

Segmentation multiéchelle de nappes d'hydrocarbure

Multiscale Oil Slicks Segmentation

Grégoire Mercier¹, Stéphane Derrode²,
Wojciech Pieczynski³

¹GET/ENST Bretagne, dpt ITI (CNRS FRE 2658, TAMCIC, équipe TIME)
Technopôle Brest-Iroise, CS 83818, F-29238 Brest Cedex, France.
gregoire.mercier@enst-bretagne.fr

²EGIM, groupe GSM (CNRS UMR 6133, Institut Fresnel).
Domaine Universitaire de Saint Jérôme, F-13013 Marseille Cedex 20, France.
stephane.derrode@enspm.u-3mrs.fr

³GET/INT, dpt CITI (CNRS UMR 5157) 9, rue Charles Fourier, F-91011 Evry Cedex, France.
wojciech.pieczynski@int-evry.fr

Manuscrit reçu le 15 décembre 2003

Résumé et mots clés

Nous nous intéressons à la détection et à la caractérisation des nappes d'hydrocarbure à partir d'images Radar à Synthèse d'Ouverture (RSO). La viscosité de l'hydrocarbure atténue sensiblement la rugosité de surface qui participe majoritairement à la rétro-diffusion. En conséquence, un film visqueux est caractérisé par un déficit d'énergie rétro-diffusée et apparaît comme une zone sombre dans les images. Cependant, la plupart des techniques de détection, basée sur un seuillage d'histogramme, s'avère insatisfaisante, puisqu'elle engendre un nombre élevé de fausses alarmes.

En considérant le fait qu'un film visqueux a un impact caractéristique sur la répartition de l'énergie des vagues selon les différentes longueurs d'onde (des vagues de gravité-capillarité jusqu'à la houle), nous avons développé une méthode de segmentation markovienne adaptée à une représentation multiéchelle de l'image originale. Cette méthode permet d'obtenir une classification qui tient compte des différents états du spectre de vagues. Grâce à l'estimation des lois intervenant dans le mélange, cette méthode de segmentation permet de caractériser statistiquement les zones détectées et ainsi de se prémunir contre de nombreuses fausses alarmes.

Cette stratégie a été appliquée avec succès à des images RSO de différentes résolutions (ERS-SAR en mode PRI à 25 m et ENVISAT-ASAR en mode *Wide Swath* à 150 m de résolution) correspondant à des situations particulières comme le naufrage d'un navire avec un hydrocarbure lourd en Atlantique et le dégazage de cuves avec un hydrocarbure plus fluide en Méditerranée.

Chaînes de Markov Cachées, Ondelettes, Radar à Synthèse d'Ouverture, Détection de Nappe d'Hydrocarbure, Segmentation Multicomposante.

Abstract and key words

This study focuses on the segmentation and characterization of oil slicks from Synthetic Aperture Radar (SAR) data. Viscosity notably reduces the roughness of the sea surface which takes a major part in the backscattering. Hence, an oil slick is characterized by a low-backscattered energy and appears as a dark area in images. This is the reason why most of detection algorithms are based on histogram thresholding, but they appear not satisfactory as the number of false alarms is generally high.

Since oil slicks have specific impact on ocean wave spectra (from gravity-capillary waves to the swell), we propose to use a Markovian model adapted to a multiscale description of the original image. This unsupervised segmentation method allows to take into account the different states of the sea surface through its spectra. Thanks to the mixture estimation, it is possible to statistically characterize the detected areas and then to prevent from most of false alarms. Results of segmentation are shown with two types of scenarios. The first one concerns oil spill in the Mediterranean sea detected by the ERS SAR sensor at a resolution of 25 m. The second scenario is related to the Prestige's wreck acquired by the Envisat ASAR sensor in a wide swath mode at a resolution of 150 m.

Hidden Markov Chain, Wavelet, Synthetic Aperture Radar, Oil Slick Detection, Multicomponent Segmentation.

Remerciements

Ce travail a été financé par le *Groupe des Écoles des Télécommunications*, sous le projet GET / MOSS RE-315.

1. Introduction : détection des nappes d'hydrocarbure

La surface de l'océan est complexe et régie par des phénomènes non-linéaires. Les phénomènes ondulatoires observés ont une longueur d'onde allant de quelques millimètres à plusieurs centaines de mètres. On découpe ainsi le spectre des vagues en trois domaines [1] :

- Les longues vagues, typiquement associées au phénomène de houle, dont la longueur d'onde est supérieure à une centaine de mètres ;
- Les vagues intermédiaires, essentiellement caractérisées par les vagues de gravité, dont la longueur d'onde est de plusieurs dizaines de mètres ;
- Les petites vagues, dues à la présence du vent qui génère des ondes capillaires ou petites ondes de gravité, dont la longueur d'onde est inférieure au mètre.

En considérant une surface de mer libre de tout obstacle, de façon schématique, le vent est à l'origine de l'apparition des ondes capillaires, par frottement avec la surface de la mer. Ces ondes capillaires ne peuvent se propager sur de longues distances et s'évanouissent si le vent disparaît. Cependant, les ondes capillaires opèrent un transfert d'énergie vers les ondes de plus grande longueur d'onde. Ce transfert s'effectue jusqu'à un état d'équilibre, qui dépend directement de la force du vent, dans lequel les ondes de gravité ont à leur tour une influence sur les ondes capillaires. Il existe de nombreux modèles de description du spectre de vagues plus ou moins précis selon les longueurs d'onde considérées. Ces modèles intègrent non seulement le vent mais aussi le courant, la pression atmosphérique, etc. Le lecteur trouvera une comparaison intéressante de ces

modèles dans le contexte de l'imagerie radar dans [2]. Alors que les ondes capillaires naissent par frottement et plus précisément par le biais de la tension de friction induite par le vent, et s'atténuent dès que la tension de friction diminue, les vagues de gravité sont, quant à elles, générées indirectement par répartition de l'énergie du spectre de vagues et peuvent se propager à de très grandes distances de l'endroit qui les a vu naître.

Ainsi, la surface de la mer peut être modélisée d'une façon générale par son spectre de vagues qui est régit par les équations de dispersion suivantes :

$$\begin{cases} \omega^2 = \frac{\tau}{\rho} \kappa^3 & \text{pour les vagues de capillarité,} \\ \omega^2 = g\kappa & \text{pour les vagues de gravité,} \\ \omega^2 = g\kappa + \frac{\tau}{\rho} \kappa^3 & \text{pour les vagues de gravité-capillarité,} \end{cases} \quad (1)$$

où ω représente la pulsation de chaque vague, κ le nombre d'onde, g l'accélération gravitationnelle, τ la tension de surface et ρ la densité de la mer. Il apparaît clairement que les longues vagues sont régies par les forces de gravité alors que les petites relèvent de la tension de surface. Nous verrons dans la section suivante que les phénomènes de rétrodiffusion de la surface de la mer sont dus à cette dernière classe de vagues, tandis que les vagues observées par le Radar à Synthèse d'Ouverture (RSO) sont des vagues de gravité.

Marangoni, en 1872, fut le premier à donner une explication satisfaisante à l'atténuation des vagues par un film à la surface de la mer. Lorsque les ondes de gravité-capillarité se propagent en surface, les compressions et extensions successives de la surface créent une hausse significative du taux de dissipation. Lorsqu'un film recouvre la surface, le vent a moins d'effet sur cette dernière. L'amplitude crêtes-creux des vagues diminue et un gradient de tension de surface se crée. Ce gradient induit une force opposée à ce mouvement d'alternance. Les ondes dites de Marangoni apparaissent dès qu'il existe ce gradient de tension

de surface, c'est-à-dire dès la présence d'un film visco-élastique. Les ondes de Marangoni sont en partie longitudinales, à l'instar des ondes de gravité-capillarité, dans la couche supérieure où la dissipation visqueuse est atténuée, et transversales où elles sont associées aux gradients de tension de surface déterminés par les propriétés visco-élastiques du film [3].

L'atténuation des petites vagues à la surface est donc associée à une diminution de la tension de surface, elle-même liée à l'élasticité du film. C'est elle qui stabilise la surface et empêche la génération des vagues par le vent. Les interactions non-linéaires sont suffisamment rapides pour transférer assez d'énergie de la région des ondes de gravité à la région d'atténuation de Marangoni pour équilibrer la dissipation visqueuse. Ce transfert d'énergie non-linéaire s'apparente à un processus de diffusion qui amène le spectre de vague à l'équilibre. Plus le spectre est déformé par l'atténuation de Marangoni, plus le transfert d'énergie non linéaire est important [4].

Ainsi, la totalité du spectre de vague est affectée par la présence d'hydrocarbure, soit par atténuation de l'énergie (disparition de petites vagues), soit par atténuation et/ou modification de la longueur d'onde des vagues de gravité (figure 1).

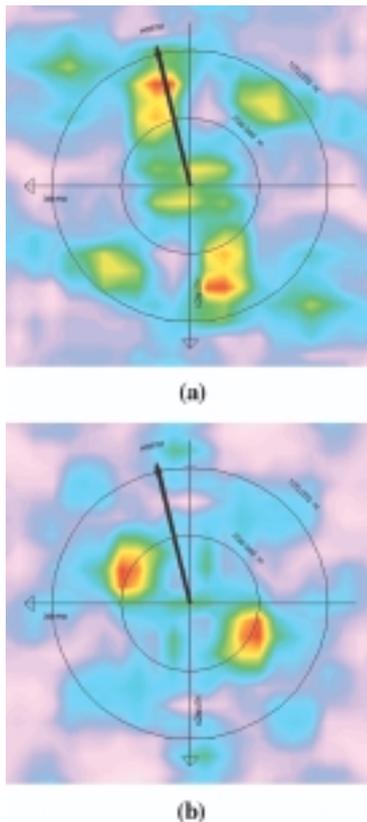


Figure 1. Ces deux spectres de vagues de la surface de la mer, estimés à partir d'une acquisition ERS dans une zone de pollution en (b) et dans une zone de mer libre en (a) à quelques centaines de mètres de la zone polluée, montrent bien les effets induits par la nappe de pétrole : atténuation et modification (en direction et longueur d'onde) de la houle, orientée Nord en mer libre et Nord-Ouest dans la nappe d'hydrocarbure.

1.1. La surface de la mer vue par un radar

L'onde électromagnétique émise par le radar est rétro-diffusée par la surface de la mer. Plusieurs modèles permettent d'expliquer ce phénomène de rétro-diffusion. Le plus simple est le modèle de Bragg qui ne tient compte que des vagues de longueur d'onde comparable à celles, électromagnétiques, envoyées par le radar. Ainsi, seules les vagues ayant un nombre d'onde $\kappa_{\text{vague}} = 2\kappa_{\text{radar}} \sin \theta$, où κ_{radar} est le nombre d'onde du radar et θ l'angle entre le rayon électromagnétique incident et la verticale, apportent une contribution à la rétrodiffusion.

Or, les capteurs RSO actuellement embarqués sur des passerelles satellitaires émettent des ondes électromagnétiques en bande C (dont la longueur d'onde est de l'ordre de 5.6 cm). Compte tenu des angles d'incidences utilisés par les capteurs (de 15 à 45° selon les capteurs et leur mode de programmation), les ondes de gravité-capillarité qui interviennent dans le phénomène de rétrodiffusion ont une longueur d'onde comprise entre 4 et 14 cm. Le tableau 1 détaille les informations des deux capteurs que nous utiliserons pour illustrer l'algorithme de détection.

Tableau 1. Caractéristiques principales des capteurs RSO utilisés pour cette étude.

Satellite Capteur	ERS-1 AMI	ENVISAT ASAR
Longueur d'onde	5,66 cm	5,62 cm
Angle d'incidence	20° - 35°	15° - 45°
Résolution	25 m	150 m
Fauchée	100 km	400 km
mode	PRI: <i>Precision Image</i> Données en amplitude	WideSwath: Image d'amplitude Moyenne résolution

Néanmoins, les images fournies par les capteurs satellitaires ont une résolution spatiale bien supérieure à la longueur d'onde et permettent de mettre en valeur des phénomènes océanographiques de plus grande échelle que les ondes de gravité-capillarité. En effet, le modèle de Bragg [5] ne fait intervenir qu'une seule longueur d'onde pour expliquer la rétrodiffusion alors qu'il est nécessaire de prendre en compte tout le spectre de vague, ou de se contenter de certaines parties de ce spectre, ainsi que le déplacement des vagues elles-mêmes qui engendre des modulations particulières [6]. La rugosité de surface due aux petites vagues est en effet modulé par des phénomènes de plus grande échelle ce qui permet à l'imagerie radar d'être utilisée pour caractériser « indirectement » des phénomènes de houle, d'ondes internes, de bathymétrie côtière, de nappe d'hydrocarbure [7], ...

1.2. Stratégie usuelle de segmentation de nappes d'hydrocarbure

La viscosité de l'hydrocarbure stoppant la propagation des petites vagues, une nappe visqueuse à la surface de la mer va donc apparaître plus lisse que la surface de la mer non polluée. Vue par un radar, la nappe va être caractérisée par un déficit d'énergie rétrodiffusée, c'est-à-dire apparaître sous forme d'une région plus sombre dans l'image [8], car selon le modèle de Bragg, la rugosité de surface participe majoritairement à la rétro-diffusion.

Ce phénomène est assez prépondérant lors de dégazages en mer Méditerranée. Cela est dû à la nature de l'hydrocarbure déversé et à la forme du spectre de vagues observé sur ce type de mer où la houle est moins prédominante que dans un océan. Dans ces conditions, un certain nombre d'algorithmes de segmentation basés sur un simple seuillage de la radiométrie des images RSO a été proposé (voir notamment [9], [10], [11]). Pourtant, ces méthodes ne sont pas toujours efficaces :

- Lorsque le vent devient très violent (typiquement supérieur à 10 m/s);
- Lorsque le type de mer est différent (le gabarit de son spectre de vagues);
- Lorsque l'hydrocarbure est de nature différente de celui d'un dégazage (une émulsion ou un pétrole dégradé par exemple);
- Ou encore, lorsque l'on est en présence de phénomènes qui perturbent la détection, notamment à l'exutoire d'un fleuve qui déverse de l'eau douce dans la mer ou lors de remontée d'eau profonde (*up-weeling*) qui atténuent l'énergie des petites vagues.

En outre, ces approches exclusivement radiométriques souffrent d'un taux de fausses alarmes très important puisque les pentes des vagues qui ne font pas face au radar sont restituées avec une radiométrie plus faible et sont souvent considérées comme de petites nappes d'hydrocarbure. C'est pourquoi beaucoup d'études de détection de nappes d'hydrocarbure intègrent également des post-traitements pour éliminer ces petites détections, le plus souvent à travers des critères géométriques, morphologiques ou contextuels [12], [13].

1.3. Stratégie multiéchelle

La stratégie multiéchelle que nous proposons de mettre en œuvre pour détecter les nappes d'hydrocarbure se justifie *a priori* à partir des points déjà évoqués plus haut et rappelés ici :

- Le radar est sensible à la rugosité de surface (à l'échelle du décimètre) qui est modulée par des phénomènes de plus grande échelle, ce qui engendre des nuances de la *texture* de l'image;
- La présence d'hydrocarbure modifie la répartition initiale de l'énergie du spectre des vagues de la surface de la mer;
- La présence d'hydrocarbure induit également, mais dans certaines conditions, une baisse de la radiométrie locale et restitue des tâches sombres sur les images RSO.

La transformation multiéchelle de l'image de la surface de la mer permet de représenter l'information initiale à travers une information radiométrique locale et un ensemble de coefficients liés à la rugosité de surface suivant plusieurs échelles (section 2). C'est donc un outil *ad hoc* pour caractériser l'allure et l'évolution locale du spectre de vagues à la surface de la mer. Pour détecter la présence éventuelle d'hydrocarbure, nous avons opté pour une méthode de segmentation statistique basée sur une modélisation par chaîne de Markov (section 3) dans laquelle les observations traitées sont des données vectorielles contenant en chaque échantillon toute la description multiéchelle locale.

La section 4 montre quelques résultats de détection à partir d'images RSO des satellites ERS et ENVISAT. Les conclusions et perspectives de ce travail sont finalement présentées dans la section 5.

2. Représentation multiéchelle d'une image

Une transformée multiéchelle permet de représenter un signal à l'aide de deux paramètres : le temps et l'échelle. L'échelle permet de définir une nouvelle notion de caractéristique « fréquentielle » dépendante du temps. C'est donc un outil idoine pour analyser localement l'allure du spectre de vague. L'analyse en multiéchelle, lorsqu'elle est linéaire, peut se décliner à l'aide de plusieurs outils :

- La transformée de Fourier locale qui n'est qu'une transformée de Fourier classique du signal initial réduite à une durée limitée par une fenêtre glissante. La fenêtre glissante utilisée peut être rectangulaire, Gaussienne (on parle alors de transformée de Gabor), une fonction de Hamming... Cette fenêtre peut également être ajustée de telle sorte qu'elle soit proportionnelle à la pulsation ω . Sous certaines conditions, on obtient alors la transformée en ondelettes.

- La transformée en ondelettes dans laquelle la fonction de base ψ (ondelette mère) remplace la sinusoïde fenêtrée de la transformée de Fourier locale telle que :

$$\text{TO}\{f\}(b,a) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{a}} \psi^* \left(\frac{t-b}{a} \right) dt.$$

Une ondelette mère peut prendre des formes très variées (mais reste soumise à certaines conditions d'admissibilité [14]) et le choix de la meilleure fonction d'ondelette reste un problème ouvert et très dépendant de l'application. La formulation de l'analyse en multirésolution à travers une transformée en ondelettes peut prendre différentes formes :

- La Transformée en Ondelette Discrète (TOD),
- La Transformée en Ondelette Continue (TOC),
- Les transformations compactes ou non, ayant une approche effectivement en multirésolution, ce qui est le cas des TOD avec

décimation, ou plutôt en multiéchelle que l'on obtient lorsque la TOC n'inclut pas de décimation.

Lorsqu'un signal est appréhendé en multiéchelle, il est disposé sous une forme progressive dans laquelle le niveau de détail contenu dans chaque bande de décomposition est croissant (on peut aussi dire que la fréquence maximale ν_{\max} du spectre de Fourier est de plus en plus grande). Par contre, si ce signal est présenté en multirésolution, le niveau de détail de chaque bande de la décomposition reste le même (les spectres de Fourier sont de même largeur de bande), mais c'est le pas de l'échantillonnage du signal qui varie.

Dans la suite de ce travail, nous nous focalisons sur la décomposition multiéchelle par ondelette continue qui présente notamment l'avantage d'être invariante par translation et qui garantit donc une représentation identique des textures quelle que soient leurs positions dans l'image.

2.1. Transformée multiéchelle par ondelettes continues

La stratégie de décomposition qui suit doit nous permettre d'analyser localement l'allure du spectre de vagues. Aussi allons-nous utiliser une transformée en ondelettes définie comme un opérateur différentiel multiéchelle [15] qui permet de caractériser la structure locale d'un signal f . L'opérateur de la transformée en ondelettes est alors défini (ici en 1D) par :

$$\text{TO}_\ell \{f\}(b, a) = a^\ell \frac{\partial^\ell}{\partial b^\ell} (f * \theta_a)(b),$$

où ℓ correspond au niveau de décomposition ($0 \leq \ell < L$). La convolution $f * \theta_a$ correspond à une moyenne de f sur un certain domaine a .

En considérant la dérivée première, $\text{TO}_1 \{f\}(b, a) = a \frac{\partial}{\partial b} (f * \theta_a)(b)$ a un module maximal aux points de variations brusques de $(f * \theta_a)(b)$. En considérant la dérivée seconde, $\text{TO}_2 \{f\}(b, a) = a^2 \frac{\partial^2}{\partial b^2} (f * \theta_a)(b)$ a des maxima qui correspondent aux maxima locaux de la courbure de f . Plus généralement, les composantes de la transformée en ondelettes sont proportionnelles aux coordonnées du vecteur gradient de f lissé par θ_a . Ainsi, avec un tel opérateur différentiel multiéchelle, toutes les singularités d'un signal sont détectées en suivant les modules maxima d'ondelettes dans les échelles les plus fines. En outre, il a été démontré que si le signal f a une transformée de Fourier à bande limitée et si l'ondelette utilisée $\psi = -\frac{\partial \theta}{\partial x}$ est à support compact, alors les modules maxima des coefficients d'ondelettes constituent une représentation compacte et stable du signal.

Pour analyser localement l'allure du spectre de vagues, observé par imagerie RSO, nous définissons une ondelette de détection de contours par produit séparable de deux ondelettes monodimensionnelles dyadiques. Leur transformée de Fourier (en 2D) s'écrit alors :

$$\begin{aligned} \text{TF}\{\psi^{\text{hori}}\}(\omega_{\text{hori}}, \omega_{\text{vert}}) &= \text{TF}\{g\}\left(\frac{\omega_{\text{hori}}}{2}\right) \text{TF}\{\phi\}\left(\frac{\omega_{\text{hori}}}{2}\right) \text{TF}\{\phi\}\left(\frac{\omega_{\text{vert}}}{2}\right) \\ \text{TF}\{\psi^{\text{vert}}\}(\omega_{\text{hori}}, \omega_{\text{vert}}) &= \text{TF}\{g\}\left(\frac{\omega_{\text{vert}}}{2}\right) \text{TF}\{\phi\}\left(\frac{\omega_{\text{hori}}}{2}\right) \text{TF}\{\phi\}\left(\frac{\omega_{\text{vert}}}{2}\right) \end{aligned}$$

avec $\text{TF}\{\phi\}(\omega) = \left(\frac{\sin \frac{\omega}{2}}{\frac{\omega}{2}}\right)^{m+1} e^{-j\varepsilon \frac{\omega}{2}}$,

$$\varepsilon = \begin{cases} 1 & \text{pour } m \text{ pair} \\ 0 & \text{pour } m \text{ impair} \end{cases}$$

Ce qui donne naissance à des coefficients de filtres passes-bas $\text{TF}\{h\}(\omega) = \sqrt{2} (\cos \frac{\omega}{2})^{m+1} e^{-j\varepsilon \frac{\omega}{2}}$ qui correspondent à une B-spline de degré m .

Parallèlement, g est une approximation discrète de la dérivation, de transformée de Fourier :

$$\text{TF}\{g\}(\omega) = -j \sqrt{2} (\sin \frac{\omega}{2})^{m+1} e^{-j\varepsilon \frac{\omega}{2}}$$

De façon à analyser le spectre de vague le plus localement possible, nous avons choisi une fonction d'échelle la plus courte possible et donc une fonction $\theta(\cdot)$ dont la transformée de Fourier soit une spline cubique. La décomposition multiéchelle conduit donc à une série d'images de coefficients d'ondelettes représentant des détails à des échelles ℓ de plus en plus grossières ($0 \leq \ell < L$), et une image lissée représentant une approximation (à l'échelle L) de l'image originale (cf. figure 2). Une observation f peut donc être représentée avec ses détails à différentes échelles par :

$$f \longrightarrow \begin{cases} \Theta_L & = f * \theta(2^{-(L-1)}x, 2^{-(L-1)}y) \\ \Psi_\ell^{\text{hori}} & = f * \psi^{\text{hori}}(2^{-\ell}x, 2^{-\ell}y) \text{ pour } 0 \leq \ell < L \\ \Psi_\ell^{\text{vert}} & = f * \psi^{\text{vert}}(2^{-\ell}x, 2^{-\ell}y) \text{ pour } 0 \leq \ell < L, \end{cases}$$

ce qui correspond à découper le spectre de Fourier de façon dyadique tous les $\nu_{\max}/2^{\ell+1}$, $0 \leq \ell < L$.

Remarque : Il faut noter ici que le vecteur $(\Psi_\ell^{\text{hori}}, \Psi_\ell^{\text{vert}})^t$ est proportionnel au vecteur gradient de f lissé par θ_{2^ℓ} . Il n'y a donc pas, dans ce type de décomposition, de fonction d'ondelettes diagonale comme dans le cas des ondelettes multirésolution définies en deux dimensions couramment utilisées. De plus, cette décomposition est bâtie pour caractériser les structures locales d'un signal et il n'a pas été question de définir une orthogonalité entre les espaces engendrés par $\psi_{2^\ell}^{\text{hori}}$, $\psi_{2^\ell}^{\text{vert}}$ et ϕ_{2^ℓ} . Il sera donc nécessaire de considérer une éventuelle corrélation entre les coefficients d'ondelettes le long des décompositions. Dans la pratique, nous n'effectuons pas plus de trois ou quatre décompositions puisque les images $\Phi_{L=3}$ ou $\Phi_{L=4}$ représentent l'observation à une résolution plus grossière que la longueur d'onde de la houle, ce qui est suffisant pour l'application visée.

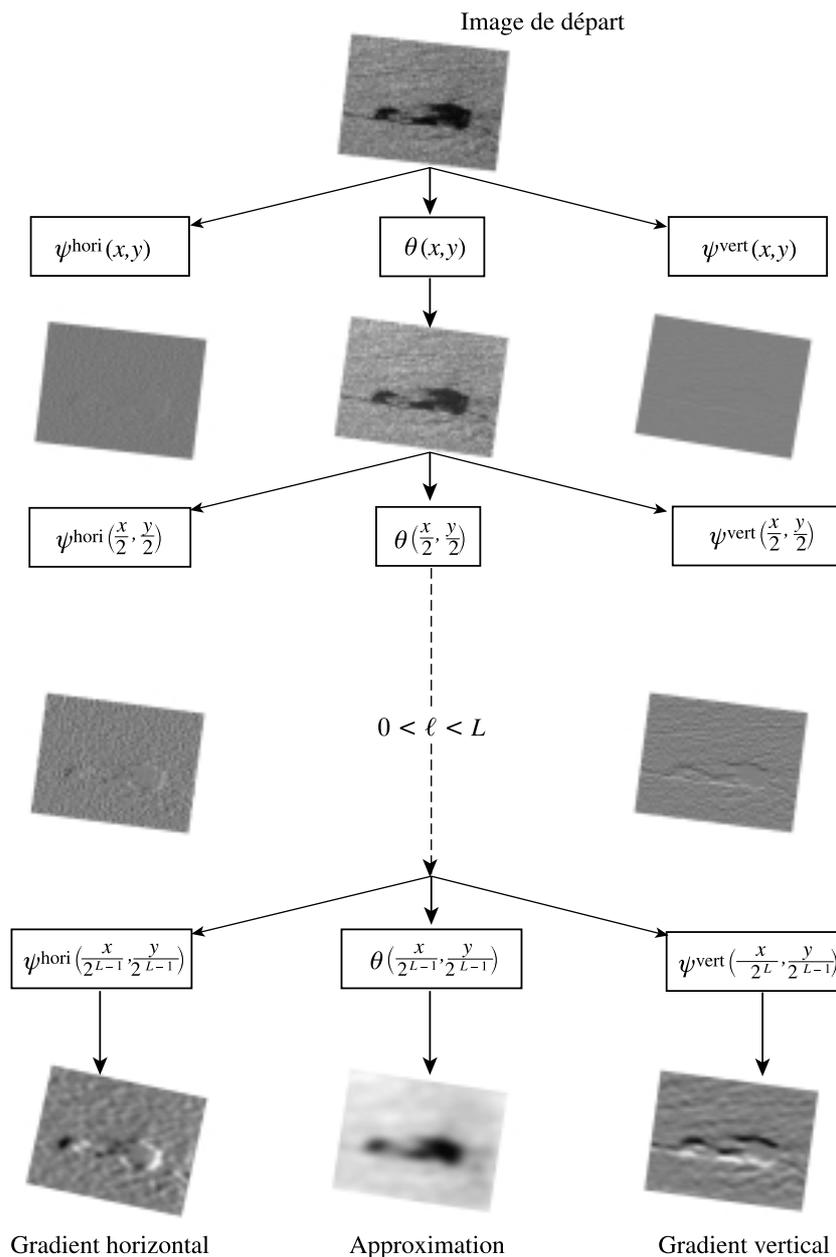


Figure 2. Décomposition multiéchelle d'une image. L'information initiale est parfaitement caractérisée par les bandes de coefficients d'ondelettes (images Ψ_ℓ issues de la convolution avec les fonctions $\psi(2^{-\ell}x, 2^{-\ell}y)$ en ligne et en colonne) et de l'image d'approximation à l'échelle L (image Φ_L issue de la convolution avec $\theta(\frac{x}{2^{L-1}}, \frac{y}{2^{L-1}})$).

2.2. Caractérisation statistique des coefficients d'ondelettes

Nous présentons les familles de lois paramétriques que nous avons utilisées pour caractériser les distributions des différentes bandes de décomposition de la représentation multiéchelle. Nous avons choisi de caractériser les distributions des coefficients passe-bas Θ_L par des lois provenant du système de Pearson, conformément aux types de lois à considérer pour une image RSO [16]. En ce qui concerne les coefficients passe-haut Ψ_ℓ^{hori} et Ψ_ℓ^{vert} , l'analyse des formes des distributions nous a

conduit à considérer les familles de lois issues du système des Gaussiennes Généralisées [17].

2.2.1. Caractérisation des coefficients de basse fréquence - Système de Pearson

L'image de basses fréquences, Θ_L , obtenue par convolution avec un filtre passe-bas $\theta(2^{-(L-1)}x, 2^{-(L-1)}y)$, présente un histogramme lissé de même forme que l'historgramme de l'image originale. Il est souvent admis que la modélisation statistique

des observations radar suit, dans les zones homogènes (où les caractéristiques physiques de rétrodiffusion sont stationnaires), une loi Gaussienne circulaire complexe. En effet, dans chaque cellule de résolution radar, un grand nombre N_d de diffuseurs élémentaires intervient de façon cohérente (par une contribution en module et phase de l'onde électromagnétique et non par une simple contribution énergétique). Alors que chaque rétrodiffusion élémentaire est déterministe et se résout en utilisant les coefficients de réflexion de Fresnel, la contribution des N_d rétrodiffuseurs devient aléatoire puisqu'on ne maîtrise pas le nombre lui-même de rétrodiffuseurs, leurs caractéristiques géométriques, leur orientation... Pour la plupart des images radar, on admet que l'amplitude se distribue selon une loi Gamma ou Gamma généralisée, avec des moments statistiques liés à la réflectivité des diffuseurs élémentaires. C'est ainsi que l'on introduit la modélisation multiplicative du chatoiement pour exprimer ce hiatus entre la variabilité des pixels d'une image radar sur une zone homogène et la constance ou stationnarité supposée du coefficient de réflexion. Pour une image radar de la surface de la mer, les hypothèses habituellement posées ne sont plus vérifiables et même parfois fausses [18]:

- Le nombre de rétrodiffuseurs peut ne pas être suffisant pour valider la loi des grands nombres et considérer un chatoiement pleinement développé;
- Les rétrodiffuseurs élémentaires ne sont plus indépendants entre eux. La description faite du spectre de vagues à la surface de la mer nous interdit à présent de considérer que l'énergie du spectre de vagues est Gaussienne en chaque longueur d'onde et indépendante de la longueur d'onde.
- Les rétrodiffuseurs élémentaires sont en mouvement.

C'est pourquoi nous n'avons pas appliqué de filtrage anti-chatoiement avant le traitement mais, au contraire, utilisé les lois induites par ce phénomène pour faciliter la segmentation de la rugosité de surface. En effet, nous observons une certaine similitude entre les distributions présentes dans les images RSO de la surface de la mer (distributions plutôt Gaussiennes ou dissymétriques à queue lourde) et les lois définies *a priori* lorsque les conditions théoriques d'un chatoiement pleinement développé sont respectées.

Ainsi, nous avons choisi d'utiliser le système de Pearson [19] qui s'est avéré très performant pour la segmentation d'images radar [20], [21]. Ce système est constitué essentiellement de huit familles de lois (incluant la loi Gaussienne, la loi Gamma, les lois Beta, ...) et offre une très large variété de formes (lois symétriques ou non, lois à support borné, semi-borné ou défini partout). Chacune des lois du système peut être caractérisée de manière unique à l'aide de sa moyenne (μ_1) et de ses trois premiers moments centrés (μ_2, \dots, μ_4). Toutes les familles du système peuvent être représentées dans le diagramme de Pearson (cf. figure 3) dont les axes sont définis par les coefficients β_1 et β_2 tels que :

- Dissymétrie $\sqrt{\beta_1}$ avec $\beta_1 = \frac{\mu_3^2}{\mu_2^3}$,
- Aplatissement $\beta_2 = \frac{\mu_4}{\mu_2^2}$.

La loi Gaussienne est située à ($\beta_1 = 0, \beta_2 = 3, N$), les lois Gamma (III) se situent sur la droite d'équation $\beta_2 = 1.5 \beta_1 + 3$. Les lois Beta de première espèce (I) se situent sous cette droite, contrairement aux lois Beta de seconde espèce (VI) et aux lois de type IV qui se situent au dessus de celle-ci. Ces deux dernières familles sont séparées par la courbe correspondant aux lois Gamma inverse (V), d'équation

$$\beta_2 = \frac{3}{\beta_1 - 32} \left(-13\beta_1 - 16 - 2(\beta_1 + 4)^{3/2} \right),$$

avec $\beta_1 < \frac{96}{25}$.

Il est donc possible d'estimer les moments empiriques d'une distribution à partir d'échantillons et de déterminer, grâce au couple de coordonnées (β_1, β_2), la famille de lois et les paramètres qui caractérisent précisément la densité de probabilité (ddp) dans cette famille.

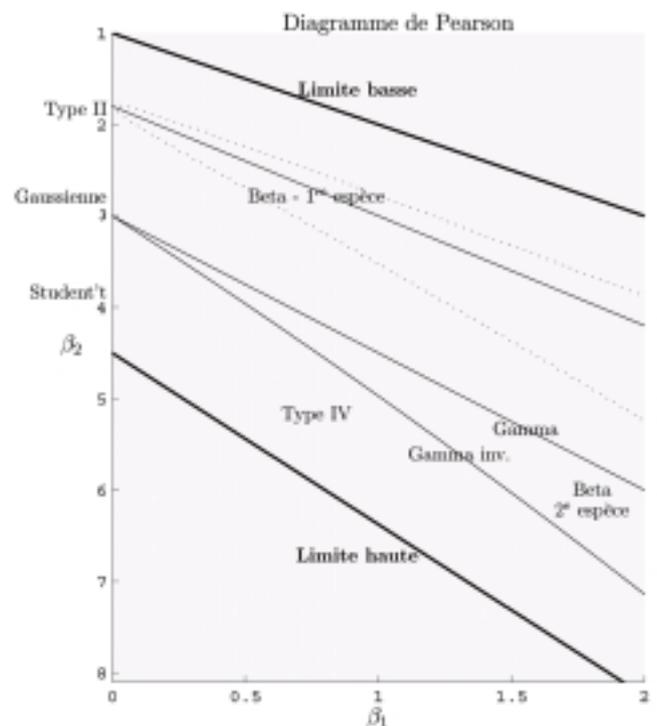


Figure 3. Caractérisation des huit familles de lois du système de Pearson dans le diagramme (β_1, β_2). Notez l'inversion de l'axe β_2 .

2.2.2. Caractérisation des coefficients de haute fréquence - Gaussiennes Généralisées

On observe [17], [22] que la ddp des coefficients d'ondelette, générés par la plupart des ondelettes mères, peut être modélisée globalement par la famille des lois Gaussiennes Généralisées d'expression :

$$p(x; \mu, \alpha, \beta) = \frac{\beta}{2\alpha \Gamma(\frac{1}{\beta})} e^{-\left(\frac{|x-\mu|}{\alpha}\right)^\beta},$$

où $\Gamma(\cdot)$ est la fonction Gamma, μ représente la moyenne, α est un paramètre d'échelle qui caractérise la largeur du mode de la ddp (cf. la variance), et où β est un paramètre de forme. Par exemple, pour $\beta = 1$, on caractérise la loi de Laplace et pour $\beta = 2$, on retrouve la distribution Gaussienne de variance $\frac{\alpha}{2}$.

L'estimation des paramètres peut être réalisée par la méthode des moments, comme dans le cas du système de Pearson. Cependant, l'estimation par maximum de vraisemblance est plus robuste pour les distributions à queue lourde et lorsque le nombre d'échantillons est limité (ce qui peut-être le cas puisque l'estimation des paramètres s'effectue conditionnellement à chacune des classes comme expliqué dans la section suivante). L'estimation des Gaussiennes Généralisées par maximum de vraisemblance ne conduit pas à une augmentation importante de la complexité algorithmique.

à partir d'un ensemble d'échantillons $\mathbf{x} = \{x_i; i = 1, 2, \dots, N\}$ indépendants, la fonction de log-vraisemblance à maximiser \mathcal{L} a pour expression :

$$\mathcal{L}(\mathbf{x}; \mu, \alpha, \beta) = \log \prod_{i=1}^N p(x_i; \mu, \alpha, \beta),$$

et revient à minimiser la différence d'entropie entre une Gaussienne généralisée de paramètres (μ, α, β) et la ddp engendrée par l'ensemble des échantillons \mathbf{x} . Cette minimisation procure, en général, une racine unique dans le cas des Gaussiennes généralisées. Il est important de remarquer que si globalement, dans toute l'image la distribution des coefficients d'ondelette est centrée, ce n'est pas nécessairement le cas sur une zone de l'image. Il est donc nécessaire d'estimer les trois paramètres. Nous obtenons donc le système d'équations suivant :

$$\begin{cases} \min_{\mu} \sum_{i=1}^N |x_i - \mu|^\beta, \\ \frac{\partial \mathcal{L}(\mathbf{x}; \mu, \alpha, \beta)}{\partial \alpha} = -\frac{N}{\alpha} + \frac{\beta}{\alpha^{\beta+1}} \sum_{i=1}^N |x_i - \mu|^\beta = 0, \\ \frac{\partial \mathcal{L}(\mathbf{x}; \mu, \alpha, \beta)}{\partial \beta} = \frac{N}{\beta} + \frac{N \Psi(\frac{1}{\beta})}{\beta^2} - \sum_{i=1}^N \left(\frac{|x_i - \mu|}{\alpha}\right)^\beta \log\left(\frac{|x_i - \mu|}{\alpha}\right) = 0, \end{cases}$$

où $\Psi(\cdot) = \frac{\Gamma'(\cdot)}{\Gamma(\cdot)}$ représente la fonction Digamma.

La première équation pose quelques difficultés de minimisation puisqu'elle est non dérivable et dépend simultanément de deux paramètres. Pour résoudre ce problème, nous avons développé une méthode numérique qui consiste à minimiser $\sum_{i=1}^N |x_i - \mu|^\beta$ par estimation successive des paramètres β et μ selon :

$$\begin{cases} \hat{\beta} \text{ tel que } \frac{\Gamma\left(\frac{2}{\hat{\beta}}\right)}{\sqrt{\Gamma\left(\frac{1}{\hat{\beta}}\right)\Gamma\left(\frac{3}{\hat{\beta}}\right)}} = \frac{\frac{1}{N} \sum_{i=1}^N |x_i - \hat{\mu}|}{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{\mu})^2}}, \\ \hat{\mu} \text{ tel que } \min_{\mu} \sum_{i=1}^N |x_i - \hat{\mu}|^{\hat{\beta}}, \end{cases}$$

la première estimation de μ étant assurée par la moyenne empirique de l'échantillon: $\hat{\mu} = \frac{1}{N} \sum_{i=1}^N x_i$.

Une fois $\hat{\mu}$ estimé, il est possible d'affiner l'estimation de β en cherchant la racine de :

$$1 + \frac{\Psi\left(\frac{1}{\hat{\beta}}\right)}{\hat{\beta}} - \frac{\sum_{i=1}^N |x_i - \hat{\mu}|^{\hat{\beta}} \log |x_i - \hat{\mu}|}{\sum_{i=1}^N |x_i - \hat{\mu}|^{\hat{\beta}}} + \frac{\log\left(\frac{\hat{\beta}}{N} \sum_{i=1}^N |x_i - \hat{\mu}|^{\hat{\beta}}\right)}{\hat{\beta}} = 0.$$

Finalement, le paramètre d'échelle α est déterminé directement par :

$$\hat{\alpha} = \left(\frac{\hat{\beta}}{N} \sum_{i=1}^N |x_i - \hat{\mu}|^{\hat{\beta}}\right)^{\frac{1}{\hat{\beta}}}.$$

Pour illustrer la méthode, nous avons représenté dans la figure 4 les histogrammes de trois bandes de décomposition en ondelettes issues de la décomposition multiéchelle de la figure 2 et les lois Gaussiennes Généralisées les plus vraisemblables.

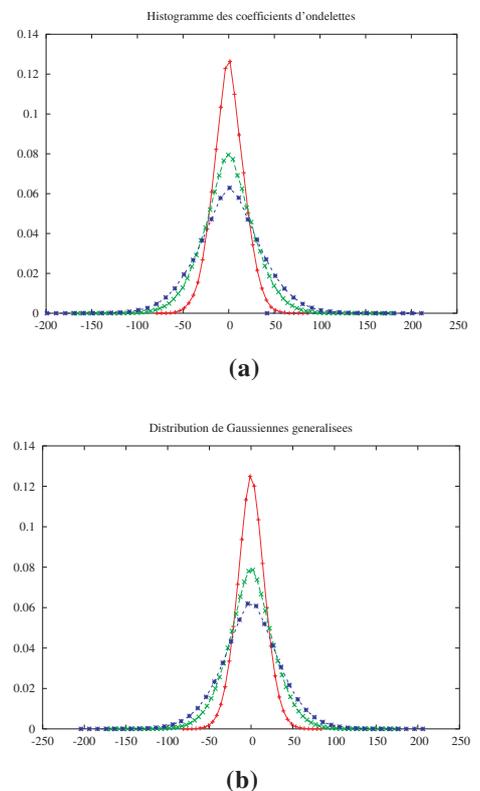


Figure 4. Histogrammes des coefficients d'ondelettes issus de décompositions à trois échelles différentes (a) et les trois Gaussiennes Généralisées correspondantes, estimées par maximum de vraisemblance (b).

3. Segmentation par chaîne de Markov cachée multicomposante

Grâce à la transformation multiéchelle, l'observation initiale f est représentée par un vecteur d'observations à $M = 2L + 1$ composantes :

$$(\Theta_L, \Psi_{L-1}^{\text{hori}}, \Psi_{L-1}^{\text{vert}}, \dots, \Psi_\ell^{\text{hori}}, \Psi_\ell^{\text{vert}}, \dots, \Psi_0^{\text{hori}}, \Psi_0^{\text{vert}})^t.$$

La classification de l'image initiale, dans sa représentation multiéchelle, nécessite donc le développement d'un algorithme de classification vectoriel (ou multicomposante).

Pour cela, nous proposons d'utiliser une extension de l'algorithme de Chaîne de Markov Cachée (CMC) au cadre vectoriel des données. Cette méthode de segmentation est relativement générale et peut s'appliquer dans des contextes différents (multispectral [23], multitemporel [24]). La spécialisation du modèle au contexte multiéchelle est effectuée par le choix de la forme des lois d'attache aux données.

3.1. Présentation du modèle des CMC

La restauration bayésienne dans le contexte des modèles de Markov cachés fait partie des méthodes de classification les plus robustes. Ce succès est principalement dû au fait que lorsque le processus caché X peut être modélisé par une chaîne de Markov finie, alors X peut être reconstruit à partir du processus observé Y selon différents critères bayésiens de classification comme le MPM (« Maximum Posterior Mode ») ou le MAP (« Maximum a Posteriori »).

Dans le contexte de classification non supervisée, les paramètres du modèle de Markov sont inconnus et doivent être estimés à partir des seules données observées. Des méthodes itératives bien connues telles que l'algorithme EM (« Estimation-Maximization ») ou SEM (« Stochastic EM ») peuvent être utilisées. Dans ce travail, nous avons considéré une troisième méthode appelée ICE (« Iterative Conditional Estimation ») [25], dont l'intérêt en segmentation a été illustré dans un certain nombre de situations, en particulier dans divers modèles de Markov cachés (champs, chaînes ou arbres) [26], pour la segmentation d'images de télédétection [27], radar [28], sonar [29], médicale [30], ou vidéo [33].

Le modèle des CMC constitue une alternative intéressante et parfois compétitive comparé au modèle des champs de Markov cachés, même si ce dernier fournit une modélisation plus intuitive et plus précise des relations spatiales dans l'image [29]. Le gain en temps de calcul est généralement très significatif. Dans le cadre des données vectorielles issues de la décomposition multiéchelle, la première étape consiste à transformer les M images en autant de chaînes en appliquant le parcours de Peano [34] sur chacune d'elles. La taille des chaînes correspond au

nombre de pixels dans les images (noté N). Nous obtenons donc M séries de N données réelles. Pour chaque composante m , $1 \leq m \leq M$, la séquence de données est notée $y^m = (y_1^m, \dots, y_N^m)$. Pour chaque indice n , $1 \leq n \leq N$, le vecteur de M composantes ainsi constitué est noté $\vec{y}_n = (y_n^1, \dots, y_n^M)^t$. L'ensemble des séquences est noté $\vec{y} = (y^1, \dots, y^M)^t = (\vec{y}_1, \dots, \vec{y}_N)$. Le principe de construction et les notations sont illustrés dans la figure 5.

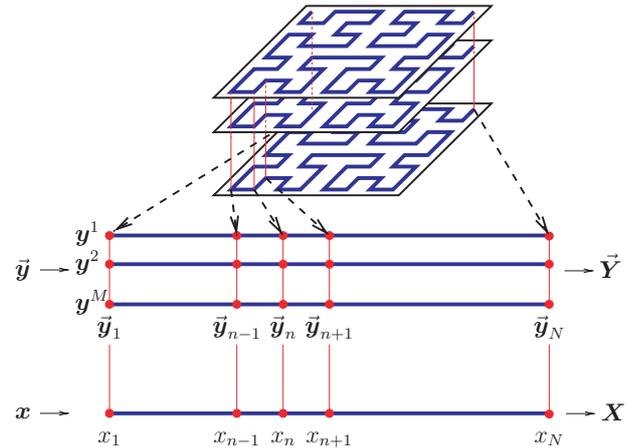


Figure 5. Parcours de Peano et représentation des données multicomposantes.

3.2. Algorithme de segmentation

L'approche statistique consiste à considérer que chaque observation \vec{y}_n , à valeurs dans \mathbb{R}^M , est la réalisation d'un vecteur aléatoire \vec{Y}_n , qu'il convient de classer parmi l'ensemble de K classes $\Omega = \{\omega_1, \dots, \omega_K\}$. Pour effectuer la segmentation, l'objectif est donc d'estimer une réalisation x du processus caché markovien et stationnaire $x = (X_1, \dots, X_n, \dots, X_N)$, pour X_n à valeurs dans Ω . En considérant les deux hypothèses classiques - Les vecteurs aléatoires $(\vec{Y}_n)_{1 \leq n \leq N}$ sont indépendants conditionnellement à X :

$$p(\vec{Y} = \vec{y} | X = x) = \prod_n p(\vec{Y}_n = \vec{y}_n | X = x),$$

- La distribution de \vec{Y}_n conditionnellement à X est égale à sa distribution conditionnelle à X_n :

$$p(\vec{Y}_n = \vec{y}_n | X = x) = p(\vec{Y}_n = \vec{y}_n | X_n = x_n),$$

nous obtenons le graphe de dépendance de la chaîne de Markov de la figure 6. Il est important de noter qu'aucune hypothèse n'est faite quant à l'indépendance des composantes Y_n^m du vecteur aléatoire \vec{Y}_n conditionnellement à X_n . Il est alors possible de tenir compte des liens statistiques entre les bandes de la décomposition multiéchelle (liens schématisés par les courbes en pointillés), cf. section 3.3.

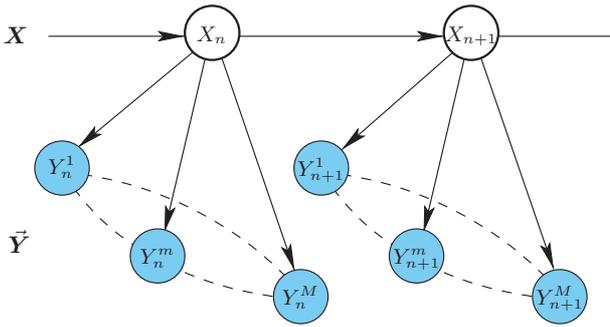


Figure 6. Graphe de dépendance de la chaîne de Markov cachée dans le cas de trois composantes.

Le bilan des paramètres à estimer est le suivant :

- **Paramètres du modèle** (ensemble γ) : nous devons estimer les K^2 paramètres $c(\omega_\ell, \omega_k) = p(X_{n-1} = \omega_\ell, X_n = \omega_k)$ permettant de calculer les probabilités *a priori* $p(\omega_k)$ et les probabilités $p(\omega_k | \omega_\ell)$ de la matrice de transition de X (ces probabilités sont indépendantes de n).

- **Paramètres d'attache aux données** (ensemble δ) : nous devons estimer les paramètres des K ddp $f_{\omega_k}(\vec{y}_n)$, à support sur \mathbb{R}^M , correspondant à $p(\vec{Y}_n = \vec{y}_n | X_n = \omega_k)$ la probabilité d'une observation *bruitée* \vec{y}_n sachant que X_n appartient à la classe ω_k . Dans un cadre Gaussien, les paramètres à estimer sont au nombre de $M \times (M + 1)$ correspondant à M moyennes et une matrice de covariance de dimension $M \times M$.

L'extension de l'algorithme d'estimation ICE aux cas de données vectorielles est relativement directe, le lecteur intéressé trouvera le détail de la méthode en annexe. Cependant, à chaque itération, nous sommes confronté à l'estimation de K lois à M dimensions non Gaussiennes.

3.3. Estimation des lois multidimensionnelles

Pour une itération p de l'algorithme ICE et pour une classe ω_k fixée, nous notons par \vec{z} les données de \vec{y} qui appartiennent à la classe ω_k . Nous cherchons à estimer les paramètres de la loi d'attache aux données multidimensionnelles f_{ω_k} . Dans un cadre non Gaussien, il est difficile d'estimer des lois multidimensionnelles. Le point de vue de l'analyse multivariée consiste à décomposer l'estimation de lois M -dimensionnelles en l'estimation de M lois monodimensionnelles. Plusieurs stratégies sont possibles, en fonction des hypothèses faites sur les données.

- Si les données sont supposées indépendantes [35], alors f_{ω_k} est le produit direct de M densités $f_{\omega_k}^m$ définies sur \mathbb{R} :

$$f_{\omega_k}(\vec{z}_n) = \prod_{m=1}^M f_{\omega_k}^m(z_n^m). \quad (2)$$

Cependant, cette hypothèse d'indépendance apparaît comme peu justifiée dans le contexte considéré.

- Si les données ne peuvent pas être supposées indépendantes, alors f_{ω_k} ne peut plus être décomposé directement en produit de M densités $f_{\omega_k}^m$. L'Analyse en Composantes Indépendantes (ACI) permet de projeter les vecteurs aléatoires \vec{z}_n dans un nouvel espace où les composantes sont statistiquement indépendantes [36]. Or la stratégie sous-jacente utilise un résultat issu du théorème de la limite centrale : *la distribution de la somme de N variables aléatoires indépendantes tend vers une Gaussienne quand N tend vers l'infini*, et plus précisément son corollaire : *la somme de deux variables aléatoires centrées est plus proche d'une Gaussienne que n'importe laquelle des deux variables initiales*. Aussi l'ACI revient-elle à maximiser un critère de non gaussianité sur les composantes projetées de \vec{z}_n [37], [38]. Malheureusement la recherche de maximum de non gaussianité engendre des types de distribution souvent multimodales. Il devient alors très difficile de considérer que ces lois multimodales soient caractéristiques de la distribution des observations restreintes à une seule classe !

- Une solution sous-optimale dans le cas Gaussien, mais mieux adaptée dans la pratique, consiste à utiliser l'Analyse en Composantes Principales (ACP). Le principe de l'algorithme est de décorréler les données originales pour revenir à la forme décrite par l'équation (2) (cf. [39], [40]).

S'il existe une matrice A telle que les données $\vec{t}_n = A\vec{z}_n$ sont décorrélées, alors la matrice de covariance des données \vec{t}_n est diagonale (matrice unité par exemple). Ainsi, nous pouvons écrire $A \Gamma_{\vec{z}} A^t = Id$, avec $\Gamma_{\vec{z}}$ la matrice de covariance des données \vec{z} . En utilisant la transformation de Choleski, une matrice A solution de cette équation s'écrit :

$$A^t = (\text{Choleski}(\Gamma_{\vec{z}}))^{-1}.$$

On vérifie aisément que les variances des données projetées sont unitaires et que leurs covariances sont nulles. À titre d'exemple, pour $M = 2$ composantes, nous obtenons :

$$A = \begin{pmatrix} \frac{1}{\sigma_1} & 0 \\ -\rho & \frac{1}{\sigma_2 \sqrt{1 - \rho^2}} \end{pmatrix},$$

si on note respectivement par σ_1 et σ_2 les variances de \vec{z}^1 et \vec{z}^2 et ρ le coefficient d'intercorrélacion.

Soit $g^m(\cdot)$, $1 \leq m \leq M$, les lois monodimensionnelles estimées grâce aux données décorrélées \vec{t}_n . Nous obtenons :

$$f_{\omega_k}(\vec{z}_n) = |\det A| \prod_{m=1}^M g_{\omega_k}^m(t_n^m). \quad (3)$$

Aucune hypothèse sur la forme des ddp marginales n'est nécessaire. La méthode peut donc très bien s'appliquer dans un cadre Gaussien (il faut alors estimer les moyennes et variances des lois marginales), ou dans le cadre d'un mélange généralisé où les marginales appartiennent à des familles de distributions différentes. C'est le cas des données multiéchelle utilisées pour détecter et caractériser les nappes d'hydrocarbure.

4. Application à la détection de nappes d'hydrocarbure

La méthode de segmentation multiéchelle est donc la suivante. À partir d'une observation de la surface de la mer y acquise par un capteur RSO, nous appliquons la transformation multiéchelle décrite dans la section 2. Ainsi, l'observation y est représentée, sans perte d'information, sous une forme vectorielle avec $\vec{y} = (\Theta_L, \Psi_{L-1}^{\text{hor}}, \Psi_{L-1}^{\text{vert}}, \dots, \Psi_{\ell}^{\text{hor}}, \Psi_{\ell}^{\text{vert}}, \dots, \Psi_0^{\text{hor}}, \Psi_0^{\text{vert}})^t$. Ensuite, cette observation multicomposante est segmentée à l'aide du modèle de chaîne de Markov présenté dans la section 3. Nous rappelons que nous avons choisi d'approcher la ddp des coefficients passe-bas Θ_L par des lois provenant du système de Pearson, et les ddp des coefficients passe-haut Ψ_{ℓ}^{hor} et $\Psi_{\ell}^{\text{vert}}$ ($0 \leq \ell < L$) par des lois issues du système des Gaussiennes Généralisées.

Précisons que le nombre de classes utilisé pour segmenter les images est fixé manuellement. Cette valeur est typiquement égale à deux lorsque l'on souhaite détecter la présence ou l'absence d'hydrocarbure. Néanmoins, une ou deux classes supplémentaires peuvent s'avérer nécessaires pour modéliser un phénomène météorologique comme un front de vent, des grains ou bien un état particulier de l'hydrocarbure comme une émulsion de pétrole et d'eau de mer.

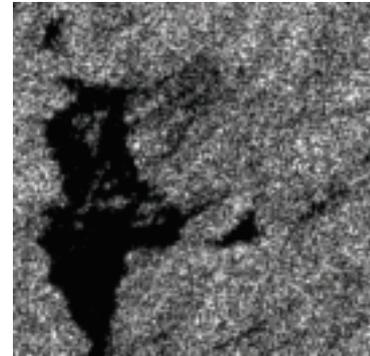
Nous avons testé cet algorithme sur deux types d'images RSO présentant des traces d'hydrocarbure. Nous montrons d'abord des résultats locaux provenant d'une image de haute résolution (résolution décimétrique pour un capteur satellitaire) avec des données ERS, puis des résultats plus globaux avec une image de résolution plus grossière (ASAR d'Envisat en mode *Wide Swath*).

4.1. Résultats avec des données ERS

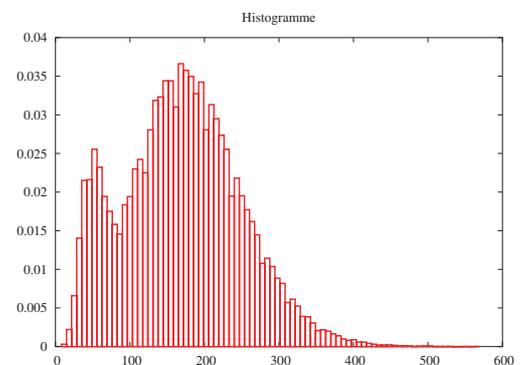
Nous avons utilisé une scène ERS SAR représentant une nappe de pétrole en mer Méditerranée (cf. figure 7). Cette image montre une nappe compacte dans la partie sombre et la mer non polluée qui apparaît de manière plus claire à cause d'une viscosité plus faible et de la présence de vagues. Des zones mitigées sont également observables sur la partie droite de l'image. Compte tenu de la petite taille de ces zones, il ne s'agit pas de variations locales de la vitesse du vent. Par contre, il est fort possible qu'il s'agisse d'une émulsion ou au contraire d'un hydrocarbure plus volatil dans lequel l'atténuation des vagues est moins importante. Cette scène est typique des dégazages effectués en mer Méditerranée.

La difficulté de la localisation des nappes de pétrole n'est pas tant de détecter les grandes nappes homogènes mais plutôt de déterminer précisément les frontières de cette nappe et également de détecter (sans fausses alarmes) des zones plus ambi-

guës telles ces tâches sombres sur le côté droit de l'image. On sait par exemple que le bord d'une nappe qui se situe au vent est plus franc que le bord sous le vent qui est plus étiré et se transforme en émulsion.



(a)



(b)

Figure 7. Image ERS SAR d'une nappe de pétrole (a) et son histogramme normalisé (b).

La figure 8 regroupe l'ensemble des résultats de segmentation obtenus avec cette image. En guise de comparaison, nous avons segmenté l'image selon différentes méthodes, avec deux ou trois classes (resp. 1^{re} et 2^e ligne). Le seuil radiométrique de la méthode de seuillage a été fixé manuellement, compte-tenu de la forme de l'histogramme.

L'algorithme de seuillage et la méthode basée sur l'algorithme ICE aveugle permettent d'illustrer les carences des stratégies de segmentation basées uniquement sur la radiométrie de la scène. Bien que la nappe soit correctement localisée, les figures (a) et (d) montrent de très nombreuses fausses alarmes en mer libre, où l'on trouve de nombreuses petites zones noires qui n'ont pas de réelle signification physique. L'algorithme s'avère incapable de prendre en compte la texture générée par les vagues et la troisième classe, introduite dans l'image (d), participe à la modélisation de la mer libre.

En ce qui concerne les deux modèles de Markov, dans le cas de deux classes, le taux d'erreur en mer libre est très nettement réduit. Par contre, c'est la détection de la nappe elle-même qui

est particulièrement insatisfaisante. L'image (c) propose, quant à elle, une localisation plus précise de la nappe compacte. La prise en compte de l'information contextuelle, radiométrique et spectrale, par la modélisation markovienne permet donc d'améliorer sensiblement la qualité de détection. En contre-partie la zone de mer libre à l'intérieur de la nappe se trouve absorbée par la classe modélisant la nappe.

L'intérêt spécifique du modèle vectoriel sur la décomposition multiéchelle est illustré dans l'image (f). En effet, lorsque l'information de l'image ERS est représentée sous forme multiéchelle et que l'algorithme de segmentation par chaîne de Markov effectue une segmentation des variations locales des textures qui se rattachent au spectre de vague, les résultats obtenus ont un sens opérationnel bien plus satisfaisant. Ceci montre que la qualité de segmentation n'est pas uniquement liée à la markovianité mais également à la façon dont la scène est représentée. La segmentation porte alors un double sens : l'information lissée de Φ_L permet de régulariser l'observation initiale alors que l'ensemble des coefficients d'ondelettes $\Psi_{\ell}^{\text{hori}}$ ou $\Psi_{\ell}^{\text{vert}}$ caractérisent toutes les nuances des textures en chaque point.

D'un point de vue thématique, la nappe de pétrole est parfaitement détectée. De façon similaire, la mer libre est caractérisée sans fausse alarme ni manque de détection. La classe intermédiaire semble ici avoir une interprétation particulièrement intéressante. En effet, cette classe se spécialise, d'une part, à l'in-

terface entre les zones de mer libre et la nappe de pétrole et d'autre part sur les zones effectivement douteuses et ambiguës où des mesures terrain pourraient révéler des galettes disloquées ou un hydrocarbure plus volatil. En fait, lorsque l'hydrocarbure est au contact de l'eau de mer, il se charge d'eau et, en se désagrégeant, produit une émulsion dont la viscosité est effectivement très différente de celle de l'hydrocarbure initial. De plus, les hydrocarbures légers se diffusent plus à la surface de l'eau.

4.2. Résultat avec des données Envisat

Le naufrage du Prestige le 19 novembre 2002 a confirmé l'intérêt de la télédétection radar dans un contexte opérationnel pour détecter la présence de nappes d'hydrocarbure. En effet, dans des conditions météorologiques sévères, par ciel couvert, ou de nuit, une acquisition optique n'est d'aucun secours alors que les plates-formes satellitaires embarquant des capteurs RSO fournissent de jour comme de nuit, par temps couvert ou ciel clair des données de qualité identique. Néanmoins, la seule détection de zones sombres sur une image n'est pas suffisante pour déterminer la présence d'hydrocarbure. Il peut s'agir d'absence de vent, de vent très violent ou de phénomènes océanographiques comme les *up-wellings*.

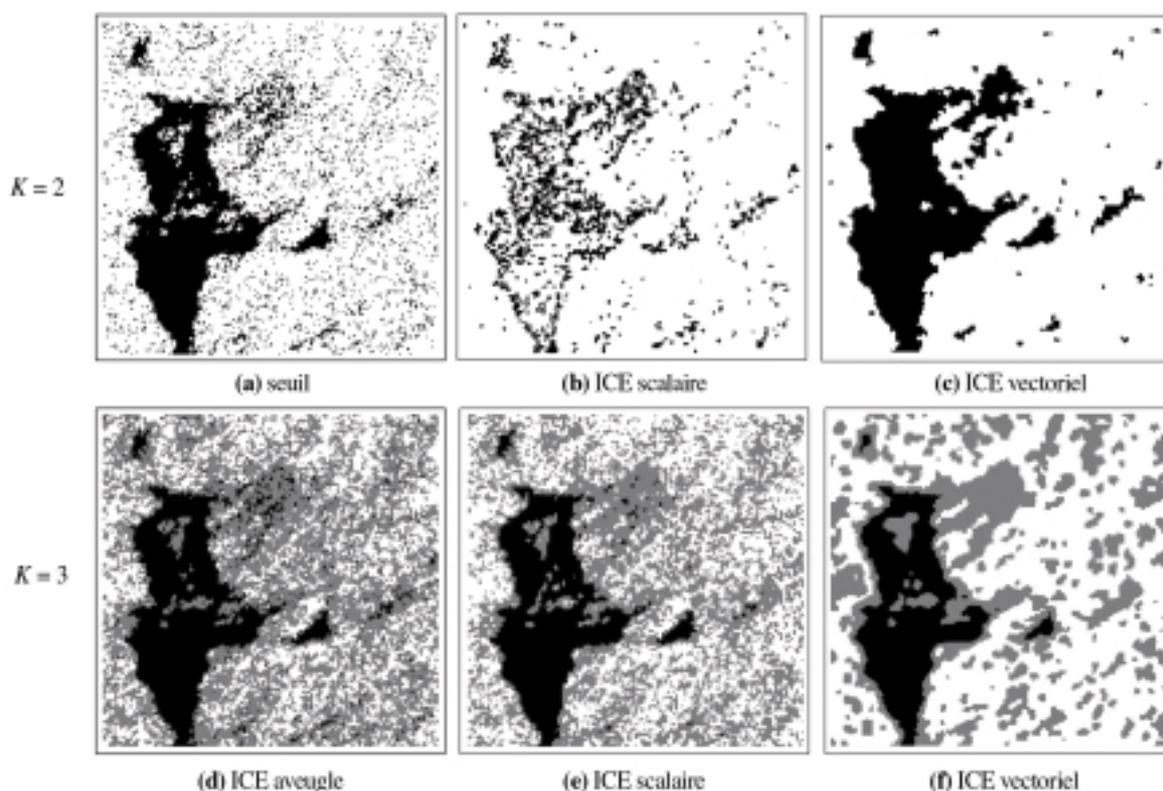
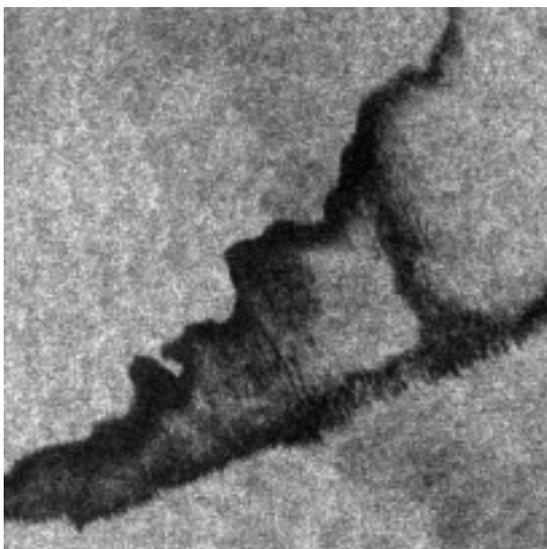


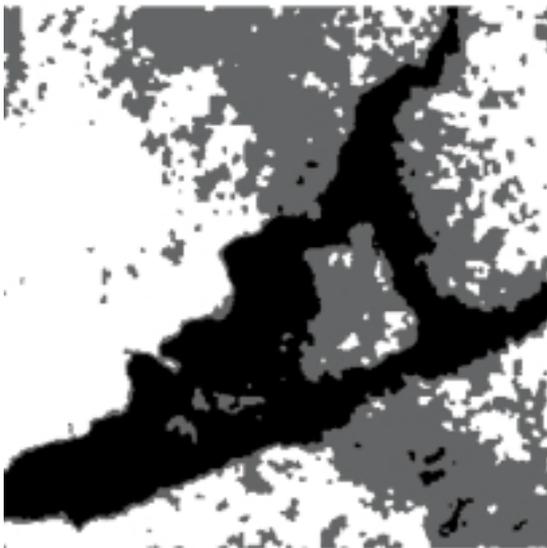
Figure 8. Résultats de segmentation de l'image de la figure 7 pour $K = 2$ et $K = 3$ classes. La première colonne correspond au seuillage (2 classes) et la méthode ICE aveugle (3 classes). La seconde colonne correspond à l'algorithme de CMC scalaire appliqué sur l'image originale. La troisième colonne correspond à l'algorithme de CMC vectorielle appliqué sur la décomposition multiéchelle.

L'intérêt supplémentaire de l'approche présentée ici est d'effectuer une segmentation qui s'appuie sur l'estimation préalable d'un mélange de lois. Ainsi, une fois la segmentation effectuée, une analyse des types et des formes des lois obtenues permet de valider ou d'infirmer la présence effective d'hydrocarbure dans une tâche sombre de l'image.

L'image de la figure 9 (a) présente une traînée d'hydrocarbure déversée juste avant le naufrage du Prestige, le 17 novembre 2002. Deux traînées d'hydrocarbure se séparent à cause de l'état de mer, du vent et de la viscosité du pétrole. Aussi, il devient difficile de caractériser la présence d'hydrocarbure entre ces deux traînées. De plus, les conditions atmosphériques induisent une pression particulière sur la surface de la mer et un front



(a)



(b)

Figure 9. Image (a) : acquisition ASAR d'Envisat effectuée lors du naufrage du Prestige ©ESA. Image (b) : segmentation de l'hydrocarbure par chaîne de Markov multicomposante le long d'une décomposition multiéchelle de l'image.

apparaît avec une radiométrie plus sombre sans pour autant être révélateur de la présence d'huile. L'image 9 (b) présente le résultat de segmentation en trois classes. Une première classe se spécialise sur la nappe d'hydrocarbure, une seconde sur une zone ambiguë dans laquelle la surface de la mer apparaît plus sombre, et une troisième caractérisant une mer libre sans hydrocarbure.

Si le résultat de la segmentation peut porter à confusion en laissant une classe ambiguë, l'analyse des types de lois obtenues (cf. table 2) permet de lever ces ambiguïtés et de décider avec plus de certitude de la présence ou de l'absence d'hydrocarbure dans chacune des classes. Il est intéressant de noter ici que les coefficients d'ondelettes de la classe d'hydrocarbure sont systématiquement caractérisés par des lois ayant une forme plus proche de la loi de Laplace que les lois des coefficients d'ondelettes des autres classes (classe de mer libre et classe dite ambiguë) qui sont plus proches de lois Gaussiennes. Ainsi, cette classe ambiguë peut être affectée *a posteriori* à une zone de mer vierge de pollution, portant sans doute la trace d'un phénomène atmosphérique, comme un coup de vent.

Finalement, nous pouvons conclure que ce type de segmentation agit bien comme une segmentation du spectre de vague local vu par le capteur RSO.

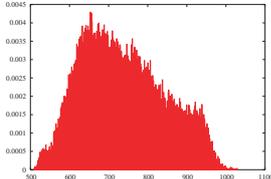
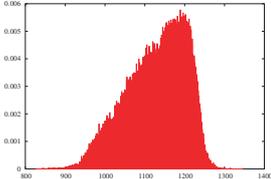
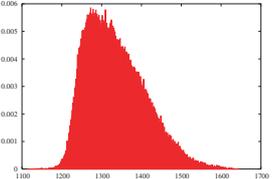
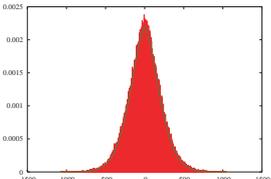
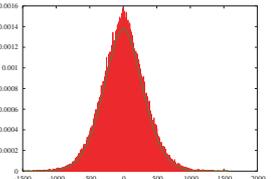
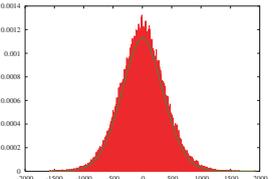
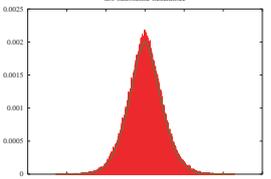
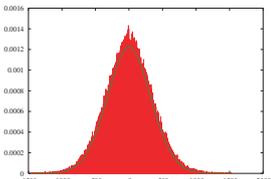
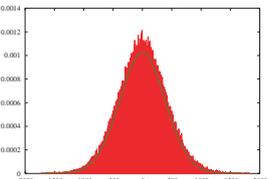
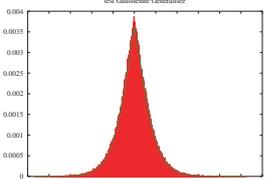
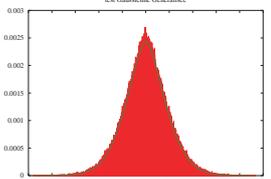
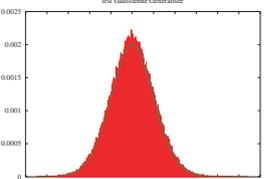
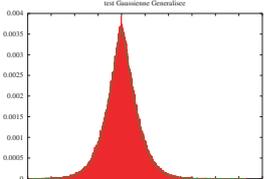
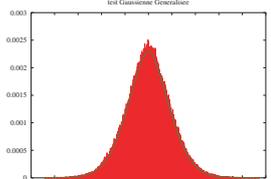
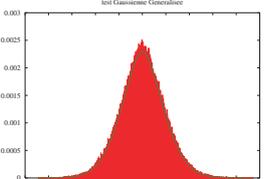
Remarque : d'un point de vue opérationnel, les images radar représentent un volume de données imposant (8000×8000 pour les images ERS) qu'il est nécessaire de prendre en compte lors des traitements. Or, le modèle par chaîne de Markov cachée n'est pas adapté aux images de grande taille étant donné l'occupation mémoire nécessaire à l'algorithme. Pour pallier ce problème, il est possible d'appliquer l'algorithme séquentiellement sur un découpage de l'image en blocs (de taille 1000×1000 par exemple). Cette démarche est valide car :

- La description multiéchelle est locale puisqu'elle est construite par convolutions avec des filtres à réponse impulsionnelle finie. De plus, un recouvrement entre les blocs (qui se nomment alors des *tuiles*) est tout à fait envisageable pour atténuer les éventuels effets de bords.

- Le modèle de Markov utilisé suppose que le processus X soit stationnaire, ce qui suggère que les processus associés aux blocs (ou tuiles) le soient également. Certes cette hypothèse n'est pas toujours vérifiée dans le cas d'images de nappes de pétrole. Néanmoins, l'influence du voisinage de chaque pixel est limité spatialement à quelques dizaines de pixels, puisque dans un modèle Markovien, la corrélation diminue de manière exponentielle avec la distance.

Il est alors possible de réunir les blocs segmentés séparément, par similitudes avec les ddp estimées, pour obtenir une carte de segmentation globale sur une image de grande taille.

Table 2. Histogrammes et lois de chacune des trois classes obtenues à l'issue de la segmentation par chaîne de Markov multicomposante sur la description multiéchelle de l'observation initiale.

Bande	Classe		
	hydrocarbure	ambiguë	mer non polluée
$\Theta_{L=2}$	$\beta_1 = 0,1$ $\beta_2 = 2,25$ 	$\beta_1 = 0,25$ $\beta_2 = 2,53$ 	$\beta_1 = 0,4$ $\beta_2 = 3,2$ 
$\Psi_{\ell=1}^{\text{horiz}}$	$\alpha = 255$ $\beta = 1,62$ 	$\alpha = 406$ $\beta = 1,79$ 	$\alpha = 499$ $\beta = 1,87$ 
$\Psi_{\ell=1}^{\text{vert}}$	$\alpha = 280$ $\beta = 1,69$ 	$\alpha = 460$ $\beta = 1,92$ 	$\alpha = 549$ $\beta = 1,94$ 
$\Psi_{\ell=0}^{\text{horiz}}$	$\alpha = 150$ $\beta = 1,29$ 	$\alpha = 228$ $\beta = 1,60$ 	$\alpha = 281$ $\beta = 1,91$ 
$\Psi_{\ell=0}^{\text{vert}}$	$\alpha = 151$ $\beta = 1,36$ 	$\alpha = 244$ $\beta = 1,74$ 	$\alpha = 286$ $\beta = 1,94$ 

5. Conclusion

Dans ce travail, nous avons présenté une méthode non supervisée de segmentation de nappes d'hydrocarbure basée sur des outils de décomposition multiéchelle et un modèle markovien d'estimation de mélange de lois. Plus précisément, la décomposition multiéchelle a été réalisée par une transformée en ondelettes qui agit comme un opérateur différentiel multiéchelle. La segmentation, quant à elle, est effectuée grâce à une extension vectorielle du modèle de chaîne de Markov cachée. L'estimation des lois d'attache aux données multidimensionnelles est réalisée par ACP, dans lequel chaque composante est issue du système de Pearson (coefficients passe-bas) ou de la

famille des Gaussiennes Généralisées (coefficients passe-haut). Cette méthode effectue une segmentation de la surface de la mer grâce à une caractérisation locale du spectre de vagues vu par un RSO. Aussi, cette stratégie de segmentation effectue-t-elle une détection de différents phénomènes océanographiques et semble idoine pour la détection de nappes d'hydrocarbure sur la surface de la mer.

Néanmoins, il semble que l'hypothèse de stationnarité de la chaîne de Markov soit un handicap pour traiter des images de taille réelle (typiquement de 8000×8000) de façon opérationnelle. Le manque de validité de cette hypothèse est pénalisant puisqu'il induit une segmentation fournissant un mélange de phénomènes mis en commun de façon à obtenir des paramètres de la chaîne de Markov stationnaires. Il devient alors difficile de

cerner les nuances entre un hydrocarbure peu visqueux et une mer non polluée agitée par un vent faible. Ainsi, l'évolution naturelle de cette méthode de segmentation consistera à prendre en compte le caractère non-stationnaire de la surface de la mer en présence de pollution par hydrocarbure.

En outre, la présence de navires induit des points brillants de très forte radiométrie sur les images RSO. Ces anomalies radiométriques sont très pénalisantes pour la caractérisation statistique des coefficients d'ondelettes et perturbent fortement les résultats de segmentation. Il est alors nécessaire de « supprimer » la signature de ces navires. Deux solutions sont envisageables : soit par détection de navires en guise de prétraitement, soit en appliquant une décomposition non-linéaire à l'aide de filtres médians, plutôt que la décomposition en ondelettes [41]. Cette dernière piste constitue la principale perspective à ces travaux.

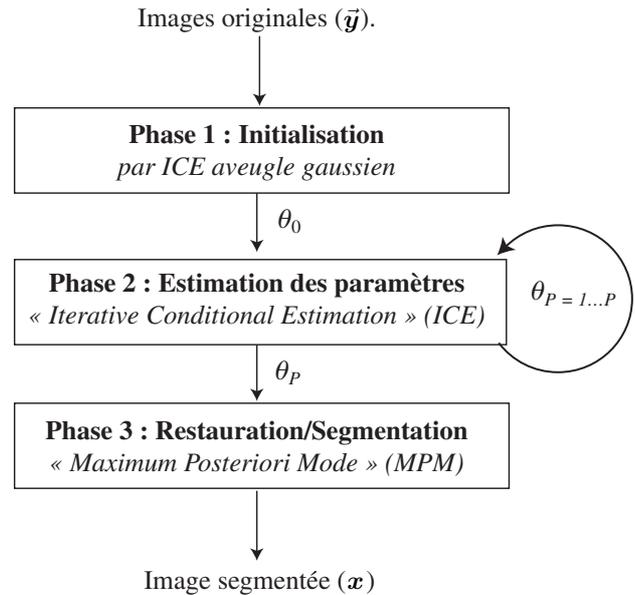


Figure 10. Squelette général de l'algorithme de segmentation. La phase 2 est détaillée dans la figure 11.

Annexe

Algorithme de segmentation

Le squelette de l'algorithme complet de segmentation se décompose en trois phases, cf. figure 10, en notant $\theta = (\gamma, \delta)$:

Phase 1 - Initialisation

L'objectif de cette phase est d'effectuer une première estimation des paramètres. Pour cela, nous avons segmenté l'image passe-bas de la décomposition (Θ_L) par un algorithme ICE aveugle, dans un contexte gaussien. L'image segmentée conduit à l'estimation θ_0 .

Phase 2 - Estimation des paramètres

Cette phase est réalisée par l'algorithme ICE décrit en annexe. Chaque itération fournit une estimation des paramètres θ_p . Le nombre P d'itérations ne pouvant être déterminé *a priori*, nous stoppons l'algorithme lorsque les paramètres ne varient quasiment plus ou après un nombre fixé d'itérations.

Phase 3 - Restauration / Segmentation

Cette dernière phase permet de segmenter l'image originale à partir des paramètres estimés (θ_p) dans le contexte du critère bayésien MPM.

Le principe d'ICE repose sur le calcul de l'espérance conditionnelle d'un estimateur à partir des données complètes $(\mathbf{x}, \vec{\mathbf{y}})$ [25]. ICE est une méthode itérative qui produit une série d'estimations θ_p du paramètre θ de la manière suivante :

- 1) Initialisation de θ_0 ;
- 2) Calcul de $\theta_{p+1} = E_{\theta_p} [\hat{\theta}(\mathbf{x}, \vec{\mathbf{Y}}) | \vec{\mathbf{Y}} = \vec{\mathbf{y}}]$, où $\hat{\theta}(\mathbf{X}, \vec{\mathbf{Y}})$ est un estimateur de θ à partir des données complètes $(\mathbf{x}, \vec{\mathbf{Y}})$;
- 3) Arrêt à l'itération P si $\theta_p \simeq \theta_{p+1}$.

Appliquée dans le cadre du modèle qui nous intéresse, cette procédure se décline en deux étapes :

Ensemble γ : l'espérance des composantes $\hat{\gamma}$ de $\hat{\theta}$ peut être calculée de manière analytique, en utilisant l'algorithme de Baum-Welch normalisé (probabilités « Forward » et « Backward ») [42].

Ensemble δ : l'espérance des composantes $\hat{\delta}$ de $\hat{\theta}$ ne peut pas être calculée directement. Par contre, elle peut être approchée en calculant la moyenne empirique de plusieurs estimations selon $\theta_{p+1} = \frac{1}{L} \sum_{l=1}^L \hat{\theta}(\mathbf{x}^l, \vec{\mathbf{y}})$, avec \mathbf{x}^l une réalisation *a posteriori* de \mathbf{X} conditionnellement à $\vec{\mathbf{Y}}$, simulée en utilisant θ_p . On peut effectivement montrer que la distribution $p(\mathbf{X} = \mathbf{x} | \vec{\mathbf{Y}} = \vec{\mathbf{y}})$ est celle d'une chaîne de Markov non homogène dont les paramètres peuvent être calculés à partir de l'algorithme de Baum-Welch normalisé, ce qui permet sa simulation.

Le squelette de l'algorithme d'estimation des paramètres avec ICE est représenté dans le schéma de la figure 11, et correspond à un zoom sur la phase 2 du squelette général donné dans la figure 10.

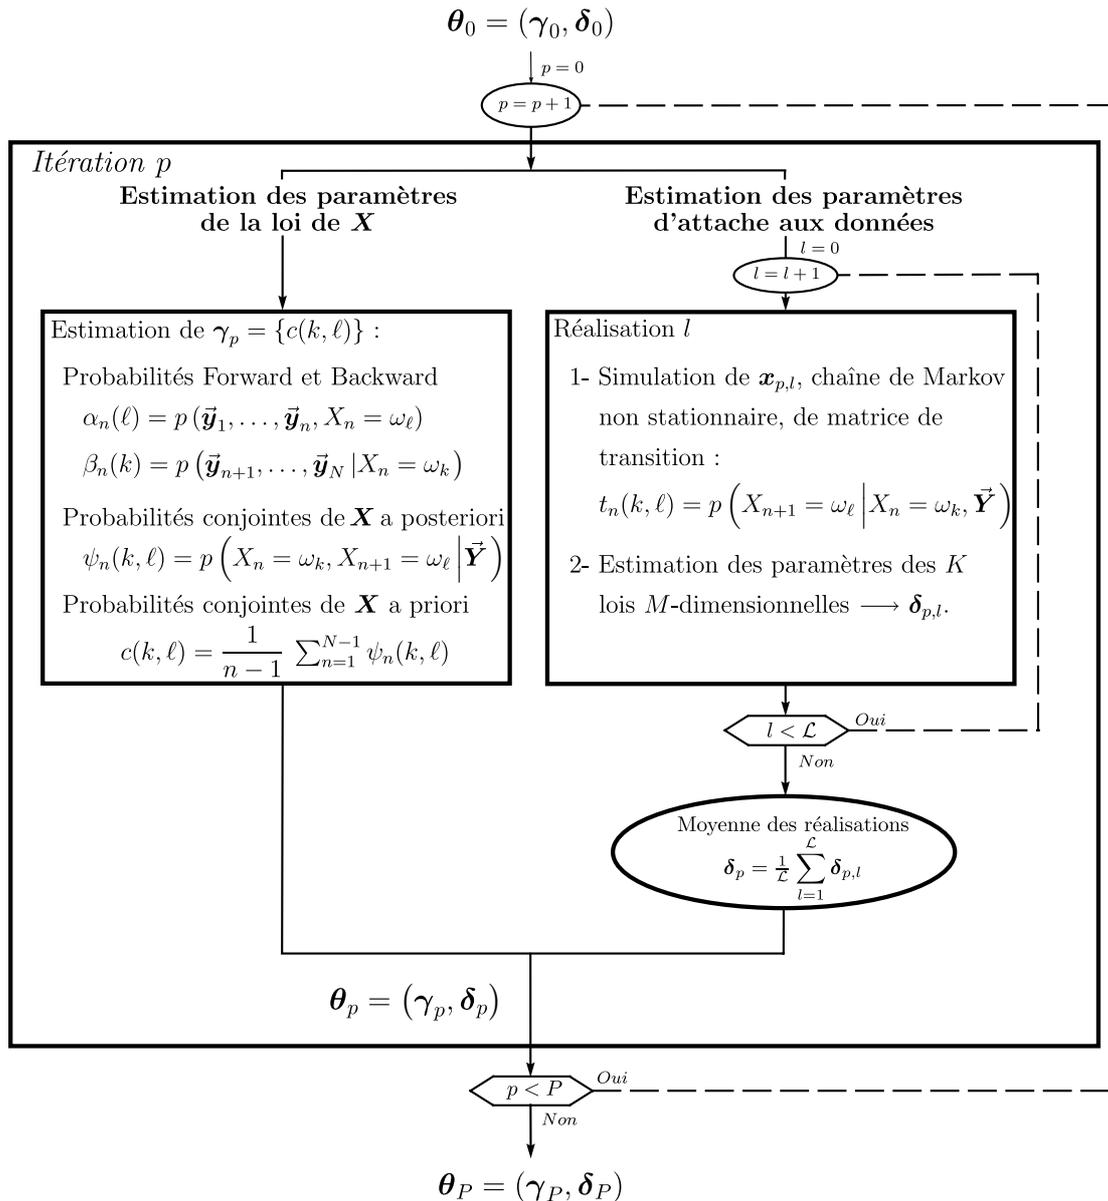


Figure 11. Squelette de l'algorithme d'estimation des paramètres (phase 2).

Références

- [1] G. FRANCESCHETTI, A. IODICE, D. RICCIO, G. RUELLO, and R. SIVIERO, "SAR raw signal simulation of oil slicks in ocean environments", *IEEE Trans. Geosci. Remote Sensing*, vol. 40, n. 9, pp. 1935-1949, Sept. 2002.
- [2] T. ELFOUHAILY and B. CHAPRON, "A comparison of wind wave spectra used in ocean remote sensing modeling", in *Proc. of the IEEE IGARSS'96*, vol. 1, Lincoln, NE (USA), 27-31 May 1996, pp. 606-608.
- [3] W. ALPERS and H. HÜHNERFUSS, "Radar signatures of oil films floating on the sea surface and the Marangoni effect", *J. Geophys. Res.*, vol. 93, no. C4, pp. 3642-3648, 1988.
- [4] —, "The damping of ocean waves by surface films: a new look at an old problem", *J. Geophys. Res.*, vol. 94, no. C5, pp. 6251-626, 1989.
- [5] J. W. WRIGHT, "A new model for sea clutter", *IEEE trans. on Antennas and Propagation*, vol. 16, pp. 217-223, 1968.
- [6] J. INGLADA, "Étude des signatures radar de la topographie sous-marine à la surface de l'océan", Thèse de doctorat, Université de Rennes I, France, 27 septembre 2000.
- [7] J.-M. LE CAILLEC and R. GARELLO, "Radarocéanographie", in *Le traitement des images radar à synthèse d'ouverture*, ser. Traité IC2, H. Maître, Ed. Hermès Science Publications, 2001, ch. 14.
- [8] M. GADE, W. ALPERS, H. HÜHNERFUSS, V. WISMANN, and P. LANGE, "On the reduction of the radar backscatter by oceanic surface films: scattometer measurements and their theoretical interpretation", *Remote Sensing of Environment*, vol. 66, pp. 52-70, 1998.
- [9] M. GADE, J. SCHOLZ, and C. VON VIEBAHN, "On the detectability of marine oil pollution in European marginal waters by means of ERS SAR imagery", in *Proc. of the IEEE IGARSS'00*, vol. 6, Honolulu, HI (USA), 24-28 July 2000, pp. 2510-2512.

- [10] P. LOMBARDO, D. CONTE, and A. MORELLI, "Comparison of optimised processors for the detection and segmentation of oil slicks with polarimetric SAR images", in *Proc. of the IEEE IGARSS'00*, vol. 7, Honolulu, HI (USA), 24-28 July 2000, pp. 2963-2965.
- [11] BJERDE A. SCHISTAD-SOLBERG, and G. STORVIK, "Oil spill detection in SAR imagery", in *Proc. of the IEEE IGARSS'93*, vol. 3, Tokyo, Japan, 18-21 August 1993, pp. 943-945.
- [12] A. SCHISTAD-SOLBERG, G. STORVIK, R. SOLBERG, and E. VOLDEN, "Automatic detection of oil spills in ERS SAR images", *IEEE Trans. Geosci. Remote Sensing*, vol. 37, pp. 1916-1924, July 1999.
- [13] H. ESPEDAL, "Detection of oil spill and natural film in the marine environment by spaceborne SAR", in *Proc. of the IEEE IGARSS'99*, vol. 3, Hamburg, Germany, 28 June, 2 July 1999, pp. 1478-1480.
- [14] I. DAUBECHIES, *Ten lectures on wavelets*. Philadelphia, Pennsylvania: Society for industrial and applied mathematics, 1992.
- [15] S. MALLAT, *A wavelet tour of signal processing*. Academic Press, 1998.
- [16] A. LOPÈS, R. GARELLO, and S. LE HÉGARAT-MASCLE, "Modèles de chatoiement", in *Le traitement des images radar à synthèse d'ouverture*, ser. Traité IC2, H. Maître, Ed. Hermès Science Publications, 2001, ch. 5.
- [17] S. MALLAT, "A theory for multiresolution signal decomposition: the wavelet representation", *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 11, no. 17, pp. 674-693, July 1989.
- [18] F. M. HENDERSON and A. J. LEWIS, *Manual of Remote Sensing, Principles & Applications of Imaging Radar*, 3rd ed. John Wiley & Sons, 1998.
- [19] N. L. JOHNSON and S. KOTZ, *Distribution in statistics: Continuous univariate distributions, Vol. 1 and 2*. New York: John Wiley and Sons, 1994.
- [20] Y. DELIGNON, A. MARZOUKI, and W. PIECZYNSKI, "Estimation of generalized mixture and its application in image segmentation", *IEEE Trans. Image Processing*, vol. 6, no. 10, pp. 1364-1375, 1997.
- [21] S. DERRODE, G. MERCIER, J.-M. LE CAILLEC, and R. GARELLO, "Estimation of sea-ice SAR clutter statistics from Pearson's system of distributions", in *Proc. of the IEEE IGARSS'01*, Sydney, Australia, 9-13 July 2001.
- [22] M. DO and M. VETTERLI, "Wavelet-based texture retrieval using generalized Gaussian density and Kullback-Leibler distance", *IEEE Trans. Image Processing*, vol. 11, no. 2, pp. 146-158, Feb. 2002.
- [23] G. MERCIER, S. DERRODE, and M. LENNON, "Hyperspectral image segmentation with Markov chain model", in *Proc. of the IEEE IGARSS'03*, Toulouse, France, 21-25 July 2003.
- [24] S. DERRODE, G. MERCIER, and W. PIECZYNSKI, "Unsupervised change detection in SAR images using a multicomponent HMC model", in *Proc. of the 2nd Int. Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp'03)*, Ispra, Italy, 16-18 July 2003.
- [25] W. PIECZYNSKI, "Statistical image segmentation", *Machine Graphics and Vision*, vol. 1, no. 2, pp. 261-268, 1992.
- [26] —, "Modèles de Markov en traitement d'images", *Traitement du Signal*, vol. 20, no. 3, pp. 255-278, 2003.
- [27] J.-M. BOUCHER and P. LENA, "Unsupervised bayesian classification, application to the forest of Paimpont (Brittany)", *Photo Interpretation*, vol. 32, no. 1994/4, 1995/1-2, pp. 79-81, 1995.
- [28] J.-N. PROVOST, C. COLLET, P. ROSTAING, P. PÉREZ, and P. BOUTHEMY, "Hierarchical Markovian segmentation of multispectral images for the reconstruction of water depth maps", *Computer Vision and Image Understanding*, vol. 93, no. 2, pp. 155-174, 2004.
- [29] R. FJØRTOFT, Y. DELIGNON, W. PIECZYNSKI, M. SIGELLE, and F. TUPIN, "Unsupervised segmentation of radar images using hidden Markov chains and hidden Markov random fields", *IEEE Trans. Geosci. Remote Sensing*, vol. 41, no. 3, pp. 675-686, 2003.
- [30] M. MIGNOTTE, C. COLLET, P. PÉREZ, and P. BOUTHEMY, "Three-class Markovian segmentation of high-resolution sonar images", *Computer Vision and Image Understanding*, vol. 76, no. 3, pp. 191-204, 1999.
- [31] S. REDD, Y. PETILLOT, and J. BELL, "An automatic approach to the detection and extraction of mine features in sidescan sonar", *IEEE J. Oceanic Eng.*, vol. 28, no. 1, pp. 90-105, 2003.
- [32] M. MIGNOTTE and J. MEUNIER, "Three-dimensional blind deconvolution of SPECT images", *IEEE Trans. Biomed. Eng.*, vol. 47, no. 2, pp. 274-280, 2000.
- [33] B. BENMILOUD and W. PIECZYNSKI, "Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images", *Traitement du Signal*, vol. 12, no. 5, pp. 433-454, 1995.
- [34] W. SKARBECK, "Generalized Hilbert scan in image printing", in *Theoretical Foundations of Computer Vision*, R. Klette and W. G. Kropetsh, Eds. Akademik Verlag, Berlin, 1992.
- [35] N. GIORDANA and W. PIECZYNSKI, "Estimation of generalized multisensor hidden Markov chains and unsupervised image segmentation", *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 19, no. 5, pp. 465-475, 1997.
- [36] J.-F. CARDOSO, "Blind signal separation: statistical principles", *Proc. IEEE*, vol. 9, no. 10, pp. 2009-2025, Oct. 1998.
- [37] C. JUTTEN and J. HÉRAULT, "Blind separation of sources, part I: an adaptive algorithm based on neuromimetic architecture", *IEEE Trans. Signal Processing*, vol. 24, pp. 1-10, 1991.
- [38] P. COMMON, "Independent component analysis, a new concept?" *IEEE Trans. Signal Processing*, vol. 36, pp. 287-314, 1994.
- [39] W. PIECZYNSKI, J. BOUVRAIS, and C. MICHEL, "Estimation of generalized mixture in the case of correlated sensors", *IEEE Trans. Image Processing*, vol. 9, no. 2, pp. 308-311, Feb. 2000.
- [40] J.-N. PROVOST, "Classification bathymétrique en imagerie multispectrale SPOT", Thèse de 3^e cycle, Université de Bretagne Occidentale, 2001.
- [41] J.-L. STARCK, F. MURTAGH, and A. BIJAOUI, *Image processing and image analysis, the multiscale approach*. Cambridge University Press, 1998.
- [42] P. A. DEVIJVER, "Baum's Forward-Backward algorithm revisited", *Pattern Recognition Letters*, vol. 3, pp. 369-373, 1985.



Grégoire **Mercier**

Grégoire Mercier a reçu le diplôme d'ingénieur de l'Institut National des Télécommunications (INT), à Evry, en 1993 et le titre de Docteur de l'Université de Rennes I en 1999. Il est actuellement Maître de Conférences à l'École Nationale Supérieure des Télécommunications de Bretagne (ENST Bretagne) à Brest dans l'équipe TAMCIC (CNRS FRE 2658) où ses activités de recherche concernent le traitement des images de télédétection. Plus spécifiquement, il s'intéresse aux méthodes de compression et de segmentation des images radar à synthèse d'ouverture ainsi que des images hyperspectrales.



Stéphane **Derrode**

Stéphane Derrode a reçu le diplôme d'ingénieur de Télécom Lille I en 1995 et le titre de Docteur de l'Université de Rennes I en 1999. Depuis 2001, il est Maître de Conférences à l'École Généraliste d'Ingénieurs de Marseille et effectue ses recherches au sein du Groupe Signaux Multidimensionnels (GSM) de l'Institut Fresnel (CNRS UMR 6133). Ses principaux domaines de recherche concernent la segmentation d'image et la reconnaissance de formes.



Wojciech **Pieczynski**

Wojciech Pieczynski a reçu le Doctorat d'état en statistiques de l'Université Pierre et Marie Curie à Paris en 1986. Il est actuellement Professeur à l'Institut National des Télécommunications (INT), à Evry, dans le département Communications, Image et Traitement de l'Information (CNRS UMR 5157) et est animateur du groupe Image et Optimisation. Ses principaux domaines de recherche concernent les processus stochastiques et le traitement statistique des images.