
Classification des sédiments marins par fusion de classifieurs binaires SVM

H. Laanaya^(1,2), A. Martin⁽¹⁾, D. Aboutajdine⁽²⁾, A. Khenchaf⁽¹⁾

⁽¹⁾ E³I² EA3876, ENSIETA, 2 rue François Verny, 29806 Brest cedex 9, France

E-mail: {laanayhi, Arnaud.Martin, Ali.Khenchaf}@ensieta.fr

⁽²⁾ Université Mohammed V-Agdal, Faculté des sciences de Rabat, Maroc

E-mail: aboutaj@fsr.ac.ma

SHORT ABSTRACT: *Seabed classification on sonar images is particularly hard to perform. Many classification algorithm are proposed without very good performance in these kind of problems. The difficulty comes essentially from the uncertainties and imprecision of underwater environments. So we must take into account of the uncertainties and imprecision coming from the sensors and the images reconstruction algorithm, that we see on sonar images. We must also take into account of these imperfections in the evaluation step of the automatic approaches. One of the numerous classifier is the vector support machine that is a binary classifier and we can use it in a multiclass case considering the classes by two subsets. The combination of these binary classifiers is generally very simple. We propose here to combine these classifiers in the belief theory context taking into account of the uncertainties and imprecision of these classifiers.*

Keywords: *Seabed classification, Support Vector Machines, belief functions.*

RÉSUMÉ COURT: *La classification des images sonar est particulièrement difficile. De nombreuses approches de classification ont été étudiées sans pouvoir fournir de très bonnes performances. La difficulté provient entre autre du caractère incertain de l'environnement sous-marin. Il est donc important de pouvoir tenir compte des incertitudes et imprécisions issues des capteurs et des méthodes de reconstruction d'images, incertitudes et imprécisions que l'on retrouve sur l'image. Il est également important de pouvoir en tenir compte lors de l'évaluation des approches automatiques. Un des nombreux classifieurs étudié est la machine à vecteurs de support qui est un classifieur binaire que l'on peut employé dans le cas de classes multiples en considérant les différentes classes par groupe de deux. La combinaison de ces classifieurs binaire est généralement des plus simples. Nous proposons ici de combiner ces classifieurs binaires dans le cadre de la théorie des fonctions de croyance permettant de tenir compte des incertitudes et imprécisions de ces classifieurs.*

Mots-clés: *Classification de sédiments marins, Machines à vecteurs de support, fonctions de croyance.*

1 INTRODUCTION

Les images Sonar sont obtenues à partir des mesures temporelles faites en traînant à l'arrière d'un bateau un Sonar qui peut être latéral, frontal, ou multifaisceaux. Chaque signal émis est réfléchi sur le fond puis reçu sur l'antenne du Sonar avec un décalage et une intensité variable. Pour la reconstruction sous forme d'images un grand nombre de données physiques (géométrie du dispositif, coordonnées du bateau, mouvements du Sonar, ...) est pris en compte, mais ces données sont entachées des bruits de mesures dus à l'instrumentation. A ceci viennent s'ajouter des interférences dues à des trajets multiples du signal (sur le fond ou la surface), à des bruits de chatolement, ou encore à la faune et à la flore. Les images sont donc entachées d'un grand nombre d'imperfections relevant de l'imprécision et l'incertitude.

Il est alors difficile pour un expert humain de caractériser précisément et avec certitude les fonds marins à partir de telles images. Cependant, en milieu sous-marin les capteurs optiques ne permettent pas d'imager rapidement et de grandes surfaces les fonds, ce qui est nécessaire pour de nombreuses applications telles que la navigation de robots autonomes. Il est donc nécessaire de proposer des approches de classifications automatiques des images Sonar.

La réalité n'étant pas connue précisément, nous avons constitué une base de données à partir de l'avis de différents experts en leur demandant d'indiquer la certitude de l'information fournie (en terme de "sûr", "moyennement sûr" et "pas sûr"). La figure 1 présente le résultat de la segmentation obtenue par deux experts, les couleurs indiquant les différents types de sédiments pour une certitude. Nous constatons ainsi le manque de précision de la segmentation et l'incertitude des experts sur leur classification.

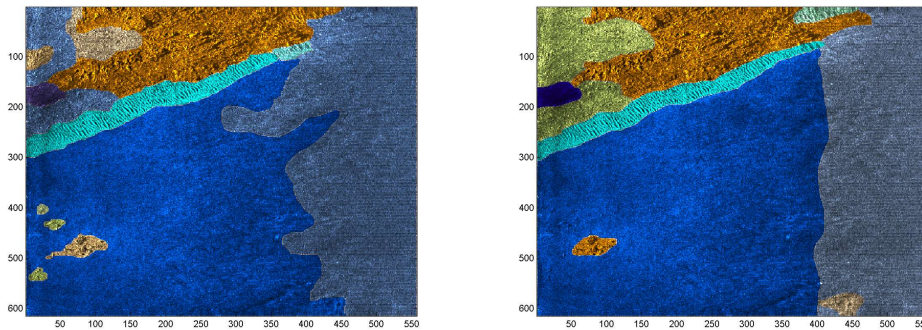


Fig. 1: Avis de deux experts sur la même image.

De nombreuses approches de classification automatique sont envisageables telles que les réseaux de neurones, les k plus proches voisins ou les machines à vecteurs de support [1, 2]. Notre choix s'est porté sur les machines à vecteurs de support (SVM) du fait de la simplicité de cette approche et de sa capacité d'extension à une classification non linéaire ce qui a poussé à un développement et une utilisation importants des SVM.

Un des problèmes posé par les SVM dans le cas de la classification de plusieurs classes est le fait que c'est avant tout une méthode de classification binaire. Ainsi plusieurs approches sont possibles pour décomposer un problème de classification à plusieurs classes en classification binaire dont il faut ensuite combiner les résultats. Le papier porte donc sur une approche originale de combinaison des résultats de classifieurs binaires dans le cadre de la théorie des fonctions de croyances.

Dans un premier temps nous reviendrons sur le principe des SVM, puis nous présenterons rapidement les différentes approches possibles de combinaison de classifieurs binaires. Nous détaillerons le cas de la combinaison dans le cadre de la théorie des fonctions de croyance. Pour finir nous présenterons des résultats sur la classifications des images sonar.

2 PRINCIPE DES SVM

Les SVM initiées par Vapnik (1998) découlent d'une approche linéaire de détection (séparation en deux classes). Supposons qu'il existe un hyperplan qui sépare les deux classes : les points de l'hyperplan sont décrits par l'équation (1) où w est la normale au plan et $|b|/\|w\|$ la distance entre l'hyperplan et l'origine.

Soient d_+ (resp. d_-) la distance minimale entre l'hyperplan et la classe des x_i tel que $y_i = +1$ (resp. $y_i = -1$). On essaye de chercher l'hyperplan optimal, *i.e.* celui qui maximise $d_+ + d_-$, ceci se traduit par l'existence d'un couple $(w, b) \in \mathbb{R}^d \times \mathbb{R}$ tel que :

$$x_i \cdot w + b = 0, \quad (1)$$

pour les points de cet hyperplan, et $x_i \cdot w + b$ si $y_i = +1$ et $x_i \cdot w + b$ si $y_i = -1$, ou encore

$$y_i(x_i \cdot w + b) - 1, \quad (2)$$

pour tout $i = 1, \dots, l$. On a $d_+ + d_- = (1 - b)/\|w\| - (-1 - b)/\|w\| = 2/\|w\|$. Ainsi, on peut trouver l'hyperplan optimal en maximisant $2/\|w\|$ sous les contraintes (2). Ce qui est équivalent à minimiser $J(w) = \|w\|^2/2$ sous les mêmes contraintes. Les points où $y_i(x_i \cdot w + b) - 1 = 0$ sont appelés *vecteurs de support*.

Il s'agit donc de chercher des constantes w et b vérifiant (2) qui minimisent $J(w)$, i.e. trouver la solution du système non-linéaire suivant :

$$\begin{cases} \min_{w,b} J(w) \\ \varphi_l(w, b) \leq 0 \end{cases} \quad (3)$$

où $f_i(w, b) = 1 - y_i(x_i \cdot w + b)$ pour tout $i = 1, \dots, l$. Si l'on veut estimer la classe d'un nouvel individu x , il suffit de calculer :

$$f(x) = \text{sign} \left(\sum_{VS} \alpha_i^0 y_i(x_i \cdot x) + b_0 \right), \quad (4)$$

où VS est l'ensemble des vecteurs de support et α_i^0 les solutions des conditions de Kuhn, Karush et Tucker. Il se peut qu'il n'existe pas d'hyperplan qui sépare les deux classes. Dans ce cas, on relâche les contraintes. Celles-ci deviennent :

$$\begin{cases} x_i \cdot w + b \geq 1 + \xi_i & \text{si } y_i = 1, \\ x_i \cdot w + b \leq -1 + \xi_i & \text{si } y_i = -1, \end{cases} \quad (5)$$

où ξ_i est une constante positive.

Cette méthode est généralisée dans le cas où la fonction de décision n'est pas linéaire en plongeant les vecteurs d'entrées dans un autre espace de dimension suffisamment grande en utilisant une fonction $\varphi : \mathbb{R} \rightarrow H$, tel qu'il existe une fonction noyau $K : \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}$ telle que $K(x, x') = \varphi(x) \cdot \varphi(x')$.

Il suffit alors de chercher l'hyperplan optimal dans l'espace H par la méthode précédente. Enfin, pour estimer la classe d'un point x , on utilise la fonction :

$$f(x) = \text{sign} \left(\sum_{VS} \alpha_i^0 y_i K(x_i, x) + b_0 \right). \quad (6)$$

De la même façon qu'il n'existe pas de méthode pour choisir φ , il n'existe pas de méthode pour choisir le noyau K . Les principaux noyaux utilisés dans les applications de reconnaissance des formes sont : les polynômes ($K(x, y) = ((x \cdot y) + 1)^p$), les gaussiennes ($K(x, y) = e^{-\|x-y\|^2/2\sigma^2}$) et les sigmoïdes ($K(x, y) = \tanh(k(x \cdot y) - \delta)$).

2.1 Stratégies de classification dans le cas de classes multiples

Il y a classiquement différentes approches pour effectuer de la classification dans le cas de classes multiples par SVM : d'une manière directe, où on essaye de résoudre un problème d'optimisation général, ou bien en fusionnant plusieurs classifieurs binaires par SVM, les résultats obtenus par chaque classifieur binaire sont combinés pour donner le résultat final, c'est le cas pour les approches un-contre-un, un-contre-reste.

- L'approche directe : est une approche étendant la notion de marge aux cas multiclasse [3]. Cette formulation intéressante permet de poser un problème d'optimisation unique justifié par des considérations théoriques. Le problème fait intervenir N fonctions de décisions et il s'écrit dans le cas où les données sont non séparables :

$$\min_{w,b,\xi_i^m} \frac{1}{2} \sum_{m=1}^N w_m \cdot w_m + C \sum_{i=1}^d \sum_{m \neq y_i} \xi_i^m \quad (7)$$

sous les contraintes

$$\begin{cases} w_{y_i} \cdot x_i + b_{y_i} \geq w_m \cdot x_i + b_m + 2 - \xi_i^m, \\ \xi_i^m \geq 0, \quad i = 1, \dots, d, \quad m = 1, \dots, N, \quad m \neq y_i. \end{cases} \quad (8)$$

Cette approche devient cependant vite coûteuse, particulièrement dans le cas non linéaire.

- un-contre-reste : l'approche la plus naturelle est d'utiliser cette méthode de discrimination binaire et d'apprendre n fonctions de décision $f_i, i = 1, \dots, n$ permettant de faire la discrimination entre chaque classe de toutes les autres. L'affectation d'un nouveau point x à une classe C_k se fait en général par la relation : $k = \operatorname{argmax}_{i=1, \dots, n} f_i(x)$.
- un contre un : Au lieu d'apprendre n fonctions de décision, ici chaque classe est discriminée d'une autre. Ainsi $n(n-1)/2$ fonctions sont apprises et chacune d'entre elles constitue la réponse d'un classifieur binaire. L'affectation d'un nouvel individu x est réalisée par la combinaison des classifieurs, généralement faite par vote.

Dans ces deux derniers cas la combinaison est réalisée par le maximum et par un vote respectivement pour l'approche un-contre-reste et un-contre-un. Une autre approche couramment employée dans le cadre des SVM est donnée par l'approche ECOC (Error Correcting Output Coding). Dans cette approche, la classe d'un individu est décrite par un mot codé sur N bits. Nous obtenons ainsi une matrice des codes avec les classes en ligne et les classifieurs en colonnes [4]. La matrice des codes représente la contribution de chaque classifieur au résultat final de la classification en se fondant sur les erreurs commises par les différents classifieurs. Ainsi la classe d'un nouvel individu est donnée par la classe qui possède le code le plus proche en terme de distance (de Hamming par exemple). Ces approches ne permettent cependant pas de tenir compte des incertitudes et imprécisions liées à l'application, il peut donc être intéressant de se tourner vers des approches issues des théories de l'incertain afin de combiner des classifieurs, en particulier la théorie des fonctions de croyance [5, 6]. Notons que d'autres approches ont été envisagées pour les SVM dans le cas un-contre-un [7].

3 THÉORIE DES FONCTIONS DE CROYANCE

La fusion d'informations a depuis plusieurs années permis d'apporter des solutions à la combinaison d'informations issues de diverses sources afin d'améliorer la prise de décision, par exemple dans un système de classification. Le fait de devoir tenir compte de plusieurs sources a poussé le développement de plusieurs théories permettant de modéliser finement les informations issues de ces sources en terme de fiabilité, incertitude, imprécision ou encore incomplétude. Parmi ces théories de l'incertain, la théorie des fonctions de croyance issue des recherches de Dempster et Shafer [8, 9] a connu ces dernières années un développement important notamment dans sa mise en forme pour de nombreuses applications.

La théorie des fonctions de croyance est fondée sur la manipulation des fonctions de masse (ou masse élémentaire de croyance). Les fonctions de masse sont définies sur l'ensemble de toutes les disjonctions du cadre de discernement $\Theta = \{C_1, \dots, C_n\}$ et à valeurs dans $[0, 1]$, où les C_i représentent les hypothèses supposées exhaustives et exclusives. Cet ensemble est noté 2^Θ . Généralement, il est ajouté une condition de normalité, donnée par :

$$\sum_{X \in 2^\Theta} m_j(X) = 1, \quad (9)$$

où $m_j(\cdot)$ représente la fonction de masse pour une source (ou un expert) $S_j, j = 1, \dots, M$. Les éléments X tels que $m(X) > 0$ sont appelés les éléments focaux. La première difficulté est donc de définir ces fonctions de masse selon le problème. A partir de ces fonctions de masse, d'autres fonctions de croyance peuvent être définies, telles que les fonctions de crédibilité, représentant l'intensité que toutes les sources croient que les éléments focaux d'une source affirment la croyance en un élément. Elles sont données pour tout $X \in 2^\Theta$ par :

$$\operatorname{bel}(X) = \sum_{Y \subseteq X, Y \neq \emptyset} m(Y), \quad (10)$$

ou encore les fonctions de plausibilité, représentant l'intensité avec laquelle on ne doute pas en un élément, données pour tout $X \in 2^\Theta$ par :

$$\operatorname{pl}(X) = \sum_{Y \in 2^\Theta, Y \cap X \neq \emptyset} m(Y) = \operatorname{bel}(\Theta) - \operatorname{bel}(X^c) = 1 - m(\emptyset) - \operatorname{bel}(X^c), \quad (11)$$

où X^c est le complémentaire de X .

Afin de conserver un maximum d'informations, il est préférable de rester à un niveau crédal (*i.e.* de manipuler des fonctions de croyance) pendant l'étape de combinaison des informations pour prendre la décision sur les fonctions de croyance issues de la combinaison. Si la décision prise par le maximum de crédibilité peut être trop pessimiste, la décision issue du maximum de plausibilité est bien souvent trop optimiste. Le maximum de la probabilité pignistique, introduite par [10], reste le compromis le plus employé. La probabilité pignistique est donnée pour tout $X \in 2^\Theta$, avec $X \neq \emptyset$ par :

$$\text{betP}(X) = \sum_{Y \in 2^\Theta, Y \neq \emptyset} \frac{|X \cap Y|}{|Y|} \frac{m(Y)}{1 - m(\emptyset)}. \quad (12)$$

La combinaison des fonctions de masse peut être réalisée par de nombreuses règles ([11, 12, 13, 14, 15, 16], *etc.*). La règle la plus employé de nos jours est a règle conjonctive [13] donnée pour tout $X \in 2^\Theta$ par :

$$m_c(X) = \sum_{Y_1 \cap \dots \cap Y_M = X} \prod_{j=1}^M m_j(Y_j), \quad (13)$$

où $Y_j \in 2^\Theta$ est la réponse de l'expert S_j , et $m_j(Y_j)$ la masse associée.

4 FONCTIONS DE MASSE POUR LA FUSION DE CLASSIFIEURS BINAIRES

La modélisation des fonctions de masse est chose délicate et plusieurs approches sont envisageables. Appriou [17] propose une modélisation particulièrement bien adaptée dans les cas où il est possible de considérer une décision contre toutes les autres. C'est les cas que nous retrouvons dans l'approche un-contre-reste mais aussi dans le cas un-contre-un. Ainsi, dans la première approche les deux décisions seront une classe et toutes les autres, tandis que dans l'approche un-contre-un, nous avons $n(n-1)/2$ fois où les deux décisions sont une classe et une autre.

Les deux modèles probabilistes proposés par Appriou reposent sur des considérations axiomatiques rigoureuses. Ils sont donnés par :

- Modèle 1 :

$$\begin{cases} m_{ij}(C_i)(x) = \frac{\alpha_{ij} R_j p(S_j|C_i)}{1 + R_j p(S_j|C_i)} \\ m_{ij}(C_i^c)(x) = \frac{\alpha_{ij}}{1 + R_j p(S_j|C_i)} \\ m_{ij}(\Theta)(x) = 1 - \alpha_{ij} \end{cases} \quad (14)$$

avec $R_j \geq 0$ et α_{ij} un facteur d'affaiblissement proche de 1.

- Modèle 2 :

$$\begin{cases} m_{ij}(C_i)(x) = 0 \\ m_{ij}(C_i^c)(x) = \alpha_{ij}(1 - R_j p(S_j|C_i)) \\ m_{ij}(\Theta)(x) = 1 - \alpha_{ij}(1 - R_j p(S_j|C_i)) \end{cases} \quad (15)$$

avec $R_j \in [0, (\max_{S_j, i} p(S_j|d_i))^{-1}]$ et α_{ij} un facteur d'affaiblissement proche de 1.

Cette écriture s'entend très bien dans le cas un-contre-reste : nous avons ainsi pour chacun des n classifieurs S_j , n fonctions de masses pour les n classes. Par contre dans le cas un-contre-un, il faut entendre C_i^c , le complémentaire de C_i comme $C_{i'}$ la classe concurrente. Ainsi pour les $n(n-1)/2$ classifieurs S_j , nous avons également n fonctions de masse.

Les probabilités $p(S_j|C_i)$ peuvent s'estimer facilement à partir des matrices de confusion des classifieurs S_j [5].

Nous obtenons ainsi une même modélisation des fonctions de masse dans les cas un-contre-reste et un-contre-un, permettant de tenir compte des incertitudes et imprécisions.

5 RÉSULTATS

Notre base d'images Sonar est composée de 42 images fournies par le GESMA (Groupe d'Etudes Sous-Marines de l'Atlantique). Ces images ont été obtenues à partir d'un Sonar latéral Klein 5400 avec une résolution de 20 à 30 cm en azimut et 3 cm en range dans des profondeurs allant de 15 m à 40 m. Ces images ont été segmentées par différents experts.

Nous ne considérons ici que des imagerie de taille 32×32 pixels ne comportant qu'un seul type de sédiment afin d'obtenir des matrices de confusion classiques. Nous obtenons ainsi une base de 30076 imagerie. Trois types de sédiments sont considérés : roche et cailloutis (15%), ride (13%), sable et vase (72%).

Sur chaque imagerie sont calculées 6 paramètres de texture issus des matrices de cooccurrence [18, 19].

Après 10 tirages aléatoires nous obtenons 7.53% et 84.05 % de taux de bonne classification respectivement dans les cas classiques un-contre-reste et un-contre-un décrits précédemment. La stratégie un-contre-reste est ici très mauvaise. Avec l'approche de combinaison donnée par les fonctions de croyance nous obtenons respectivement 18.67% et 84.17% pour les cas un-contre-reste et un-contre-un. Nous avons ainsi une amélioration du taux de bonne classification dans les deux cas. Dans le cas un-contre-un nous avons pour vecteurs de bonne classification par classe : [72.12 11.32 97.96] dans le cas classique et [72.04 12.42 97.96] avec les fonctions de croyance et pour vecteurs d'erreur par classe : [25.91 44.81 18.22] dans le cas classique et [25.66 44.30 18.22] avec les fonctions de croyance. Nous constatons ainsi que les fonctions de croyance apporte une amélioration essentiellement sur la classe des rides et que les erreurs produites sur la classe des roches et cailloutis sont plus faibles.

Afin d'évaluer plus finement les approches de classification d'images sonar, il est important de considérer les images dans leur globalité, *i.e.* en considérant également les imagerie inhomogènes. Pour ce faire nous avons défini des mesures d'évaluation à la fois de la classification et de la segmentation issue de la segmentation. Nous avons proposé de telles mesures tenant compte des incertitudes des experts et des imprécisions dues à la taille de l'imagerie considérée [20, 21].

6 CONCLUSIONS

Nous avons étudié dans cet article une approche originale pour la classification des images sonar. Cette classification est fondée sur les machines à vecteurs de support qui est un classifieur binaire. L'originalité porte sur la combinaison des classifieurs binaires issus des SVM. Nous avons proposé de combiner ces classifieurs binaires (un-contre-un et un-contre-reste) dans le cadre de la théorie des fonctions de croyance permettant de tenir compte des incertitudes et imprécisions.

Les résultats restent sur les données étudiées restent assez proches des façons usuelles de combiner ces classifieurs, même si une amélioration est notée *via* les fonctions de croyances. Cette approche offre de plus l'avantage de combiner toutes les sortes de classifieurs binaires.

Il apparaît plus rigoureux d'évaluer les algorithmes de classification d'images sonar sur un grand nombre d'images et en tenant compte des incertitudes des experts sur ces images. Ce travail montre une nouvelle fois la difficulté de la classification des sédiments marins.

References

- [1] I. Leblond, M. Legris, and B. Solaiman, "Use of classification and segmentation of sidescan sonar images for long term registration," in *IEEE Oceans'05 Europe*, (Brest,France), Juin 2005.
- [2] H. Laanaya, A. Martin, D. Aboutajdine, and A. Khenchaf, "A new dimensionality reduction method for seabed characterization: Supervised curvilinear component analysis," in *IEEE OCEANS'05 EUROPE*, (Brest,France), Juin 2005.
- [3] J. Weston and C. Watkins, "Support vector machines for multi-class pattern recognition machines," tech. rep., CSD-TR-98-04, Department of Computer Science ,Royal Holloway, University of London, 1998.
- [4] T. Dietterich and G. Bakiri, "Solving multiclass learning problems via error-correcting output codes," *Journal of Artificial Intelligence Research*, vol. 2, pp. 263–286, 1995.

- [5] A. Martin, "Comparative study of information fusion methods for sonar images classification," in *International Conference on Information Fusion*, (Philadelphia, USA), Juillet 2005.
- [6] B. Quost, T. Denoeux, and M. Masson, "Pairwise classifier combination in the transferable belief model," in *International Conference on Information Fusion*, (Philadelphia, USA), Juillet 2005.
- [7] A. Lauberts and D. Lindgren, "Generalization ability of a support vector classifier applied to vehicle data in a microphone network," in *International Conference on Information Fusion*, (Florence, Italia), Juillet 2006.
- [8] A. Dempster, "Upper and Lower probabilities induced by a multivalued mapping," *Annals of Mathematical Statistics*, vol. 38, pp. 325–339, 1967.
- [9] G. Shafer, *A mathematical theory of evidence*. Princeton University Press, 1976.
- [10] P. Smets, "Constructing the pignistic probability function in a context of uncertainty," *Uncertainty in Artificial Intelligence*, vol. 5, pp. 29–39, 1990.
- [11] R. Yager, "On the Dempster-Shafer Framework and New Combination Rules," *Informations Sciences*, vol. 41, pp. 93–137, 1987.
- [12] D. Dubois and H. Prade, "Representation and combination of uncertainty with belief functions and possibility measures," *Computational Intelligence*, vol. 4, pp. 244–264, 1988.
- [13] P. Smets, "The Combination of Evidence in the Transferable Belief Model," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 5, pp. 447–458, 1990.
- [14] P. Smets, "Belief Functions: the Disjunctive Rule of Combination and the Generalized Bayesian Theorem," *International Journal of Approximate Reasoning*, vol. 9, pp. 1–35, 1993.
- [15] A. Martin and C. Osswald, "Human experts fusion for image classification," *Information & Security: An International Journal, Special issue on Fusing Uncertain, Imprecise and Paradoxist Information (DSmT)*, 2006.
- [16] A. Martin and C. Osswald, *Applications and Advances of DSmT for Information Fusion, Book 2*, ch. A new generalization of the proportional conflict redistribution rule stable in terms of decision. American Research Press Rehoboth, 2006.
- [17] A. Appriou, *Décision et Reconnaissance des formes en signal*, ch. Discrimination multiségnal par la théorie de l'évidence, pp. 219–258. Hermes Science Publication, 2002.
- [18] A. Martin, G. Sévellec, and I. Leblond, "Characteristics vs decision fusion for sea-bottom characterization," in *Journée d'Acoustique Sous-Marine*, (Brest, France), Octobre 2004.
- [19] A. Martin and C. Osswald, "Une nouvelle règle de combinaison répartissant le conflit - applications en imagerie sonar et classification de cibles radar," *Traitement du Signal*, 2006.
- [20] A. Martin, "Fusion for evaluation of image classification in uncertain environments," in *International Conference on Information Fusion*, (Florence, Italia), Juillet 2006.
- [21] A. Martin, H. Laanaya, and A. Arnold-Bos, "Evaluation for uncertainty image classification and segmentation," *Pattern Recognition Journal*, 2006.