



**HAL**  
open science

## Recalage et fusion d'images sonar multivues : utilisation du conflit

Cédric Rominger, Arnaud Martin

► **To cite this version:**

Cédric Rominger, Arnaud Martin. Recalage et fusion d'images sonar multivues : utilisation du conflit. Revue des Nouvelles Technologies de l'Information, 2011, E (21), pp.231-246. hal-00657626

**HAL Id: hal-00657626**

**<https://hal.science/hal-00657626>**

Submitted on 7 Jan 2012

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Recalage et fusion d'images sonar multivues : utilisation du conflit

Cedric Rominger\*, Arnaud Martin\*

\*ENSIETA E<sup>3</sup>I<sup>2</sup> EA3876  
2 rue François Verny 29806 Brest Cedex 9  
{Cedric.Rominger,Arnaud.Martin}@ensieta.fr,  
<http://www.ensieta.fr/e3i2/index.php>

**Résumé.** Ce papier présente une application pour le recalage et la fusion d'images sonar classifiées. Nous adaptons ici la méthode présentée dans un précédent papier à des données multivues. Pour la caractérisation de fond marin, nous avons besoin de fusionner des images sonar multivues afin d'améliorer les résultats. Néanmoins, avant de pouvoir fusionner ces images, il faut les recaler. Notre approche de recalage s'appuie sur un critère de dissimilarité calculé à partir du conflit issu de la combinaison des fonctions de croyance. L'utilisation de la théorie des fonctions de croyance offre un cadre théorique unique qui permet une bonne modélisation des imperfections, et qui a déjà prouvé son intérêt pour la fusion de classifieurs en traitement d'images.

## 1 Introduction

Le domaine de l'imagerie sous marine s'appuie principalement sur des données issues de capteurs acoustiques. Les sonars présentent l'intérêt de pouvoir imager les fonds marins à des distances bien plus importantes que les capteurs optiques (comme la vidéo), et de couvrir des surfaces à des cadences pouvant aller jusqu'à plusieurs miles nautiques carrés par jour.

Le traitement des images sonar présente plusieurs difficultés. En effet, les mouvements du sonar peuvent altérer la géométrie des objets qui reposent sur le fond marin. De plus le signal peut suivre plusieurs chemins, en fonction de la réflexion sur le fond ou d'autres objets, la faune ou la flore conduisant à des interférences sur l'intensité résultante. À ces incertitudes et imprécisions s'ajoutent un autre élément de complexité : la variation de l'information suivant l'angle de prise de vue. Cette multiplicité de l'information peut conduire à des informations conflictuelles.

Un aspect du traitement des images sonar est la caractérisation du fond marin. Comme le montrent Martin et al. (2006), la nature même des images rend cette caractérisation difficile, même pour des experts humains, qui par exemple pourront reconnaître le même sédiment, mais être en désaccord sur sa frontière. De plus, ils ne peuvent humainement pas traiter l'énorme masse de données disponible. Dhibi et al. (2008) et Williams (2009) ont montré que les techniques issues du domaine de la fusion peuvent apporter une réponse à ce problème en fusionnant des données provenant de plusieurs points de vues.

## Recalage et fusion d'images sonar multivues

Cette caractérisation permet de produire des points de repère utiles pour la navigation sous marine. Quand un robot sous marin autonome (AUV) navigue, il peut déterminer sa position par différents instruments (comme une centrale inertielle) qui peuvent subir des dérives ou des imprécisions. L'utilisation de points de repère (ou amers) issus de la caractérisation du fond peut aider l'AUV à déterminer sa position.

La production de carte de fonds marin s'appuie sur des techniques de recalage d'images appliquées aux images sonar. Une fois déterminée la transformation la plus adaptée pour mettre en correspondance les deux images, celles-ci sont fusionnées pour en produire une plus fiable. En recalant toutes les images sonar d'une même campagne, une carte est ainsi produite. Une fois caractérisée, cette carte peut être utilisée par un AUV. Le processus de recalage d'images sonar peut être amélioré en utilisant des images préalablement classifiées (Leblond et al. (2005); Leblond (2006)), et la phase finale du processus, la génération de la mosaïque, peut alors être traité comme un simple problème de fusion.

Nous avons proposé l'utilisation de la théorie des fonctions de croyance pour la fusion, et le recalage d'image. Les fonctions de croyance permettent de prendre en compte l'incertitude et l'imprécision des images sonar. En associant à chaque pixel des images classifiées une fonction de croyance, nous définissons un critère de dissimilarité pour le recalage fondé sur le conflit issu de la combinaison conjonctive (Rominger et al. (2009)). De plus la génération de la mosaïque peut s'appuyer sur la combinaison des fonctions de masse, directement à l'aide des résultats obtenus pendant le calcul du critère de dissimilarité.

Au cours de précédents travaux (Rominger et Martin (2010)), nous avons présenté l'application de ce processus de recalage sur des images sonar multivues. Nous proposons ici une nouvelle définition pour les fonctions de masses modélisant la décision des classifieurs générant les images que nous souhaitons recalculer. Nous étudions aussi le comportement de notre critère en présence d'ignorance totale, et proposons une prise en compte particulière de cette absence d'information.

Dans la suite de ce papier, nous commençons par présenter le principe du recalage d'images. Puis, nous introduisons les éléments de la théorie des fonctions de croyance dont nous avons besoin. La section 4 présente notre processus de recalage, et son extension pour la prise en compte de l'absence d'information de classification. Enfin, nous présentons les résultats obtenus sur nos images sonar multivues.

## 2 Recalage d'images

Le recalage d'images est un processus visant à déterminer quelle est la meilleure transformation qui permet d'aligner deux prises de vues. La figure 1 illustre la problématique pour deux images  $I_1$  et  $I_2$  de taille et angle différents, où l'on cherche à recalculer l'image  $I_2$  sur l'image  $I_1$  prise comme image de référence. Le problème étant symétrique pour deux images ce choix importe peu *a priori*. Classiquement, comme présenté par Zitova et Flusser (2003), les méthodes de recalage sont organisées en deux familles :

- Les méthodes géométriques sont fondées sur une extraction d'un ensemble de caractéristiques des images (points, contours, formes), et leur mise en correspondance pour déterminer la meilleure transformation à appliquer.
- Les méthodes iconiques prennent en compte l'intégralité des pixels des images, et comparent directement leur intensité, ou une fonction de cette intensité.




FIG. 1 – Technique du recalage, image  $I_2$  recalée sur l'image  $I_1$ .

En environnements naturels et incertains, il existe peu de formes géométriques simples et comparables d'une image à l'autre. Ces images peuvent de plus être fortement déformées selon l'angle de vue par exemple avec l'apparition d'ombre. Ainsi dans cet article notre choix s'est porté sur une méthode iconique.

Les méthodes de recalage cherchent à déterminer la meilleure transformation au sens d'un critère de similarité. Cette transformation appartient à un ensemble de transformations caractérisé par différents types que Maintz et Viergever (1998) énumèrent :

- Rigide : uniquement translation et rotation.
- Affine : transforme des lignes parallèles en lignes parallèles.
- Projective : met en correspondance des lignes non parallèles.
- Élastique : transforme des lignes droites en courbes.

De plus, les modèles de transformation peuvent être appliqués à tout ou partie de l'image. On parle alors respectivement de modèles globaux ou locaux.

Par nature, le meilleur moyen de mettre en correspondance deux images sonar est de s'appuyer sur un modèle de transformation projectif. Les modèles élastiques restent les plus intéressants puisqu'ils permettent de recalculer le plus finement possible deux images. Néanmoins, traiter de tels modèles conduit à devoir traiter un nombre très important de paramètres de transformation. Dans le but de réduire cette complexité, nous nous intéressons aux transformations rigides locales que nous considérons comme une approximation d'un modèle de transformation élastique global.

Dans le cadre des méthodes de recalage iconique, nous cherchons à mesurer la similarité (ou dissimilarité)  $s$  entre l'intensité des pixels d'une image  $I_1$  et d'une image ayant subi une transformation  $t(I_2)$ . Suivant la nature de ce lien, il existe différentes mesures qui sont plus ou moins bien adaptées. Une classification de ces mesures est d'ailleurs suggérée par Roche (2001). Le choix du critère de similarité dépend de la relation supposée entre les intensités de pixels des images.

L'idée la plus simple est que l'intensité est stationnaire d'une image à l'autre. On parle alors de relation *identité*, et on peut utiliser une mesure de corrélation (corrélation croisée, somme absolue des différences des intensités, variance des différences, etc, telles que présentées par Chambon (2005)). L'utilisation de ces mesures permet de déterminer rapidement la meilleure transformation, mais elles sont sensibles aux valeurs aberrantes.

Dans la pratique la relation identité est rarement vérifiée, car la valeur des intensités dépend de l'instrument de mesure. Il convient donc de prendre en compte une remise à l'échelle des intensités grâce à une relation affine de type  $j = \alpha i + \beta$ . Hill et Hawkes (2000) montrent que le coefficient de corrélation affine permet de prendre en compte cette relation.

Bien que donnant généralement de bons résultats dans le cadre du recalage monomodal, l'hypothèse de relation affine n'est plus adaptée dès qu'il s'agit de recalage multimodale. On généralise alors à une relation fonctionnelle de type  $j = f(i)$ , avec l'hypothèse que pour une intensité d'une image donnée on peut associer une unique intensité de l'autre image. On trouve dans cette catégorie de mesures le critère de Woods et al. (1993) et le rapport de corrélation listés par Roche (2001).

Il est possible de considérer une relation moins restrictive que la relation fonctionnelle en considérant les images comme des réalisations de variables aléatoires dont on cherche à caractériser la dépendance. L'outil alors utilisé est l'histogramme conjoint. Et les critères tels que l'information mutuelle utilisée par Chailloux (2007) sur des images sonar, permettent de mesurer la dispersion de l'histogramme conjoint, avec l'idée que plus la dispersion est faible, plus forte est la dépendance entre les deux images.

Dans le cas d'images classifiées, l'intensité de chaque pixel ne représente plus une mesure physique, mais son appartenance à une classe. Il faut donc chercher à modéliser la relation entre ces appartenances. De plus en environnements incertains, ces appartenances ne sont pas strictes. Il est donc raisonnable d'envisager une telle relation, dont les précédents critères de similarité ne tiennent pas compte.

L'étape de décision consiste donc à déterminer la transformation  $t$  à appliquer à  $I_2$ , parmi l'ensemble des transformations  $T$  considérées, donnant la dissimilarité  $d$  la plus faible (ou la similarité  $d$  la plus forte). Nous décidons donc de la transformation  $t_d$  donnée par :

$$t_d = \operatorname{argmin}_{t \in T} d(I_1, t(I_2)) \quad (1)$$

ou

$$t_d = \operatorname{argmax}_{t \in T} s(I_1, t(I_2)) \quad (2)$$

Dans la suite, nous allons voir comment le critère de dissimilarité peut s'appuyer sur la théorie des fonctions de croyance.

### 3 Fonctions de croyance

La théorie des fonctions de croyance est issue des travaux de A. Dempster (1967), et du formalisme de G. Shafer (1976) sous le nom de *theory of evidence*. Les fonctions de croyance ont trouvé de nombreuses applications en traitement d'images (Bloch et Maître (1994); Vannoorenberghe et al. (2003)), telles que la segmentation d'images (Taleb-Ahmed et al. (2002); Vannoorenberghe et al. (1999)), ou la fusion de classifieurs sur des images (Milisavljevic et al. (2003); Martin (2005); Dhibi et al. (2008)). Dans ces deux dernières applications, les images sonar sont supposées déjà recalées. Si ce n'est le cas, il peut être intéressant de chercher à les recalier et les fusionner en conservant le même formalisme de la théorie des fonctions de croyance que nous décrivons ci-dessous.

La théorie des fonctions de croyance repose sur la manipulation de fonctions de masse. À la différence des probabilités, les fonctions de masse sont définies sur l'ensemble de toutes

les disjonctions possibles des classes  $C_k$  noté  $2^\Theta = \{\emptyset, \{C_1\}, \{C_2\}, \{C_1 \cup C_2\}, \dots, \Theta\}$ . Une fonction de masse  $m$  est donc définie sur  $2^\Theta$  à valeurs dans  $[0, 1]$ , et vérifie la propriété de normalisation suivante :

$$\sum_{A \in 2^\Theta} m(A) = 1. \quad (3)$$

La fonction de masse modélise le degré de croyance élémentaire que l'on accorde à chaque proposition  $A$  de  $2^\Theta$ . Ce degré croyance est indépendant de la croyance que l'on peut accorder aux éventuels sous-ensembles et sur-ensembles de  $A$ .

Lorsqu'on suppose l'exhaustivité des classes de notre cadre de discernement, on se place en monde fermé (*i.e.*  $m(\emptyset) = 0$ ). Par opposition dans l'hypothèse du monde ouvert de Smets et Kennes (1994) (que nous ferons ici), nous admettons que l'on puisse avoir  $m(\emptyset) > 0$ .

Une fois définies les fonctions de masse pour chaque classifieur  $S_i$ , différents opérateurs de combinaison sont envisageables. La règle orthogonale de Dempster-Shafer non normalisée proposée par Smets (1990) permet de calculer la fonction de masse  $m_{(1, \dots, j)}$  pour un ensemble de  $n$  fonctions de masse  $\{m_j\}$  :

$$m_{(1, \dots, j)} = m_1 \oplus \dots \oplus m_n$$

Elle est définie pour tout  $A \in 2^\Theta$  par :

$$m_{(1, \dots, j)}(A) = \sum_{B_1 \cap \dots \cap B_n = A} \prod_{j=1}^n m_j(B_j). \quad (4)$$

Cet opérateur est associatif et commutatif, mais pas idempotent.

La masse affectée sur l'ensemble vide  $m_{\text{Conj}}(\emptyset)$  s'interprète généralement comme une mesure de conflit. Si cette masse représente dans une certaine mesure le conflit entre les classifieurs, une partie provient également de la non-idempotence. Ce conflit peut résulter d'un manque d'exhaustivité des sources, d'un manque de fiabilité des classifieurs, ou encore lorsque les classifieurs ne représentent pas la même chose comme le souligne Appriou (2002).

L'auto-conflit est défini comme le conflit de la combinaison d'une fonction de masse avec elle-même :  $ac(m) = m_{\text{Conj}(m, m)}(\emptyset)$ . L'auto-conflit à l'ordre  $n$  est l'extension de cette définition à la combinaison de  $n$  fonctions de masses identiques (avec  $n \geq 1$ ) :

$$ac_n(m) = m_{\text{Conj}(\underbrace{m, \dots, m}_{n \text{ fois}})}(\emptyset) \quad (5)$$

La dernière étape de la fusion de classifieurs concerne la décision de la classe  $C_k$  sur l'image ou partie de l'image observée. Il est mal aisé de réaliser cette décision directement sur les fonctions de masse, ainsi plusieurs fonctions de croyance (telles que plausibilité ou crédibilité, qui peuvent être vues comme une croyance supérieure ou inférieure), ou probabilités (telle que la probabilité pignistique) ont été définies.

Dans le cadre de notre application, nous nous appuyons sur la probabilité pignistique pour décider de la classe du pixel issue de la fusion. La probabilité pignistique est définie pour tout  $X \in \Theta$  avec  $X \neq \emptyset$  par :

$$betP(X) = \sum_{Y \in 2^\Theta, Y \neq \emptyset} \frac{|X \cap Y|}{|Y|} \frac{m(Y)}{1 - m(\emptyset)} \quad (6)$$

où  $|X|$  est le cardinal de  $X$ .

La classe du pixel  $x_i$  décidée par la fusion est alors déterminée par :

$$cl_{x_i} = \max_{X \in \Theta} (BetP(X)) \quad (7)$$

## 4 Recalage d'images à partir des fonctions de croyance

Nous nous plaçons dans ce papier dans le cas où nous possédons des images classifiées  $I_i$ . Ces images sont donc les sorties des classifieurs, notés  $S_i$ , et sont composées pour chaque pixel, d'information symbolique correspondant au type de classe. Les approches fondées sur des opérations arithmétiques de ces images symboliques, telles que proposées par Olteanu (2007), sont donc peu envisageables.

Dans le but d'approcher un modèle de transformations élastiques global, nous traitons plusieurs transformations rigides localement. Pour ce faire, nous déterminons un ensemble de zone d'intérêt, dans lesquelles nous savons qu'il y a une correction à déterminer, et dont nous extrayons des imagerie  $I_i^j$  que nous recalons au travers d'un modèle de transformation rigide global (au sens des imagerie) noté  $T$ .

Les images à recalculer ont été classifiées et donc implicitement segmentées par des classifieurs possédant le même cadre de discernement  $\Theta$  selon  $n$  classes  $C_k$ . De fait, chaque pixel de chacune des deux images (celle de référence et celle à recalculer) appartient à une (unique) classe. L'ensemble  $\Theta$  des  $n$  classes  $C_k$  est donc le cadre de discernement de nos images  $I_i$  (et de nos imagerie  $I_i^j$ ).

Chaque pixel  $x_i$  de chaque image  $I_i$  (images qui peuvent être de taille différente) a déjà été affecté à une classe  $C_k$  par un classifieur. Au cours de précédents travaux, nous nous appuyions sur des fonctions de masses à support simple. Le classifieur a déjà été étudié, et nous avons pu déterminer son comportement par une matrice de confusion  $F = \{\alpha_{gk}\}$ . Nous pouvons mesurer l'imprécision de ce classifieur au travers de cette matrice de confusion, et le reporter dans la modélisation de notre fonction de masse.

Lorsque que notre pixel  $x_i$  est affecté à la classe  $C_k$ , nous déterminons la classe  $C_{k'}$  qui est la classe sur laquelle notre classifieur a le plus tendance à se tromper :

$$k' = \operatorname{argmax}_{g \in \{1 \dots n\} \setminus k} (F_{gk}) \quad (8)$$

Ce qui nous permet de définir pour chaque pixels  $x_i$  la fonction de masse :

$$\begin{cases} m_{x_i}(C_k) = \alpha_{kk} & \text{si } x_i \in C_k \\ m_{x_i}(C_{k'}) = \alpha_{k'k} & \text{si } x_i \in C_k \\ m_{x_i}(A) = 0 & \text{si } A \in 2^\Theta \setminus \{C_k, C_{k'}, \Theta\} \\ m_{x_i}(\Theta) = 1 - \alpha_{kk} - \alpha_{k'k} \end{cases} \quad (9)$$

Dans le cas de deux images, nous cherchons donc à combiner l'image de référence  $I_1^j$  avec le résultat de la transformation  $t(I_2^j)$  de l'image à recalculer  $I_2^j$ , pour une transformation donnée  $t \in T$ . Cependant, rien ne nous garantit que le résultat  $t(I_2^j)$  et  $I_1^j$  représente la même chose, puisque justement nous cherchons également cette transformation. Nous sommes alors

dans le cas où les sources à combiner ne représentent pas la même chose, et il ne faut donc pas les combiner, ou en l'occurrence recalculer  $t(I_2^j)$  sur  $I_1^j$ . Le problème du recalage par les fonctions de croyance se résume alors par le choix de la transformation  $t$  la plus crédible pour la combinaison de  $I_1^j$  et  $t(I_2^j)$ .

Le conflit qui apparaît si l'on combine  $t(I_2^j)$  avec  $I_1^j$  à tort est donc une bonne mesure de dissimilarité de nos deux images  $I_1^j$  et  $t(I_2^j)$ . Nous considérons que cette mesure de conflit est directement donnée par la masse  $m_{\text{Conj}}(\emptyset)$  transférée sur l'ensemble vide lors de la combinaison conjonctive non normalisée de l'équation (4).

Formellement, nous cherchons donc à combiner la fonction de masse  $m_{x_1}$  associée à un pixel  $x_1$  de l'image  $I_1^j$  avec la fonction de masse  $m_{t(x_2)}$  associée à  $t(x_2)$  où  $x_2$  est un pixel de l'image  $I_2^j$ , telle que  $t(x_2) = x_1$  :

$$m_{(x_1, t(x_2))} = m_{x_1} \oplus m_{x_2}(C_{x_2}) \quad (10)$$

Le conflit associé à la transformation  $t \in T$  est alors donné par :

$$m_t(\emptyset) = \sum_{x_1 \in I_1} m_{(x_1, t(x_2))}(\emptyset). \quad (11)$$

Dans le cas des transformations rigides, il y a bijectivité des fonctions  $t$  et l'équation précédente s'écrit aussi :

$$m_t(\emptyset) = \sum_{x_2 \in I_2} m_{(x_1, t(x_2))}(\emptyset). \quad (12)$$

Nous avons donc intérêt à considérer l'image de taille la plus petite.

Enfin pour décider de la transformation  $t$  la plus crédible dans l'ensemble  $T$ , il suffit de considérer la transformation minimisant ce conflit  $m_t(\emptyset)$ . Nous choisissons donc, après une recherche exhaustive sur  $T$ , la transformation  $t_r^j$  donnée par :

$$t_r^j = \underset{t \in T}{\operatorname{argmin}} m_t(\emptyset). \quad (13)$$

L'étape finale de notre application est la génération d'une mosaïque par fusion des différentes imageries  $I_i^j$  au travers des transformations optimales  $t_r^j$ . La fusion de chaque paire d'imageries  $I_1^j$  et  $t_r^j(I_2^j)$  a déjà été réalisée lors du calcul de la valeur du critère de dissimilarité pour cette transformation. Nous pouvons donc reprendre immédiatement les fonctions de masse générées pour les futurs pixels de la mosaïque. La classe de chacun de ces pixels est ainsi déterminée en prenant le maximum de la probabilité pignistique (équations (6) et (7)).

Au cours de nos premières études, il nous est apparu que notre critère pouvait adopter un comportement plutôt chaotique (voir figure 7). En plus du comportement normal d'un critère de dissimilarité (avec des maximums et des minimums atteints progressivement) nous observons des oscillations rapides de la valeur du critère. L'hypothèse émise est que ce comportement apparaît lorsque les images que l'on cherche à recalculer comportent des zones représentées par de l'ignorance.

En effet la combinaison d'une fonction de masse quelconque avec l'ignorance ne génère pas de conflit. Ce qui amène le critère de dissimilarité à adopter une valeur particulièrement faible, pouvant conduire le processus de recalage à décider d'une transformation qui ne serait pas la bonne.



## Recalage et fusion d'images sonar multivues




FIG. 2 – Comportement du critère au cours d'un recalage

Pour neutraliser l'effet particulier de l'ignorance sur notre critère de dissimilarité, nous définissons une fonction de masse particulière qui prendra la place de l'ignorance dans toutes les parties de l'image non renseignées. Cette fonction de masse a pour but de générer un conflit moyen lorsqu'elle sera combinée à d'autres fonctions de masse. Nous déterminons cette fonction à partir des fonctions de masse générées par le classifieur. Pour générer un conflit moyen à la combinaison, nous la définissons une fonction de masse qui porte une valeur moyenne de croyance pour  $\emptyset$ . Nous avons décidé de prendre la moyenne des auto conflits de toutes les masses disponibles au sein du processus de recalage (avant calcul du critère de dissimilarité) :

$$m_0(X) = \begin{cases} \text{mean}_{i \in \{1 \dots n\}} (ac_2(m_i)) & \text{si } X = \emptyset \\ 1 - \text{mean}_{i \in \{1 \dots n\}} (ac_2(m_i)) & \text{si } X = \Theta \\ 0 & \text{sinon} \end{cases} \quad (14)$$

## 5 Application au recalage d'images sonar segmentées

Nous travaillons à partir de données sonar Klein 5500B acquises sur la « Grande Vaille » (83) par la société SEMANTIC-TS et le GESMA (Groupe d'Études Sous-Marines de l'Atlantique) dans le cadre du contrat REI (Recherche Exploratoire et Innovation) n° 05.34.011.00.470.75.65 mis en place par la DGA/D4S/MRIS et intitulé "cartographie de la couverture du fond marin par fusion multi-capteurs".

Nous disposons de sept passes sonar mesurant jusqu'à 800m de long pour 130m de large, avec une résolution finale de 10cm sur les images. Ces relevés portent sur une zone côtière peu profonde (environ 15m).

Les passes sonar sont caractérisées automatiquement par un classifieur de type  $k$ -plus proches voisins ( $k$ -ppv) crédibiliste développé par Denoeux (1995). Un exemple de classification est présenté par la figure 3. Les images sont classifiées selon quatre classes : sable (jaune pale), rides de sable (jaune foncé), roche/posidonie (vert), et vase (gris).




FIG. 3 – Un exemple de trace sonar brute, et classifiée (extrait)

Le classifieur a déjà été testé, et confronté à une classification par un expert humain, nous permettant de déterminer ses taux de bonne classification par classe. C'est ces taux que nous utilisons dans la définition des fonctions de masse des pixels par l'équation (9).

Associés aux relevés sonar, nous possédons les informations de géoréférencement du bateau tractant le sonar. Ces données sont moins bruitées que dans le cas d'une application avec un robot sous-marin, où ces données seraient issues de la centrale inertielle du robot.

Nous pouvons donc réaliser une projection de nos relevés sonar classifiés (voir figure 4). Néanmoins, ces informations ne prennent pas en compte les mouvements du sonar lui-même, et même si nous pouvons mettre en correspondance deux traces, il reste encore quelques erreurs de recalage que nous cherchons à corriger.

En s'appuyant sur les données de géoréférencement, nous pouvons mettre en correspondance deux traces sonar, et les fusionner. Le résultat de cette fusion génère une certaine quantité de conflit. Les endroits où le conflit est maximum indiquent là où nous devons chercher à corriger des erreurs. Nous déterminons donc les zones d'intérêt, avec une taille fixée, sur nos deux traces qui englobent le maximum de conflit généré.

Après observation, nous considérons que les mouvements du sonar et l'imprécision d'autres paramètres (tels que la longueur du câble reliant le sonar au bateau) nous conduit à faire une erreur pouvant aller jusqu'à une dizaine de mètres sur le recalage par géoréférencement. Nous choisissons aléatoirement parmi les deux traces celle qui deviendra l'image de référence, et

## Recalage et fusion d'images sonar multivues




FIG. 4 – Une trace sonar projetée selon ses données de géoréférencement.


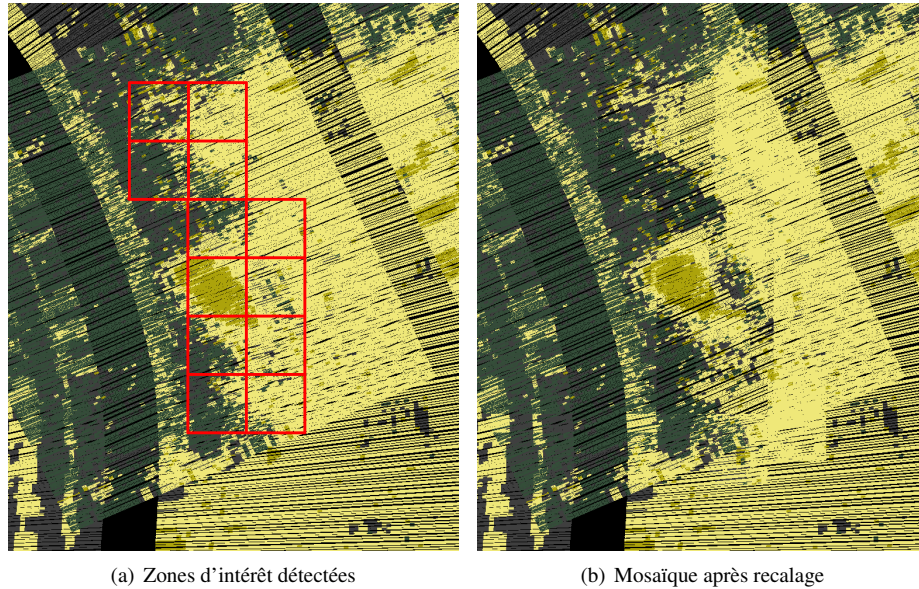


FIG. 5 – Deux extraits de traces sonar recalés selon leurs données de géoreférencement, puis fusionnés.

celle que nous cherchons à recalibrer. Au sein de la zone d'intérêt, nous extrayons de l'image de référence des imagerie carrées de 300 pixels de côté (soit 30 m), qui deviendront des imagerie de référence, et de l'image à recalibrer des imagerie de 100 pixels de côté (soit 10 m). Ceci nous permet de calculer la valeur de dissimilarité sur une zone de 10 m de côté, et de recalibrer sur une distance de 10 m autour de la position d'origine des imagerie.

Le coût calculatoire de notre algorithme est actuellement très élevé, en particulier à cause de la combinaison. La taille des données ne limite que la génération de la mosaïque (l'image finale de notre base de données actuelle tend vers  $9000 \times 6000$  pixels) car nous nous ramenons à un problème de recalibrer sur des données limitées ( $300 \times 300$  pixels).

FIG. 6 – *Détail de la zone de recalage*

Nous avons appliqué notre processus de recalage aux images présentées précédemment. La figure 6(a) présente les zones d'intérêt que nous allons chercher à corriger.

Lors de la projection des informations de classification selon les informations de géoreferencement, il apparaît des interstices entre les informations de classifications. Ces traits de non information sont considéré comme de l'ignorance au cours du recalage, ce qui conduit à un comportement chaotique du critère de dissimilarité.

La difficulté qui en ressort est que notre processus de recalage va avoir tendance à recalculer sur ces zones de non information. Pour palier ce comportement, nous redéfinissons donc la fonction de masse associée à ces pixels de non information (l'ignorance) par la fonction  $m_0$  définie par l'équation (14).

La figure 7 présente l'évolution de notre critère de dissimilarité dans le cas où nous interprétons la non information comme de l'ignorance (figure 7(a)), ou avec la fonction de masse  $m_0$  (figure 7(b)). L'évolution entre les deux cas est la suivante : la dynamique est plus élevée en utilisant la fonction  $m_0$  : les maximums sont plus élevés, et le minimum est relativement plus bas. Les ondulations sont toujours présentes, mais leur variations sont plus faibles. Nous pouvons donc déterminer plus aisément le minimum atteint par notre critère, mais la présence des ondulations ne nous garanti pas que ne puissions le déterminer précisément.

Pour réduire cette incertitude, il faudrait déterminer précisément la valeur à affecter à  $m_0(\emptyset)$  (et donc à  $m_0(\Theta)$ ) qui permettrait de réduire au mieux l'influence de l'absence d'information sur la valeur de notre critère de dissimilarité.




FIG. 7 – Comportement du critère au cours du recalage d'une imagerie

## 6 Conclusion

Nous présentons dans cet article une application de notre processus de recalage pour les images classifiées. Afin de tenir compte des imperfections des résultats de classification nous nous sommes tournés vers la théorie de fonction de croyance. Cette théorie a de plus été employée avec succès pour la fusion de classifieurs qui est la dernière étape du recalage. Ce choix nous permet donc réaliser deux étapes (le recalage et la fusion) en une seule opération.

L'approche proposée repose sur l'utilisation du conflit issu de la combinaison des fonctions de croyance comme critère de dissimilarité afin de déterminer la meilleure transformation au sein d'un algorithme de recalage. Nous avons utilisé ici une nouvelle définition pour les fonctions de masses modélisant les décisions de notre classifieur.

Ce travail étudie l'impact de l'absence d'information sur le comportement de notre critère de dissimilarité. Considérer l'absence d'information comme de l'ignorance totale peut conduire notre processus de recalage à se tromper, et nous pourrions étendre ces travaux en déterminant quel valeur donner à l'absence d'information. Une autre piste possible serait d'appliquer un algorithme de lissage sur notre critère pour affaiblir l'impact de la présence d'ignorance.

## Références

- Appriou, A. (2002). Discrimination multisérial par la théorie de l'évidence. In R. Lenglé (Ed.), *Décision et Reconnaissance des formes en signal* (Lavoisier ed.), Chapter 7, pp. 219–258. Hermes Science Publication.
- Bloch, I. et H. Maitre (1994). Fusion de données en traitement d'images : modèles d'information et décisions. *Traitement du Signal* 11(6), 435–446.
- Chailloux, C. (2007). *Recalage d'images sonar par appariement de régions. Application à la génération d'une mosaïque*. Ph. D. thesis, ENST Bretagne.

- Chambon, S. (2005). *Mise en correspondance stéréoscopique d'images couleur en présence d'occultations*. Ph. D. thesis, Université Paul Sabatier, Toulouse.
- Dempster, A. P. (1967). Upper and Lower probabilities induced by a multivalued mapping. *Annals of Mathematical Statistics* 38, 325–339.
- Denoeux, T. (1995). A k-nearest neighbor classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems Man and Cybernetics* 25(5), 804–813.
- Dhibi, M., R. Courtis, et A. Martin (2008). Multi-segmentation of sonar images using belief function theory. In *Acoustics*, Paris, France.
- Hill, D. L. G. et D. J. Hawkes (2000). Across-modality registration using intensity-based cost functions. pp. 537–553.
- Leblond, I. (2006). *Recalage à long terme d'images sonar par mise en correspondance de cartes de classification automatique des fonds*. Ph. D. thesis, ENSIETA.
- Leblond, I., M. Legris, et B. Solaiman (2005). Use of classification and segmentation of side-scan sonar images for long term registration. *Oceans 2005-Europe 1*.
- Maintz, J. et M. Viergever (1998). A survey of medical image registration. *Medical Image Analysis* 2(1), 1–36.
- Martin, A. (2005). Comparative study of information fusion methods for sonar images classification. In *International Conference on Information Fusion*, Philadelphia, USA.
- Martin, A., H. Laanaya, et A. Arnold-Bos (2006). Evaluation for uncertainty image classification and segmentation. *Pattern Recognition* 39(11), 1987–1995.
- Milisavljevic, N., I. Bloch, S. Van Den Broek, et M. Acheroy (2003). Improving mine recognition through processing and dempster-shafer fusion of ground-penetrating radar data. *Pattern Recognition* 36(5), 1233–1250.
- Olteanu, A. (2007). A multi-criteria fusion approach for geographical data matching. In *Proceedings of the Fifth Internat. Symp. on Spatial Data Quality (ISSDQ'07), June*.
- Roche, A. (2001). *Recalage d'Images Médicales par Inférence Statistique*. Ph. D. thesis, Université de Nice Sophia Antipolis.
- Rominger, C. et A. Martin (2010). Recalage et fusion d'images sonar multivues : utilisation du conflit. In *Atelier Fouille de données complexes lors de la Conférence Extraction et la Gestion des Connaissances*.
- Rominger, C., A. Martin, A. Khenchaf, et H. Laanaya (2009). Sonar image registration based on conflict from the theory of belief functions. In *International Conference on Information Fusion*.
- Shafer, G. (1976). *A mathematical theory of evidence*. Princeton University Press.
- Smets, P. (1990). The Combination of Evidence in the Transferable Belief Model. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 12(5), 447–458.
- Smets, P. et R. Kennes (1994). The Transferable Belief Model. *Artificial Intelligent* 66, 191–234.
- Taleb-Ahmed, A., L. Gautier, et M. Rombaut (2002). Architecture de fusion de données basée sur la théorie de l'évidence pour la reconstruction d'un vertèbre. *Traitement du Signal* 19(4), 267–283.

## Recalage et fusion d'images sonar multivues

- Vannoorenberghe, P., O. Colot, et D. de Brucq (1999). Color image segmentation using Dempster-Shafer's theory. In *Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on*, Volume 4.
- Vannoorenberghe, P., E. Lefevre, et O. Colot (2003). Traitement d'images et théorie des fonctions de croyance. *Rencontres Francophones sur la Logique Floue et Ses Applications, LFA'2003*, 26–27.
- Williams, D. P. (2009). Bayesian data fusion of multi-view synthetic aperture sonar imagery for seabed classification. *IEEE Signal and Image Processing* 18(6), 1239–1254.
- Woods, R., J. Mazziotta, et S. Cherry (1993). MRI-PET registration with automated algorithm. *Journal of computer assisted tomography* 17(4), 536–546.
- Zitova, B. et J. Flusser (2003). Image registration methods : a survey. *Image and Vision Computing* 21(11), 977–1000.

## Summary

This paper presents an application for classified image registration and fusion. We extend here results developed on a previous paper to multiview images. For seabed characterization, we need to fuse the multiview of sonar images to increase performances. However, before fusion, we have to proceed to an image registration. The proposed approach is based on the use of the conflict due to the combination as a dissimilarity measure in the classified images registration. The theory of belief functions allows an unique framework to model the imperfections and to fuse the classified images.