

Application de la méthode de Sammon pour la reconnaissance des cibles radar à partir de leur profils de distance

André QUINQUIS¹, Emanuel RADOI²

¹Département EIA, ENSIETA
2 rue François Verny, 29806 BREST Cédex 09, France

²Département Electronique et Informatique, Académie Technique Militaire
81-83 bd. George Cosbuc, Bucarest, Roumanie

quinquis@ensieta.fr, radoiem@mta.ro

Résumé – Un travail de recherche important est déployé depuis plusieurs années pour permettre aux radars de réaliser la reconnaissance des cibles à partir de leurs profils de distance. Le principal inconvénient lié à leur utilisation concerne leur dépendance par rapport à l'angle de visée, ce qui conduit à des bases de données de taille très importante. Nous proposons alors pour la sélection des caractéristiques d'associer la méthode de Sammon à un perceptron multicouches, initialisé par la solution de l'analyse en composantes principales. Nous obtenons ainsi une technique de projection fidèle, rapide et disposant d'une bonne capacité de généralisation.

Abstract – Many efforts have been devoted in the last years to the automatic recognition of the radar targets using their range profiles. The main problem related to the use of the range profiles is their variation with respect to the aspect angle, which results in a huge data base. A technique which combines the Sammon method and a multilayer perceptron, initialized with the principal component analysis solution, is then proposed for the feature selection phase. It is fast, reliable and has a good generalization capability.

1. Introduction

Les radars à haute résolution sont particulièrement adaptés pour la reconnaissance des cibles aériennes, car ils sont capables de mesurer leurs signatures électromagnétiques. Celles-ci sont liées à la caractéristique de réflectivité des cibles, qui à son tour est en relation directe avec leur géométrie. Le profil de distance, qui est une des signatures monodimensionnelles les plus utilisées, constitue la projection de la caractéristique de réflectivité de la cible sur la ligne de visée.

Les profils de distance sont utilisés généralement tels quels pour la classification des cibles radar. Une classe entière de profils de distance pour chaque cible doit être considérée pour l'entraînement du classifieur, en raison de leur dépendance par rapport à l'angle de visée. Le volume de la base de données augmente très rapidement avec le nombre de cibles et les calculs nécessaires pour réaliser leur traitement deviennent assez vite prohibitifs. C'est la raison pour laquelle dans les cas réels il faut absolument faire recours à une méthode de sélection de caractéristiques pour diminuer la taille des vecteurs et rendre ainsi efficace le processus d'apprentissage du classifieur.

L'approche utilisée dans ce but est de type compression et est réalisée par différentes méthodes : décomposition en ondelettes, quantification vectorielle, réseaux de neurones. Bien que la réduction du volume de la base de données soit significative, la taille des vecteurs reste importante, tandis que la mise en oeuvre des méthodes de compression citées ci-

dessus requiert parfois un effort de calcul qui ne peut pas être justifié par la réduction obtenue.

Notre idée a été alors de considérer non plus le profil de distance entier comme vecteur des paramètres, mais uniquement les distances entre les pics correspondant aux différents points brillants et le premier pic détecté. Ce choix présente trois avantages évidents :

- taux de compression très élevé, car le nombre des points brillants d'une cible radar est assez réduit ;
- efficacité, car l'information la plus pertinente et la moins affectée par le bruit, concernant le type de la cible, est représentée en effet par la localisation de ces pics ;
- grande simplicité, car la construction de nouveaux vecteurs exige uniquement le calcul de quelques distances ;

De plus, l'application en amont des méthodes à haute résolution pour le prétraitement des données, au lieu des techniques de type Fourier, conforte ce choix, car généralement ces méthodes, très performantes en matière de résolution et de débruitage, perdent l'information d'amplitude en dehors des positions où sont localisées les projections des points brillants sur la ligne de visée.

L'article est organisé de la manière suivante. Le § 2 énonce le problème de projection à travers un exemple simple. La technique de projection proposée est décrite au § 3. Les résultats expérimentaux obtenus sur quatre maquettes de cibles réelles sont présentés au § 4. Enfin, les conclusions de notre démarche font l'objet du § 5.

2. Formulation du problème

Le point faible de la méthode d'extraction de paramètres utilisés est représenté par la possibilité d'avoir des vecteurs extraits de dimensions différentes. Ce fait est illustré sur la figure 1, qui montre la variation des positions des pics du profil de distance pour une cible simple, constituée par quatre points brillants. Normalement, le vecteur de paramètres est de dimension 3, mais lorsque deux points brillants ont la même projection il devient de dimension 2. C'est précisément le cas des deux situations critiques décrites sur la figure 1.

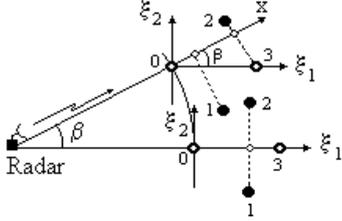


FIG. 1 : Illustration de la variation du vecteur de paramètres

Le fait est aussi mis en évidence par la figure 2, qui montre l'évolution des projections des points brillants 1 (PB1), 2 (PB2) et 3 (PB3) par rapport au point 0, considéré comme référence.

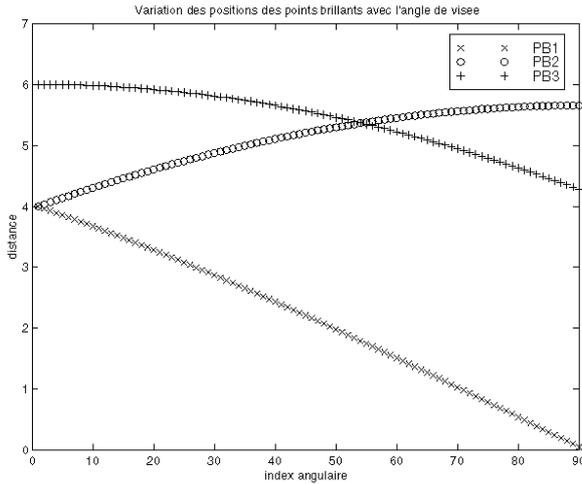


FIG. 2 : Migration des points brillants en fonction de l'angle de visée

Ces projections ont été calculées en utilisant la relation :

$$x_i = \xi_1^{(i)} \cos \beta + \xi_2^{(i)} \sin \beta \quad (1)$$

pour un domaine de variation de l'angle de visée compris entre 0° et 45° , avec un increment angulaire de 0.5° . Dès lors, on obtient la trajectoire du vecteur des paramètres, représentée sur la figure 3.

La solution que nous proposons consiste à projeter tous les vecteurs, quelle que soit leur dimension, dans un espace de dimension minimale au moyen d'une technique basée sur la méthode de Sammon. Cette dimension minimale est choisie égale à 2, lorsqu'on considère la détection d'au moins trois pics sur un profil de distance comme nécessaire pour la classification de la cible. Le schéma bloc du système serait alors celui indiqué sur la figure 4.

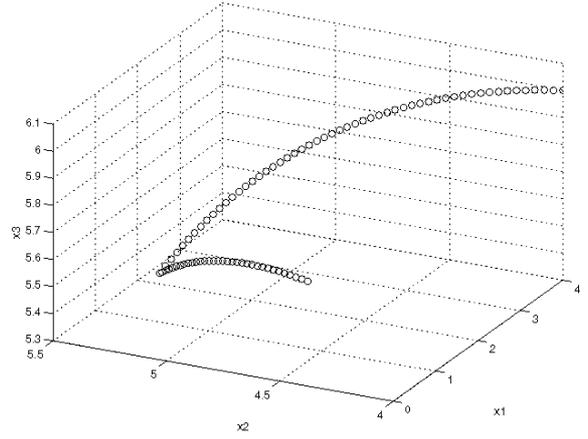


FIG. 3 : Trajectoire du vecteur des paramètres calculés

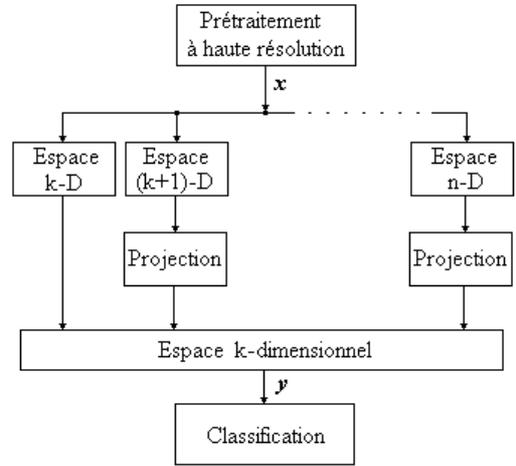


FIG. 4 : Schéma bloc du système de projection

3. Technique de projection

Nous avons comparé deux méthodes de projection : une transformation linéaire, à savoir *l'analyse en composantes principales* (ACP) [1], et une technique non-linéaire, représentée par la méthode de Sammon [2]. Cette dernière est particulièrement intéressante du fait qu'elle cherche à conserver au mieux les distances entre les vecteurs. Son utilisation est rendue difficile par le grand nombre de calculs exigés dans la phase opérationnelle, car le résultat est obtenu à la suite d'un processus d'optimisation.

La fonction à minimiser est l'erreur de Sammon, définie par la relation suivante :

$$E = \frac{1}{\sum_{i=1}^{N_v-1} \sum_{j=i+1}^{N_v} d^*(x_i, x_j)} \cdot \sum_{i=1}^{N_v-1} \sum_{j=i+1}^{N_v} \frac{[d^*(x_i, x_j) - d(y_i, y_j)]^2}{d^*(x_i, x_j)} \quad (2)$$

où N_v désigne le nombre de vecteurs, tandis que $d^*(x_i, x_j)$ et $d(y_i, y_j)$ représentent respectivement les distances entre deux vecteurs dans l'espace initial et dans l'espace transformé.

Différentes approches sont décrites dans la littérature pour la minimisation de la fonction E : la méthode du gradient stochastique, celle du recuit simulé, etc. L'approche la plus récente [3] utilise les réseaux de neurones en vertu de leur

capacité d'apprendre et d'opérer en temps réel. Ils sont ainsi capables d'éliminer le grand inconvénient des techniques non-linéaires, qui réside dans l'incapacité de celles-ci de généraliser le résultat du processus d'optimisation.

C'est la raison pour laquelle nous avons choisi l'utilisation de la méthode de Sammon en association avec un perceptron multicouches (PMC) qui peut lui fournir la capacité de généralisation et la rendre ainsi rapide, tout en conservant les performances de la méthode de Sammon en matière de projection.

La structure du réseau (figure 5) est celle d'un PMC classique :

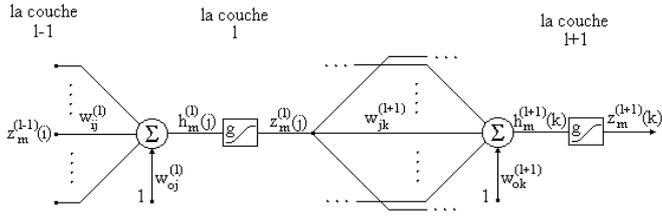


FIG. 5 : Structure détaillée du réseau pour deux neurones qui se trouvent sur deux couches consécutives

La règle d'apprentissage utilisée est donnée par la relation suivante :

$$\Delta w_{ij}^{(l)}(t) = -\eta \cdot \frac{\partial E}{\partial w_{ij}^{(l)}} + \beta \cdot \Delta w_{ij}^{(l)}(t-1) \quad (3)$$

où :

$$\frac{\partial E}{\partial w_{ij}^{(l)}} = \Delta_{1j}^{(l)} \cdot z_1^{(l-1)}(i) - \Delta_{2j}^{(l)} \cdot z_2^{(l-1)}(i)$$

et :

$$\delta_{mj}^{(l)} = \sum_{k=1}^{n_{l+1}} \Delta_{mk}^{(l+1)} \cdot w_{jk}^{(l+1)}, \quad m = \overline{1,2}$$

$$\Delta_{mj}^{(l)} = z_m^{(l)}(j) \cdot [1 - z_m^{(l)}(j)] \cdot \delta_{mj}^{(l)}, \quad m = \overline{1,2}$$

pour les couches cachées et :

$$\delta_k^{(N_C)} = -2\lambda \cdot \frac{d^*(\mathbf{x}_1, \mathbf{x}_2) - d(\mathbf{y}_1, \mathbf{y}_2)}{d^*(\mathbf{x}_1, \mathbf{x}_2) \cdot d(\mathbf{y}_1, \mathbf{y}_2)} \cdot [y_1(k) - y_2(k)]$$

$$\Delta_{mk}^{(N_C)} = \delta_k^{(N_C)} \cdot (1 - y_m(k)) \cdot y_m(k), \quad m = \overline{1,2}$$

pour la couche de sortie.

Le PMC lui confère ses avantages, mais lui fait également partager ses faiblesses. Il s'agit notamment du risque, non-négligeable, de considérer un minimum local de la surface d'erreur comme la vraie solution.

Bien que le PMC soit muni pendant son apprentissage d'un terme de moment, qui diminue beaucoup ce risque, une solution idéale semble être son initialisation astucieuse avec la solution fournie par l'ACP. Ce choix est justifié par le fait que la projection par l'ACP conduit à la meilleure approximation linéaire de la solution exacte, et par conséquent ne peut pas être loin du minimum global. La méthode de Sammon sera alors capable d'affiner cette solution grâce à son caractère non-linéaire.

L'algorithme pour la mise en œuvre de la méthode de projection de Sammon combinée à un réseau de neurones de type PMC est donné ci-dessous.

1. Normaliser les vecteurs de l'espace initial.
2. Projeter les vecteurs de l'espace initial au moyen d'une ACP.
3. Entraîner un PMC pour reproduire le résultat de projection linéaire. Les poids du réseau à la fin de l'apprentissage sont utilisés pour initialiser le PMC dans l'étape suivante.
3. Continuer l'entraînement du PMC en utilisant la règle d'apprentissage décrite ci-dessus pour minimiser l'erreur de Sammon.
4. Dénormliser les vecteurs projetés.

En utilisant cette idée nous avons réalisé la projection des vecteurs synthétiques obtenus au § 2. La variation de l'erreur de Sammon pendant le processus d'apprentissage est représentée sur la figure 6, tandis que la projection obtenue pour 10000 itérations est illustrée sur la figure 7.

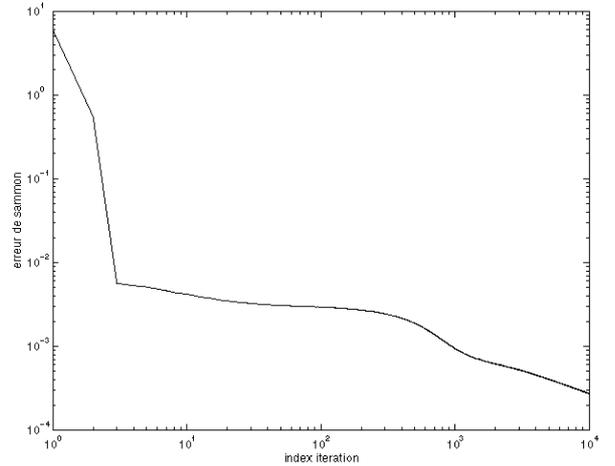


FIG. 6 : Variation de l'erreur de Sammon au cours de l'apprentissage

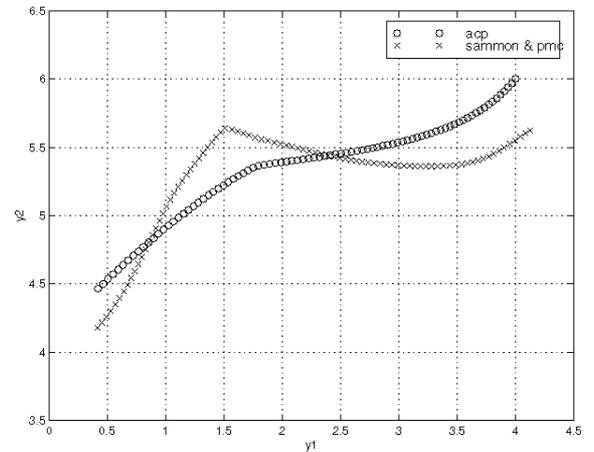


FIG. 7 : Résultat de la projection réalisée avec un PMC à deux couches cachées

La projection donnée par l'ACP est aussi représentée comme référence. Le PMC comprend deux couches cachées constituées respectivement de 5 et 3 neurones. La vitesse d'apprentissage utilisée a été choisie égale à 0.7 et le coefficient de moment égal à 0.3. L'erreur de Sammon à la fin de l'entraînement vaut 0.0003 et est bien plus faible que la valeur obtenue par l'ACP, 0.0067.

4. Résultats expérimentaux

La méthode a été également validée sur des données réelles obtenues dans la chambre anéchoïque de l'ENSIETA pour quatre maquettes d'avions à l'échelle 1/48 : Tornado, Mirage 2000, F 14 et Rafale [4]. Les projections 2D et 3D des vecteurs correspondant aux quatre classes sont représentées respectivement sur les figures 8 et 9.

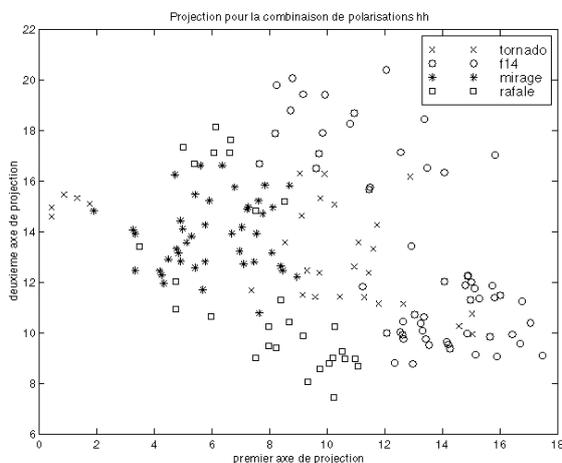


FIG. 8 : Projection 2D des données réelles

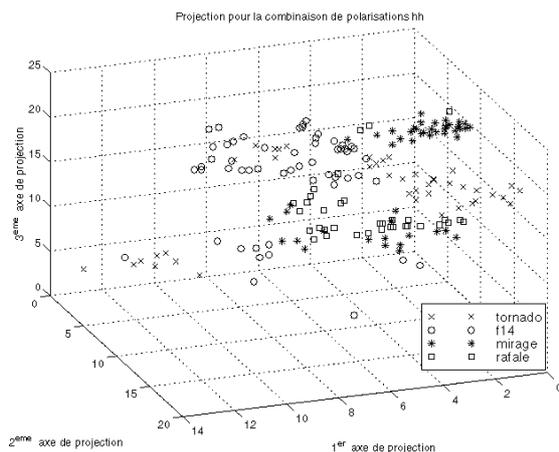


FIG. 9 : Projection 3D des données réelles

Les résultats de la classification et les valeurs de l'erreur de Sammon correspondantes sont indiquées dans la table 1. Plus la dimension de l'espace de projection est large, meilleurs sont les résultats de la classification. Le fait est illustré dans la table 1 pour une dimension de l'espace de projection égale à 3. La réduction de l'erreur de Sammon est moins spectaculaire dans ce cas, par rapport à l'exemple

simple, présenté peu avant. Par contre, le taux de bonne classification assuré par la méthode de Sammon est supérieur à celui obtenu par ACP dans les deux cas. Remarquons également que cette amélioration est d'autant plus importante que la dimension de l'espace de projection est faible.

TAB. 1 : Résultats des simulations sur les données réelles

Méthode de projection	Erreur de Sammon	Taux de bonne classification sur l'ensemble de test [%]				
		Tornado	Mirage	F 14	Rafale	Moyen
ACP 2D	0.53	96	83	80	91	87.5
Sammon 2D	0.16	91	91	90	93	91.25
ACP 3D	0.23	98	86	83	90	89.25
Sammon 3D	0.13	91	93	86	96	91.5

5. Conclusions

L'extraction du vecteur des paramètres par le calcul des distances entre les pics correspondants aux projections des points brillants sur la ligne de visée est simple et permet une compression très forte du volume de la base de données. Combinée avec les techniques de prétraitement de haute résolution, elle conduit, en plus, à l'extraction de l'information essentielle et lui confère une bonne robustesse au bruit.

La méthode de projection présentée permet de ramener tous les vecteurs de paramètres à la même dimension, tout en conservant, au mieux, (au sens de l'erreur de Sammon) les structures des espaces initiaux, à savoir les relations de voisinage entre les vecteurs de ces espaces.

Deux méthodes de projection, l'ACP et la méthode de Sammon, ont été utilisées afin d'accomplir cette tâche. Un réseau de neurones de type PMC a été entraîné pour réaliser la projection non-linéaire définie par la méthode de Sammon.

La méthode de Sammon permet l'amélioration des résultats de la classification. Son utilisation devient d'autant plus intéressante que la dimension de l'espace de projection est faible, car, par rapport à l'ACP elle conserve mieux la structure des espaces initiaux, grâce à son caractère non-linéaire.

Références

- [1] G. Saporta. *Probabilités, Analyse des Données et Statistique*. Technip, Paris, 1990.
- [2] E. Backer. *Computer Assisted Reasoning in Cluster Analysis*. Prentice Hall, New York, 1995.
- [3] J. Mao, A.K. Jain. *Artificial Neural Networks for Feature Extraction and Multivariate Data Projection*. In : IEEE Trans. on NN, Vol. 6, No. 2, 1995, p. 296-316, New York.
- [4] E. Radoi. *Contribution à la reconnaissance automatique des objets 3D à partir de leur signature électromagnétique*. Thèse de doctorat, Université de Bretagne Occidentale, Brest, 1999.