

Étude Comparative d'un Détecteur CFAR Neuronal de Plusieurs Cibles Radar dans un Fouillis de type K-Distribution

Karim Mezzoug¹ - Bachir Djebbar²

¹ Lab. SIMPA, Dép. Informatique, Fac. Sciences, USTMB-Oran, Algérie

² Dép. Informatique, Fac. Sciences, USTMB-Oran, Algérie

¹ mezzougk@hotmail.fr ² badj2001@yahoo.fr

Abstract. This paper presents the development and performance evaluation of a particular Multi-Layer Perceptron neural network (MLP) classifier for radar target detection in a noisy, non-Gaussian environment using CFAR (Constant False Alarm Rate). The Technique, architecture details and principle of working of the MLP-CFAR detector training algorithm are presented. A comparison of the MLP-CFAR performances is also described according to different target scenarios. The principles results show that the detector performances are deteriorating by increasing the number of targets considered.

Résumé. Ce présent travail, s'intéresse au développement et l'analyse de performances d'un détecteur classifieur particulier, sous forme d'un Perceptron Multi-Couches (PMC), de cibles radar dans un environnement (Fouillis) non-gaussien, en utilisant le modèle CFAR. La technique, le détail de l'architecture et le principe de fonctionnement de l'algorithme d'apprentissage du détecteur MLP-CFAR, sont présentés. Une comparaison de performances du MLP-CFAR selon plusieurs scénarios de nombre de cibles considérées est aussi présentée. Les principaux résultats montrent que les performances du détecteur se dégradent en augmentant le nombre de cibles considérés.

Mots-clefs: CFAR, MLP, K-Distribution, Swerling.

1 Introduction

Le filtrage du signal électronique est une tâche très complexe, qui demande beaucoup de calculs et d'équipements spécialisés relativement coûteux dans le domaine de traitement de signal. Dans les systèmes radar, la cible doit être séparée du fouillis et cela en présence du bruit thermique dans la majorité de cas. Ce genre de filtrage peut être considéré comme étant un problème de classification, d'où les réseaux de neurones artificiels (ANN : Artificial Neural Networks) sont bien adaptés à ce genre de tâches. Beaucoup de modèles CFAR classiques ont été proposés dans un premier temps pour séparer le signal utile du fouillis de nature homogène, affecté par un bruit gaussien [1][2]. D'autres travaux se sont intéressés à étudier l'effet de l'existence de plusieurs cibles (une attaque aérienne brusque). En 1986, *Al-Hussaini* et *Ibrahim* ont

mené une étude comparative du CA-CFAR (Cell Averaging CFAR) en présence de plusieurs cibles [1], deux ans plus tard les même chercheurs ont prouvé l'effet du nombre de cibles, mais cette fois-ci pour un autre modèle qui est le GO-CFAR (Greatest Of Selection CFAR) et le OS-CFAR (Smalest Of Selection CFAR) [2][3]. En 1989, *Barkat, Himonas et Varshney* étudiaient le modèle CFAR de base en présence d'interférences de cibles [4], et dans le même axe on trouve *Barbooy, Lome et Perkalski* [5]. Au début des années 90s, des modèles CFAR neuronaux ont été déjà proposé, puisque l'utilisation des réseaux de neurones a montrée depuis longtemps leur capacité de généralisation et de classification pour des problèmes de forte variation et en particulier du non déterminisme du signal radar. En 1993, *Ramamurti, Rao et Gandhi* proposaient un modèle neuronal pour la détection des signaux radar noyés dans un bruit non-Gaussien [6], les travaux de *Buciarili, Amoozegar et Sundareshan* ont pris le même chemin [7][8]. En 1996 *Mirko Kück* de l'université Skövede au suède, propose un nouveau modèle neuronal tout en respectant l'architecture CFAR en considérant l'existence d'une seule cible [9]. Toujours dans le domaine neuronal, des travaux basés sur les modèles PNN (Probabilistic Neural Nets) GPNN (Generalized PNN) et GCNN (Gram Charlier Neural Nets), ont montré la capacité des modèles neuronaux. [10][11].

La suite de cet article sera consacré à l'étude des performances d'un détecteur CFAR neuronal (appelé : MLP-CFAR) en respectant l'architecture d'un Perceptron Multi-couches (MLP : Multi layer Perceptrons), suivant l'algorithme de la descente du gradient par rétro-propagation (BP : Back Propagation) suivant le nombre de cibles radar considérées. Le type de fouillis utilisé lors de l'étape des expériences est défini par la fonction ou le modèle de K-Distribution non-homogène, qui représente un bruit non-Gaussien. Enfin tous les résultats sont récapitulés dans une table de performances pour pouvoir comparer différents cas traités.

2 Le Fonction de Densité de K-Distribution

Cette fonction a été proposée dans le domaine du signal pour modéliser un fouillis de formes assez complexe et d'un environnement non-homogène (endroit maritime), tout en considérant l'effet des corrélations spatiales et temporelles surgissant sur le signal [20]. La fonction K-distribution est une densité composée, définit par :

$$\begin{aligned}
 f(x) &= \int_0^{\infty} f(x/y) f(y) dy & (1) \\
 &= \frac{2c^{\nu+1}}{\Gamma(\nu)} x^{\frac{\nu-1}{2}} K_{\nu-1}(2c\sqrt{x}) \\
 f(x/y) &= \frac{\pi}{4y^2} \exp\left(-\frac{\pi x}{4y^2}\right) \quad ; \quad 0 \leq x \leq \infty \\
 f(y) &= \frac{2b^{\nu}}{\Gamma(\nu)} y^{2\nu-1} \exp(-b^2 y^2) \quad ; \quad 0 \leq y \leq \infty
 \end{aligned}$$

Remarque 1, « $K_\nu(x)$ » est la fonction de Bessel modifiée de l'ordre de ν du 2ième type ; $c = \frac{\sqrt{\pi b}}{2}$ et on suppose qu'il n'existe pas de bruit thermique.

« $\Gamma(\cdot)$ » est la fonction gamma, « ν » et « b » représentent la forme et le niveau du signal. « $K_\nu(\cdot)$ » est la fonction de Bessel modifiée de l'ordre de ν du 2ième type. Dans notre cas nous nous intéressons aux séquences non-Corrélées.

3 Le Modèle CFAR Neuronal

Depuis les premières apparitions des modèles CFAR Neuronales, plusieurs architectures ont été proposé en se basant sur des travaux récentes menés par Ziemki, Mirko et Bucciarili [13][9][7]. Bien que dans notre cas nous allons adopter le modèle CFAR à base de MLP amélioré par Mezzoug et Benyettou [14][15]. Donc, notre détecteur MLP-CFAR comme le montre la Fig. 1, n'est autre qu'un MLP à une seule couche cachée contenant 11 neurones cachés [15]. D'un coté, l'entrée du détecteur est constituée de 31 neurones, $N=31$ (fenêtre de référence idéal dans le cas classique et neuronal), de l'autre coté la sortie est représentée par un seul neurone déterminant la présence ou l'absence de la cible.

Dans la détection CFAR classique, on utilise des formules probabilistes analytiques pour estimer les deux fameux paramètres de performances qui sont la probabilité de fausse alarme et la probabilité de détection, d'où leurs formules se présentent sous la forme analytique générale suivante :

$$P_D = P(y \geq T) = \int_T^{\infty} f_{cut}(y) dy \quad (2)$$

$$P_{FA} = p(x \geq T) = \int_T^{\infty} f_{clut}(x) dx \quad (3)$$

Remarque 2, f_{cut} est la distribution du signal + bruit (Cell Under Test) ; f_{clut} est la distribution du bruit et T est un seuil de décision fixe.

Par contre dan le domaine neuronal ces formules ne sont désormais plus valables pour mesurer les performances du MLP-CFAR. De ce fait, les deux paramètres sont estimés en utilisant des formules analytiques calculées d'une manière expérimentale définie comme suit [9] :

$$P_{FA} = \frac{\text{Nombre de Fausses Détections}}{\text{Nombre de Cellules Testées}} \quad (4)$$

$$P_D = \frac{\text{Nombre de Détections}}{\text{Nombre de Cibles}} \quad (5)$$

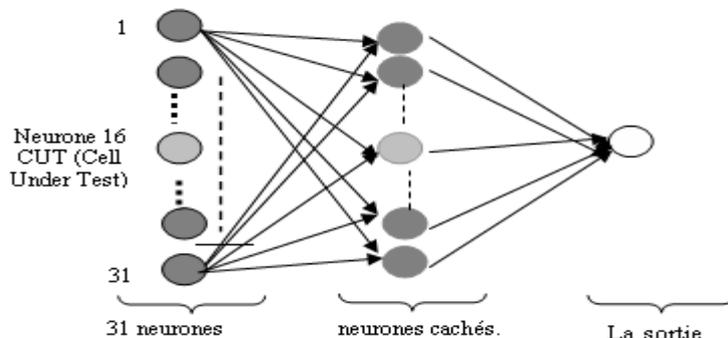


Fig. 1. Architecture d'un détecteur MLP-CFAR. (31/11/1).

4 La Modélisation du Signal K-Distribution

Pour simuler le signal radar (Clutter) nous sommes menés à le modéliser par la fonction de densité de probabilité de K-Distribution (expliquée précédemment) d'où la base de données utilisée, est subdivisée en deux parties, d'où la première représente l'ensemble d'apprentissage, et la deuxième partie construit l'ensemble des vecteurs de test. Chaque partie ou ensemble est constituée de séquences de signal de longueur 10^6 cellules (ce qui correspond à une $P_{FA} = 10^{-6}$). Chaque séquence contient au moins une cible simulée expérimentalement par la fonction de densité de Rayleigh en suivant le modèle de fluctuation de cible de Swerling I, et au maximum quatre cibles se trouvant à des emplacements cellules allant de 1 à 10^6 , d'une façon aléatoire. En faite, voici quelques statistiques sur l'ensemble de la base de données utilisée, illustrée sur la Table. 1 :

Table 1. Statistiques sur la base de données utilisée.

Nombre de cibles	Fouillis de K-Distribution (Séquence)
1 cible	10^3
2 cibles	10^3
3 cibles	10^3
4 cibles	10^3

Le choix réalisé sur les paramètres de forme (ν), est basé essentiellement sur des remarques tirées des travaux précédents [14][15].

5 Simulation & Discussion

Dans cette partie nous étudions le degré de tolérance du MLP-CFAR face à ce genre de problème d'interférences de cibles [2][3]. Donc notre étude ne se base

quantitativement pas sur la distance mais d'une façon globale sur la présence de plusieurs cibles sur la même séquence.

Le modèle MLP-CFAR utilisé contenant 31 neurones en entrée ($N=31$), est celui expliqué déjà précédemment (voir Fig. 1).

Les simulations sont réalisées par étape, c'est à dire en fonction de nombre de cibles considérées.

Les résultats sont présentés sous forme de graphes, en utilisant des taux SCR (Signal Clutter Ratio) bien précises, c'est à dire que pour chaque séquence on aura un taux SCR qui lui correspond et une P_D et P_{FA} estimées. Ce fameux taux SCR est défini de la manière suivante :

$$SCR = \frac{\text{Energie Moyenne du Signal Utile}}{\text{Energie Moyenne du Clutter}} = \frac{E[s^2]}{E[br^2]} \quad (6)$$

Remarque 3, s : le signal utile et br : le bruit.

En examinant la Fig. 2, nous pouvons dire que le détecteur MLP-CFAR a bien gardé un degré de tolérance face aux interférences cibles et ceci pour le cas de 1, 2 et 3 cibles, pour un taux SCR allant de -10dB jusqu'à 17dB, bien qu'il existe une légère différence entre les trois cas (1, 2 et 3 cibles) de telle façon que le MLP-CFAR donne de meilleurs résultats pour les deux premier cas (1 et 2 cibles), et ceci essentiellement à partir de 17dB par rapport au troisième cas (3 cibles), qui rafraîchisse une probabilité presque maximale de 0,68 au point 32 dB.

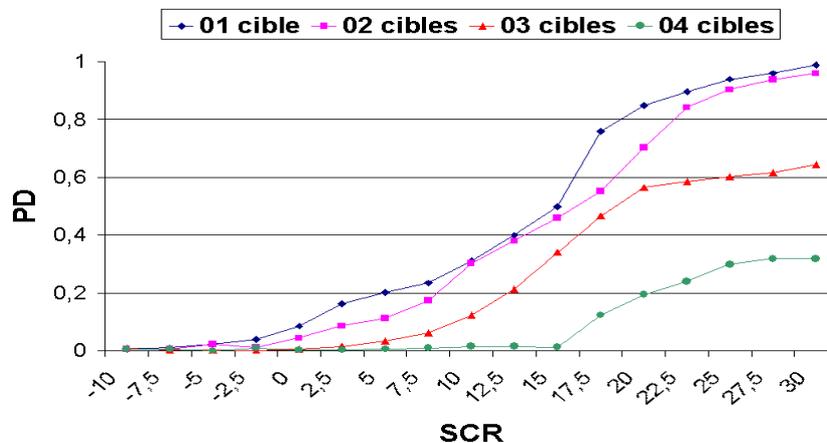


Fig. 2. Probabilité de détection pour $\nu=2.6$ et $N=31$. (MLP-CFAR)

On remarque aussi une forte dégradation pour le quatrième cas (4 cibles), d'où on marque une monotonie presque constante jusqu'à un taux SCR de 18dB, et une forte augmentation au delà de cette valeur, mais une probabilité de détection maximale de

0,4 . On peut encore noter que dans l'intervalle de 10dB jusqu'à 16dB, le MLP-CFAR donne des résultats presque identiques pour les deux premiers cas (1 et 2 cibles). On peut tirer comme importante remarque à partir de la table. 2, qu'il existe une faible variation dans les probabilités de fausses alarmes pour les trois premiers cas (1, 2 et 3 cibles), alors que cette valeur est bien supérieur dans le cas de 4 cibles ($P_{FA} = 0,00374$). Ces probabilités reflètent bien les résultats obtenus dans la Fig. 2, déjà discutés.

Table 2. Probabilité de fausse alarme (P_{FA}) en fonction de nombre de cibles du MLP-CFAR.

Nombre de cibles	P_{FA}
1 cible	0,00193
2 cibles	0,00196
3 cibles	0,00216
4 cibles	0,00374

Remarque 4, La durée d'apprentissage est estimée à 6440 époques.

6 Conclusion

À travers cet étude de performances, nous avons présenté une analyse détaillée sur le détecteur MLP-CFAR, en évoquant le problème des interférences cibles (en fonction de nombre de cibles). Tous les expériences ont été réalisées sur une base de données que nous considérons assez riche du point de vu quantitatif et qualitatif (d'une façon relative). Les résultats ont montrées que le MLP-CFAR est fortement influencé par le nombre de cibles considérées (la cadence de cibles). Nos résultats restent à validés par d'autres expériences et futur travaux et ceci en considérant par exemple le problème de fouillis de bords et les rapprochements subissant entre cibles [2][3].

L'amélioration du MLP-CFAR peut se faire d'un coté, en considérant d'autres architectures neuronales, comme les réseaux de neurones probabilistes [10][11][14], ou bien en introduisant d'autres algorithmes d'apprentissage d'où les AGs (Algorithmes Génétiques) qui sont des processus stochastiques d'optimisation globale [14][16][17][18], d'où ils représentent un outil performant qui peut remplacer les algorithmes d'apprentissage classiques qui souffrent du problème de la localité de la solution. De l'autre coté, nous pensons aux modèles neuronaux temporels (par exemple le TDNN : Time Delay Neural Network) pour soulever le problème de la forte variation du signal [19], ou plus efficacement par les ATDNNs (Adaptive TDNN) d'où une classification CFAR est effectuée tout en respectant le contexte temporel, qui est présent sous forme des corrélations spatio-temporelles agissantes sur le signal radar (généralement le fouillis).

Références

1. Al-Hussaini E. K, Ibrahim B.M. Comparison of adaptive cell-averaging detectors for multiple-target situations. IEE Proceedings. Juin 1986.
2. Al-Hussaini E. K. Performance of the greater-of and censored greater-of detectors in multiple target environments. IEE Proceedings. 1988.
3. Al-Hussaini E. K, El-Mashade M. B. Performance of cell-averaging and order-statistic CFAR detectors processing correlated sweeps for multiple interfering targets. Signal Processing. Mars 1996.
4. Barkat M, Pramod K, Varshney P.K. Decentralized CFAR Signal Detection. IEEE Transactions on Aerospace and Electronic Systems. Mars 1989.
5. Barboy B, Lomes A, Perkalski E. Cell-averaging CFAR for multiple-target situations. IEE Proceedings. Avril 1992.
6. Ramamurti V, Rao S.S, Gandhi P.P. Neural Network for Signal Detection in non-Gaussian Noise. ICASSP'93. 1993.
7. Bucciarelli T, Fedele G, R. Parisi. Neural Networks Based Signal Detection. IEEE Transactions. 1993.
8. Amoozegar F, Sundareshan M.K. A Robust Neural Network Scheme for Constant False Alarm Rate Processing for Target detection in Clutter Environment. Proceedings of the American Control Conference, Baltimore, Maryland. Juin 1994.
9. Mirko K. Constant False Alarm Rate Detection of Radar Signals with Artificial Neural Networks. Höskolan i Skövde. Department of Computer Science, PhD Thesis. Octobre 1996.
10. Kim M.W. Gram-Charlier and Generalized Probabilistic Neural Networks Based Radar Target Detection in Non-Gaussian Noise. IEEE Transactions. 1994.
11. Lotfi A, Benyettou A. Generalized Probabilistic Neural Networks for Radar Target Detection in non-Gaussian Noisy Environment. Conférence CNIE'04. Novembre 2004.
12. Darricau J. Physique et Théorie du Radar. Tom2, Editeur SODIP. 1981.
13. Ziemke T. Radar Image Segmentation using Self-Adapting Recurrent Networks. Phd Thesis, Connectionist Research Group. Département d'Informatique, Université de Skövde. 1995.
14. Mezzoug K, Lotfi A, Benyettou A. Les Réseaux de Neurones Probabilistes pour la Détection de Cibles Mobile dans un Environnement à Bruit non Gaussien par le Modèle CFAR. MCSEAI'08, Université USTO, Oran Mai 2008.
15. Mezzoug K, Benyettou A. Analyse des Performances d'un Détecteur CFAR Neuronal Robuste de Cibles Mobile dans un Fouillis de type K-distribution. CNIE'04, Département d'Electronique, Université d'Oran. 2004.
16. Seiffert U. Multiple Layer Perceptron Training Using Genetic Algorithms. European Symposium on Artificial Neural Networks. Conférence ESANN'01, 2001.
17. Cheikh K, Faozi S. Application of Neural Networks to Radar Signal Detection in K-distributed Clutter. IEEE Proceeding. 2004.
18. Tlemsani R, Neggaz N, Benyettou A. Evolutionary Algorithm applied to Phonetic Classification. ACIT. Juin 2004.
19. Lin D.T, Dayhoff J.E, Ligomenides P.A. A Learning Algorithm for Adaptive Time-Delays in a Temporal Neural Network. Technical Research Report. University of Maryland and Harvard University. 1993.
20. Watts S. Radar detection Prediction in sea clutter using the compound K-distribution model. IEE Proceedings, pages : 613-620. Décembre 1985.