

Classification parcimonieuse pour l'aide à la reconnaissance de cibles radar

Ayoub Karine^{*,**}, Abdelmalek Toumi^{*}
Ali Khenchaf^{*}, Mohammed EL Hassouni^{**,***}

^{*}Lab-STICC UMR CNRS 6285, ENSTA Bretagne, 29806 Brest Cedex 9, France
{abdelmalek.toumi, ali.khenchaf}@ensta-bretagne.fr

^{**}LRIT URAC 29, Faculty of sciences, Mohammed V University in Rabat, Morocco
{ayoub.karine, mohamed.elhassouni}@gmail.com

^{***}DESTEC, FLSHR, Mohammed V University in Rabat, Morocco

Résumé. Dans le présent papier, nous proposons l'étude et l'application d'une nouvelle approche pour l'aide à la reconnaissance automatique de cibles (ATR, pour Automatic Target Recognition) à partir des images à synthèse d'ouverture inverse (ISAR, pour Inverse Synthetic Aperture Radar). Cette approche est composée de deux phases principales. Dans la première phase, nous utilisons deux méthodes statistiques pour extraire les caractéristiques discriminants à partir des images ISAR. Nous nous intéressons dans ce travail aux deux descripteurs multi-échelles issus des deux méthodes SIFT (Scale-Invariant Feature Transform) et la décomposition en ondelettes complexes DT-CWT (Dual-Tree Complex Wavelet Transform) qui sont calculées disjointement. Ensuite, nous modélisons séparément les descripteurs issus des deux méthodes précédentes (SIFT et DT-CWT) par la loi Gamma. Les paramètres statistiques estimés sont utilisés pour la deuxième phase dédiée à la classification. Dans cette deuxième phase, une classification parcimonieuse (SRC, pour Sparse Representation-based Classification) est proposée. Afin d'évaluer et valider notre approche, nous avons eu recours aux données réelles d'images issues d'une chambre anéchoïque. Les résultats expérimentaux montrent que l'approche proposée peut atteindre un taux de reconnaissance élevé et dépasse largement l'utilisation du même descripteur avec le classifieur machine à vecteurs de support (SVM, pour Support Vector Machine).

1 Introduction

La reconnaissance automatique de cibles est devenu un axe de recherche important pour plusieurs applications que ce soit militaires ou civiles. L'objectif principal d'un système ATR est la détection et la reconnaissance de façon automatique la nature d'une cible, qui, dans notre cas sera représentée par une image radar 2D. Dans cette optique, nous traitons des images de types ISAR. Cependant, l'architecture générale d'un système de reconnaissance de cibles est généralement composée de trois étapes : acquisition des données, préparation des données et la phase de la classification pour la prise de décision. Dans la première étape, l'image ISAR

est reconstruite à partir des signaux radar réfléchis. Cette étape est suivie par la phase d'extraction de descripteurs qui consiste à calculer la signature de chaque cible radar. Finalement, les vecteurs caractéristiques extraits sont utilisés par la phase de classification. Dans la littérature, plusieurs approches sont proposées pour reconnaître automatiquement les cibles radar. Dans le contexte des systèmes ATR basés sur des images ISAR, plusieurs travaux se sont focalisés sur la représentation de l'image dans d'autres espaces transformés tels que l'espace polaire et log-polaire (Kim et al. (2005); Toumi et Khenchaf (2010)) où des architectures de classification bien adaptées (combinaison hybride et séquentielle) sont proposées. Dans un autre travail, Toumi et al. (2009) ont proposé une méthode basée sur la ligne de partage des eaux pour extraire la forme de la cible à partir de laquelle, des descripteurs de Fourier ont été calculés. Pour la phase de classification, l'algorithme du K-Plus Proche Voisin (KPPV) a été adopté. Dans le travail de Saidi et al. (2009), les auteurs ont utilisé de la théorie de fusion en utilisant deux descripteurs : descripteurs de Fourier et les moments invariants. Pour la phase de reconnaissance, le classifieur SVM a été utilisé. Pour les travaux de Wang et al. (2010), les auteurs ont proposé un vecteur caractéristique basé sur la transformation en ondelettes et MB-LBP (Multi-scale Block Local Binary Pattern) en entrée du classifieur KPPV. D'autre part, les auteurs dans Jdey et al. (2012) ont exploité la fusion de trois méthodes de classification : KPPV, SVM et RN (Réseau de neurones) pour la classification des descripteurs de Fourier calculés sur la forme extraite des cibles radar.

Dans ce papier, nous proposons une nouvelle méthode pour la reconnaissance des cibles radar à partir des images ISAR. Cette approche est composée de deux étapes. Dans un premier lieu, deux descripteurs caractérisant chaque image radar sont calculés. Le vecteur descripteur final est calculé à partir de la modélisation du descripteur SIFT et les coefficients de la décomposition en ondelettes complexes par la loi Gamma. Le vecteur caractéristique extrait, ayant une dimension réduite, est utilisé dans le classifieur SRC.

La suite de cet article est structurée comme suit. Nous présentons la méthode proposée pour l'extraction de vecteur descripteur dans la section 2. Dans la section 3, nous décrivons brièvement le principe de la méthode de classification SRC. Nous validons par la suite dans la section 4 l'approche proposée en utilisant une base de données des images radars de type ISAR. Enfin, nous concluons dans la section 5 tout en dressant nos perspectives.

2 Extraction de descripteurs

Le défi majeur dans cette étape du processus de reconnaissance est de proposer un descripteur discriminant capable de caractériser le contenu des images radars d'une manière précise et efficace. Pour ce faire, nous nous intéressons dans ce papier aux méthodes SIFT et DTCWT qui ont prouvé leur efficacité dans plusieurs domaines d'application en traitement d'images. Leur majeur inconvénient réside au niveau du temps de calcul important nécessaire pour la phase d'extraction du vecteur caractéristique ainsi la grande dimensionnalité de ce dernier. Pour contourner cet inconvénient, nous proposons dans ce papier de modéliser ce vecteur caractéristique par la loi Gamma qui est caractérisée par deux paramètres statistiques. Le choix de cette distribution a été justifié par l'allure statistique des vecteurs caractéristiques (issus de ces deux méthodes) caractérisée par une queue lourde (leptokurtique) ce qui nécessite le choix d'un modèle non-Gaussien. De cette manière, le vecteur caractéristique obtenu à partir de la méthode SIFT est représenté par deux paramètres statistiques et cela pour chaque image tandis

que pour la méthode DTCWT, nous avons utilisé trois niveau de décomposition ce qui produit $3 \times 6 = 18$ sous-bandes complexes dont chaque sous-bande est représentée par deux paramètres Gamma. Par conséquent, 36 paramètres statistiques sont calculés pour constituer le nouveau vecteur caractéristique. Enfin, le descripteur global de chaque image radar est composé de 38 valeurs (2 issues de SIFT et 36 issues de la DTCWT). Pour plus de détails sur les méthodes DT-CWT et SIFT et la loi Gamma, le lecteur peut se référer aux références Kingsbury (2001); Lowe (2004); Kwitt et Uhl (2010).

3 Classification basée sur la représentation parcimonieuse

Dans la dernière décennie, la méthode de classification SRC a connu un succès remarquable dans plusieurs applications de traitement d'images à l'instar de la reconnaissance de visages (Wright et al. (2009)). Pour cette raison, nous avons choisi d'implémenter cette méthode de classification parcimonieuse pour la phase de reconnaissance. La méthode SRC détermine la classe d'une observation de test en se basant sur sa combinaison parcimonieuse et linéaire avec un dictionnaire comportant les observations d'apprentissage (Wright et al. (2009)). Nous notons à ce stade que l'observation de test est représentée par l'image de la cible radar à reconnaître.

La première étape du classifieur parcimonieux consiste à construire un dictionnaire $A \in \mathbb{R}^{m \times n}$ en utilisant la base d'apprentissage, avec m est la dimension du vecteur caractéristique et n est le nombre d'images d'apprentissage.

Une image de test $y \in \mathbb{R}^m$ peut se représenter comme une combinaison linéaire de toutes les images d'apprentissage avec un vecteur parcimonieux x :

$$[y]^{m \times 1} = [A]^{m \times n} [x]^{n \times 1} \quad (1)$$

Considérant la formulation de l'équation 1, l'image de test y et le dictionnaire A sont donnés en entrée, et le vecteur x doit être déterminé. Il existe en théorie une infinité de solutions x de l'équation 1, dans ce cas l'objectif est de trouver la solution la plus parcimonieuse possible, c'est-à-dire celle présentant le plus petit nombre de valeurs non nulles dans x . Donc, le problème à résoudre devient (Wright et al. (2009)) :

$$\hat{x} = \min_x \|x\|_1 \text{ sous la contrainte } \|y - Ax\|_2 \leq \epsilon \quad (2)$$

avec $\|x\|_1 = \sqrt{\sum_i^n |x_i|}$ est la norme- l^1 et ϵ est une erreur admissible. Ce problème d'optimisation convexe peut être résolu par l'algorithme SOCP (Second-Order Cone Programming) proposé par Candes et Romberg (2005).

Pour chaque classe i , soit $\delta_i : \mathbb{R}^n \rightarrow \mathbb{R}^n$ la fonction caractéristique qui sélectionne dans \hat{x} juste les coefficients associés à la classe i . En d'autres termes, les valeurs non nulles de $\delta_i(\hat{x}) \in \mathbb{R}^n$ sont les valeurs associées à la classe i dans \hat{x} . Après l'obtention de la solution optimale \hat{x} , la reconstruction de l'image de test \hat{y}_i est $A\delta_i(\hat{x})$. Finalement, l'identité (le *label*) de l'image de test y est la classe qui possède la valeur minimale du résidu entre y et \hat{y}_i :

$$\begin{aligned} \text{class}(y) &= \min_i r_i(y) \\ &= \min_i \|y - \hat{y}_i\|_2 \end{aligned} \quad (3)$$

Le coeur de la classification parcimonieuse est la recherche de la représentation parcimonieuse du vecteur « \hat{x} » (Equation 2) dont la dimension est égale au nombre d'images dans la base d'apprentissage. Le vecteur parcimonieux obtenu est utilisé dans la phase de test pour reconstruire (coder) le vecteur de test.

4 Résultats expérimentaux

Pour valider l'approche proposée, nous avons eu recours à une base de données des images radars acquises dans une chambre anéchoïque, cette dernière contient 1944 images ISAR qui correspondent à 12 classes (cibles) à l'échelle 1/48 : Harrier, Rafale, Tornado, F104, F117, A10, F14, F15, F16, MIG29, F18 et F4. Chaque classe contient 162 images radars de taille 256×256 pixels en niveau de gris. Ces images sont reconstruites en utilisant la transformée de Fourier inverse (IFFT, pour Inverse Fast Fourier Transform) (Toumi et al. (2012)). La figure 1 montre un exemple d'une image ISAR de la cible Tornado.




FIG. 1 – Exemple d'une image ISAR de type Tornado.

Dans le contexte de la classification supervisée, les données doivent être partitionnées en bases d'apprentissage et de test. Pour ce faire, nous adoptons l'utilisation de la validation croisée de type *hold-out cross validation* avec différentes portions de la base d'apprentissage. Le dictionnaire défini dans la méthode de classification parcimonieuse regroupe tous les descripteurs globaux (38 valeurs pour chaque image) de toutes les images de la base d'apprentissage. L'utilisation de ce vecteur (38 dimension) a engendré une amélioration non négligeable en temps de reconnaissance et une simplification pour la résolution du problème d'optimisation convexe (Equation 2). Il est à noter que l'erreur admissible dans l'équation 2 est maintenue à $\epsilon = 0.05$.

Afin de valider et comparer notre démarche, nous avons comparé les résultats obtenus avec le classifieur SVM avec un noyau polynomial en termes de taux de bonne classification en utilisant le descripteur proposé. En principe, les tailles des bases d'apprentissage et de test affecte significativement les résultats de classification. Pour illustrer cela, nous varions dans les simulations présentées par la figure 2 le rapport de sélection de la base d'apprentissage/test. Nous soulignons qu'à chaque portion, nous sélectionnons de manière aléatoire la base et nous réitérons ce processus 10 fois afin de présenter le taux moyen de bonne classification. À partir des résultats présentés, plusieurs conclusions peuvent être mentionnées. Premièrement, les deux méthodes de classification (SRC et SVM) sont sensibles au nombre d'images dans la base d'apprentissage. Par conséquent, quand le pourcentage de sélection de la base d'apprentissage augmente (respectivement, la base de test diminue), un gain en performance est observé. Par

exemple, si nous considérons 90% de la base de données pour l'apprentissage, la qualité de la classification atteint un taux de 99.28%. D'autre part, pour différentes tailles de la base d'apprentissage, la méthode de classification SRC fournit des résultats meilleurs que ceux obtenus par le classifieur SVM. Nous notons aussi que la méthode SRC ne nécessite pas un paramétrage de données contrairement à la méthode SVM. En utilisant une configuration de $65 \times 12 = 780$ images pour l'apprentissage et $1944 - 780 = 1164$ images pour le test, l'approche proposée atteint un taux de classification de 96.83%. Cette performance remarquable prouve la robustesse du descripteur proposé combiné avec la méthode SRC dans le contexte de la reconnaissance de cibles radar.




FIG. 2 – Comparaison entre SRC et SVM en termes de taux de reconnaissance en utilisant différentes tailles de la base d'apprentissage.

5 Conclusion

Dans le présent papier, nous avons proposé une approche de reconnaissance de cibles radar aériennes en utilisant la modélisation statistique et la représentation parcimonieuse. L'approche construit en premier lieu le vecteur descripteur composé des paramètres statistiques des coefficients DT-CWT et du descripteur SIFT. Ce vecteur descripteur est utilisé par le classifieur SRC. Les résultats obtenus nous confortent sur les performances et l'amélioration que peut apporter le vecteur de caractéristiques proposé et le classifieur SRC comparé à SVM. Comme perspectives, nous comptons étudier notre approche en bruitant les données et en la validant aussi sur d'autres types de base de données.

Références

Candes, E. et J. Romberg (2005). 11-magic : Recovery of sparse signals via convex programming. <http://statweb.stanford.edu/~candes/11magic/>.

- Jdey, I., A. Toumi, M. Dhibi, et A. Khenchaf (2012). The contribution of fusion techniques in the recognition systems of radar targets. In *IET International Conference on Radar Systems (Radar)*, pp. 1–5.
- Kim, K., D. Seo, et H. Kim (2005). Efficient classification of ISAR images. *IEEE Transactions on Antennas and Propagation* 53(5), 1611–1621.
- Kingsbury, N. G. (2001). Complex wavelets for shift invariant analysis and filtering of signals. *Applied and computational harmonic analysis* 10(3), 234–253.
- Kwitt, R. et A. Uhl (2010). Lightweight probabilistic texture retrieval. *IEEE Transactions on Image Processing* 19(1), 241–253.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vision* 60(2), 91–110.
- Saidi, M., A. Toumi, A. Khenchaf, D. Aboutajdine, et B. Hoeltzener (2009). Feature extraction and fusion for automatic target recognition based ISAR images. *INFOCOMP Journal of Computer Science* 8(4), 1–10.
- Toumi, A., B. Hoeltzener, et A. Khenchaf (2009). Hierarchical segmentation on ISAR image for target recongition. *International Journal of Computational research* 5, 63–71.
- Toumi, A. et A. Khenchaf (2010). Log-polar and polar image for recognition targets. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 1609–1612.
- Toumi, A., A. Khenchaf, et B. Hoeltzener (2012). A retrieval system from inverse synthetic aperture radar images : Application to radar target recognition. *Elsevier Information Sciences* 196, 73–96.
- Wang, F., W. Sheng, X. Ma, et H. Wang (2010). Target automatic recognition based on ISAR image with wavelet transform and MBLBP. In *International Symposium on Signals, Systems and Electronics*, Volume 2, pp. 1–4.
- Wright, J., A. Y. Yang, A. Ganesh, S. S. Sastry, et Y. Ma (2009). Robust face recognition via sparse representation. *IEEE transactions on pattern analysis and machine intelligence* 31(2), 210–227.

Summary

This paper presents a novel approach for automatic target recognition (ATR) using inverse synthetic aperture radar (ISAR). This proposed approach is mainly composed of two steps. In the first step, we adopt a statistical method to compute a novel target template from feature descriptors. The proposed template is achieved by combining the Gamma statistical parameters of the both dual-tree complex wavelet transform (DT-CWT) coefficients and the scale-invariant feature transform (SIFT) descriptor. In order to validate the proposed target template, we achieve in the second step the recognition task using a sparse representation-based classification (SRC) method. The performance of the proposed approach has been successfully verified using ISAR images reconstructed from anechoic chamber. The experimental results show that the proposed method can achieve a high average accuracy and is significantly superior to the well-known SVM classifier.