

Fonctions de croyance pour le recalage d'images classifiées en environnement incertain

Belief functions for classified images registration in uncertain environment

C. Rominger

A. Martin

A. Khenchaf

ENSIETA E³I² EA3876

2 rue François Verny 29806 Brest Cedex 9

{Cedric.Rominger,Arnaud.Martin,Ali.Khenchaf}@ensieta.fr

Résumé :

Ce papier présente une proposition de recalage d'images classifiées permettant de tenir compte des erreurs possibles des classifieurs. Afin de rester dans un même cadre théorique que la fusion de classifieurs, bien souvent étape suivante du recalage, notre choix s'est porté sur la théorie des fonctions de croyance. En effet cette dernière permet une bonne modélisation des imperfections et a été employée avec succès pour la fusion de classifieurs en imagerie.

Ainsi l'approche proposée repose sur l'utilisation du conflit issu de la combinaison comme nouvelle mesure de similarité dans le recalage d'images classifiées. Les premiers résultats présentés montrent que cette approche peut être prometteuse.

Mots-clés :

Recalage d'images, fonction de croyance, conflit.

Abstract:

This paper presents a proposition for classified images registration taking account of some possible errors of classification. To keep the same framework than the classifier fusion - that is often the following step of the registration - we choose the belief function theory. Indeed this theory allows a good modelization of imperfections and has been employed with success for classifier fusion in images processing.

Hence, the proposed approach is based on the use of the conflict due to the combination as a similarity measure in the classified images registration. The first presented results show that this approach is hopeful.

Keywords:

Image registration, belief functions, conflict.

1 Introduction

Le recalage d'images a pour but de combiner des images ou informations de l'image issues de capteurs différents ou provenant d'un même type de capteur mais prises d'angles de vues différents. Ainsi le recalage d'images

est nécessaire dans de nombreuses applications telles que en télédétection ([8], [27]), en médecine [11], en navigation sous-marine [4], en fusion d'images en général [25], etc [28].

Nous nous intéressons ici au recalage d'images préalablement classifiées. En effet en environnements incertains, une classification des images est souvent une étape préliminaire indispensable pour des traitements de plus haut niveaux. Ce type d'approches trouve par exemple un intérêt dans des environnements incertains tels que sous-marin [9, 4] qui sont notre motivation première. Cependant une classification sur ce type d'image et la segmentation intrinsèque qui en découle, sont d'une part très difficile dans les meilleures conditions et d'autre part très dépendantes de l'angle de vue [14]. Les classes sont donc entachées d'imperfections telles que incertitude du type de classes et imprécision de l'emplacement des frontières. Pour prendre en compte ces imperfections lors du recalage il nous faut un modèle spécifique. L'objectif final étant bien souvent de produire une mosaïque (*i.e.* de combiner l'information des images), il nous a paru naturel de nous tourner vers des cadres théoriques permettant à la fois la combinaison des informations et la modélisation fine des imperfections. La théorie des fonctions de croyance est l'une de ces alternatives. Elle offre en particulier la possibilité d'employer une mesure de conflit afin de décider du meilleur recalage des images. Une autre alternative serait

l'utilisation de la logique floue qui reste confidentielle en recalage ([10], [3], [22]).

Nous proposons donc dans ce papier, l'idée d'une approche utilisant le conflit issu de la combinaison de fonctions de croyance modélisant l'information des images classifiées à recaler. Ce conflit est employé comme mesure de similarité dans le processus de recalage. Ainsi, nous introduisons la méthodologie générale du recalage d'images dans la partie 2. Puis la partie 3 est consacrée aux rappels de la théorie des fonctions de croyance. La partie 4 présente notre approche de recalage crédibiliste détaillant les hypothèses, le modèle retenu de fonctions de masse et l'utilisation du conflit comme mesure de similarité. Enfin dans la dernière partie 5, nous discutons des premiers résultats obtenus sur une image générée et de l'évaluation de notre méthode.

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 recaler 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 les méthodes de recalage sont organisées en deux familles [28] :

- 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.

En environnements naturels et incertains, il existe peu de formes géométriques simples et




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

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.

2.1 Méthodes de transformation

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 [11] :

- Rigide : uniquement translation et rotation.
- Affine : transforme des lignes parallèles en lignes parallèles.
- Projective : met en correspondance des lignes non parallèles.
- Déformable : 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. Pour des raisons de simplification, nous nous sommes restreint ici aux transformations rigides globales.

2.2 Critères de similarité

Dans le cadre des méthodes de recalage iconique, nous cherchons à mesurer la similarité (ou dissimilarité) s entre l'intensité des pixels

des deux images $t(I_2)$ et I_1 . 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 [17]. 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 [5]). 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 $j = \alpha i + \beta$. Le coefficient de corrélation affine [7] 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 [26] et le rapport de corrélation [17].

Il est possible d'employer 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. Un histogramme conjoint permet de considérer deux images (de même taille) comme un couple de variables aléatoires, il est défini par :

$$f(i_1, i_2) = \text{Card}\{k | I_1(k) = i_1 \wedge I_2(k) = i_2\} \quad (1)$$

où $i_1, i_2 \in [1, \dots, N]$, N est la plus grande intensité présente, et $I_1(k)$ (resp. $I_2(k)$) l'intensité

du pixel k de l'image I_1 (resp. I_2). Par normalisation par la taille découle la densité de probabilité conjointe p qui permet de calculer l'information mutuelle [4] qui les lie :

$$IM(I_1, I_2) = H(I_1) + H(I_2) - H(I_1, I_2) \quad (2)$$

où $H(I_1)$ et $H(I_2)$ sont les entropies des images I_1 et I_2 , et $H(I_1, I_2)$ l'entropie conjointe :

$$\begin{aligned} H(I_1) &= - \sum_{i \in [1, \dots, N]} p_1(i) \log_2(p_1(i)) \\ H(I_2) &= - \sum_{j \in [1, \dots, N]} p_2(j) \log_2(p_2(j)) \\ H(I_1, I_2) &= - \sum_{i, j \in [1, \dots, N]} p(i, j) \log_2(p(i, j)) \end{aligned} \quad (3)$$

où p_1 et p_2 sont les densités de probabilité de I_1 et I_2 estimées à partir d'un histogramme.

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.

2.3 Décision

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 s la plus faible (similarité la plus forte). Nous décidons donc de la transformation t_d donnée par :

$$t_d = \underset{t \in T}{\text{argmin}} s(I_1, t(I_2)). \quad (4)$$

3 Fonctions de croyance

La théorie des fonctions de croyance est issue des travaux de A. Dempster [6], et du formalisme de G. Shafer [18] sous le nom de *theory of evidence*. Les fonctions de croyance

ont trouvé de nombreuses applications en traitement d'images [2, 24], telles que la segmentation d'images [21, 23], ou la fusion de classifieurs sur des images [15, 13]. Dans cette dernière application, les images sont supposées déjà recalées. Si ce n'est le cas, il peut être intéressant de chercher à les recalculer et de les fusionner en conservant le même formalisme de la théorie des fonctions de croyance que nous décrivons ci-dessous.

3.1 Cadre de discernement

Le cadre de discernement défini par $\mathcal{C}_i = \{C_1, \dots, C_n\}$, où C_k est une classe possible représente l'ensemble des classes envisageables par un classifieur que nous noterons S_i . Les n classes C_k sont supposées exclusives mais pas nécessairement exhaustives. Les cadres de discernement des classifieurs S_i peuvent être différents mais doivent être compatibles dans le sens où une classe d'un classifieur S_i doit pouvoir s'écrire comme l'union de classes d'un autre classifieur $S_{i'}$ ou inversement. Par soucis de simplification d'écriture, nous considérons ici des cadres de discernement identiques pour tous les classifieurs.

3.2 Fonctions de masse

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 $2^\Theta = \{\emptyset, \{C_1\}, \{C_2\}, \{C_1 \cup C_2\}, \dots, \}$. Une fonction de masse m est donc définie sur 2^Θ , par convenance elle est à valeur dans $[0, 1]$, et vérifie la propriété de normalisation suivante :

$$\sum_{A \in 2^\Theta} m(A) = 1. \quad (5)$$

La fonction de masse modélise le degré de croyance que l'on accorde à chaque proposition A de 2^Θ . Ce degré de 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 [20], nous admettons que l'on puisse avoir $m(\emptyset) > 0$.

3.3 Opérateur de combinaison

Une fois définies les fonctions de masse pour chaque classifieur S_i , différents opérateurs de combinaison sont envisageables. La règle orthogonale de Dempster non normalisée proposée par Smets [19] est définie pour deux fonctions de masse m_1 et m_2 et pour tout $A \in 2^\Theta$ par :

$$m_{\text{Conj}}(A) = \sum_{B \cap C = A} m_1(B)m_2(C). \quad (6)$$

Cet opérateur est associatif et commutatif, mais non-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 [1]. Dans le premier cas le fait d'avoir une masse non nulle sur l'ensemble vide (cas d'un monde ouvert) est concevable. Si l'on souhaite rester en monde fermé, de nombreuses règles de combinaison répartissant le conflit ont été proposées dans la littérature. Initialement, Dempster repris par Shafer a proposé une règle orthogonale normalisée, répartissant le conflit de manière uniforme, donnée pour tout $X \in 2^\Theta$, $X \neq \emptyset$ par :

$$m_{\text{DS}}(X) = \frac{m_{\text{Conj}}(X)}{1 - m_{\text{Conj}}(\emptyset)}. \quad (7)$$

3.4 Décision

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), ou probabilités (telle que la probabilité pignistique) ont été définies. Si cette étape est importante dans le cadre de la fusion de classifieurs, l'utilisation des fonctions de croyance que nous présentons dans le cadre du recalage d'images ne nécessite pas ces fonctions.

4 Recalage d'images à partir des fonctions de croyance

4.1 Hypothèses

Nous nous plaçons dans ce papier dans les cas où nous possédons des images classifiées I_i . Ces images sont donc les sorties des classifieurs précédemment 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 sont donc peu envisageables [16]. De plus nous ne considérerons que les transformations rigides t parmi l'ensemble possible de ces transformations noté T .

Les images à recalcer ont été classifiées et donc segmentées par des classifieurs possédant le même cadre de discernement selon n classes C_k . De fait chaque pixel de chacune des deux images (celle de base et celle à recalcer) appartient à une (unique) classe. L'ensemble des n classes C_k est donc le cadre de discernement de nos images I_i .

La théorie des fonctions de croyance permet de gérer le conflit entre deux sources d'information. Le conflit est une mesure du désaccord entre deux sources, ou dans notre cas de la classe à laquelle a été affectée un pixel.

4.2 Définition des fonctions de masse

Chaque pixel x_i de chaque image I_i (images qui peuvent être de taille différente) ayant déjà été affecté à une classe C_k par un classifieur, nous

pouvons utiliser une fonction à support simple pour définir nos masses. Pour une image I_i composée des pixels x_i , une fonction de masse à support simple pour chaque pixel x_i se définit ainsi :

$$\begin{cases} m_{x_i}(C_k) = \alpha_{ik} & \text{si } x_i \in C_k \\ m_{x_i}(\cdot) = 1 - \alpha_{ik} \\ m_{x_i}(A) = 0 & \text{si } A \in 2^\Theta \setminus \{C_k, \cdot\} \end{cases} \quad (8)$$

où α_{ik} est la fiabilité du classifieur ayant produit I_i pour la classe C_k . Cette fiabilité peut par exemple être estimée à partir du taux de bonne classification par classe [12]. Lorsque les performances du classifieur sont sensiblement les mêmes pour chaque classe, la fiabilité peut être donnée par α_k , le taux de bonne classification global du classifieur.

4.3 Combinaison et décision

Dans le cas de deux images, nous cherchons donc à combiner l'image de référence I_1 avec le résultat de la transformation $t(I_2)$ de l'image à recalcer I_2 , pour une transformation donnée $t \in T$. Cependant rien ne nous garantit (puisque c'est ce que nous cherchons au final) que le résultat $t(I_2)$ et I_1 représente la même chose. 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 recalcer $t(I_2)$ sur I_1 . 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 et $t(I_2)$.

Le conflit qui apparaît si l'on combine $t(I_2)$ avec I_1 à tort est donc une bonne mesure de dissimilarité de nos deux images I_1 et $t(I_2)$. 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 (6).

Formellement, nous cherchons donc à combiner la fonction de masse m_{x_1} associée à un pixel x_1 de l'image I_1 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 , telle que $t(x_2) = x_1$. Le conflit associé à la combinaison des fonctions de masse de ces deux pixels est donc nul si $C_{x_1} = C_{x_2}$ et sinon est donné par :

$$m_{(x_1,t(x_2))}(\emptyset) = m_{x_1}(C_{x_1})m_{x_2}(C_{x_2}), \quad (9)$$

où C_{x_i} est la classe du pixel x_i et avec $x_1 = t(x_2)$, $x_1 \in I_1$, $x_2 \in I_2$. Le conflit associé à la transformation $t \in T$ est alors donné par :

$$m_t(\emptyset) = \sum_{x_1 \in I_1} m_{(x_1,t(x_2))}(\emptyset). \quad (10)$$

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

$$m_t(\emptyset) = \sum_{x_2 \in I_2} m_{(x_1,t(x_2))}(\emptyset). \quad (11)$$

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

Enfin pour décider de la transformation t la plus crédible parmi T , il suffit de considérer la transformation minimisant ce conflit $m_t(\emptyset)$. Nous choisirons donc, après une recherche exhaustive sur T , la transformation t_r donnée par :

$$t_r = \operatorname{argmin}_{t \in T} m_t(\emptyset). \quad (12)$$

5 Premiers résultats

Nous présentons ici les premiers résultats obtenus sur une image générée. Cette image simule une segmentation par un classifieur en 4 classes. Le niveau de gris de chaque pixel représente la classe à laquelle il appartient. Dans cette simulation, l'appartenance à chaque classe est supposée déterminée par un classifieur parfait (donc $\forall k \in \{1, 2, 3, 4\}, \alpha_k = 1$). Nous extrayons une partie de cette image et nous allons chercher à la recaler sur l'image d'origine. La figure 2 montre l'image originale et l'extrait à recaler.

Nous définissons une transformation t_0 qui permet de recaler l'extrait I_2 sur l'image d'origine



Figure 2 – Exemple d'images pour le recalage : I_1 à gauche, I_2 à droite.

I_1 . Les paramètres de cette transformation t_0 sont l'angle de rotation θ_0 , et le décalage en abscisse et en ordonnée (x_0, y_0) . La figure 3 montre que l'extrait est parfaitement recalé sur l'image d'origine avec l'approche proposée.



Figure 3 – Recalage de l'extrait sur l'image originale.

Afin de vérifier la robustesse de notre algorithme face à des erreurs de classification, nous générons aléatoirement des erreurs sur l'image à recaler, comme par exemple sur la figure 4, où 25% des pixels sont affecté à une classe qui n'est pas la leur. Nous considérons que l'erreur de classification vient du classifieur censé avoir généré l'image à recaler, et prenons en compte la diminution de son taux de bonne classification dans la définition des fonctions de masse.




Figure 4 – Image avec un taux d'erreur de classification de 25%.

Faisant varier le pourcentage d'erreurs, pour

chacune des images obtenues, notre algorithme cherche la meilleure transformation t à appliquer pour les recaler sur I_1 . Les paramètres de la transformation sont l'angle de rotation θ_t et le décalage (x_t, y_t) . La figure 5 montre que la transformation déterminée pour l'image I_2 avec 25% d'erreurs de classification permet de recaler correctement notre extrait altéré sur I_1 .




Figure 5 – Recalage de l'extrait avec 25% d'erreurs de classification sur l'image originale.

Les résultats visuels présentés dans les figures 3 et 5 sont similaires à ceux obtenus par des méthodes classiques utilisant une simple corrélation ou l'information mutuelle.

Pour évaluer de manière quantitative, la qualité de notre recalage en faisant varier le pourcentage d'erreurs, nous introduisons une mesure de dérive d qui correspond à la somme des distances euclidiennes mesurant l'écart entre l'angle trouvé θ_t et l'angle réel θ_0 et l'écart du décalage trouvé (x_t, y_t) avec le décalage réel (x_0, y_0) . Cette mesure d est donnée par :

$$d(t_0, t) = \sqrt{\theta_0 - \theta_t)^2 + \sqrt{(x_0 - x_t)^2 + (y_0 - y_t)^2} \quad (13)$$

La figure 6 présente l'évolution de cette mesure en fonction du taux d'erreur de classification appliqué à l'image I_2 à recaler. Nous comparons les résultats de notre algorithme à ceux d'un algorithme de recalage par information mutuelle connu pour donner de bons résultats dans ce contexte.

Entre 0 et 40% de taux d'erreur, les résultats de notre méthode sont équivalents à ceux du recalage par information mutuelle. À partir de 40% d'erreur de classification, l'approche fondée




Figure 6 – Dérive du recalage en fonction du taux d'erreur de classification.

sur l'information mutuelle commence à dériver (transformations de plus en plus loin du recalage idéal), alors que notre approche continue de déterminer de bonnes transformations jusqu'à 60% voire 70% d'erreur de classification.

L'information mutuelle permet de mesurer la correspondance entre deux sources d'information, de manière stricte. Les fonctions de croyances prennent en compte dans la modélisation d'une part d'ignorance (la masse allouée à \emptyset). Lors de la phase de combinaison, et lorsque les masses à fusionner ne portent pas sur la même classe, la présence de masse sur l'ignorance permet d'absorber une partie du conflit généré, et ainsi réduire l'impact des erreurs de classification sur l'algorithme de recalage.

6 Conclusion et perspectives

Nous proposons dans cet article un premier travail pour la définition d'une approche de recalage d'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 classificateurs qui est l'étape suivant le recalage. Ce choix nous permet donc de rester dans un même cadre théorique.

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. Les premiers résultats présentés dans des cas simples, montrent l'intérêt d'une telle approche.

Ce travail d'évaluation doit être poursuivi, sur davantage de données et par exemple en considérant des transformations déformables. L'approche doit aussi être confrontée avec des données réelles telles que les images sonar; la caractérisation des fonds marins étant notre première motivation.

Références

- [1] A. Appriou. Discrimination multisériel par la théorie de l'évidence. In *Décision et Reconnaissance des formes en signal*, Hermès Science Publication, pp 219-258, 2002.
- [2] I. Bloch and H. Maître. Fusion de données en traitement d'images : modèles d'information et décisions. *Traitement du Signal*, 11(6) :435-446, 1994.
- [3] A. Butt, R. Acharya, C. Sibata and K.H. Shin. Surface matching of multimodality image volumes by a fuzzy elastic registration technique. *Computerized Medical Imaging and Graphics*, 22 : 13-23, 1998.
- [4] C. Chailloux. *Recalage d'images sonar par appariement de régions : application à la génération d'une mosaïque*, Thèse de doctorat de l'Université de Rennes 1, 2007.
- [5] S. Chambon, *Mise en correspondance stéréoscopique d'images couleur en présence d'occultations*, Thèse de doctorat de l'Université Paul Sabatier, Toulouse, décembre 2005.
- [6] A. Dempster. Upper and Lower Probabilities Induced by a Multivalued Mapping. *AMS*, 38 : 325-339, 1967.
- [7] D.L.G. Hill and D.Z. Hawkes. Across-modality registration using intensity-based cost functions. *Handbook of medical imaging*, 34 : 537-553, 2000.
- [8] J. Jianying and Z. Qiming. A novel method for multispectral aerial image. *IEEE International Geoscience and Remote Sensing Symposium*, Barcelona, Spain, 23-27 july 2007.
- [9] I. Leblond. *Recalage à long terme d'images sonar par mise en correspondance de cartes de classification automatique des fonds*. Thèse de doctorat de l'Université de Bretagne Occidentale, ENSIETA, Brest, 9 février 2006.
- [10] J. B. A. Maintz, P. A. van den Elsen, and M. A. Viergever. Registration of SPECT and MR brain images using a fuzzy surface. *Medical Imaging '96 - Image processing*, 2710 : 821-829, 1996.
- [11] J. B. A. Maintz and M. A. Viergever. A survey of Medical Image Registration. *Medical Image Analysis*, 2(1) : 1-36, 1998.
- [12] A. Martin, and E. Radoï, Effective ATR Algorithms Using Information Fusion Models, *The 7th International Conference on Information Fusion*, Stockholm, Sweden, 28 Juin- 1 Juillet 2004.
- [13] A. Martin. Comparative study of information fusion methods for sonar images classification, *The 8th International Conference on Information Fusion*, Philadelphia, USA, 25-29 Juillet 2005.
- [14] A. Martin, H. Laanaya, and A. Arnold-Bos, Evaluation for Uncertainty Image Classification and Segmentation, *Pattern Recognition*, 39 : 1987-1995, 2006.
- [15] N. Milisavjevic, I. Bloch, S. Van Den Broek and M. Acheroy. Improving mine recognition through processing and dempster-shafer fusion of ground-penetrating radar data. *Pattern Recognition*, 36 :1233-1250, 2003.
- [16] A-M. Olteanu. A multi-criteria fusion approach for geographical data matching, *In proceedings from 5th ISSDQ*, 2007
- [17] A. Roche. *Recalage d'Images Médicales par Inférence Statistique*. Thèse de Doctorat, Université de Nice Sophia Antipolis, 2001.
- [18] G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
- [19] Ph. Smets. The Combination of Evidence in Transferable Belief Model. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(5) : 447-458, 1990.
- [20] Ph. Smets and R. Kennes. The Transferable Belief Model. *Artificial Intelligence*, 66(2) : 191-234, 1994.
- [21] A. Taleb-Ahmed, L. Gautier and M. Rombaut. 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, 2002.
- [22] J-P. Tarel and N. Boujemaa. A coarse to fine 3D registration method based on robust fuzzy clustering. *Computer vision and image understanding*, 1999.
- [23] P. Vannoorenberghe, O. Colot and D. de Brucq. Color Image Segmentation Using Dempster-Shafer's Theory, *ICIP (4)*, pp 300-303, 1999.
- [24] P. Vannoorenberghe, E. Lefevre, O. Colot. Traitement d'images et Théorie des fonctions de croyance, *rencontre francophone sur la Logique Floue et ses Applications, LFA'2003*, pp.287-294, 2003.
- [25] M.L.F. Velloso and F.J. de Souza. Image fusion using fuzzy-nonparametric interpolation approach. *IEEE International Geoscience and Remote Sensing Symposium*, Seoul, Korea, 25-29 july 2005.
- [26] R.P. Woods, J.C. Mazziota and S.R. Cherry. MRI-PET registration with automated algorithm. *Journal of Computer Assisted Tomography*, 17(4) : 536-546, 1993.
- [27] W. Yang, C. Han, H. Sun and Y. Cao. Registration of high resolution SAR and optical images based on multiple features. *IEEE International Geoscience and Remote Sensing Symposium*, Seoul, Korea, 25-29 july 2005.
- [28] B. Zitová and J. Flusser. Image registration methods : a survey. *Image and Vision Computing*, 21(11) : 977,1000, 2003.