
Segmentation des images sonar latéral assurant l'invariance en rasance

Ahmed Nait-Chabane, Benoit Zerr, Gilles Le Chenadec

Lab-STICC (UMR CNRS 6285), équipe TOMS

ENSTA Bretagne (UEB)

2, rue François Verny

F-29806 Brest cedex 9

{ahmed.nait_chabane, benoit.zerr, gilles.le_chenadec}@ensta-bretagne.fr

RÉSUMÉ. Un sonar latéral de cartographie enregistre les signaux qui ont été rétrodiffusés par le fond marin sur une large fauchée. Les signaux sont ainsi révélateurs de l'interaction entre l'onde acoustique émise et le fond de la mer pour une large plage de variation de l'angle de rasance. L'analyse des statistiques de ces signaux rétrodiffusés montre une dépendance à ces angles de rasance, ce qui pénalise fortement la segmentation des images en régions homogènes. Pour améliorer cette segmentation, l'approche classique consiste à corriger les artefacts dus à la formation de l'image sonar (géométrie d'acquisition, gains variables, etc.) en considérant un fond marin plat et en estimant des lois physiques (Lambert, Jackson, etc.) ou des modèles empiriques. L'approche choisie dans ce travail propose de diviser l'image sonar en bandes dans le sens de la portée ; la largeur de ces bandes étant suffisamment faible afin que l'analyse statistique de la rétrodiffusion puisse être considérée indépendante de l'angle de rasance. Deux types d'analyse de texture sont utilisés sur chaque bande de l'image. La première technique est basée sur l'estimation d'une matrice des cooccurrences et de différents attributs d'Haralick. Le deuxième type d'analyse est l'estimation d'attributs spectraux. La bande centrale localisée à la moitié de la portée du sonar est segmentée en premier par un réseau de neurones compétitifs basé sur l'algorithme SOFM (Self-Organizing Feature Maps) de Kohonen. Ensuite, la segmentation est réalisée successivement sur les bandes adjacentes, jusqu'aux limites basse et haute de la portée sonar. A partir des connaissances acquises sur la segmentation de cette première bande, le classifieur adapte sa segmentation aux bandes voisines. Cette nouvelle méthode de segmentation est évaluée sur des données réelles acquises par le sonar latéral Klein 5000. Les performances de segmentation de l'algorithme proposé sont comparées avec celles obtenues par des techniques classiques comme l'algorithme K-moyennes (K-means).

ABSTRACT. The sidescan sonar records the energy of an emitted acoustical wave backscattered by the seabed for a large range of grazing angles. The statistical analysis of the recorded signals points out a dependence according grazing angles, which penalizes the segmentation of the seabed into homogeneous regions. To improve this segmentation, classical approaches consist in compensating artifacts due to the sonar image formation (geometry of acquisition, gains, etc.) considering a flat seabed and using either Lambert's law or an empirical law estimated from the sonar data. The approach chosen in this study proposes to split the sonar image into stripes in the swath direction; the stripe width being limited so that the statistical analysis of pixel values can be considered as independent of grazing angles. Two types of texture analysis are used for

each stripe of the image. The first technique is based on the Grey-Level Co-occurrence Matrix (GLCM) and different Haralick attributes derived from. The second type of analysis is the estimation of spectral attributes. The starting stripe at mid sonar slant range is segmented with an unsupervised classifier based on the SOFM (Self-Organizing Feature Maps) Kohonen algorithm. Then, from the knowledge acquired on the segmentation of this first stripe, the classifier adapts its segmentation to the neighboring stripes, allowing slight changes of statistics from one stripe to the other. The operation is repeated until the beginning and the end of the slant range are reached. The study made in this work is validated on real data acquired by the sidescan sonar Klein 5000. Segmentation performances of the proposed algorithm are compared with those of conventional approaches (K-means).

MOTS-CLÉS : segmentation des fonds marins, analyse de texture, analyse spectrale, classification non supervisée, cartes auto-organisées (SOFM).

KEYWORDS: seafloor segmentation, texture analysis, spectral analysis, unsupervised classification, self-organizing feature maps (SOFM).

DOI:10.3166/TS.30.119-148 © 2013 Lavoisier

Extended abstract

Context

For the sonar images, the statistical description of the backscattering is not constant over the full swath of the sonar. Thus, the segmentation results of algorithms applied to sidescan sonar images are non optimal with poor sonar compensation, artifact classes with borders parallel to the ship track are often seen (Capus *et al.*, 2008; Preston, 2009). This artifact is principally due to the grazing angle dependency of statistical features derived from sonar data. The aim of image compensation for classification is to reduce grazing angle effects on the image. Two approaches to compensation exist: the first is based on sonar calibration. This approach needs a strong knowledge on the conditions of acquisition and sonar system characteristics. The second approach is based on the estimation of a law describing the change in energy with grazing angle and uses this law to correct each amplitude sample. The law is either estimated from the data or based on a mathematical or physical model of backscattering (Lambert, Jackson) whose parameters are estimated from the data. To avoid any preprocessing step, we propose an algorithm for sidescan sonar segmentation, in which the sonar slant range is divided into small stripes. In this case, in each stripe the statistics can be considered homogeneous.

Methodology

This paper uses an unsupervised segmentation algorithm of sidescan sonar images without pre-processing stage. The idea is to divide the range of sonar image into narrow images stripes in which the statistical analysis of the backscattered signal can be considered in the same grazing angle range.

The raw image data is splitted in the direction of the range of the sonar on overlapping narrow stripes. In each stripe a set of features are computed: Haralick features and spectral features. Then, the pixels of each stripe are segmented by an unsupervised classifier, starting with the central stripe (mid range of sonar system). The choice to start with the central strip is not arbitrary, because in this part of the sonar image called “sweet spot” by (Chapple, 2008), the backscattered signal is considered optimal.

The adjacent stripes are then sequentially segmented from the central stripe up to the two sides of the image. The continuity between the stripes is provided by the SOFM (Self-Organizing Feature Maps) learning algorithm phase (Kohonen, 1982; 1997). Thus, the learning parameters of a given stripe of the image are initialized with those of the previous one. The process is repeated until the two limits of the image

Experimental results

The sonar images used for our study are provided by the GESMA (Groupe d’Etudes Sous-Marines d’Atlantique). Data were acquired by the Klein 5000 sidescan sonar at the BP02 campaign, recorded between May and June 2002 near Framura, north to the Cinque Terre region (Italy). The BP02 experiment was conducted by NATO/NURC. The carrier frequency of the sonar is 455kHz. In low resolution mode, the along-track resolution is 20cm and the maximum range is 150m on each side of sonar which gives a swath of 300m. In high resolution, the along-track resolution is 10cm and the maximum range is limited to 75m (*i.e.* a swath of 150m). In both modes, the across-track resolution is 3cm. In our study we only use images acquired in high resolution mode.

To assess the performances of our new approach, two comparisons are made. First, we compare the segmentation results obtained by application of K-means algorithm on raw sonar data with performances of proposed algorithm. Then a comparison between results of proposed algorithm with segmentation results of sonar images previously corrected then segmented with SOFM algorithm without splitting process.

Conclusion

In this paper, an unsupervised algorithm for segmentation of raw sidescan sonar images is proposed. This algorithm is based on the adaptation of the Kohonen SOFM algorithm. Segmentation performances of the proposed algorithm are compared with those obtained by the K-mean algorithm using confusion matrix. The proposed algorithm performs a segmentation independent to the grazing angle, without a priori information on the dependence on the incidence angle of the acquisition system (*i.e.* without image preprocessing) by managing transitions and continuity of classes between the adjacent stripes.

1. Introduction

Les signaux enregistrés par un sonar de cartographie à balayage latéral sont représentatifs des caractéristiques des fonds marins insonifiés et peuvent donc servir de support à leur classification. Cependant, ces signaux sont affectés par un certain nombre de phénomènes liés à la propagation, aux caractéristiques propres du sonar et à l'interaction entre l'onde acoustique et son environnement (Hellequin *et al.*, 2003). Les images acquises par le sonar latéral couvrent une large plage d'angles de rasance. Comme les propriétés statistiques de ces images dépendent de l'angle de rasance (Le Chenadec *et al.*, 2007), une confusion d'affectation de classes est constatée lors de l'application des algorithmes de segmentation automatique des images des sonars latéraux (Capus *et al.*, 2008). Preston (2009) mentionne dans son article que la dépendance en rasance des images sonar provoque l'apparition de lignes parallèles à l'axe de déplacement du sonar lors de l'application des algorithmes de classification.

Dans la littérature, de nombreux travaux se sont intéressés à la prise en compte de l'angle de rasance pour la segmentation des données sonar. Deux approches peuvent être distinguées. La première approche consiste tout d'abord à calibrer le sonar en corrigeant les données des artefacts liés à la propagation de l'onde acoustique et aux caractéristiques du système sonar (Le Chenadec et Boucher, 2005 ; Dugelay, 1997). Cette approche nécessite donc une connaissance précise du système et des conditions d'acquisition (géométrie d'acquisition, mouvement du bateau : tangage, lacet et roulis, mesures de célérité, salinité, pression et température, etc.). La seconde approche est fondée sur une étape de correction des données sans connaissance des caractéristiques du système mais en estimant expérimentalement une loi de dépendance selon l'angle de rasance (Leblond *et al.*, 2008 ; Karoui *et al.*, 2008 ; Preston, 2009). Les données sont ensuite corrigées de cette dépendance et sont dirigées vers un algorithme de segmentation classique. Le choix de la loi se reporte généralement sur un modèle mathématique de rétrodiffusion (Lambert) dont il s'agit de calculer les paramètres ou sur une loi empirique qu'il convient d'estimer à partir des données. (Preston, 2009 ; Capus *et al.*, 2008) spécifient bien que l'utilisation de cette loi ou de ces paramètres conditionnent significativement la qualité des résultats de segmentation car les lois proposées sont empiriques et/ou reposent sur des hypothèses de fond plat et de nature homogène.

Cet article propose un algorithme de segmentation non supervisée d'images sonar en fonds marins sans aucun prétraitement préalable. Le principe est de diviser la portée en bandes de faible largeur dans lesquelles l'analyse statistique du signal rétrodiffusé peut être considérée comme indépendante de la rasance.

La segmentation de l'image sonar ne s'appuie pas directement sur les niveaux de gris, mais sur des attributs extraits de l'image originale ou d'une des ses transformées. Plusieurs auteurs se sont intéressés aux statistiques du premier ordre de l'énergie rétrodiffusée (Dugelay, 1997 ; Hellequin, 1998 ; Le Chenadec et Boucher, 2005). Parmi les modèles les plus utilisés pour représenter les données, la loi de Weibull, la loi de Rayleigh et la loi K peuvent être citées. Les images de

sonars latéraux dévoilent également des textures. Les informations de textures les plus utilisées sont celles basées sur le calcul des matrices des cooccurrences (statistiques de second ordre) (Linnett *et al.*, 1994 ; Lianantonakis et Petillot, 2007) ou sur les filtres de Gabor et les paquets d'ondelettes (Celik et Tjahjadi, 2011). Dans cet article, les informations extraites proviennent des matrices des cooccurrences et de l'analyse spectrale de Fourier.

Dans la littérature, le choix des algorithmes de segmentation automatique porte sur des approches supervisées (Dugelay, 1997 ; Hellequin, 1998 ; Le Chenadec et Boucher, 2005 ; Karoui, 2007) ou non supervisées (Yao *et al.*, 2000 ; Preston, 2009).

En ce qui concerne la segmentation des bandes de pixels, l'approche proposée ici est fondée sur une classification non supervisée à base de cartes auto-organisées (*Self Organizing Feature Maps* « *SOFM* ») (Kohonen, 1982 ; 1997). Par rapport à une méthode non supervisée classique, l'algorithme SOFM définit un lien topologique entre les classes.

La section 2 expose brièvement les notions essentielles à l'interprétation des données d'un sonar latéral et au développement d'un algorithme de segmentation automatique. Cette section montre aussi la dépendance de la rétrodiffusion à la rasanse et décrit l'approche proposée pour s'en affranchir. Dans la section 3, les différents attributs de textures utilisés pour discriminer les fonds marins sont présentés. La section 3 montre également la dépendance à la rasanse des attributs de textures sur des données expérimentales et justifie ainsi la démarche de découpage en bandes proposée dans cet article. La section 4 présente deux approches de segmentation non supervisée utilisées dans cet article : une approche adaptant l'algorithme des K-moyennes (*K-means*) et une approche adaptant l'algorithme SOFM. Dans la section 5, l'évaluation de cette nouvelle méthode sur des données expérimentales démontre la pertinence de la démarche, par comparaison avec les approches classiques de classification des fonds marins. Nous terminons par une conclusion en section 6.

2. Interprétation des images d'un sonar latéral de cartographie

2.1. Fonctionnement et caractéristiques

Un sonar latéral est un système acoustique de cartographie des fonds marins, généralement fixé sur un poisson remorqué à une faible altitude par rapport au fond marin. Le sonar émet des ondes acoustiques sur le fond marin à l'aide de deux antennes identiques disposées de part et d'autre du poisson. L'ouverture horizontale du faisceau est faible (quelques dixièmes de degrés, typiquement) ce qui permet d'avoir une fine résolution longitudinale (dans le sens du déplacement du poisson). L'ouverture verticale est large (quelques dizaines de degrés, typiquement) ce qui permet de couvrir une large fauchée. En réception, l'antenne capte les signaux s'étant propagés et ayant interagis avec le fond marin. De plus, la plupart des systèmes appliquent, à la réception des signaux, un gain variable en temps destiné à compenser les pertes dues à la propagation dans la colonne d'eau et ainsi réduire la dynamique du

signal reçu. Le signal est ensuite numérisé et stocké. L'émission d'ondes acoustiques à intervalles de temps réguliers allié au déplacement du poisson permet la formation d'une image bidimensionnelle du fond marin (figure 1).

Dans ce travail, les données du sonar Klein 5000 ont été utilisées. La fréquence émise par le sonar est de 455 kHz. Sa portée maximale est de 150 m pour chaque côté, ce qui nous donne une fauchée de 300 m. Toutefois, ce sonar présente aussi un mode haute résolution (utilisé dans cette étude) et dans ce cas, sa portée est réduite à 75 m de chaque côté du sonar pour une fauchée de 150 m. La durée du signal d'émission est de 50 μ s ce qui correspond à la possibilité de discriminer deux cibles espacées de 3,75 cm dans le sens de la portée. La fréquence d'échantillonnage est de 22 750 Hz, ce qui correspond à une dimension transversale (direction perpendiculaire au déplacement du poisson) du pixel de $cT/2 = 3,3$ cm (c : célérité de l'onde dans l'eau, T : la période d'échantillonnage en réception). En mode haute résolution, la dimension longitudinale du pixel est de 10 cm grâce à la formation de voies parallèles (Leblond, 2006).

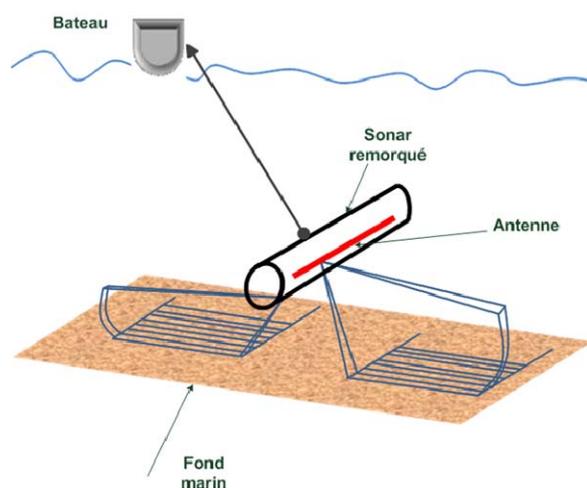


Figure 1. Principe de formation de l'image d'un sonar latéral de cartographie

2.2. Dépendance à la rasanté du signal rétrodiffusé

Lors de l'interaction entre une onde acoustique incidente et le fond de mer (supposé rugueux), cette onde est diffusée dans toutes les directions de l'espace. L'onde rétrodiffusée est celle qui est renvoyée dans la direction du sonar. Dans le cas du sonar latéral, une large plage d'angles de rasanté est couverte ce qui affecte le niveau du signal rétrodiffusé. La perte d'énergie des ondes acoustiques due à leur propagation dans le milieu marin a une double origine : la divergence sphérique (étalement de l'énergie acoustique sur une surface de plus en plus importante) et

l'absorption (conversion de l'énergie acoustique en dissipation thermique). Les pertes par divergence sphérique s'expriment en fonction de la distance parcourue par l'onde ultrasonore $R(t)$ par la relation $20 \log_{10} (R(t))$. Les pertes par absorption s'expriment par $\beta.R(t)$ où β est le coefficient d'absorption (dB/m.) dépendant de la température, de la salinité, de la pression et de la fréquence de l'onde émise. L'énergie rétrodiffusée est caractérisée par un indice de rétrodiffusion dont le comportement en fonction de l'angle de rasance a montré des capacités à discriminer les fonds marins (Le Chenadec et Boucher, 2005). Plusieurs modèles prédisent la valeur de l'indice de rétrodiffusion ($BS(\theta)$) en fonction de l'angle de rasance pour différents types de fond. Le modèle heuristique de Lambert (équation (1), figure 2) montre la dépendance en rasance de l'indice rétrodiffusion $BS(\theta)$ (θ : angle de rasance) par un fond plat.

$$\begin{cases} BS(\theta) = BS_0 + 20 \cdot \log(\cos(\theta)) \\ \sin(\theta) = \frac{H}{R(t)} = \frac{H}{\frac{ct}{2}} \end{cases} \quad (1)$$

- $BS(\theta)$: indice de rétrodiffusion (dB),
- BS_0 : constante qui dépend du type du fond (dB),
- $R(t)$: distance oblique (m), H : altitude du sonar (m),
- C : célérité de l'onde acoustique (m.s^{-1}), t : le temps (s).

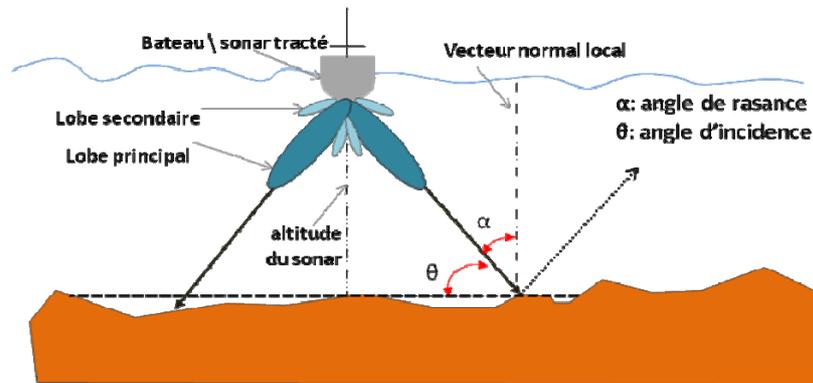


Figure 2. Géométrie du sonar latéral et définitions des paramètres : angle de rasance et angle d'incidence

Pour une surface plane complètement réfléchissante, BS_0 est approximativement égal à -5 dB. En pratique, la dynamique des valeurs BS_0 s'étend de 0 dB à -40 dB pour les différents types du fond (gravier, roche, sable, vase, argile...) (Bouvet, 1992). A titre d'exemple, la figure 3 présente l'évolution de l'indice de

rétrodiffusion en fonction de l'angle de rasance, pour quatre types de fond (roche, sable, vase et argile).

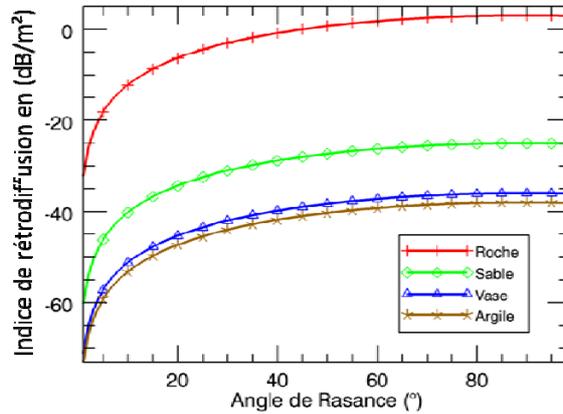


Figure 3. Modèle de Lambert pour l'indice de rétrodiffusion (dB/m²) en fonction de l'angle de rasance et de quatre types de fond (roche, sable, vase et argile)

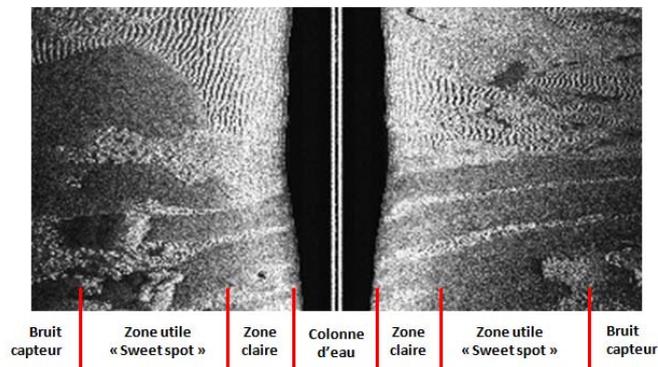


Figure 4. Illustration des différentes zones de rasance présentes dans une image brute enregistrée par un sonar latéral

Les données brutes enregistrées par un sonar latéral présentent une dépendance à l'angle de rasance. La figure 4 représente une image sonar acquise par le sonar latéral Klein 5000. L'axe horizontal de l'image est suivant la portée sonar et l'axe vertical suivant le déplacement du sonar. La zone sombre sur la (figure 4) représente le trajet des ondes dans la colonne d'eau. De part et d'autre de la colonne d'eau, se distinguent trois zones :

- une zone « claire » où les angles de rasance sont importants, les niveaux de gris sont élevés et varient rapidement, les textures sont difficilement discernables (pas de formation d'ombre à la verticale du sonar) ;
- une zone « utile » dite aussi en anglais « sweet spot » selon (Chapple, 2008). Dans cette plage les angles de rasance sont intermédiaires, les niveaux de gris sont moyens et les textures sont aisément observables et le moins déformées géométriquement ;
- une zone « bruit capteur » (bruit électronique propre au sonar) ; cette plage représente des angles de rasance faibles où le niveau du signal reçu devient de plus en plus faible (le rapport signal sur bruit s'effondre), les textures subissent des déformations géométriques et sont difficilement observables.

2.3. Approche proposée d'une segmentation d'images sonar

Dans l'optique de segmenter les images des sonars latéraux en différents types de fonds, il est généralement convenu de prétraiter les données pour s'affranchir des caractéristiques spécifiques des données sonar. Les travaux antérieurs font apparaître deux approches. La première approche tente de remonter à l'indice de rétrodiffusion en corrigeant les données des artefacts produits par la propagation dans la masse d'eau (atténuation de l'onde acoustique) et par les caractéristiques du sonar (directivité, durée d'émission, mouvement du porteur). Cette approche nécessite ainsi une connaissance fine des caractéristiques du sonar et des conditions d'acquisition. La seconde approche vise l'estimation d'une loi de variation des images soit en fonction du temps soit en fonction de l'angle de rasance ou les deux (Preston, 2009). La loi choisie peut être empirique ou paramétrique comme le modèle de Lambert (figure 3).

Le travail proposé dans cet article considère une autre approche dans laquelle aucun prétraitement n'est envisagé afin d'éviter des mesures des caractéristiques du sonar et des conditions de propagation ou l'estimation d'une loi décrivant la dépendance de l'énergie avec l'angle de rasance. L'image des données brutes est séparée, dans le sens de la portée, en un ensemble de bandes de largeur restreinte qui se chevauchent comme on le montre sur l'image sonar tribord (figure 5). A l'intérieur de chaque bande, les pixels proviennent de la même gamme d'angles de rasance. Les pixels de chaque bande sont segmentés par un classifieur non supervisé en commençant par la bande centrale (mi-portée du sonar). Les bandes adjacentes sont ensuite segmentées séquentiellement en allant d'une part, vers la colonne d'eau et, d'autre part, vers la fin de la portée. Ces segmentations bénéficient de caractéristiques recueillies lors de la segmentation de la bande centrale. Le choix de démarrer avec la bande centrale n'est pas arbitraire car c'est dans cette partie de la portée sonar que le signal rétrodiffusé est considéré optimal (cf. figure 4). Dans notre travail la bande centrale est choisie au centre du « sweet spot ». La continuité entre les bandes est assurée par la phase d'apprentissage de l'algorithme SOFM. Ainsi, les paramètres d'apprentissage d'une bande donnée de l'image sont initialisés par ceux de la bande précédente. Le processus est répété jusqu'aux deux limites de

l'image. Le diagramme de la figure 6 présente les cinq étapes de l'algorithme proposé :

1. découpage en bandes de l'image sonar brute,
2. création du vecteur d'attributs,
3. classification non supervisée du vecteur des attributs en utilisant l'algorithme SOFM,
4. segmentation de l'image d'entrée en classes disjointes par l'analyse de la carte topologique créée par le SOFM,
5. codage supervisé de la carte par des couleurs à partir des résultats de classification de la phase 3 de l'algorithme.

La partie « création du vecteur d'attributs » est détaillée dans la section 3. Les parties « classification non supervisée » et « segmentation » sont détaillées dans la section 4.

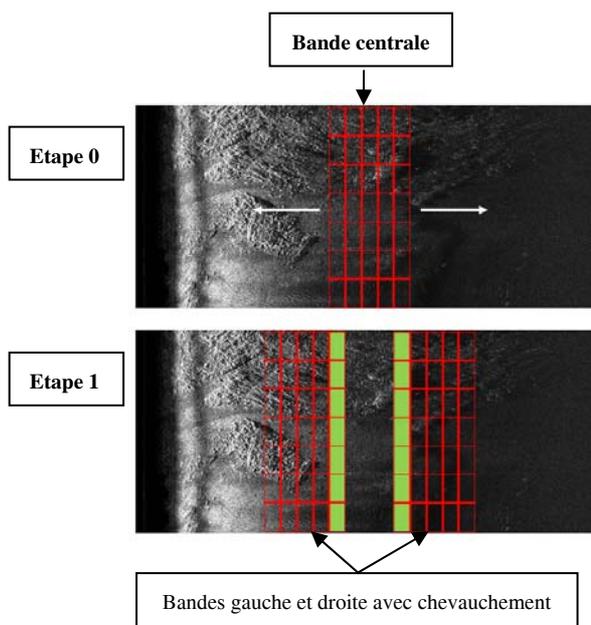


Figure 5. Découpage en bandes de pixels d'une image sonar (côté tribord). Etape 0 représente la bande centrale. Etape 1 représente les deux bandes gauche et droite adjacentes à la bande centrale avec chevauchement

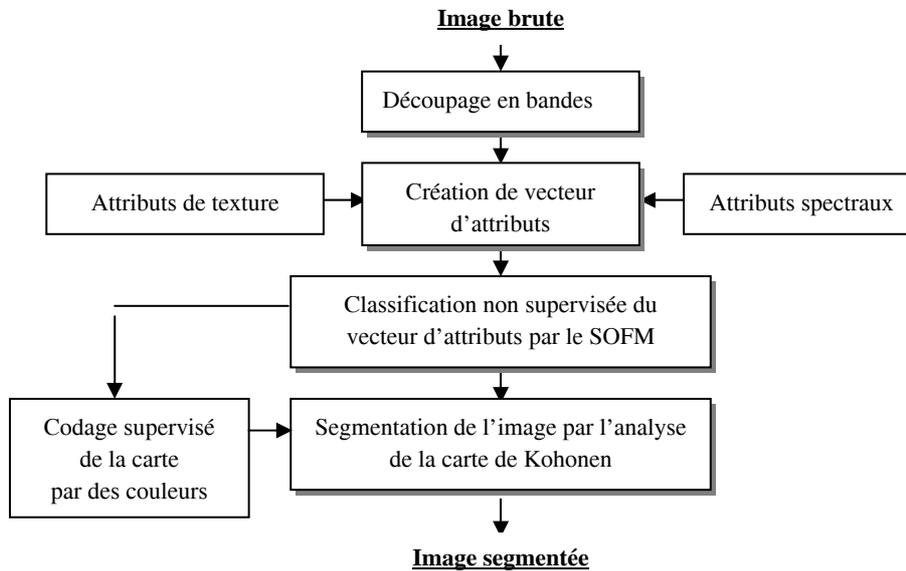


Figure 6. Schéma synoptique de l'algorithme proposé

3. Extraction d'information à partir des images sonar

Les conditions d'acquisition d'un sonar latéral (tracté près du fond) autorisent l'apparition de textures dans l'image du fond marin. Plusieurs méthodes d'analyse de texture sont proposées dans la littérature. Il existe des méthodes basées sur les statistiques du premier ordre reposant sur le calcul d'histogramme (Laur *et al.*, 1987), d'autres basées sur les statistiques du second ordre (matrices des cooccurrences) (Pican *et al.*, 1998) et d'autres sur l'analyse spectrale (Transformée de Fourier, paquets ondelettes, filtre de Gabor, etc.) (Tang et Stewart, 1995 ; Kernéis, 2007). La capacité de ces attributs à discriminer les textures de fonds marins a été montrée dans plusieurs travaux (Karoui *et al.*, 2009 ; Pican *et al.*, 1998).

Dans notre cas, deux types d'analyse de texture sont utilisés sur chaque bande de l'image. La première technique est basée sur l'estimation de matrice des cooccurrences et de différents attributs d'Haralick. Le deuxième type d'analyse est l'estimation d'attributs liés à la transformée de Fourier. Ceux-ci permettent d'affiner la séparabilité des différents types de textures et de détecter les macrotextures périodiques comme les rides de sable et les dunes. Le dernier attribut utilisé est l'altitude du sonar. Des auteurs comme (Lubniewski et Pouliquen, 2004 ; Pouliquen, 2004) se sont intéressés à étudier l'influence de l'altitude du sonar sur la classification des fonds marins.

3.1. Attributs extraits de la matrice des cooccurrences

La matrice des cooccurrences MC est un histogramme bidimensionnel qui estime la probabilité conjointe que deux pixels distants d'une distance d dans une direction θ aient certaines valeurs de niveaux de gris (Haralick, 1979). Cet outil statistique du second ordre est ainsi adapté à l'analyse de texture et a obtenu de bons résultats dans la segmentation de différents types d'images satellitaires (Laur *et al.*, 1987 ; Marceau *et al.*, 1990) et médicales (Sercic et Loncaric, 1998 ; Moysan *et al.*, 1992). La MC d'une image I de N lignes et M colonnes codée en N_g niveaux de gris est une matrice de taille $(N_g \times N_g)$. L'expression analytique de la MC pour une distance d dans une direction θ d'une image I est donnée par :

$$MC_{(d,\theta)}(i,j) = \sum_{n=1}^N \sum_{m=1}^M \begin{cases} 1 & \text{si } \{I(n,m) = i \text{ et } I(n+d.\cos(\theta), m+d.\sin(\theta)) = j\} \\ 0 & \text{sinon} \end{cases} \quad (2)$$

Afin d'obtenir une estimation de la probabilité conjointe, la MC est usuellement normalisée :

$$P_{(d,\theta)}(i,j) = \frac{MC_{(d,\theta)}(i,j)}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} MC_{(d,\theta)}(i,j)} \quad (3)$$

Classiquement pour caractériser les textures de manière robuste, d prend plusieurs valeurs parmi $\{1, 2, 3, \dots\}$ (nombre de pixels) et θ balaye quatre directions : 0° , 45° , 90° , 135° aboutissant au calcul d'un grand nombre de MC . Haralick (1973 ; 1979) a proposé d'extraire quatorze attributs permettant de discriminer différents types de texture (Haralick, 1979 ; Tuceryan *et al.*, 1998 ; Pican *et al.*, 1998). Dans ce travail, les attributs d'Haralick suivants ont été utilisés : entropie, contraste, hétérogénéité, homogénéité, corrélation, maximum de probabilité, kurtosis et facteur d'élongation (Haralick, 1973 ; 1979).

3.2. Attributs spectraux

Le calcul de MC pour différentes distances d permet d'évaluer la périodicité des textures et pour différentes directions θ sert à caractériser leur direction (Karoui, 2007). Ce schéma de calcul permet une caractérisation précise des textures d'une image mais au détriment d'un temps de calcul important. Pour cette raison, dans ce travail nous avons choisi d'utiliser une seule distance mais plusieurs directions pour le calcul de MC et des attributs. La caractérisation de la périodicité des textures résulte d'une analyse spectrale par transformée de Fourier à deux dimensions. L'analyse spectrale a montré sa complémentarité à l'analyse par MC pour la discrimination des macrottextures périodiques comme les rides de sable ou non périodiques comme la roche (Tang et Stewart, 1995 ; Kernéis, 2007). Dans cette étude, six attributs ont été extraits à partir de la transformée de Fourier. Soit une image I de taille $(M \times N)$, et soit $F(u,v)$, sa transformée de Fourier à deux

dimensions, les trois premiers attributs issus du module de $F(u,v)$ sont la moyenne (Moy), la variance (Var) et l'énergie (E) du spectre, définis par :

$$Moy = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} |F(u,v)| \quad \text{et} \quad Var = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} (|F(u,v)| - Moy)^2 \quad (4)$$

$$E = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} |F(u,v)|^2 \quad (5)$$

Les trois autres attributs sont estimés après filtrage du module du spectre en trois bandes spectrales : basse (BF), moyenne (MF) et haute fréquence (HF). Dans l'espace des fréquences, ces trois filtres sont caractérisés par les fréquences de coupure en deux dimensions $(f_{bf,x}, f_{bf,y})$ et $(f_{hf,x}, f_{hf,y})$. A partir des spectres filtrés, l'énergie dans la bande basse fréquence (EBF), l'énergie dans la bande moyenne fréquence (EMF) et l'énergie dans la bande haute fréquence (EHF) complètent l'ensemble d'attributs.

En tenant compte de la résolution spatiale du pixel de l'image sonar, les fréquences de coupure sont calculées de manière à révéler dans la bande HF les fonds marins de périodicité spatiale inférieure à 0,25 m ce qui représente 4 cycles/m ; dans la bande MF, les périodicités spatiales comprises entre 0,25 m et 1 m et dans la bande BF, donc entre 1 cycle/m et 4 cycles/m, les périodicités spatiales supérieures à 1 m, ce qui représente 1 cycle/m. Ainsi, les fréquences de coupure spatiales basses et hautes sont définies par les équations suivantes, sachant que la résolution dans le sens de la portée (axe horizontal x) est de 0,03 m et la résolution dans le sens de l'avance du sonar (axe vertical y) de 0.1 m :

$$\left\{ \begin{array}{l} f_{bf,x} = \frac{0.25}{0.03} = 8.33 \text{ pixel/ cycle} \\ f_{bf,y} = \frac{0.25}{0.1} = 2.5 \text{ pixel/ cycle} \end{array} \right. \quad \left\{ \begin{array}{l} f_{hf,x} = \frac{1}{0.03} = 33.33 \text{ pixel/ cycle} \\ f_{hf,y} = \frac{1}{0.1} = 10 \text{ pixel/ cycle} \end{array} \right. \quad (6)$$

Lors du calcul de la transformée de Fourier, un problème intervient lorsque la transformée de Fourier rapide n'est pas calculée sur un nombre entier de périodes. Dans ce cas, le spectre obtenu par FFT n'est pas une bonne approximation du spectre du signal. Il faut généralement envisager l'existence possible d'une discontinuité. Cet effet, connu sous le nom de fuites spectrales (*leakage*) (Harris, 1978) se manifeste dans le domaine fréquentiel. Cette discontinuité provoque un élargissement de la raie spectrale. L'utilisation d'une fenêtre type Hanning, Hamming ou Blackman (Harris, 1978) aura pour effet, en filtrant fortement les extrémités du motif dans le domaine temporel, d'atténuer l'effet des fuites. Dans notre cas la fenêtre de Hanning 2D est utilisée avant l'application du filtrage de Fourier pour minimiser les effets de bords sur l'image.

La figure 7 donne un schéma représentant les étapes effectuées pour le filtrage spectral en trois bandes spectrales basses, moyennes et hautes fréquences d'un exemple de texture de rides de sable.

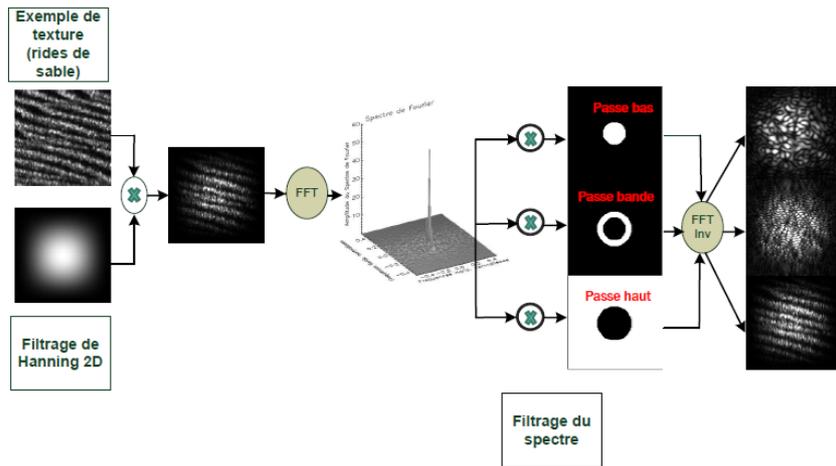


Figure 7. Etapes de filtrage en trois bandes spectrales basses moyennes et hautes fréquences d'un exemple de texture (rides de sable)

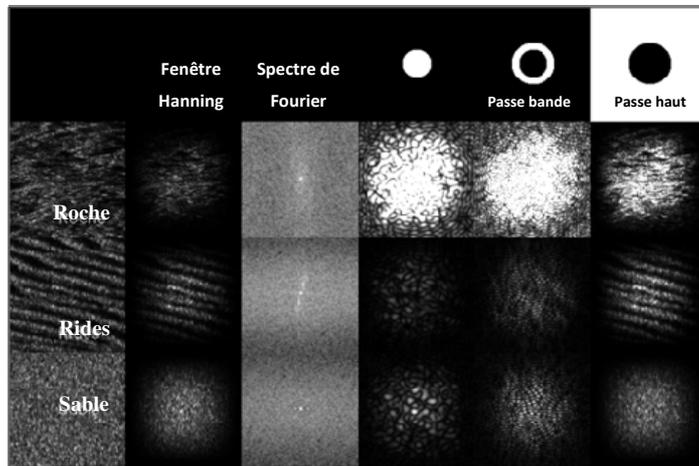


Figure 8. Filtrage en trois bandes spectrales par les étapes décrites sur la figure 7. Colonne 1 : image sonar des trois types de fond marin : roche, rides de sable et sable fin. Colonne 2 : filtrage par la fenêtre de Hanning 2D. Colonne 3 : spectre logarithme du module du spectre de Fourier. Colonne 4 : image filtrée par le filtre passe bas. Colonne 5 : image filtrée par le filtre passe bande. Colonne 6 : image filtrée par le filtre passe haut

La figure 8 représente le résultat du filtrage en trois bandes spectrales obtenues par le principe détaillé sur la figure 7 pour trois types de fond : roche, rides de sable et sable fin. Les trois imagerie de test ont une taille de 128 x 128 pixels.

La moyenne et l'écart type des six attributs spectraux pour les trois fonds de test (roche, rides et sable) sont reportés sur le tableau 1. Cinq imagerie pour chaque type de fond de taille 64 x 64 pixels ont été utilisées pour le calcul. L'énergie EBF est normalisée par rapport à l'énergie totale du spectre. Par contre pour les attributs EMF et EHF, l'énergie EBF de l'énergie totale est d'abord soustraite afin de rendre ces attributs indépendants du niveau moyen (composante continue). Ensuite les attributs EMF et EHF sont normalisés par rapport à la proportion de l'énergie calculée entre les moyennes et les hautes fréquences. L'énergie E est normalisée par rapport à la valeur de l'énergie du spectre à l'origine $E(0,0)$.

Tableau 1. Moyenne et écart type des six attributs spectraux pour cinq imagerie de test (64 x 64) pour les trois types de fond marin (roche, rides et sable). Les résultats sont écrits sous la forme (**moyenne** + **écarte type**)

	Roche	Rides de sable	Sable fin
EBF	0.74±0.179	0.84±0.010	0.88±0.001
EMF	0.15±0.013	0.27±0.043	0.19±0.015
EHF	0.84±0.013	0.72±0.043	0.80±0.015
Moy	4.72±0.891	1.03±0.038	0.95±0.021
Var	72.48±33.60	8.48±0.212	9.82±0.415
E/E(0,0)	1.72±0.106	1.59±0.076	1.22±0.012

3.3. Vecteur d'attributs

L'image sonar brute est d'abord subdivisée en bandes verticales de 96 pixels de largeur. Sur chaque bande, les attributs de texture et spectraux que nous avons exposés dans les sections 3.1 et 3.2 sont estimés en utilisant une fenêtre d'analyse de taille 96 x 32 pixels avec un déplacement des fenêtres de 32 x 8 pixels. Le vecteur d'attributs est composé de 39 attributs :

- 32 attributs de texture (8 attributs d'Haralick pour quatre directions différentes $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ avec une distance $d=1$) ;
- 6 attributs spectraux ;

– l’altitude du sonar donnée dans le fichier de navigation est aussi intégrée comme attribut afin de prendre en compte les variations d’altitude du sonar.

3.4. Exemple de dépendance à la rasance d’attributs calculés

Pour montrer l’influence de l’angle de rasance sur les attributs de texture, deux attributs sont analysés : l’entropie estimée à partir de la matrice de cooccurrence et l’énergie du spectre d’amplitude E estimée à partir de la transformée de Fourier. Les deux attributs sont estimés pour deux types de fonds texturés (figure 9 (a_1) et (a_2)), une zone de rides de sable et une zone rocheuse. La figure 9 (b_1) et figure 9 (b_2) représentent l’énergie du spectre des deux zones ; la figure 9 (c_1) et figure 9 (c_2) représentent l’entropie des deux zones.

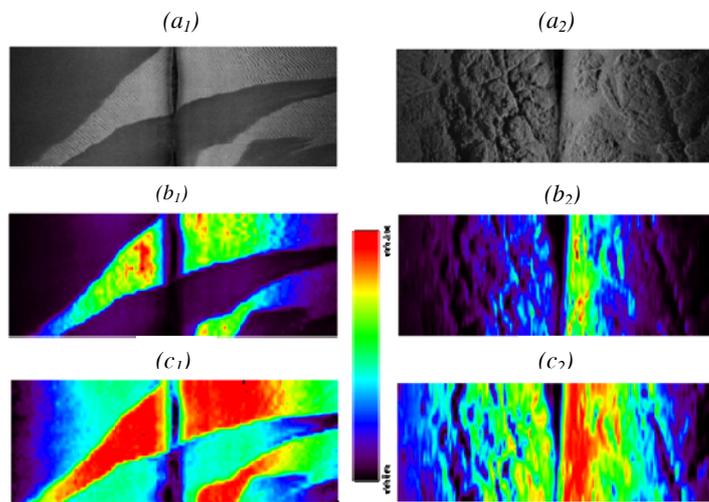


Figure 9. Energie du spectre et entropie des deux textures : (a_1) rides et sable (a_2) roche, (b_1) et (b_2) représentent E , l’énergie du spectre de Fourier, (c_1) et (c_2) représentent l’entropie calculée à partir des matrices des cooccurrences

La figure 10 montre l’évolution moyenne de l’entropie et de l’énergie en fonction de la portée pour ces deux types de fond. Pour chaque valeur de la portée, la courbe représente la valeur moyenne de l’attribut calculée sur l’ensemble des lignes. Ces courbes montrent une dépendance significative de la valeur de l’attribut (entropie ou énergie) en fonction de la portée ce qui peut conduire à une classification ambiguë ; l’entropie pour un fond de type sable à une certaine portée peut être similaire à l’entropie d’un fond rocheux à une autre portée. Le découpage en bandes étroites dans le sens de la portée (sens horizontal de l’image sonar) permet de réduire ces ambiguïtés.

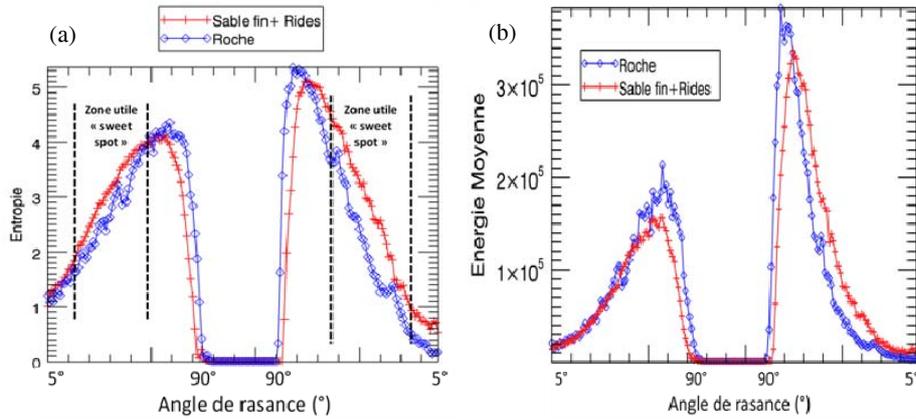


Figure 10. Profil horizontal moyen de l'entropie (a) et de l'énergie du spectre (b) pour la roche et les rides de sable en fonction de l'angle de rasance

4. Segmentation non supervisée

Dans cet article nous avons opté pour une segmentation non supervisée des images sonar par deux algorithmes. Le premier algorithme utilisé comme référence est fondé sur les K-moyennes (Duda *et al.*, 2001) (*K-means* en anglais) et un second algorithme proposé basé sur l'adaptation de l'algorithme de Kohonen SOFM.

Au terme de l'apprentissage, le classifieur nous permet à partir des attributs extraits de l'image brute de construire l'image correspondante en termes de classes. L'algorithme K-means cherche à classer des observations en K classes (*clusters*). Chaque classe est représentée par un prototype dont les coordonnées sont généralement calculées à partir de la moyenne des coordonnées des observations composant la classe. Chaque observation est affectée à la classe qui présente une distance minimale entre les coordonnées de l'observation et les coordonnées des prototypes. Usuellement, le choix de la distance pour l'évaluation de la similarité se porte sur la distance euclidienne. La distance euclidienne est adaptée lorsque la dispersion (variance) est équivalente selon les différentes dimensions des observations et les différentes classes. Preston (2009) plaide pour l'utilisation de la distance de Mahalanobis dans le cas des données extraites des images sonar. Pour cette raison, la distance de Mahalanobis a été retenue pour l'algorithme K-means utilisé dans cet article.

La distance euclidienne et la distance de Mahalanobis entre un vecteur x donné et le centroïde (centre de la classe) m_i de la classe i sont définies par :

$$\begin{aligned} d_i(x) &= (x - m_i)(x - m_i)^T \\ d_i(x) &= (x - m_i)C_i^{-1}(x - m_i)^T \end{aligned} \quad (7)$$

où la matrice inverse de variance-covariance de la classe i est notée C_i^{-1} .

Le principe de fonctionnement de l'algorithme SOFM de Kohonen est détaillé à la section 4.1.

4.1. Segmentation par cartes auto-organisées

Une carte auto-organisée (SOFM) est un type de réseau de neurones artificiel compétitifs composé en général de deux couches de neurones. La première couche sert uniquement à représenter les observations dans l'espace des attributs. Chaque observation $i \in \{1, \dots, n\}$ est décrite par un vecteur à P attributs $x_i = (x_i^1, \dots, x_i^P)$. La seconde couche représentant la couche de compétition, est structurée en un treillis de neurones (figure 11). Ce choix de structure est effectué *a priori*. La structure du réseau choisie dans notre étude est une grille rectangulaire (Kohonen, 1997) à deux dimensions de taille $m \times m$ neurones. Chaque neurone de la seconde couche peut être vu comme un prototype de classe (Hastie *et al.*, 2009) connecté au prototype des classes voisines. Chaque observation de la couche d'entrée x_i est connectée à chaque neurone $j \in \{1, \dots, m^2\}$ de la seconde couche par des vecteurs de poids synaptiques notés w_{ij} . Le principe de l'apprentissage de l'algorithme SOFM consiste à déformer le treillis de neurones de la seconde couche pour que la topologie définie par ces prototypes s'adapte aux observations. Les principales phases de l'algorithme SOFM sont données dans l'algorithme 1. Les poids w_{ij} sont initialisés aléatoirement. Les observations sont traitées une par une. Le neurone j le plus proche (au sens de la distance euclidienne) d'une observation x_i est déterminé. Les poids w_{ij} de tous les neurones sont alors recalculés de manière à ce que tous les neurones du voisinage du neurone j se rapprochent de x_i . Le lien entre les deux couches se fait par des vecteurs notés w_{ij} (poids synaptiques) qui sont mis à jour de manière itérative lors de la phase d'apprentissage.

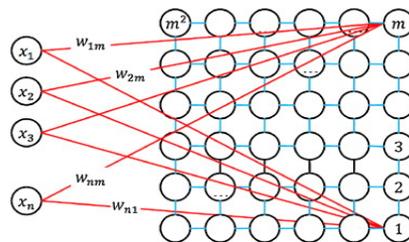


Figure 11. Exemple de structure rectangulaire de la carte 2D de Kohonen de taille $m \times m$ et représentation des deux couches d'apprentissage

L'algorithme 1 SOFM détaille la phase et les paramètres d'apprentissage.

Algorithme 1. Cartes auto-organisées (SOFM)

-
- 1 : Initialisation aléatoire des poids w_{ij} pour la première itération.
 - 2 : Un vecteur de l'espace d'entrée x_i est choisi aléatoirement et présenté à l'entrée du réseau.
 - 3 : Calcul de la distance euclidienne de chacun des neurones par rapport au vecteur d'entrée x_i présenté.
 - 4 : Sélection du neurone gagnant j minimisant le critère de distance :

$$\min_{j \in \{1, \dots, m^2\}} \left((x_i - w_{ij})(x_i - w_{ij})^T \right)$$
 - 5 : Mise à jour des poids w_{ij} des neurones de la carte pour l'itération suivante :

$$w_{ij}(t+1) \leftarrow w_{ij}(t) + \alpha(t) V_{ij}(t) \cdot (x_i - w_{ij}(t))$$
 où $\alpha(t)$ est le taux d'apprentissage et $V_{ij}(t)$ la fonction de voisinage.
 - 6 : Retour à l'étape 2 tant qu'un nombre d'itérations T n'est pas atteint.
-

L'algorithme proposé dans cette étude repose sur un découpage de l'image sonar en bandes de pixels. A chaque bande de pixels, l'apprentissage d'une carte auto-organisatrice va être réalisé. Pour guider l'apprentissage et assurer une forme de continuité entre chaque bande, il a été décidé d'initialiser les poids w_{ij} avec ceux appris sur la bande précédente ; les poids de la première bande étant initialisés aléatoirement.

Les performances de l'algorithme SOFM dépendent de deux paramètres : le taux d'apprentissage $\alpha(t)$ et la fonction de voisinage $V_{ij}(t)$. Ces deux paramètres sont choisis heuristiquement (Kohonen, 1997). La fonction de voisinage $V_{ij}(t)$ autour du neurone gagnant j décrit dans la cinquième étape de l'algorithme a la forme d'une gaussienne :

$$V_{ij}(t) = \exp\left(-\frac{d^2(i,j)}{2\sigma_t^2}\right) \quad (8)$$

où σ_t est la largeur du voisinage à l'itération t et $d^2(i,j)$ est la distance euclidienne entre le x_i et le neurone j .

D'après Kohonen (1997), la convergence du processus d'apprentissage exige que la fonction de voisinage $V_{ij}(t) \rightarrow 0$ quand $t \rightarrow T$ (nombre d'itérations) ; le taux d'apprentissage α_t et l'écart type σ_t de la fonction de voisinage doivent être deux fonctions monotones décroissantes (Kohonen, 1982).

$$\left\{ \begin{array}{l} \sigma_t = \sigma_0 \left(\frac{\sigma_{T-1}}{\sigma_0} \right)^{\frac{t}{T-1}} \text{ où } \left\{ \begin{array}{l} \sigma_0 = \frac{m}{2} \\ \sigma_{T-1} = \frac{1}{2} \end{array} \right. \\ \alpha_t = \alpha_0 \left(\frac{1-t}{T} \right) \text{ où } \alpha_0 = 0.03 \end{array} \right. \quad (9)$$

4.2. Codage de la couleur des classes

Le résultat de la segmentation par l'algorithme K-means est représenté par une image dont chaque pixel est codé par une couleur. Pour l'affectation des couleurs de classe, la démarche classique consiste à affecter à chaque classe K une couleur quelconque définie arbitrairement. Pour éviter cette définition arbitraire, le codage en couleur des classes que nous proposons se fonde sur l'analyse des attributs descriptifs spectraux et statistiques définis à la section 3. Une analyse en composantes principales (ACP) a été utilisée pour réduire la dimension du vecteur d'attributs de trente-neuf attributs aux trois combinaisons linéaires de ces attributs les plus importantes en termes de valeurs propres. Ces trois valeurs définissent une couleur en codage rouge, vert, bleu (RGB).

L'apprentissage par l'algorithme SOFM d'une bande donnée de l'image sonar est initialisé par les valeurs finales des paramètres estimés sur la bande précédente. Cette adaptation permet de garder la continuité de représentation des classes (couleurs) entre deux bandes successives de la même image sonar. Par contre un problème est rencontré pour la gestion de continuité des classes dans le cas de deux images sonar successivement présentées à l'algorithme. La couleur de la classe dépend de la position du neurone sur la carte qui est initialisée aléatoirement. Pour remédier à ce problème et rendre la couleur de classe indépendante de la position du neurone, une table fixe de couleur a été créée (figure 12) commune pour toutes les images acquises par le sonar. Cette table a été calculée de façon identique à celle employée pour représenter les résultats du K-Means.

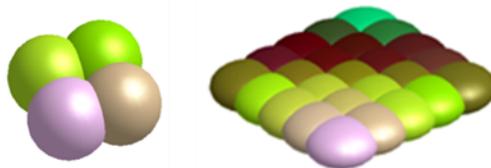


Figure 12. Exemple de la carte de Kohonen 2 x 2 (4 couleurs) et 5 x 5 (25 couleurs) avec codage en couleur

5. Résultats expérimentaux et discussions

Dans la section 5.1, une étude comparative qualitative est effectuée de manière à montrer l'intérêt de l'approche proposée. Dans la section 5.2, une analyse quantitative est menée.

5.1. Étude qualitative

Les images sonar que nous exploitons dans cet article ont été fournies par le Groupe d'Études Sous-Marines d'Atlantique (GESMA) de la Direction générale de l'armement (DGA). Les données ont été acquises par le sonar latéral Klein 5000 pendant la campagne OTAN - BP02 (Battlespace Preparation) menée entre les mois de mai et juin 2002 sur les régions de Cinque Terre et de Framura en Italie. Un exemple d'image sonar brute exploitée est représenté sur la figure 13. Quatre types de fonds marins peuvent être distingués : une zone homogène (à gauche dans l'image) de type vase et le reste de l'image est plus complexe ; on y distingue du sable, des rides de sable, de la végétation et des affleurements rocheux. Le cadre sur l'image de la figure 13 représente la zone exploitée pour notre test de segmentation.

La figure 14 présente le résultat de segmentation en quatre classes, obtenu par l'application de l'algorithme K-means pour chaque bande de pixels. Ce résultat de segmentation montre des performances limitées. Les grandes structures de l'image sonar (figure 13) se devinent mais des artefacts de segmentation liés à la dépendance à l'angle de rasance sont rencontrés. Ce phénomène est parfaitement visible sur le fond plat homogène (partie gauche de l'image) : des bandes horizontales dans le sens du déplacement du sonar (voir la figure 14) apparaissent pour un fond supposé homogène. Ce phénomène est rencontré également sur les autres zones de l'image segmentée. L'algorithme K-means semble ne pas gérer convenablement la continuité des classes d'une bande à l'autre.

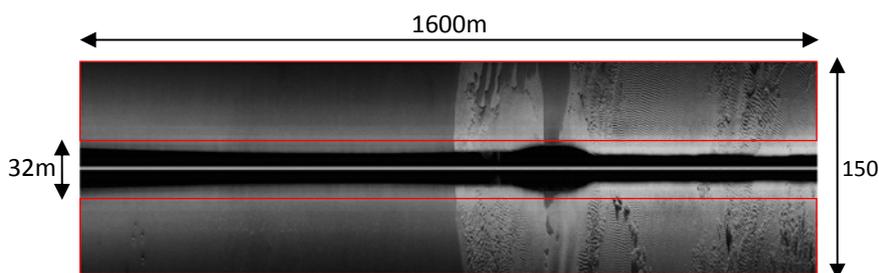


Figure 13. Exemple d'image sonar brute acquise par le sonar Klein 5000. L'image ne subit aucun prétraitement. La zone encadrée représente la partie de l'image exploitée pour les tests de segmentation

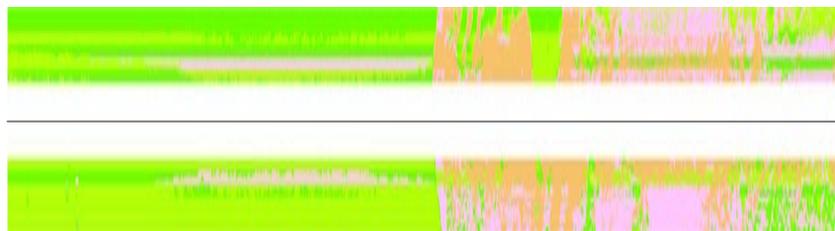


Figure 14. Segmentation par l'algorithme K-means (nombre de classes $K = 4$) de l'image de la figure 13

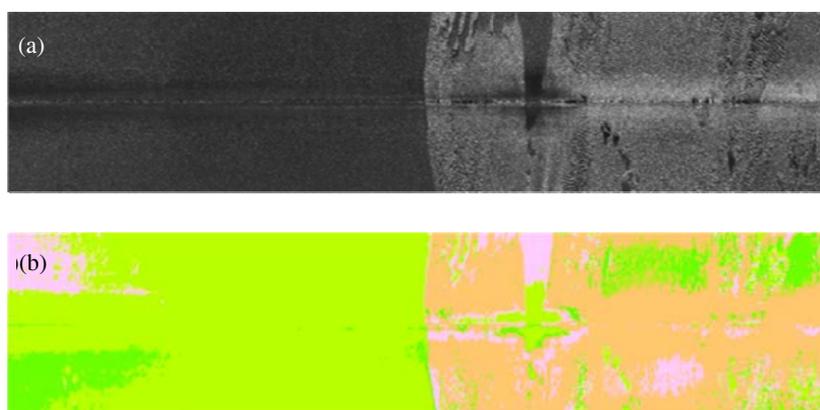


Figure 15. (a) image sonar de la figure 13, corrigée de l'amplitude en fonction de l'angle de rasance et projection géométrique sur un fond plat. (b) segmentation par l'algorithme SOFM de l'image corrigée

Une technique classique de segmentation d'images sonar est de corriger l'amplitude des pixels de l'image en fonction de la rasance et par projection géométrique sur un fond plat. La courbe de correction de l'amplitude en fonction de l'angle de rasance a été estimée sur l'image brute puis appliquée. Cette correction vise l'indépendance à la rasance des images sonar brutes. L'image corrigée est représentée sur la figure 15 (a). On remarque que la correction géométrique de l'image sonar brute fait disparaître la colonne d'eau (zone sombre). L'algorithme SOFM est appliqué sur cette image corrigée sans découpage en bandes. La structure de la carte de Kohonen est rectangulaire et de taille 4×4 ($m = 4$). Le codage en couleur de ces neurones est celui décrit en section 4.2. Le résultat de cette segmentation est présenté sur la figure 15 (b). L'image segmentée porte les grandes structures de l'image sonar et ne présente pas de bandes horizontales montrant une amélioration des résultats par rapport à l'algorithme du K-means. Cependant, une

dépendance à l'angle de rasance est constatée sur des zones de l'image montrant que la correction effectuée n'est pas optimale.

L'approche proposée de segmentation par l'algorithme SOFM avec découpage en bandes de pixels est finalement réalisée sur l'image brute (figure 13). La structure de la carte de Kohonen est identique à celle utilisée dans le test précédent. Les paramètres du découpage en bandes de pixels sont donnés en section 3.3. Le résultat de cette approche est donné sur la figure 16. Les grandes structures de l'image sont parfaitement retrouvées et le résultat est indépendant de l'angle de rasance ce qui justifie notre approche. Le résultat sur la zone homogène (gauche de l'image) est satisfaisant. En revanche, le résultat sur la zone complexe semble perfectible.



Figure 16. Segmentation de l'image de la figure 13 sans prétraitement par l'approche proposée : découpage en bandes de pixels et segmentation par l'algorithme SOFM

5.2. Étude quantitative

L'étude quantitative menée dans cette section repose sur deux méthodes d'évaluation. La première méthode exploite le chevauchement entre bandes de pixels successives pour comparer les deux approches basées sur le découpage en bandes. La deuxième méthode compare l'ensemble des méthodes sur une image présentant un type de fond marin homogène.

La première méthode profite du chevauchement entre deux bandes successives. Sur ce chevauchement, le résultat de segmentation doit être identique. Un taux d'adéquation est calculé pour quantifier ce résultat et comparer l'algorithme du K-means à l'approche proposée. Ce taux d'adéquation est exprimé en pourcentage de pixels qui sont classés de manière identique dans les deux bandes adjacentes. Le calcul est réalisé sur chaque côté de l'image bâbord et tribord. Chaque côté de l'image est découpé en sept bandes ce qui donne six zones de chevauchement. Les résultats de cette étude concernant l'analyse de l'image de la figure 13 sont reportés sur le tableau 2.

D'après le tableau 2, nous constatons que l'algorithme proposé donne de meilleurs résultats ; la valeur moyenne des deux côtés bâbord et tribord est de 75 % pour seulement 44 % pour le K-means. L'ensemble des taux d'adéquation sur les six

zones de chevauchement est en faveur de l'algorithme proposé à l'exception de deux valeurs. Cette étude confirme notre approche qui gère plus efficacement la dépendance à l'angle de rasance.

Tableau 2. Analyse de l'invariance de classification par le calcul du taux d'adéquation sur six zones de chevauchement entre deux bandes successives

<i>N° de zone de chevauchement</i>	K-means (%)		Algorithme proposé (%)	
	<i>Bâbord</i>	<i>Tribord</i>	<i>Bâbord</i>	<i>Tribord</i>
1	6	42	86	85
2	46	42	78	63
3	79	35	74	80
4	53	39	71	80
5	56	35	76	79
6	70	40	60	70
<i>Moyenne</i>	51	38	74	76
<i>Moyenne totale</i>	<u>44</u>		<u>75</u>	

La seconde méthode consiste à choisir une image présentant un type de fond homogène et à évaluer le résultat de segmentation. Pour l'expérimentation, une zone homogène de sable fin a été extraite (figure 17). Les résultats de segmentation de cette zone homogène par les différents algorithmes (K-means avec découpage et sans correction, SOFM sans découpage sur image corrigée et SOFM avec découpage sur image brute) sont donnés sur la figure 17. Les résultats montrent clairement la bonne performance de l'approche proposée. Les résultats quantitatifs reportés sur la figure 18, montrent le taux de pixels dans chaque classe pour les trois algorithmes utilisés.

On remarque de l'analyse des résultats de la figure 18 que les trois algorithmes K-means, le SOFM appliqué sur une image corrigée et l'approche proposée détectent trois classes sur quatre. L'algorithme proposé segmente la zone à 99,97 % pour une seule classe. L'algorithme SOFM sur image corrigée présente un taux de 85 % de pixels bien classés et l'algorithme des K-means, un taux de 54 %. Ces résultats confirment les bonnes performances de classification de l'approche

proposée par rapport à celles obtenues par l'algorithme K-means et à l'algorithme SOFM appliqué sur une image sonar préalablement corrigée.

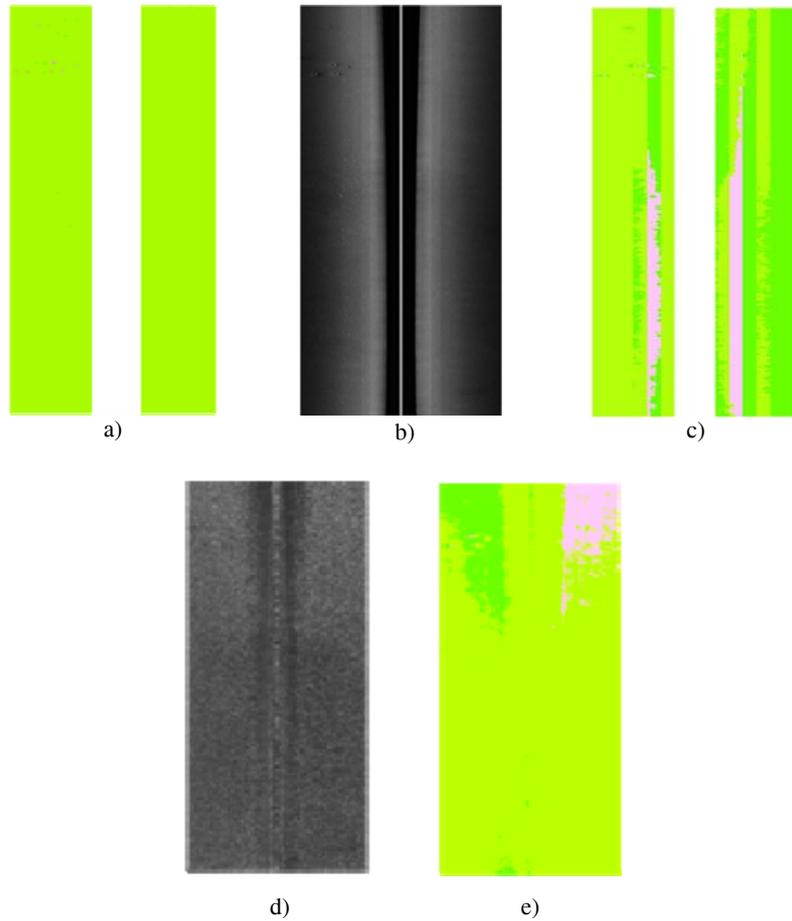


Figure 17. Segmentation d'une zone homogène a) algorithme proposé (découpage en bandes + SOFM), b) image sonar brute de nature homogène (sans prétraitement), c) algorithme K-means avec découpage en bandes, d) image sonar prétraitée, e) algorithme SOFM (sans découpage en bandes + correction en amplitude + projection géométrique sur un fond plat)

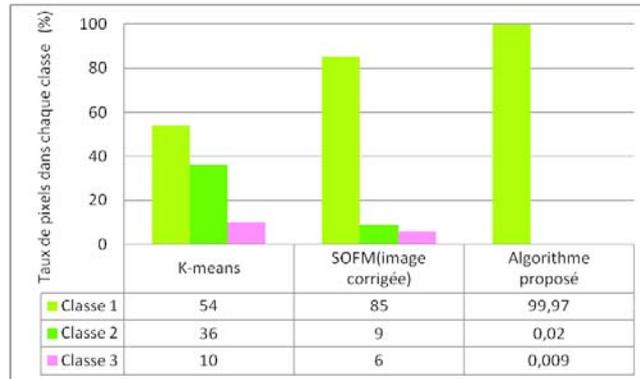


Figure 18. Comparaison de segmentation d'une zone homogène par les trois algorithmes : K-means ; SOFM + image corrigée ; approche proposée

5.3. Classification d'une zone d'étude à partir d'un ensemble de traces sonar

Classiquement les systèmes sonar enregistrent les données d'une zone d'étude sous forme d'un ensemble de traces (images) sonar. Les résultats de la section précédente considèrent une seule trace sonar et ont montré la possibilité d'une segmentation de cette trace sans aucun traitement préalable. Dans cette section, un ensemble de six traces sonar de la zone de Framura matérialisée par le polygone tracé sur la figure 19 est considéré. L'objectif est d'analyser les résultats de segmentation par l'approche proposée ainsi que la continuité géographique des classes sur cette zone. Le résultat de la segmentation des six traces est ainsi représenté après projection en coordonnées géographiques (latitude, longitude) sur la figure 20. Le résultat présente des structures bien marquées et homogènes ce qui montre la possibilité de notre approche à s'appliquer sur une zone d'étude complète.

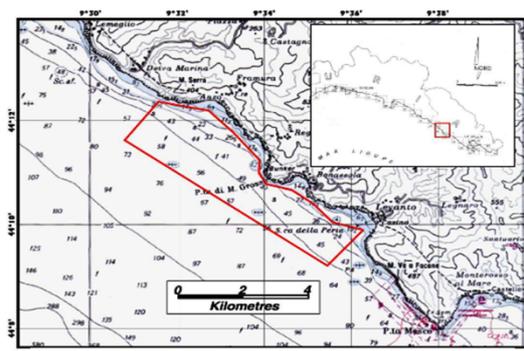


Figure 19. Localisation géographique des données exploitées dans cet article

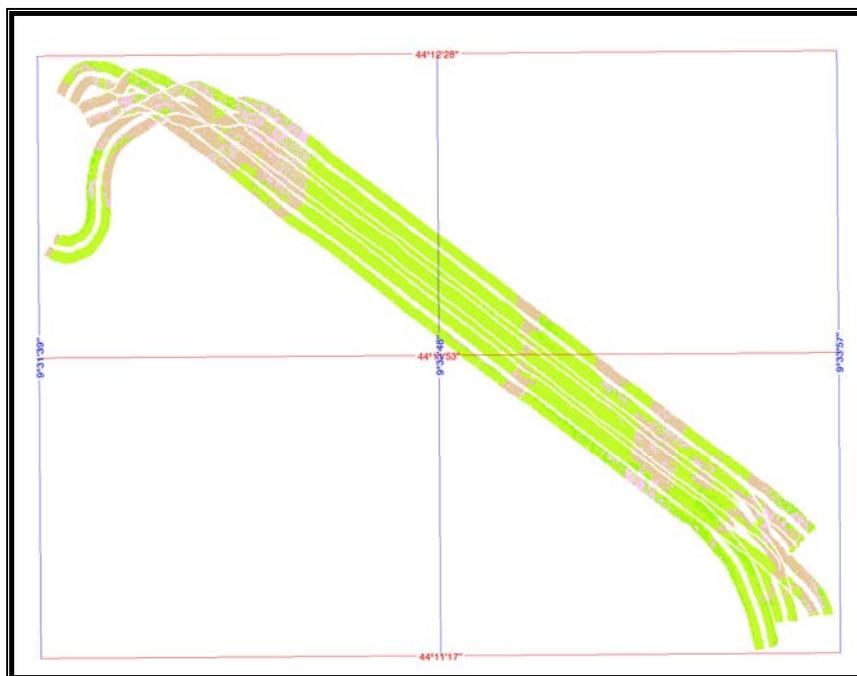


Figure 20. Segmentation géoréférencée de six traces sonar par l'algorithme proposé de la zone d'étude

6. Conclusion

Cet article concerne la segmentation des images sonar latéral brutes. Ces images présentent une dépendance des statistiques à l'angle de rasance. Pour s'affranchir de cette dépendance, nous avons proposé une approche basée sur le découpage des images sonar brutes en bandes de pixels. Chaque bande de pixels est segmentée par un algorithme adapté des cartes auto-organisées (SOFM) de Kohonen. Les performances de segmentation de cette approche sont comparées à celles obtenues par les approches non supervisées classiques comme le K-means et celles traitant au préalable les images sonar. L'approche proposée dans cet article permet d'obtenir une segmentation indépendante de la rasance, avec une homogénéité de segmentation supérieure aux deux autres approches. La généralisation de cette méthode à plusieurs traces sonars a été démontrée. Les perspectives d'évolution de l'approche porteront sur la capacité à traiter différents sites géographiques, c'est-à-dire sur la capacité de s'adapter à l'apparition de nouvelles classes.

Remerciements

Nous tenons à remercier le GESMA (DGA/TN) et le NURC de nous avoir fourni les images sonar expérimentales permettant l'évaluation de notre méthode de segmentation.

Bibliographie

- Bouvet M. (1992). *Traitements des signaux pour les systèmes sonar*. Masson et CNET-ENST, Paris.
- Capus C., Banks A.C., Coiras E., Tena I.R., Smith C., Petillot Y. (2008). Data correction for visualization and classification of sidescan sonar imagery. *IET Radar Sonar Navigation*, vol. 2, n° 3, p. 155-169.
- Celik T., Tjahjadi.T. (2011). A Novel Method for Sidescan Sonar Image Segmentation. *IEEE Journal of Oceanic Engineering*, vol. 36, n° 2, p. 186-194.
- Chapple P. (2008). *Automated detection and classification in high-resolution sonar imagery for autonomous underwater vehicle operations*. Australian Government Department of Defence Technical Report, DSTO GD-0537.
- Duda R.O., Hart P.E., Stork D.G. (2001). *Pattern classification*. A Wiley-interscience Publication, John Wiley & Sons, INC.
- Dugelay S. (1997). *Caractérisation des fonds marins à partir des données sondeurs EM 12*. Thèse de doctorat. Université de Paris-SUD U.F.R Scientifique d'Orsay.
- Haralick R.M. (1979). Statistical and structural approaches to texture. *Proceeding of the IEEE*, vol. 67, n° 5, p. 786-804.
- Haralick R.M. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3, vol. 6, p. 610-621.
- Harris F. j. (1978). On the use of Windows for Harmonic Analysis with the Discrete Fourier Transform. *Proceedings of the IEEE*, vol. 66, n° 1, p. 51-83. doi:10.1109/PROC.1978.10837.
- Hastie T., Tibshirani R., Friedman J. (2009). *Elements of Statistical Learning: Data Mining, Inference and Prediction*. (Second Edition). Springer-Verlag, New York.
- Hellequin L., Boucher J.M., Lurthon X. (2003). Processing of high-frequency multibeam echo sounder data for seafloor characterization. *IEEE Journal of Oceanic Engineering*, vol. 28, n° 1, p. 78-89.
- Hellequin L. (1998). *Analyse statistique et spectral des signaux de sondeurs multifaisceaux EM950*. Thèse de doctorat en terre, océan, espace. Université de Rennes 1.
- Karoui I., Fablet R., Boucher J.M., Augustin J.M. (2009). Seabed segmentation using optimized statistics of sonar textures. *IEEE Journal of Oceanic Engineering*, vol. 47, n° 6, p. 1621-1631.

- Karoui I., Fablet R., Boucher J.M., Augustin J.M. (2008). Segmentation texturales des images sonar des fonds marins par une approche variationnelle basée région. *Traitement du Signal*, vol. 25, n° 1-2, p. 73-86.
- Karoui I. (2007). *Segmentation par méthodes markoviennes et variationnelles des images texturées : application à la caractérisation des fonds marins*. Thèse de doctorat en Traitement du signal et Télécommunications ENST de Bretagne et Université de Rennes.
- Kernéis D. (2007). *Amélioration de la classification automatique des fonds marin par la fusion multicapteurs acoustiques*. Thèse de doctorat en Traitement du signal et Télécommunications ENST Bretagne et Université de Rennes I.
- Kohonen T. (1997). *Self-organizing Maps*. Springer-Verlag. USA, New York.
- Kohonen T. (1982). Self-Organizing Formation of Topologically Correct Feature Maps. *Proceedings Biological Cybernetics*, vol. 46, p. 59-69.
- Laur H., Le.Toan T., Lopes A. (1987, May). Textural segmentation of SAR Images using First Order Statistical Parameters. *Proc. International Geoscience and Remote Sensing Symposium (IGARSS'87)*. Ann Harbor, Michigan, USA, p. 1463-1468.
- Leblond I., Legris. M, Solaiman. B. (2008). Apport de la classification automatique d'images sonar pour le recalage à long terme. *Revue Traitement du signal*, vol. 25, n° 1-2, p. 87-104.
- Leblond I. (2006). *Recalage à long terme d'images sonar par mise en correspondance de cartes de classification automatique des fonds*. Thèse de doctorat en Traitement du Signal ENSTA Bretagne et UBO.
- Le Chenadec G., Boucher J.M., Lurthon X. (2007). Angular dependence of K-distributed sonar data. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, n° 5, p. 1224-1235.
- Le Chenadec G., Boucher J.M. (2005). Sonar image segmentation using the angular dependence of backscattering distributions. *In Proceedings of Oceans '05*, Brest, France, 20-23 Juillet.
- Lianantonakis M., Petillot Y.R. (2007). Sidescan sonar segmentation using texture descriptors and active contours. *IEEE Journal of Oceanic Engineering*, vol. 32, n° 3, p. 744-752.
- Linnett L.M., Clarke S.J., Carmichael D.R. (1994). The analysis of sidescan sonar images for seabed types and objects. *Proceedings of Second European Conference on Underwater Acoustics ECUA 1994*, p. 22:187-194.
- Lubniewski Z., Pouliquen E. (2004). Sensitivity of echo parameters to seafloor properties and depth variability. *Proceedings of the Seventh European Conference on Underwater Acoustics ECUA 2004*, p. 763-768.
- Marceau D.J., Howarth P, Dubois J.M., Gratton D.J. (1990). Evaluation of the grey-level cooccurrence matrix method for land-cover classification using spot imagery. *IEEE on Geoscience and Remote Sensing*, vol. 28, n° 4, p. 513-519.
- Moysan J., Corneloup G., Magnin I.E., Benoist P. (1992). Matrice de co-occurrence optimale pour la segmentation automatique d'images ultrasonores. *Traitement du Signal*, vol. 9, n° 4, p. 309-323.

- Pican N., Trucco E., Ross M., Lane D.M., Petillot Y., Tena Ruiz I. (1998). Texture Analysis for Seabed classification: Co-occurrence Matrices vs Self-Organizing Maps. *OCEANS '98 Conference Proceedings*, 28 Sep-1 Oct. Nice, France, vol. 1, p. 424-428.
- Pouliquen E. (2004). Depth dependence correction for normal incidence echosounding. *Proceedings of the Seventh European Conference on Underwater Acoustics ECUA 2004*, 5-8 July, Delft, Netherlands.
- Preston J. (2009). Automated acoustic seabed classification of multibeam images of Stanton Banks. *Applied Acoustics*, vol. 70, n° 10, p. 1277-1287.
- Sercic D., Loncaric S. (1998). Enhancement of mammographic for detection of microcalcifications. *Proceedings of the IX European Signal Processing Conference*, Island of Rodos, Greece, vol. II, p. 693-696.
- Tang X., Stewart W.K. (1995). Texture classification using wavelet packet and Fourier transforms. *OCEANS '95. MTS/IEEE. Challenges of Our Changing Global Environment. Conference Proceedings*, vol. 1, 9-14 Oct. San Diego, CA, USA, vol. 1, p. 387-396.
- Tuceryan M., Jain A.K., Chen C.H., Pau L.F., Wang P.S.P. (1998). Texture analysis. The Handbook of pattern Recognition and computer Vision (2nd Edition). *World Scientific publishing Company*, p. 207-248.
- Yao K.C., Mignotte M., Collet C., Galerne P., Burel G. (2000). Unsupervised segmentation using a self-organizing map and a noise model estimation in sonar imagery. *Pattern Recognition*, vol. 33, p. 1575-1584.

Ahmed Nait-Chabane est doctorant à l'ENSTA Bretagne au département OSM (Ocean Sensing and Mapping) et membre du laboratoire LAB STICC UMR CNRS 6285. Son domaine de recherche est l'extraction et le traitement de l'information dans les signaux et les images. Il s'intéresse particulièrement aux techniques de classification et de segmentation et aux applications des algorithmes d'apprentissage artificiel.

Benoît Zerr est responsable du département OSM (Ocean Sensing and Mapping) de l'ENSTA Bretagne et membre du laboratoire LAB STICC UMR CNRS 6285. Son domaine de recherche est l'automatisation de la perception des fonds marins. Il s'intéresse plus particulièrement à la robotique navale, à l'extraction d'informations dans les images sonar et à la reconnaissance automatique de cibles en environnement sous-marin.

Gilles Le Chenadec est enseignant-chercheur à l'ENSTA Bretagne dans l'équipe Ocean Sensing and Mapping. Il est membre du laboratoire LAB STICC UMR CNRS 6285. Ses travaux portent sur l'exploitation de l'information dans les signaux et les images et plus particulièrement sur la classification et la caractérisation des fonds marins à partir de systèmes SONAR.