

Fusion de segmentation et classification automatique d'images sonar

Julien Lengrand-Lambert*, Arnaud Martin*
Hicham Laanaya**, Romain Courtis***

*ENSIETA, E³I², EA3876, 2 rue François verny, 29806 Brest cedex 9
lengraju@ensieta.fr, Arnaud.Martin@ensieta.fr,

**HEUDIASYC, Université de Technologie de Compiègne (UTC),
Centre de recherche Royallieu, BP 20529 - 60205 Compiègne Cedex - France
hicham.laanaya@utc.fr

***GESMA/SDP/GDM, BP 42 - 29240 BREST ARMEES - France
Romain.Courtis@dga.defense.gouv.fr

Résumé. Cet article aborde la problématique de la classification et de la segmentation des images sonar du fond marin et de la fusion des deux approches afin d'en extraire de manière automatique des informations de classes et de frontières entre régions. Ce travail s'inscrit dans une démarche de cartographie automatique des fonds marins. La segmentation manuelle par expert est en effet une démarche coûteuse en temps et en argent et se traduit de plus par une variabilité des résultats. Deux experts n'auront en effet jamais exactement la même interprétation d'un fond marin. Ce travail s'appuie sur un précédent logiciel réalisé par Artigues et Billard (2005), qui permet de classifier automatiquement une image de fond marin à l'aide d'une base d'apprentissage. Afin de le compléter, nous nous sommes concentrés sur une approche par régions, puis avons cherché une méthode de fusion de ces deux approches. Ceci permet alors d'effectuer un premier bilan quand aux possibilités que pourraient offrir ces méthodes et l'utilité de continuer dans cette voie.

1 Introduction

La segmentation automatique des images sonar est un thème de recherche qui mobilise de nombreuses ressources à travers le monde aujourd'hui (*cf.* par exemple Leblond et al. (2005); Le Chenadec et Boucher (2005)). En effet, il n'existe aucune méthode générale qui traite automatiquement les données sonar et celles-ci sont de manière usuelle segmentées à la main par un expert du domaine. Ce traitement manuel, coûteux en temps et en moyens financiers, possède de plus une part d'incertitude car deux experts ne donneront jamais la même interprétation des images qu'ils ont traitées (voir figure 1). Enfin, il est important de noter que l'imagerie sonar est un domaine où s'expriment de fortes contraintes : hostilité et méconnaissance du lieu d'études, pertes importantes dues au domaine de propagation, et surtout changement constant de la typographie des fonds marins. Les données sonar sont ainsi complexes à traiter.




FIG. 1 – Segmentation effectuée par deux experts différents

Devant l'intérêt croissant porté au monde sous-marin dans le monde industriel et militaire, à travers des applications telles que la chasse aux mines, on comprend aisément l'enjeu du développement d'un logiciel intégrant une chaîne complète de correction et segmentation des images sonar. Une première version présentée par Laanaya (2007), intègre une classification automatique des images fondée sur la caractérisation de la texture. Cependant, comme toute méthode automatique, elle est loin d'être parfaite et les erreurs de reconnaissance sont nombreuses. L'objectif de ce papier est donc de proposer une méthode de fusion de classification et de segmentation automatiques.

Il est important de distinguer clairement les deux méthodes qui ont été employées pour traiter le fond marin : la classification automatique, puis la segmentation automatique. Toutes deux ont la même image sonar en entrée mais diffèrent totalement dans leurs résultats, ce qui justifie une approche de fusion. La méthode de classification a pour but une division de l'espace de l'image en différentes classes que l'on choisit au départ. Ainsi, on utilise dans notre cas une classification supervisée. L'image de sortie est donc divisée en zones de types de fonds différents (sable, cailloux, roche, vase, ...). La segmentation quant à elle, utilise la même image, mais sans *a priori*. Le principe choisi pour cette segmentation repose sur une recherche des plages de niveaux. Cela signifie que les frontières obtenues en sortie correspondent à une forte variation de niveau dans l'image. Cette méthode ne présume absolument pas du type de fond de chaque classe de l'image et ne recherche que des frontières. C'est pour cela qu'on la nomme 'approche région'. Au vu de ces explications, on peut comprendre l'intérêt d'une fusion de ces deux résultats. Joindre la performance en frontière à une prévision des classes peut permettre d'obtenir l'objectif recherché.

Dans cet article, nous allons donc tout d'abord nous attacher à présenter rapidement les deux méthodes de segmentation et classification utilisées. Nous traitons ensuite la fusion, et la démarche suivie pour l'obtention des résultats, présentées dans une dernière section.

2 Classification des images sonar

Une première méthode de classification automatique a été mise au point par Laanaya (2007). Cette approche permet, à partir d'images sonar qui ont été au préalable débruitées, de fournir une image de sortie séparant l'image selon la classe de fond marin. L'utilisation d'une




FIG. 2 – Exemple de matrice des paramètres d'une image sonar

classification supervisée peut s'expliquer par le fait que nous possédons des images d'expert segmentées manuellement et donc les différents types de sédiment recherchés.

Extraction de texture Les différents type de sédiments se caractérisent sur l'image sonar au travers de leur texture. Trois classes sont ici distinguées : rides, sable et roche. Pour représenter la texture, les images sonar sont divisées en petites imagettes pour lesquelles on calcule un vecteur de paramètres de texture. Différentes approches sont envisageables Martin *et al.* (2004), l'approche retenue ici se fonde sur les matrices de confusion proposée par Haralick (1979). Six paramètres de texture sont utilisées : homogénéité, contraste, entropie, corrélation, directivité et uniformité de l'énergie Russ (2002). Une image est donc représentée par six images de texture (*cf.* figure 2).

Classification d'images Laanaya (2007) a proposé différentes approches de classification supervisée pour les images sonar telles que les machines à vecteurs de support ou encore des approches plus simples telles que les k -plus proches voisins. Cette dernière approche montre des résultats déjà assez cohérents en elle-même. Les classes sont assez bien représentées pour peu que la base d'apprentissage soit fournie et que l'image ne soit pas de fond trop changeant. Cependant, elle manque de précision en raison du fait que l'on travaille sur des imagettes. On a donc des valeurs moyennes qui ne sont assignées qu'à un nombre plus faible de pixels ce qui conduit à une perte de résolution spatiale. De plus, une approche de classification ne permet pas de définir précisément les frontières entre les classes.

3 Segmentation automatique des images sonar

Afin de tenter d'améliorer ces résultats, nous avons appliqué une méthode originale de segmentation du fond marin dans Lengrand-Lambert (2009). Cette méthode est indépendante de la classification et se fonde sur une approche par régions. Cette dernière n'apporte donc pas d'informations sur le type de fond marin de l'image testée mais sur ses frontières. Cela devrait donc permettre d'être plus précis au niveau des frontières et avoir un gain d'informations face à la méthode de classification seule. Cette segmentation automatique a pour cœur la méthode des plages de niveaux proposée par Sumenger (2005), qui a été choisi dans l'objectif d'un travail préliminaire. L'algorithme de segmentation peut être divisé en trois étapes principales :

- **Paramétrage de la méthode** : Il s'agit ici de choisir les paramètres qui seront utilisés. C'est la seule interaction de l'opérateur dans la chaîne de traitement.
- **Prétraitement des données** : La première phase utilise les images créées à partir des imagerie, c'est-à-dire des images contenant les paramètres de Haralick calculés. Ces entrées sont modifiées afin de les rendre utilisables par la suite. On n'extraira notamment que certains des paramètres afin d'améliorer les résultats.
- **Segmentation** : La phase principale de la méthode prend en entrée les matrices de chaque paramètre de Haralick choisi par l'utilisateur et leur applique l'algorithme des plages de niveaux. Différents traitements seront encore effectués jusqu'à obtenir en sortie une matrice des régions de l'image sonar de base de même taille que l'image classifiée automatiquement.

Voici le détail des deux dernières étapes.

3.1 Prétraitement des données

Cette étape est importante car elle va conditionner la suite de l'approche. Si les données sont mal prétraitées, elles ne pourront en effet pas être de bonne qualité en sortie, et les résultats obtenus seront donc mauvais. Le prétraitement des données se décompose en plusieurs parties distinctes, qui sont appliquées de manière séquentielle.

Récupération des paramètres choisis Le but principal de la classification est de déterminer une nouvelle méthode qui permette de compléter l'existant à l'aide des mêmes données d'entrée. Cette partie consiste donc à examiner les données afin de les utiliser de la meilleure manière possible. L'implémentation de l'algorithme est assez ouverte pour permettre l'insertion de nouveaux paramètres par la suite ou encore d'insérer des méthodes de choix 'dynamiques'. Les constatations suivantes sont ainsi valables pour les images de notre base de données, et pourraient être approfondies dans une étude complémentaire. La première opération à effectuer est un choix des paramètres de Haralick à utiliser pour le reste de l'étude. Ce choix est resté le même lors de toute notre étude et est donc considéré comme appartenant à la phase de prétraitement. Il correspond à une phase de calibrage qui va dépendre de la base de données d'apprentissage. Tous les résultats obtenus ne sont pas de bonne qualité, et donc pas forcément utilisables. De manière assez générale sur nos images, nous observons que la corrélation et le contraste sont assez bruités (*cf.* figure 2). Ces deux paramètres n'ont donc pas été pris en compte pour la segmentation. De plus pour n'importe quelle image, l'uniformité et l'homogénéité donnent les mêmes informations en terme de segmentation, à ceci près que l'uniformité semble être atténuée par rapport à l'homogénéité. Afin d'optimiser le temps de calcul, ce paramètre n'est donc pas pris en compte. Les trois paramètres de Haralick choisis pour la segmentation sont donc : l'homogénéité, l'entropie et la directivité. On peut bien sûr tenir compte d'un grand nombre d'autres paramètres Martin et al. (2004).

Segmentation de chaque matrice On effectue une segmentation de Fisher sur chaque image des trois paramètres de texture retenus, afin de passer d'une matrice à niveaux continus à une matrice contenant 4 niveaux (*cf.* Russ (2002)). Cette segmentation permet de réduire de manière significative le nombre de plages de niveaux obtenues lors de la segmentation, et donc d'être plus précis dans les zones sélectionnées en sortie d'algorithme. La méthode de

Fisher est une méthode de segmentation qui se fonde sur un calcul à partir de l'histogramme d'une image. Quatre niveaux d'intensité sont discriminés avec pour critère de calcul celui de la minimisation de la somme des inerties de chacune des régions. Cette méthode de calcul recherche donc à partir de l'histogramme de départ et du nombre de régions à optimiser, la partition de l'algorithme en identifiant les séparateurs entre les régions.

Mise en forme des matrices Pour appliquer la suite de la segmentation, il convient de faire en sorte que toutes les matrices aient des contours de fortes amplitudes dans les mêmes zones. En effet, pour les paramètres choisis au départ ; les matrices obtenues ont des variations qui se situent globalement dans les mêmes zones. Cependant, les matrices d'homogénéité et contraste ont des niveaux bas là où la matrice d'entropie possède des niveaux hauts. Il faut donc effectuer une modification (une inversion) des trois matrices obtenues afin que toutes possèdent des **maxima** pour les mêmes zones. Ceci est indispensable pour la suite de l'algorithme, qui va rechercher à récupérer des contours précis ; en se fondant sur les zones de l'image de plus fortes valeurs.

3.2 Segmentation

Cette partie est la plus importante de notre démarche de segmentation automatique des images. C'est elle qui va permettre d'obtenir les résultats finaux, et qui encapsule les algorithmes de plages de niveaux. Chaque étape de cette partie est effectuée à la suite des autres de manière séquentielle.

Application de l'algorithme des plages de niveaux Les plages de niveaux sont une méthode de calcul utilisée dans les cas où l'on recherche à observer l'évolution de force au sein d'une image, et notamment la recherche des discontinuités. Pour un contour fermé donné, les plages de niveaux vont permettre la recherche de la zone de discontinuité minimale ; et donc tendre à se refermer sur ce contour comme le montre Sumenger (2005). En supposant que ce dernier délimite deux zones d'évolution différentes plusieurs forces peuvent alors exister : dans la direction normale à la courbe, venant d'un vecteur extérieur ou fondée sur le contour lui-même. Cela se traduit par l'équation différentielle suivante :

$$\frac{\partial f}{\partial t} + \vec{S} \cdot \text{div}(f) + V_n \cdot |\text{div}(f)| = V_n \cdot |\text{div}(f)|$$

où le premier terme est la force de type vectorielle, le seconde terme la force de direction normale et la dernière celle qui correspond à une force f appliquée sur la courbe. L'algorithme présenté ici est appliqué uniquement dans la direction de la courbe ce qui signifie que les zones recherchées sont du type :

$$\frac{\partial f}{\partial t} = V_n \cdot |\text{div}(f)|$$

Cela équivaut à rechercher les zones de plus fort gradient dans l'image.

La méthode a été très peu modifiée lors de l'étude : elle prend en entrée l'une des matrices de la cellule de départ, ainsi qu'un nombre d'itérations, qui va jouer fortement sur la qualité finale du rendu. En effet, plus le nombre d'itérations sera grand, plus les contours obtenus

Fusion de segmentation et classification automatique d'images sonar




FIG. 3 – Schéma explicatif de la création de matrice des distances gaussiennes

seront lissés et fins. Il convient donc de modérer le nombre d'itérations choisis. Cette étape joue donc le rôle de filtre, et va permettre de discriminer rapidement les zones de fort changement dans l'image. Ce lissage sera ensuite utilisé pour obtenir les frontières recherchées.

Création de la matrice des distance gaussiennes Après passage de l'algorithme sur chacune des trois matrices, il convient de rechercher maintenant les contours lissés des images d'entrée. Une recherche de contours est appliquée puis les résultats sont discriminés pour ne garder que les contours les plus forts. Ces trois matrices sont ensuite fusionnées. La méthode utilisée est la création d'une matrice des distances gaussiennes (voir figure 3). Le principe est simple : il suffit de calculer pour chaque point d'une matrice la distance qui la sépare du point de contour le plus proche, pour obtenir une 'matrice des distances'. Une fois tous les pixels traités, il reste à créer la matrice 'gaussienne' de la précédente et à sommer les trois résultats. De cette manière, on peut observer des zones de recouvrement qui correspondent à des zones de corrélation des frontières pour les différents paramètres de Haralick.

Récupération de la matrice des régions Ceci est la dernière étape de la méthode de segmentation automatique. La matrice de distances gaussiennes contient en effet les frontières finales. Il ne reste maintenant plus qu'à mettre l'image sous la bonne forme pour pouvoir la réutiliser plus tard. C'est l'objectif de cette partie. Pour ce faire, nous passons d'une matrice des frontières à une matrice des régions. La seule barrière qu'il reste à franchir pour terminer cette segmentation est l'obtention de frontières exactes. En effet, les frontières sont encore larges de plusieurs pixels en raison de la création de la matrice des distances gaussiennes.

Cette méthode de segmentation est totalement décorrélée de la classification automatique et permet d'apporter de nouvelles informations sur l'image de fonds marins traitée. Au vu des résultats, les frontières obtenues en fin de segmentation sont de meilleure qualité que celles de la classification. Cependant, nous n'avons aucune information quand au type de fond des régions trouvées. Après vérification manuelle, les résultats obtenus sont de meilleure qualité pour les fonds rocheux et de sable, mais les zones de rides ont tendance à être occultée par l'algorithme.

Maintenant que nous parvenons d'une part à segmenter puis d'autre part à classifier une image sonar de manière automatique, la recherche d'une méthode de fusion qui permette de lier les résultats de ces deux méthodes paraît se justifier. C'est l'objet de la partie suivante.

4 Algorithme et méthode de la fusion

Cette partie présente une méthode dont le but est de fusionner les résultats obtenus jusqu'à maintenant afin d'avoir une classification automatique des images sonar. Celle-ci contiendrait à la fois les informations d'une approche 'classe' et d'une approche 'région'. Durant cette partie, les deux premières étapes de segmentation et classification sont déjà effectuées. L'objectif est alors d'obtenir une image prévisionnelle la plus proche possible de la réalité à partir des deux images obtenues précédemment. La démarche présentée est en deux étapes principales : récupération des contours fins et détermination de la classe de chaque région obtenue.

4.1 Récupération des contours fins

Il s'agit de la première étape de la fusion de données. Les deux matrices d'entrée sont la matrice des régions obtenue par la segmentation, ainsi que celle des régions de la classification. Ces régions et leurs frontières sont différentes, et le but de la fusion va être de les unifier du mieux possible. Une fois les frontières trouvées, on pourra alors rechercher les classes de fond de chaque région obtenue.

Une méthode similaire à celle de la segmentation automatique des trois paragraphes précédents est utilisée pour fusionner les frontières entre les deux images d'entrée. Ainsi, nous appliquons un seuillage à l'aide de l'algorithme de Fisher puis des plages de niveaux. Cette étape est suivie d'un passage de la matrice obtenue en matrice des distances gaussiennes. Cela permet donc d'avoir une matrice qui correspond à la somme gaussienne des frontières de chacune des deux matrices prises en entrée. Les frontières de cette image de somme gaussienne de sortie peuvent donc être récupérées en utilisant les zones de recouvrement. La frontière de deux régions sera donc déterminée par le maximum de recouvrement obtenue pour la matrice. Il ne reste plus alors qu'à passer d'une approche par contour à une approche par région. Chaque zone de l'image sera donc considérée en sortie comme une région. De cette manière, l'utilisation des outils déjà développés précédemment permet de sélectionner plusieurs zones de l'image qui représentent les différentes présences de classes.

4.2 Détermination de la classe de chaque région

L'objectif de cette partie est de réussir à attribuer une classe de terrain à chacune des régions de l'image qui vient d'être créée. Pour cela, les paramètres de Haralick vont encore une fois permettre de discriminer les différentes classes, en s'appuyant sur une classification supervisée. L'algorithme comprend deux étapes centrales, la recherche d'un vecteur de paramètres pour les régions de la matrice à classifier et la récupération de la classe de la région sélectionnée.

Recherche d'un vecteur de paramètres pour les régions de la matrice à classifier Chaque pixel d'une région étant représenté par un vecteur de paramètres de Haralick, il faut calculer le vecteur moyen des paramètres. Ce vecteur moyen est ensuite pris comme représentatif de la texture de la région homogène.

Classification des régions Pour classifier la région à partir du vecteur de paramètres, plusieurs approches sont envisageables. Nous présentons ici : i la méthode des k plus proches voi-

sins, qui cherche la proximité d'un élément avec un ensemble d'apprentissage, *ii* la méthode des prototypes, dérivée de la méthode précédente en moyennant les vecteurs d'apprentissage.

La première étape de test est effectuée avec une méthode simple, la méthode des k plus proches voisins (knn) (*cf.* Pasini et Grandgeorge (2003)). Il s'avère en fait que la méthode des knn a donné les résultats les plus précis et reproductibles. Ainsi, les k vecteurs les plus proches de chaque vecteur de région sont recherchés dans la base d'apprentissage. Le paramètre k est choisi entre 3 et 5 durant nos expériences. Les distances utilisées ici sont des distances euclidiennes qui conviennent bien dans ce type d'espace. À l'issue de cette recherche, il suffit enfin d'assigner la région à la classe majoritairement représentée dans l'échantillon. Nous supposons donc que l'échantillon choisi fait partie de l'ensemble le plus représenté autour de lui.

La méthode des prototypes est assez proche de la méthode des knn. À partir des vecteurs de la base d'apprentissage, les vecteurs sont moyennés pour obtenir en sortie un seul vecteur caractéristique par classe qui sera le 'prototype' de celle-ci. Notre base de connaissance se présente donc maintenant sous la forme de trois vecteurs, soit un par classe. Il reste alors à rechercher lequel de ces trois vecteurs est le plus proche de chacun des vecteurs de région et d'assigner la région à la classe correspondante.

Avant de présenter les résultats finaux, il reste à ajouter que le programme total est relativement rapide si l'on omet la création de la base d'apprentissage lors de la première utilisation. En effet, la totalité de l'algorithme de fusion est effectif en moins de 30 secondes sur une machine de bureau standard (2 Coeurs à 2.1 Ghz et 3 Gigas de mémoire) et pour une image au préalable débruitée de 600x3000 pixels. Cela permet d'imaginer dans le futur une approche opérationnelle de fusion en sortie directe de sonar. Les résultats obtenus pour chacune des deux approches de fusion, ainsi que les paramètres nous permettant de juger de leur qualité, sont présentés dans la section suivante.

5 Premiers résultats

Dans cette dernière section, nous allons présenter tour à tour les résultats que nous avons pu obtenir avec les différentes méthodes. Le jugement de la qualité des résultats et leur exploitation s'appuiera sur le calcul des matrices de confusion comparant l'image de résultat avec l'image d'expert. Les 42 images sonar fournies par le GESMA (Groupe des Études Sous-Marines de l'Atlantique) proviennent d'une campagne de données effectuée au large des côtes finistériennes. Elles sont issues d'un sonar de type Klein 5400 et ont une résolution de 20 à 30 cm en azimut et 3 cm en range. La profondeur des fonds se situe entre 15 et 40 m.

L'utilisation de classifications supervisées lors de l'étude impose de scinder la base de données en deux parties : la base d'apprentissage qui permet d'obtenir les ressources nécessaires à appliquer les algorithmes et la base de test contenant les images sonar qui seront classifiées. La base d'apprentissage actuelle comporte 39 images sonar segmentées manuellement ce qui permet d'obtenir plus de 6700 imageries. Les imageries sont carrées et ont une dimension de 32 pixels de côté. De plus, le milieu naturel ne possède pas un équilibre parfait des différents types de sédiments qui se traduit par un nombre d'imageries changeant en fonction des types de terrain. Afin de régler ce problème, la base contiendra autant de vecteurs pour chacune des trois classes de terrain à discriminer pour contenir finalement 2304 vecteurs de chaque classe (rides, sable et roche). Cette base devrait être suffisamment fournie pour obtenir de bons résul-

tats en sortie. Pour les images suivantes, nous utiliserons la couleur bleue pour la **classe roche**, la couleur verte pour la **classe ride** et la couleur rouge pour la **classe sable**.

5.1 Segmentation et Classification

La première étape de la phase de test passe par la validation de la classification et segmentation automatiques.

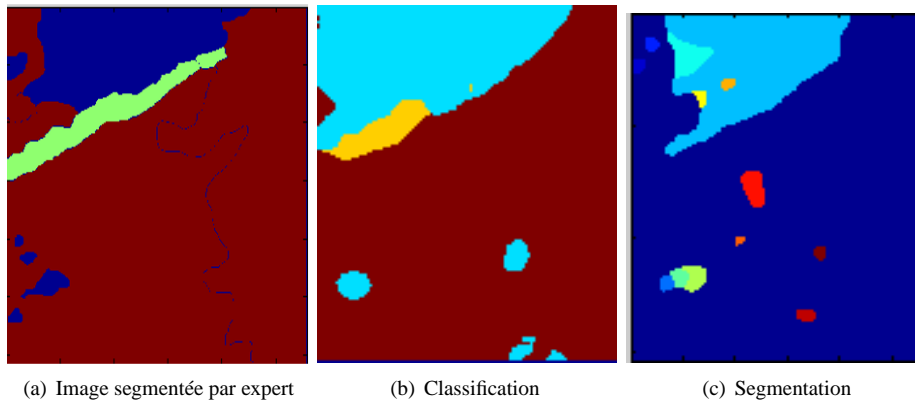


FIG. 4 – résultats obtenus pour la classification puis la segmentation automatiques

Classification automatique Après application de la méthode de classification automatique détaillée, nous observons les résultats présentés sur la figure 4. Il existe une similitude apparente entre l'image segmentée par expert et l'image classifiée automatiquement. Les zones présentes concordent et les 3 classes sont bien présentes en sortie. La qualité de ces résultats se vérifie avec la matrice de confusion correspondante (*cf.* tableau 1). Les pourcentages de bonne détection obtenus dans le cas des classes roche et sable sont en effet très bons (supérieurs à 80%). Cependant, nous observons également que le taux d'erreur dans le cas de la classe ride est supérieur à 60%. La détection est donc peu fiable dans le cas de la détection de rides. Les résultats semblent cependant assez cohérents pour continuer notre démarche de fusion. Nous obtenons ainsi 84% de bonne détection pour la **classe roche**, 64% d'erreur pour la **classe ride** (la zone de ride est écourtée par rapport à l'image de base) et 82.9% de bonne détection pour la **classe sable**.

	ride	roche	sable
ride	1424	2243	298
cailloux	298	13336	2243
sable	414	11158	56075

TAB. 1 – Matrice de confusion pour la classification automatique

Segmentation automatique Avant d'effectuer cette fusion, il reste à bien vérifier que la segmentation automatique produit elle aussi des résultats convenables. Nous ne pourrions toutefois pas nous appuyer sur des résultats statistiques cette fois pour valider notre démarche. L'approche par régions ne permet en effet que de discriminer des ensembles et ne donne aucune information quand aux classes de types de fond. Une approche d'évaluation de la segmentation a cependant été proposée par Martin et al. (2006). L'image finale obtenue est représentée sur la figure 5. Chaque couleur sur l'image correspond une région différente. Les frontières apparaissent moins régulières que pour l'approche de classification. De plus, elles semblent se conformer à l'allure de la segmentation de l'expert. La démarche de fusion se justifie donc.

Dans l'idéal, la fusion de ces deux méthodes pourrait permettre de déterminer à la fois les types de fonds tout en gardant la précision des contours de l'approche région.

5.2 Fusion de la classification et segmentation

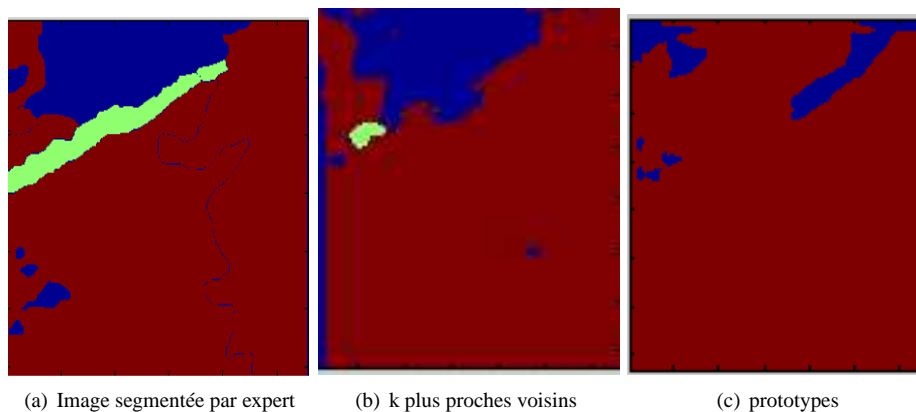


FIG. 5 – résultats obtenus pour la fusion par les deux méthodes utilisées

Méthode des k plus proches voisins À l'issue de cette méthode, l'image obtenue est présentée sur la figure 5(b). L'allure générale de la matrice de fusion reste la même que la matrice d'expert. Les trois classes sont présentes et apparaissent globalement bien placées. Des différences significatives sont pourtant remarquables. La classe roche est très bien représentée, avec l'apparition de la zone bleue dans la partie supérieure de l'image. Cependant, les zones rocheuses dans la partie basse de l'image sont absentes dans les résultats. L'algorithme n'a pas permis de les détecter. De même, la zone de rides de sable est toujours présente en sortie, mais seule une petite partie apparaît. La perte d'informations est relativement élevée en ce qui concerne cette zone de rides, qui est remplacée par du sable simple (en rouge).

La matrice de confusion correspondant aux résultats permet de quantifier ces différences (cf. tableau 2). Nous obtenons ainsi 69.2% de bonne détection pour la **classe roche**, 62% d'erreur pour la **classe ride** (la zone de ride est écourtée par rapport à l'image de base) et 95.4% de bonne détection pour la **classe sable**.

	ride	roche	sable
ride	374	560	52
cailloux	4	2489	1101
sable	30	639	14023

TAB. 2 – Matrice de confusion pour l’algorithme des *knn*

Méthode des prototypes À l’issue de cette méthode, nous obtenons la segmentation présentée sur la figure 5. Cette méthode donne des résultats totalement incohérents. Cela est dû à la forte variation des paramètres de Haralick pour des images de même classe. Faire la moyenne de tous ces éléments implique une perte de l’information de dispersion des ensembles dans l’espace. De fait, les résultats obtenus sont totalement faux et inutilisables. Il suffit pour s’en convaincre de regarder la matrice de confusion correspondant à l’image (*cf.* figure 5).

	ride	roche	sable
ride	0	392	3202
cailloux	106	134	746
sable	220	332	14140

TAB. 3 – Matrice de confusion pour l’algorithme des prototypes

Nous obtenons ainsi 24.3% de bonne détection pour la **classe roche**, 100% d’erreur pour la **classe ride** (la zone de ride est écourtée par rapport à l’image de base) et 96.2% de bonne détection pour la **classe sable**.

Après visualisation des différents résultats, la méthode des *k* plus proches voisins semble la plus adaptée. En effet, les résultats sont cohérents et paraissent être assez proches de la réalité. La matrice de confusion obtenue par cette méthode est en effet de loin meilleure que celle de la méthode par prototypes. Enfin, si les classes roches et sable sont bien représentées, la classe ride est dans tous les cas fortement réduite par rapport à la réalité. Il serait opportun de concentrer les efforts de recherche sur cette partie dans un projet futur.

6 Conclusion et perspectives

Nous avons présenté d’une part une approche de segmentation des images sonar puis une méthode originale de fusion de la classification et de la segmentation d’images. Les résultats préliminaires montrent l’intérêt de l’approche. Les fonds marins peuvent donc ainsi être classifiés de façon autonome. De plus, cette méthode pourrait facilement être implémentée du fait de sa rapidité d’exécution. Même si ce travail est encourageant, la qualité des résultats obtenus reste modeste et est encore loin d’être utilisable directement. Nous pouvons cependant observer une bonne synergie entre les méthodes de classification et de segmentation, dont la fusion permet de garder un pourcentage de bonne détection acceptable tout en affinant les frontières.

Ce travail donne un aperçu d’une première méthode qui pourrait être réellement efficace, et ouvre la porte à une recherche plus approfondie dans le domaine. Nous pouvons ainsi ima-

giner l'implémentation d'approches plus complexes afin de combiner les résultats. La théorie des fonctions de croyance est par exemple un cadre envisageable. Enfin, il est important de garder à l'esprit que la présence d'un expert est toujours indispensable pour la phase d'apprentissage. Les experts indiquant leur degré de certitude, ce dernier pourrait être employé pour un meilleur apprentissage des approches supervisées. L'utilisation de méthodes de classification non-supervisées pourrait également permettre d'obtenir une segmentation de l'image.

Références

- Artigues, S. et C. Billard (2005). Logiciel de segmentation et de classification automatique de sédiments marins. Technical report, Projet industriel, ENSIETA.
- Haralick, R. (1979). Statistical and textural approaches to textures. *Proceedings of the IEEE* 67(5), 786–804.
- Laanaya, H. (2007). *Classification en environnement Incertain : Application la Caractérisation de Sédiments Marins*. Ph. D. thesis, Université de Bretagne Occidentale, ENSIETA, Brest.
- Le Chenadec, G. et J.-M. Boucher (2005). Sonar image segmentation using the angular dependence of backscattering distributions. In *IEEE Oceans'05 Europe*, Brest, France.
- Leblond, I., M. Legris, et B. Solaiman (2005). Use of classification and segmentation of sidescan sonar images for long term registration. In *IEEE Oceans'05 Europe*, Brest, France.
- Lengrand-Lambert, J. (2009). Fusion de la segmentation et de la classification automatique des images sonar. Technical report, Projet industriel, ENSIETA.
- Martin, A., H. Laanaya, et A. Arnold-Bos (2006). Evaluation for uncertainty image classification and segmentation. *Pattern Recognition* 39(11), 1987–1995.
- Martin, A., G. Sévellec, et I. Leblond (2004). Characteristics vs decision fusion for sea-bottom characterization. In *Journée d'Acoustique Sous-Marine*, Brest, France.
- Pasini, S. et B. Grandgeorge (2003). Image segmentation. *Projet en Digital Photography - Image Segmentation 1*, 5–9.
- Russ, J. C. (2002). *The image processing handbook*. Cleveland: CRC Press.
- Sumenger, B. (2005). Level set method presentation. Technical report, Vision Research Lab, UCSB.

Summary

This issue handles the ability of processing sonar images in order to automatically draw a map of undersea borders and classes. This study takes part of the project of automatic undersea cartography. Indeed, the current use of experts to analyse those images is very long and costs money. In addition, two experts have almost always different points of view on the same image. This work is based on an older software capable of automatically classify images using a learning database. In order to enhance its results, we worked on a different way of segmentation using the 'level-sets method'. Then, we tried to fuse the two results. Finally, this issue allows us to draw a conclusion of such a method and to explore deeper in this way.