

Technique neuronale pour la détection CFAR optimale dans du fouillis de mer non-Gaussien

E. RADOI¹, A. QUINQUIS¹, P. SAULAIS²

¹ENSIETA, Laboratoire E3I2, 2 rue François Verny, 29806 Brest, France,

radoiem@ensieta.fr, quinquis@ensieta.fr

²THALES NAVAL France, 7/9 rue des Mathurins, 92221 Bagneux, France,

pierre.saulais@fr.thalesgroup.com

Résumé – Un nouveau processeur radar CFAR (Constant False Alarm Rate) pour la détection optimale des cibles navales est proposé dans l'article. Il est basé sur l'utilisation d'un réseau de neurones pour approximer de façon implicite, par apprentissage, les densités de probabilité multidimensionnelles correspondant au fouillis et au signal écho utile. La règle de décision utilisée est équivalente au test du maximum du rapport de vraisemblance généralisé. Des méthodes pour le calcul du seuil de détection et pour assurer son invariance par rapport au rapport S/B et aux paramètres du fouillis sont également présentées.

Abstract – A new CFAR (Constant False Alarm Rate) radar processor for the optimal detection of the naval targets is proposed in the paper. It is based on the use of a neural network that is trained to approximate implicitly the multidimensional probability density functions corresponding to the clutter and to the useful echo signal. The decision rule is equivalent to the generalized maximum likelihood ratio test. Methods for calculating the detection threshold and for insuring its invariance to the S/N ratio and to the clutter parameters are also presented.

1. Introduction

Un travail de recherche important est mené depuis plusieurs années pour développer des techniques adaptées à la détection des cibles navales par un radar à haute résolution, à faible angle rasant. Les caractéristiques du fouillis évoluent de manière significative, les données enregistrées ayant un aspect piqué d'autant plus accentué que l'angle rasant est faible et la résolution en distance est fine. L'utilisation des techniques de détection classiques dans ce contexte a comme effet le blocage du processeur de traitement à cause du nombre trop important de fausses cibles détectées [1,2].

La difficulté fondamentale pour la mise au point d'un détecteur adapté vient du fait que malgré les travaux de recherche dans le domaine, un modèle statistique du fouillis qui soit généralement accepté n'existe pas [3]. L'approche standard pour la densité de probabilité (ddp) au premier ordre, à savoir la ddp de l'amplitude du fouillis, est de l'approximer par des lois connues de probabilité, telles que K, Weibull, log-normale etc. Le problème est que suivant les conditions de mesure et le scénario, la distribution la mieux adaptée peut varier d'un cas à l'autre, ce qui n'est pas tout à fait étonnant vu que pour certains jeux de paramètres ces distributions ont des valeurs très similaires. Le problème est donc mal posé, car il y a une infinité de solutions.

Cette ambiguïté rajoutée au fait qu'une détection efficace doit aussi prendre en compte les propriétés de corrélation du fouillis conduit à une description multidimensionnelle très générale de celui-ci, sous la forme des processus aléatoires à invariance sphérique [4].

Leurs deux inconvénients majeurs sont liés tout d'abord au fait qu'il est bien plus difficile d'adapter une ddp

multidimensionnelle à un ensemble de données mesurées et deuxièmement à la difficulté du passage de l'expression du rapport de vraisemblance généralisé vers la structure concrète du détecteur CFAR optimal.

L'approche que nous présentons dans cet article conserve l'idée de la description multidimensionnelle du fouillis et s'appuie sur deux idées fondamentales :

- tout problème de détection est un problème de classification à deux classes et par conséquent tous les résultats de la théorie de la classification y sont applicables ;
- un réseau de neurones entraîné pour résoudre un problème de classification permet de mettre à jour une configuration fortement adaptée à la structure de l'espace des vecteurs d'entrée et finit par approximer les ddp associées aux classes.

Le résultat a été une structure à base d'apprentissage, que nous avons appelé le détecteur CFAR neuronal.

2. Détection CFAR optimale dans le cas multidimensionnel

Le signal réfléchi par la cible est considéré entaché par du fouillis de mer additif, caractérisé par sa densité de probabilité multidimensionnelle issue du modèle des processus aléatoires à invariance sphérique. Le problème de détection se présente dans ce cas sous la forme du test des hypothèses statistiques suivantes :

$$\begin{aligned} H_0 &: \mathbf{y} = \mathbf{x} \\ H_1 &: \mathbf{y} = \mathbf{x} + \mathbf{s} \end{aligned} \quad (1)$$

où $\mathbf{x}, \mathbf{s}, \mathbf{y}$ sont les vecteurs de dimension m formés à partir des échantillons du fouillis, du signal réfléchi par la cible et du signal mesuré.

Le rapport de vraisemblance peut être alors défini sous la forme suivante [3] :

$$\Lambda(\mathbf{y}) = \frac{f_1(\mathbf{y})}{f_0(\mathbf{y})} = \frac{F_m((\mathbf{y}-\mathbf{s})^H \Phi^{-1}(\mathbf{y}-\mathbf{s}))}{F_m(\mathbf{y}^H \Phi^{-1} \mathbf{y})} \quad (2)$$

où :

$$F_m(u) = \int_0^\infty \frac{1}{\tau^m} \exp\left(-\frac{u}{\tau}\right) dF_\tau(\tau) \quad (3)$$

et τ est le paramètre qui décrit la variation aléatoire locale de la puissance du fouillis et $F_\tau(\tau)$ sa fonction de répartition.

Le détecteur CFAR optimal au sens du rapport de vraisemblance prend la décision selon la règle :

$$\Lambda(\mathbf{y}) \underset{>}{<} T \Rightarrow \begin{cases} H_0 \\ H_1 \end{cases} \quad (4)$$

où T représente le seuil de détection, déterminé de façon à assurer une certaine valeur de la probabilité de fausse alarme.

Cette expression du rapport de vraisemblance ne peut pas être utilisée pour les schémas pratiques de détection, car le calcul analytique de la probabilité de fausse alarme et par conséquent du seuil de détection n'est pas possible.

Le détecteur que nous proposons est basé sur l'utilisation des réseaux de neurones de type perceptron multicouches (PMC), qui sont capables d'arriver par apprentissage à une représentation interne précise de densités de probabilité multidimensionnelles arbitrairement compliquées [5]. L'idée est donc d'entraîner un PMC afin qu'il puisse distinguer les signaux écho utiles du fouillis généré par la surface de la mer.

3. Structure du détecteur neuronal

Dans le cas considéré, le PMC doit séparer deux classes : la classe « signal » comprenant les échos de la cible entachés de fouillis, et la classe « fouillis » comprenant les échos du fouillis seul. La dimension des vecteurs d'entrée est fixée par la fenêtre de traitement, qui est à son tour liée à la largeur du faisceau de l'antenne et à la vitesse de rotation de celle-ci. La matrice de confusion fait apparaître les deux éléments fondamentaux pour un problème de détection : la probabilité de fausse alarme et la probabilité de détection (fig. 1).

	\mathbf{s}	\mathbf{x}
\mathbf{s}	P_D	$1-P_D$
\mathbf{x}	P_{FA}	$1-P_{FA}$

FIG. 1 : Matrice de confusion pour le PMC utilisé en tant que détecteur

L'apprentissage du détecteur est réalisé en deux étapes. La première (fig. 2) concerne l'entraînement du PMC qui, par rapport à l'algorithme de retropropagation classique introduit

une contrainte sur le taux de fausse alarme. Ainsi, celui-ci est évalué sur l'ensemble de test après chaque étape d'entraînement et le processus continue jusqu'au moment où il atteint la valeur de la probabilité de fausse alarme exigée.




FIG. 2 : Schéma de la première étape d'entraînement du détecteur CFAR neuronal

Les données utilisées dans cette étape de l'entraînement correspondent à un certain rapport S/B de référence rsb_0 . Pour que le fonctionnement du détecteur obtenu ne dépende pas des paramètres du fouillis, nous avons tout d'abord normalisé les vecteurs d'entrée de telle façon qu'ils soient tous d'énergie unitaire. Cette première opération rend la structure obtenue invariante par rapport au paramètre d'échelle. Pour qu'elle soit aussi invariante par rapport au paramètre de forme du fouillis les vecteurs qui constituent les ensembles d'apprentissage et de test ont été générés pour différentes valeurs de ce paramètre.

La structure obtenue n'est un détecteur CFAR que pour le rapport S/B rsb_0 utilisé pendant la première étape d'entraînement, car pour des rapports S/B plus faibles le taux de fausse alarme augmente. Afin de contrôler sa valeur nous proposons la modification de la règle de décision dans le cas de l'hypothèse H_1 . L'idée est de valider la détection uniquement si le coefficient de confiance calculé sous la forme :

$$\text{coeff_conf} = \frac{o_s - o_x}{o_s} \quad (5)$$

dépasse un certain seuil, déterminé de façon à assurer le taux de fausse alarme voulu. L'estimation par apprentissage de ce seuil pour chaque rapport S/B constitue l'objectif de la deuxième étape d'entraînement du détecteur neuronal (fig. 3).




FIG. 3 : Schéma de la deuxième étape d'entraînement du détecteur CFAR neuronal

Les seuils de confiance déterminés de la manière présentée ci-dessus assurent un taux de fausse alarme constant pour chaque rapport S/B. Bien évidemment, pour que la technique soit opérationnelle il faut pouvoir estimer ce rapport. Nous avons alors utilisé la moyenne des vecteurs d'entrée qui est

directement liée au rapport S/B, du fait qu'ils ont subi la normalisation énergétique. Une approximation polynomiale est alors suffisante pour estimer la variation du seuil de confiance en fonction du rapport S/B à partir de la moyenne des vecteurs d'entrée.

Le seuil de détection caractéristique aux détecteurs classiques est donc remplacé par un seuil de confiance. Tout comme le seuil de détection il est obtenu à partir de la moyenne des vecteurs d'entrée, à la différence près que ceux-ci sont normalisés du point de vue énergétique, et que cette moyenne est utilisée comme argument d'un polynôme, dont les coefficients sont déterminés toujours par apprentissage. L'autre différence importante est que dans le cas d'un détecteur classique le seuil est comparé directement à l'amplitude de l'échantillon de la cellule de test, alors que pour le nouveau détecteur ce seuil est comparé au coefficient de confiance en sortie du réseau de neurones. Les deux ont cependant le même effet, c'est-à-dire, la réduction à la fois du taux de fausse alarme et du taux de détection.

Par conséquent, les résultats du processus d'apprentissage du détecteur CFAR neuronal sont les poids du PMC et les coefficients du polynôme qui nous permettent de calculer le seuil de confiance pour un vecteur d'entrée donné. Avec ces éléments, le détecteur est opérationnel et peut être utilisé dans la phase de test (fig. 4).

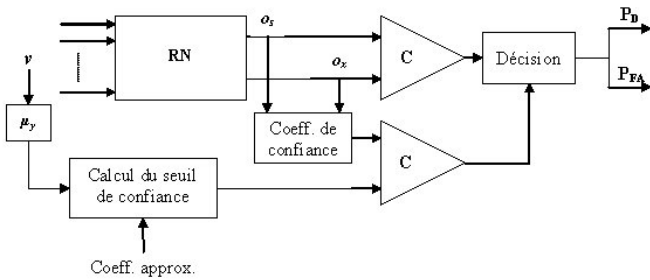


FIG. 4 : Schéma de test du détecteur CFAR neuronal

Contrairement à l'étape d'apprentissage, où les vecteurs d'un ensemble de test étaient générés pour différentes valeurs du paramètre de forme, dans la phase de test ils sont tous caractérisés par le même paramètre. Ceci nous permet d'évaluer les performances du détecteur pour chaque valeur de ce paramètre.

Afin d'évaluer le comportement du détecteur dans le cas où le fouillis est corrélé nous avons utilisé le schéma représenté sur la figure 5 pour générer des vecteurs ayant une matrice d'autocorrélation Σ donnée.




FIG. 5 : Génération du fouillis corrélé ayant une matrice d'autocorrélation donnée

Cette méthode est basée sur le fait que la matrice d'autocorrélation des vecteurs $z = K \cdot y$ obtenus par une transformation linéaire K des vecteurs y a l'expression :

$$\Sigma = K \Sigma_0 K^H \quad (6)$$

où Σ_0 représente la matrice d'autocorrélation des vecteurs y . Il est facile de remarquer que la matrice de la transformation doit s'exprimer dans ce cas par :

$$K = \Sigma^{1/2} \Sigma_0^{-1/2} \quad (7)$$

4. Résultats des simulations

Afin de tester le nouveau concept proposé nous avons généré du fouillis corrélé, distribué selon la loi K. Cette densité de probabilité a été choisie en raison du fait qu'elle permet d'identifier une relation directe avec le mécanisme du phénomène physique vu comme une superposition de vagues de gravité et de vagues de capillarité. Le signal écho est alors obtenu par le produit entre un processus Gaussien complexe à variation rapide et un processus modulant indépendant à variation lente [2]. Elle remplit également toutes les conditions d'admissibilité en tant que ddp au premier ordre correspondant à un processus SIRP [4].

Le nombre d'échantillons dans la fenêtre de traitement est égal à 8. Le PMC utilisé compte deux couches cachées, où le nombre de neurones a été choisi suivant des règles empiriques (12 et 6 neurones). Les ensembles d'apprentissage et de test sont constitués par 10000 vecteurs. La probabilité de fausse alarme est fixée à 10^{-2} . Le taux d'apprentissage a été choisi à 0,01 et la constante de moment fixée à 0,9. Afin d'assurer la capacité de généralisation maximale du réseau, ses performances sont testées après chaque itération sur un ensemble de test. Si au bout de 5 itérations successives les performances sur l'ensemble de test ne s'améliorent pas le processus d'apprentissage s'arrête.

Les variations du taux de fausse alarme et du taux de détection pendant le processus d'apprentissage sont représentées sur la figure 6. Le signal écho réfléchi par la cible est simulé selon le modèle Swerling 0. Le rapport S/B utilisé pendant l'entraînement vaut 15 dB. Les résultats obtenus pendant l'étape de test sont donnés sur la figure 7. Il est à noter que les valeurs du taux de fausse alarme sont très proches de la valeur fixée initialement.

5. Conclusions

Le résultat essentiel du travail de recherche présenté dans cet article est constitué par le développement d'un nouveau processeur radar CFAR à base d'apprentissage utilisant un perceptron multicouches. Son idée de base est de considérer les échantillons de la fenêtre de traitement comme les composantes des vecteurs appartenant à une des deux classes : la classe signal ou la classe fouillis, en fonction de la provenance du signal écho. Les densités de probabilité des deux classes, qui interviennent dans l'expression du rapport de vraisemblance généralisé seront approximées d'une manière implicite par le perceptron multicouches à la suite du


processus d'apprentissage. Un deuxième test sur le coefficient de confiance en sortie du réseau de neurones est réalisé avant de prendre la décision afin de pouvoir contrôler le taux de fausse alarme indépendamment du rapport S/B.

Le processeur radar proposé a montré des performances supérieures par rapport aux techniques classiques. De plus, si le radar doit changer d'environnement, entraînant la modification de la statistique multidimensionnelle du fouillis, il suffit de reprendre le processus d'apprentissage ou de remplacer les poids du réseau par d'autres poids prédéterminés, ce qui confère au système une grande flexibilité.


Les limites du nouveau détecteur sont inhérentes à tout réseau de neurones. Il s'agit tout d'abord du choix de sa structure (nombre de neurones sur chaque couche cachée) qui reste empirique, en dépit d'un certain nombre de règles qui peuvent orienter plus ou moins l'utilisateur. Il s'agit également du fait qu'il faut disposer d'une base de données d'apprentissage statistiquement représentative pour les distributions du fouillis seul et du signal utile entaché de fouillis et que parfois il faut reprendre plusieurs fois l'entraînement avant d'arriver à une solution satisfaisante.

Références

- [1] N.B. Pulsone et R.S. Raghavan, *Analysis of an adaptive CFAR detector in non-gaussian interference*, IEEE Trans. on AES, Vol. 35, pp 903-916. 1999.
- [2] Watts S., *Radar detection prediction in sea clutter using the compound K-distributed model*, IEE Proc., No. 7, pp 613-620, 1985.
- [3] Sangston K.J., Gerlach K.R., *Coherent detection of radar targets in a non-gaussian background*, IEEE Trans. on AES, Vol. 30, No. 2, pp 330-340, 1994.
- [4] Conte E., Longo M., *Characterisation of radar clutter as a spherically invariant random process*, IEE Proc., vol.134, part F, No. 2, 1987, pp. 191-197.
- [5] M.D. Richard, R.P. Lippmann, *Neural Network Classifiers Estimate Bayesian a posteriori Probabilities*, Neural Computation, 3/1991, pp. 461-483.




a)




b)

FIG. 6 : Le processus d'apprentissage du PMC : a) variation du taux de fausse alarme, b) variation du taux de détection



a)



b)

FIG. 7 : Performances en détection : a) variation du taux de fausse alarme, b) variation du taux de détection