sur le quadarbre (b). Le masque occultant les régions « autre que mer » est en noir.

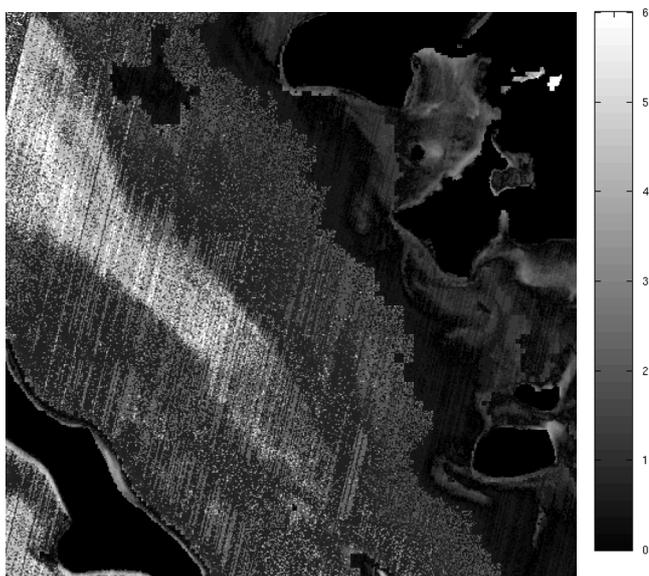


Figure 9. – Cette image permet de visualiser la valeur absolue de la différence (en mètres) entre les images 8a et 8b. La segmentation de la zone de mer en trois classes permet une meilleure adaptation du modèle d'inversion bathymétrique (cf. Tab. 3). La présence de traînées est liée aux capteurs et au mode d'acquisition de l'image par le satellite SPOT. Toutefois, la quantification des cartes marines s'effectuant par pas de 5 mètres, ces effets demeurent négligeables pour l'établissement des cartes nautiques par le SHOM.

Tableau 1. – Pour $n = 15$ points de calage (dont deux sont des valeurs aberrantes détectées *a posteriori*) et $m = 100$ points de contrôle, on constate que l'estimation des paramètres du modèle d'inversion est meilleure dans le cas d'une estimation robuste, pour une évaluation de la précision de reconstruction au sens de la norme \mathcal{L}_1 comme de la norme \mathcal{L}_2 . Les résultats présentés sont obtenus en moyennant les erreurs constatées sur une centaine d'ensembles de m points de contrôle pris arbitrairement sur la zone de mer. Les valeurs du tableau sont exprimées en mètres.

	MC	MCR
erreur au sens de la norme \mathcal{L}_1	3,2	2,2
erreur au sens de la norme \mathcal{L}_2	15,6	10,6

Tableau 2. – Paramètres estimés pour le modèle d'inversion dans chaque classe. Les deux colonnes de droite indiquent la profondeur moyenne et l'écart-type en mètres des bathymétries associées à chacune des 3 classes de la figure 8b.

	A	B	C	moyenne	écart-type
classe 1	- 4,99	- 5,15	30,44	5,4	2,6
classe 2	- 2,64	- 2,39	18,02	11,6	2,7
classe 3	- 13,55	3,69	30,45	17,4	4,0

Tableau 3. – A partir de la même base d'apprentissage (45 points de calage et 300 points de contrôle (cf. Fig. 7)), une segmentation préalable des zones de mer en 3 classes) fournit de meilleurs résultats que l'estimation d'un unique jeu de paramètres (MCR 1 classe), au sens des normes \mathcal{L}_1 et \mathcal{L}_2 . Les valeurs du tableau sont exprimées en mètres.

	MCR 1 classe	MCR 3 classes
erreur au sens de la norme \mathcal{L}_1	1,9	1,7
erreur au sens de la norme \mathcal{L}_2	7,1	6,2

5. conclusions et perspectives

La télédétection spatiale en zone côtière présente les avantages d'un traitement rapide de vastes étendues, de l'indépendance par rapport à des infrastructures terrestres, de la répétitivité et de la disponibilité. Cette approche nécessite toutefois de compléter le traitement d'images par une validation sur des observations effectuées avec un moyen éprouvé (*i.e.*, levé hydrographique classique). L'exploitation des images SPOT apporte ainsi une aide efficace pour la préparation et la mise à jour des cartes nautiques. Les avantages les plus marquants de notre approche vis-à-vis d'autres techniques d'hydrographie côtière sont la rapidité du traitement de zones étendues, le peu de données bathymétriques relevées *in situ* nécessaires, le faible coût (sans commune mesure avec une campagne hydrographique). Nous avons montré que peu de points de calage étaient nécessaires. Certaines zones seront ainsi hydrographiées grâce à la segmentation préalable des images satellitaires, d'autres seulement investiguées et c'est au cartographe de veiller à ce que la fiabilité réelle des données figurant sur la carte informe sans ambiguïté l'utilisateur du document nautique. Le traitement d'image proposé a pour objectif d'analyser automatiquement de vastes zones (*i.e.*, la majeure partie des données) et de ne focaliser l'attention du cartographe que sur quelques zones présentant un aspect litigieux. Plusieurs extensions de ce travail sont à l'étude. En particulier, la segmentation des zones de mer, qui joue un rôle très important sur la qualité finale des cartes bathymétriques, pourrait être affinée en utilisant un modèle d'attache aux données plus général [31]. Par ailleurs, il conviendra de gérer les éventuels artefacts sur les zones de frontière entre classes.

6. remerciements

Les auteurs remercient le Service Hydrographique et Océanographique de la Marine pour sa participation financière et intellectuelle à ce travail. Ce travail a été réalisé au GTS (Groupe de Traitement du Signal) de l'IRENav, École Navale, Brest.

BIBLIOGRAPHIE

- [1] C.A. Bouman et M. Shapiro. A multiscale random field model for {B}ayesian image segmentation. *IEEE Trans. on Image Processing*, 3(2) : 162-177, 1994.
- [2] A. Chardin et P. Pérez. Semi-iterative inferences with hierarchical energy-based models for image analysis. *Proc. International Workshop EMMCV-PR'99 : Energy Minimisation Methods in Computer Vision and Pattern Recognition, Lecture Notes in Computer Science*, 1654, 1999.
- [3] J.P. Delmas. Relations entre les algorithmes d'estimation itérative EM et ICE avec exemples d'applications. In *15th colloque GRETSI*, pages 185-188, Antibes, France, 1995.
- [4] A.P. Dempster, N.M. Laird, et D.B. Rubin. Maximum Likelihood from incomplete data via the EM algorithm. *Royal Statistical Society*, pages 1-38, 1976.
- [5] X. Descombes, R. Morris, J. Zérubia, et M. Berthod. Estimation of Markov random field prior parameters using Markov chain Monte Carlo Maximum Likelihood. *IEEE Trans. Image Process.*, 8(7):954-963, July 1999.
- [6] P.A. Devijver et M. Dekesel. Algorithme d'apprentissage d'un modèle Markovien d'images. In *Actes du 6^{ème} congrès RFIA*, pages 193-207, novembre 1987.
- [7] J.N. Provost, C. Collet, et P. Pérez et P. Bouthemy. Segmentation d'images radiométriques multispectrales pour l'obtention de cartes bathymétriques. *Actes des Journées Francophones des jeunes chercheurs en analyse d'images et perception visuelle – Orasis'99 – Aussois, France*, 1, avril 1999.
- [8] J.N. Provost et C. Collet et P. Pérez et P. Bouthemy. Segmentation non-supervisée d'images multispectrales SPOT : Application à la cartographie maritime. In *17^{ème} Colloque sur le Traitement du Signal et des Images, GRETSI'99*, volume I, pages 27-30, Vannes, France, 1999.
- [9] J.M. Laferté, F. Heitz et P. Pérez. Modèles Markoviens d'images et algorithmes d'estimation non linéaire sur le quadarbre. *Traitement du signal*, 15(3) : 213-230, 1998.
- [10] G. Celeux et J. Diebolt. L'algorithme SEM : un algorithme d'apprentissage probabiliste pour la reconnaissance de mélanges de densités. *Revue de Statistique Appliquée*, 34(2), 1986.
- [11] P.A. Devijver et M. Dekesel. Champs aléatoires de Pickard et modélisation d'images digitales. *Traitement du signal*, 5(5) : 131-150, 1988.
- [12] B. Benmiloud et W. Pieczynski. Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images. *Traitement du Signal*, 12(5) : 433-454, 1995.
- [13] A. Lorette, X. Descombes et J. Zérubia. Extraction des zones urbaines fondée sur une analyse de la texture par modélisation Markovienne. Rapport de recherche 3423, INRIA – Sophia-Antipolis, mai 1998.
- [14] A. Fourgassie. La spatiocarte marine, une solution pour la cartographie des atolls polynésiens. Conférence Pix'Iles 90 – volume 1, pages 329-341, Nouméa-Tahiti, France, 19-24 novembre 1990.
- [15] S. Geman et D. Geman. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-6(6) : 721-741, November 1984.
- [16] N. Giordana. *Segmentation non supervisée d'images multispectrales par chaînes de Markov cachées*. Thèse de doctorat, Institut National des Télécommunications (INT), décembre 1996.
- [17] C. Graffigne, F. Heitz, P. Pérez, F. Prêteux, M. Sigelle, et J. Zerubia. Hierarchical Markov random field models applied to image analysis : a review. In *SPIE Neural Morphological and Stochastic Methods in Image and Signal Processing*, volume 2568, pages 2-17, San Diego, 10-11 July 1995.
- [18] M. Hamren-Larsson. Modelling bathymetry and temporal changes in a coastal region of the Dominican Republic : the use of Landsat thematic mapper. <http://www.geog.ubc.ca/courses/klink/g472/class98/hamren-larsson/index.html>.
- [19] J. Huber. *Robust statistics*. John Wiley and sons, New York, 1981.
- [20] Z. Kato, J. Zérubia, et M. Berthod. Unsupervised parallel image classification using Markovian models. *Pattern Recognition*, 32(4) : 591-604, April 1999.

- [21] J.M. Laferté. *Contribution à l'analyse d'images par modèles Markoviens sur des graphes hiérarchiques. Application à la fusion de données multirésolution*. Thèse de doctorat, Université de Rennes 1, IRISA, octobre 1996.
- [22] L. Loubersac et P.Y. Burban. Integrated study of Aitutaki's lagoon (Cook islands) using SPOT satellite data and in situ measurements : bathymetric modelling. *Geocarto International*, 2 : 31-37, 1991.
- [23] D.R. Lyzenga. Passive remote sensing techniques for mapping water depth and bottom features. *Journal of Applied Optics*, 17(3) : 379-383, 1978.
- [24] D.R. Lyzenga. Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and Landsat data. *IEEE Transactions on Geoscience and Remote Sensing*, 2 : 77-82, 1983.
- [25] P. Mainguenaud, R. Jeansoulin, et JP. Rudant. Caractérisation neuronale des propriétés texturales des images radar à synthèse d'ouverture ERS1 et JERS1. *Bulletin de la Société Française de Photogrammétrie et Télédétection*, Octobre 1995.
- [26] C. Nikou. *Contribution au recalage d'images médicales multimodales : approches par fonction de similarité robuste et modèles déformables sous contraintes statistiques*. Thèse de doctorat, Université Louis Pasteur-Strasbourg I, mai 1999.
- [27] J.M. Odobez. *Estimation, détection et segmentation du mouvement : une approche robuste et Markovienne*. Thèse de doctorat, Université de Rennes 1, IRISA, décembre 1994.
- [28] W. Pieczynski. Champs de Markov cachés et estimation conditionnelle itérative. *Traitement du signal*, 11(2) : 141-153, 1994.
- [29] P. Pérez et F Heitz. Multiscale Markov random fields and constrained relaxation in low level image analysis. *IEEE International Conference on Acoustics, Speech and Signal Processing. (ICASSP-92)*, 3 : 61-64, 1992.
- [30] J.-N. Provost. Classification bathymétrique en imagerie multispectrale SPOT. Thèse de doctorat, Université de Bretagne Occidentale, juin 2001. <http://www-isis.enst.fr>
- [31] P. Rostaing, J.-N. Provost, et C. Collet. Unsupervised multispectral image segmentation using generalized Gaussian noise model. In *Proc. International Workshop EMMCVPR'99 : Energy Minimisation Methods in Computer Vision and Pattern Recognition, Springer Verlag – Lecture Notes in Computer Science*, volume 1654, pages 141-156, York, UK, July 1999.
- [32] F. Salzenstein. *Modèles Markoviens flous et segmentation statistique non-supervisée d'images*. Thèse de doctorat, Université Rennes 1 – Institut National des Télécommunications d'Evry, décembre 1996.
- [33] P. Thourel. *Segmentation d'images sonar par modélisation Markovienne hiérarchique et analyse multirésolution*. Thèse de doctorat, Université de Bretagne Occidentale – Ecole Navale (Laboratoire GTS), juillet 1996.
- [34] G.C. Wei et M.A. Tanner. A Monte Carlo implementation of the EM algorithm and the poor man's data augmentation algorithms. *Journal of the American Statistical Association*, 85 : 699-704, 1990.

Manuscrit reçu le 18 avril 2000.

LES AUTEURS

Christophe COLLET



Christophe Collet est né le 31 mars 1966. Il a obtenu son doctorat à l'Université de Toulon en 1992 et soutenu son Habilitation à diriger des Recherches à l'Université de Bretagne Occidentale en mai 2000. Nommé maître de conférences à l'UBO en 1993, il a dirigé le laboratoire GTS de l'École Navale de 1994 à 2000. Il est professeur à l'Université Louis Pasteur de Strasbourg, depuis le 1^{er} septembre 2001. Ses centres d'intérêt en recherche concernent l'analyse

statistique des images en océanographie, la segmentation markovienne hiérarchique non supervisée (imagerie SPOT, sonar, infrarouge), le traitement des formes, l'analyse de textures en imagerie sonar, les techniques d'optimisation en traitement d'images.

Philippe ROSTAING



Philippe Rostaing a obtenu son Doctorat au laboratoire I3S à Nice en 1997 sur l'étude de signaux cyclostationnaires et la mise en œuvre de détecteurs exploitant ces propriétés « cycliques ». Il rejoint l'équipe du GTS à l'École Navale de 1997 à 2000 où il mène des activités en traitement statistique des images (modèles markoviens, modélisation de l'attache aux données dans le cas multispectrales, etc...). Depuis sept. 2000, il est maître de conférences au LEST (Laboratoire

d'électronique et des systèmes de Télécommunication, Université de Brest) où il travaille dans le domaine des communications numériques multi-antennes.

Patrick BOUTHEMY



Patrick Bouthemy est ingénieur Télécom-Paris, Docteur-Ingénieur (1982) et Habilité à Diriger des Recherches (1989) de l'Université de Rennes 1. Il est actuellement Directeur de Recherche Inria à l'Irisa, et responsable du projet Vista. Ses axes principaux de recherche sont les suivants: approches statistiques pour l'analyse d'image, analyse du mouvement et des déformations, vision dynamique, suivi, indexation vidéo. Il est éditeur associé de la revue IEEE Transactions on Image Processing.

Jean-Noël PROVOST



Jean-Noël Provost est né en 1973. Diplômé de l'École Nationale Supérieure de Marseille en 1995, il est titulaire d'un DEA en électronique et optronique de l'Université de Bretagne Occidentale depuis 1996. Il a soutenu le 8 juin 2001 une thèse en traitement d'image à l'Université de Bretagne Occidentale. Ses recherches portent sur la segmentation d'images multispectrales SPOT appliquée à la cartographie bathymétrique.

Patrick PÉREZ



Patrick Pérez est né en 1968. Diplômé de l'école Centrale Paris en 1990, il a effectué sa thèse à l'Irisa/Inria-Rennes. Après un an de séjour post-doctoral au Dpt of Applied Mathematics à Brown University (Rhode-Island, USA), il a rejoint l'INRIA en 1994 en tant que chargé de recherche. Ses thèmes de recherches portent sur les modèles statistiques pour le traitement de problèmes inverses de grande dimension, en analyse d'images. Les domaines d'applications privilégiés sont l'analyse du mouvement appa-

rent dans les séquences d'images d'une part, et la fusion multirésolution d'autre part (en télédétection et en imagerie sonar).