

Détection de cibles radar par auto-encodeur variationnel

Y. A. ROUZOUKKA^{1,2} E. TERREAUX¹ C. MORISSEAU¹ J.-P. OVARLEZ^{1,2} C. REN²

¹DEMIR, ONERA, Université Paris Saclay, F-91123 Palaiseau, France,

²SONDRA, CentraleSupélec, Université Paris-Saclay, 91190 Gif-sur-Yvette, France.

Résumé – Cet article présente une nouvelle approche de détection de cibles radar basée sur les Auto-Encodeurs Variationnels (VAEs). Reconnus pour leur capacité à apprendre des distributions complexes et à détecter des échantillons hors distribution, l’architecture VAE proposée permet de distinguer efficacement les cibles radar de divers types de bruit, y compris le fouillis gaussien corrélé et le fouillis gaussien composé, souvent combinés à un bruit thermique blanc gaussien additif. En plus des simulations, nous testons notre VAE sur des données réelles CSIR (fouillis de mer), ce qui renforce sa pertinence en conditions réelles. Les résultats montrent que le VAE proposé surpasse les détecteurs adaptatifs classiques tels que le filtre adapté (MF) et le filtre adapté normalisé (NMF), en particulier dans des environnements bruités complexes, mettant en avant sa robustesse et son adaptabilité pour les applications radar.

Abstract – This paper presents a novel approach to radar target detection using Variational AutoEncoders (VAEs). Known for their ability to learn complex distributions and detect out-of-distribution samples, the proposed VAE architecture effectively distinguishes radar targets from various noise types, including correlated Gaussian and compound Gaussian clutter, often combined with additive white Gaussian thermal noise. In addition to simulations, we evaluate our VAE on the actual CSIR dataset (sea clutter), further demonstrating its practical applicability. The results show that the proposed VAE outperforms classical adaptive detectors such as the Matched Filter (MF) and the Normalized Matched Filter (NMF), particularly in challenging noise environments, highlighting its robustness and adaptability in radar applications.

1 Introduction

La détection de cibles par radar est un défi fondamental en traitement du signal [4], visant à détecter avec fiabilité la présence d’une cible dans un environnement bruité. Les méthodes classiques de détection, telles que le filtre adapté (MF), le filtre adapté normalisé (NMF) et leurs variantes adaptatives (AMF [13], Kelly [6] et ANMF [14]), ont été largement étudiées et sont reconnues pour leur efficacité dans des environnements à bruit gaussien ou gaussien composé. Cependant, dans les applications réelles, les signaux radar rencontrent souvent des structures de bruit plus complexes, notamment le fouillis gaussien composé combiné à du bruit thermique blanc gaussien additif, ce qui dégrade significativement les performances de ces détecteurs classiques en termes de probabilité de détection et de régulation du taux de fausse alarme.

Les avancées récentes en apprentissage automatique, notamment dans le domaine de l’apprentissage profond [3], offrent des alternatives prometteuses pour améliorer les capacités de détection radar. Parmi ces approches, les Auto-Encodeurs Variationnels (VAEs) se sont imposés comme des outils puissants pour la détection hors distribution (OOD) [12, 16], en modélisant la distribution de probabilité sous-jacente des données d’entrée [8]. Les approches traditionnelles de détection d’anomalies rencontrent souvent des difficultés face à des environnements bruités complexes, tandis que les méthodes basées sur les VAEs offrent une robustesse accrue grâce à leur capacité à détecter des événements se situant hors de la distribution apprise lors de l’entraînement. Cela est particulièrement pertinent pour les applications radar, où la variabilité environnementale et la complexité du bruit sont monnaie courante. Bien que la détection d’anomalies basée sur les VAEs ait démontré son efficacité dans divers domaines, notamment en traitement de

signal acoustique [1], ou d’image médicale [9], son application à la détection de cibles radar reste peu explorée. Par exemple, des architectures VAEs ont montré leur potentiel dans la détection de mouvements corporels humains à l’aide de radar à ondes continues modulées en fréquence [5].

Dans cet article, nous étudions le potentiel des VAEs pour la détection de cibles par radar, en nous concentrant sur leur capacité à gérer divers modèles de fouillis et de bruits qui posent des défis majeurs aux méthodes traditionnelles. Notre approche intègre la détection hors distribution afin d’assurer que les cibles restent détectables dans des environnements hétérogènes complexes. La structure de l’article est la suivante : la section 2 passe en revue les modèles statistiques et les détecteurs classiques utilisés en détection radar. La section 3 présente notre approche de détection basée sur les VAEs, en détaillant son architecture et sa stratégie de détection. La section 4 présente le processus d’entraînement du VAE ainsi que les résultats de simulations comparant ses performances à celles des détecteurs classiques sous différentes conditions de bruits et de fouillis. Enfin, la section 5 conclut cet article en mettant en évidence les avantages des VAEs pour la détection radar.

Notations : Les matrices sont en majuscules gras, les vecteurs en minuscules gras. Pour toute matrice \mathbf{A} , \mathbf{A}^T (resp. \mathbf{A}^H) est la transposée (resp. hermitienne) de \mathbf{A} . \mathbf{I} est la matrice identité. $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Gamma})$ et $\mathcal{CN}(\boldsymbol{\mu}, \boldsymbol{\Gamma})$ désignent respectivement les distributions gaussiennes réelles et complexes circulaires de moyenne $\boldsymbol{\mu}$ et de matrice de covariance $\boldsymbol{\Gamma}$. L’opérateur matriciel $\mathcal{T}(\cdot)$ représente l’opérateur de Toeplitz défini par $\rho \rightarrow \{\mathcal{T}(\rho)\}_{i,j} = \rho^{|i-j|}$. Le symbole \odot désigne le produit élément par élément de Hadamard. L’opérateur $\log^\circ(\cdot)$ représente l’opération log appliquée composante par composante.

2 Modèle statistique

En détection radar adaptative, le problème principal consiste à détecter un signal complexe $\alpha \mathbf{p} \in \mathbb{C}^m$ corrompu par un bruit de fouillis additif \mathbf{c} et un bruit thermique \mathbf{n} , blanc gaussien, de matrice de covariance $\sigma^2 \mathbf{I}$ et indépendant du fouillis \mathbf{c} . Dans le cas d'une cible ponctuelle, ce problème peut être formulé sous la forme du test d'hypothèse binaire suivant :

$$\begin{cases} H_0 : \mathbf{z} = \mathbf{c} + \mathbf{n}, \\ H_1 : \mathbf{z} = \alpha \mathbf{p} + \mathbf{c} + \mathbf{n}, \end{cases} \quad \text{où } \mathbf{z} \text{ est le vecteur complexe de réception, } \alpha \text{ est l'amplitude complexe de la cible inconnue et } \mathbf{p} \text{ représente un } \textit{steering} \text{ vecteur connu caractérisant ici la vitesse Doppler de la cible.}$$

Dans le cas d'un fouillis homogène, \mathbf{c} est modélisé par un vecteur gaussien circulaire complexe distribué suivant $\mathcal{CN}(\mathbf{0}, \Sigma_c)$. Pour un fouillis hétérogène ou quasi-homogène, on utilise un modèle gaussien composé, avec $\mathbf{c} = \sqrt{\tau} \mathbf{g}$, où \mathbf{g} suit une loi $\mathcal{CN}(\mathbf{0}, \Sigma_c)$ associé à la texture $\tau \in \mathbb{R}^+$, représentant les fluctuations de puissance d'une cellule radar à une autre. Par simplicité, on supposera la moyenne des fluctuations de puissance $\mathbb{E}[\tau] = 1$. Le rapport signal-sur-bruit (RSB, ou *SNR* pour *Signal-to-Noise Ratio*) sous l'hypothèse H_1 , après blanchiment, est défini comme suit : $\text{SNR} = |\alpha|^2 \mathbf{p}^H \Sigma^{-1} \mathbf{p}$, où $\Sigma = \Sigma_c + \sigma^2 \mathbf{I}$. Le rapport de puissance $r = \text{Tr}(\Sigma_c) / (m \sigma^2)$ entre le fouillis et le bruit thermique sera fixé à 1 dans la suite.

Sans le terme de bruit thermique, les deux cas précédents ont leurs solutions optimales correspondantes [4] ainsi que leurs versions adaptatives. Dans un environnement gaussien homogène, le MF conduit à :

$$\Lambda_{\text{MF}}(\mathbf{z}) = \frac{|\mathbf{p}^H \Sigma^{-1} \mathbf{z}|^2}{\mathbf{p}^H \Sigma^{-1} \mathbf{p}} \geq \lambda. \quad (1)$$

Dans un bruit gaussien partiellement homogène, le filtre adaptatif optimal est le NMF [14] :

$$\Lambda_{\text{NMF}}(\mathbf{z}) = \frac{|\mathbf{p}^H \Sigma^{-1} \mathbf{z}|^2}{(\mathbf{p}^H \Sigma^{-1} \mathbf{p})(\mathbf{z}^H \Sigma^{-1} \mathbf{z})} \geq \lambda, \quad (2)$$

Dans le cas non gaussien, ces deux détecteurs adaptatifs rencontrent des difficultés à réguler le taux de fausse alarme et voient leurs performances de détection dégradées. En environnement de fouillis gaussien composé ($\mathbf{c}_k = \sqrt{\tau_k} \mathbf{g}_k$), des alternatives existent telles que le détecteur de Tyler Adaptive Normalized Matched Filter (ANMF-FP), qui remplace la matrice de covariance empirique dans (2) par l'estimateur de covariance de Tyler $\hat{\Sigma}_{\text{FP}}$ [15, 10]. Ces approches sont particulièrement efficaces [11] en présence d'un fouillis impulsif. Dans la suite, nous proposons un détecteur basé sur un VAE capable de gérer des environnements de fouillis complexes avec du bruit thermique additif.

3 Détecteur OOD VAE Proposé

Pour surmonter le modèle statistique du fouillis plus bruit thermique, les VAE peuvent aujourd'hui apprendre la distribution sous H_0 en utilisant un ensemble d'entraînement sans cible $\mathcal{D}_{H_0} = \{\mathbf{z}_1, \dots, \mathbf{z}_N | H_0\}$. Ensuite, les méthodes de détection OOD [16] visent à identifier si un échantillon s'écarte significativement de la distribution de \mathcal{D}_{H_0} , offrant ainsi une solution flexible et généralisable pour les environnements radar complexes et hétérogènes. En apprenant les caractéristiques

des données dites In-Distribution (ID), les détecteurs OOD peuvent signaler les échantillons situés en dehors de cette distribution comme des anomalies potentielles. Cette approche ne repose pas sur des données cibles, ce qui la rend particulièrement adaptée aux applications radar où les cibles sont rares et non étiquetées.

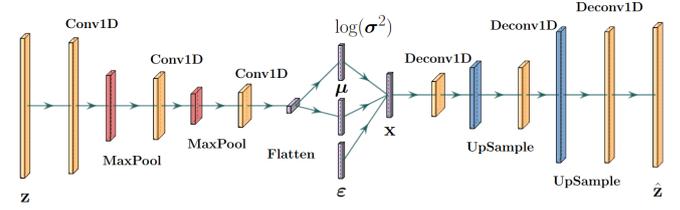


FIGURE 1 : Architecture du VAE pour la détection radar.

3.1 Architecture du VAE Proposé

Notre architecture VAE est conçue pour gérer la complexité des signaux radar tout en traitant et reconstruisant efficacement les profils de signaux radar 1D. L'architecture se compose d'un encodeur et d'un décodeur, chacun intégrant des couches convolutionnelles afin d'extraire et de représenter les caractéristiques clés des données radar dans un espace latent de dimension réduite $q < m$.

L'encodeur (voir Fig. 1) compresse les signaux radar de haute dimension en un espace latent de plus faible dimension à travers une série de blocs d'encodage. Ces blocs incluent des couches de convolution, une normalisation par *batch*, des fonctions d'activation non linéaires ReLU et des couches de sous-échantillonnage par le *max-pooling* pour extraire progressivement les caractéristiques pertinentes et réduire leur dimension. La sortie finale est ensuite transmise à des couches entièrement connectées afin de générer la moyenne $\mu \in \mathbb{R}^q$ et le logarithme de la variance $\log(\sigma^2) \in \mathbb{R}^q$, qui sont les paramètres de la distribution a priori gaussienne. Il est bien connu qu'un aspect essentiel du VAE est l'*astuce de reparamétrisation* [8], qui permet la rétropropagation des gradients à travers les variables latentes stochastiques. Plus précisément, l'échantillon latent généré est donné par $\mathbf{x} = \mu + \sigma \odot \epsilon$ où $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$. Ce processus normalise la variabilité dans l'espace latent et garantit que le processus d'échantillonnage reste différentiable, permettant ainsi au VAE d'apprendre des représentations latentes continues et informatives lors de l'entraînement.

Le décodeur (voir Fig. 1) inverse ce processus en utilisant des couches de sur-échantillonnage (*upsampling*) et chaque bloc réalise d'abord une interpolation linéaire qui double la longueur du vecteur, puis applique une convolution 1D pour affiner la reconstruction du signal radar à partir de la représentation latente \mathbf{x} . La couche de sortie applique une opération de convolution afin de générer le signal radar reconstruit $\hat{\mathbf{z}}$.

Notre VAE est entraîné en maximisant la borne inférieure de l'évidence (*evidence lower bound*) [8, Section 2.2]. Lorsque la distribution a priori et la distribution a posteriori approximée sont gaussiennes, cette fonction de perte revient à minimiser $\mathcal{L}_{\text{VAE}} = \mathcal{L}_{\text{rec}} + \beta \mathcal{L}_{\text{KL}}$, qui combine l'erreur quadratique moyenne (MSE) $\mathcal{L}_{\text{rec}}(\mathbf{z}, \hat{\mathbf{z}}) = \|\mathbf{z} - \hat{\mathbf{z}}\|^2$ pour la reconstruction des données et la divergence de Kullback-Leibler

$$\mathcal{L}_{\text{KL}} = \frac{1}{2} \sum_{i=1}^q (\mu_i^2 + \sigma_i^2 - \log(\sigma_i^2) - 1) \text{ pour la régularisation}$$

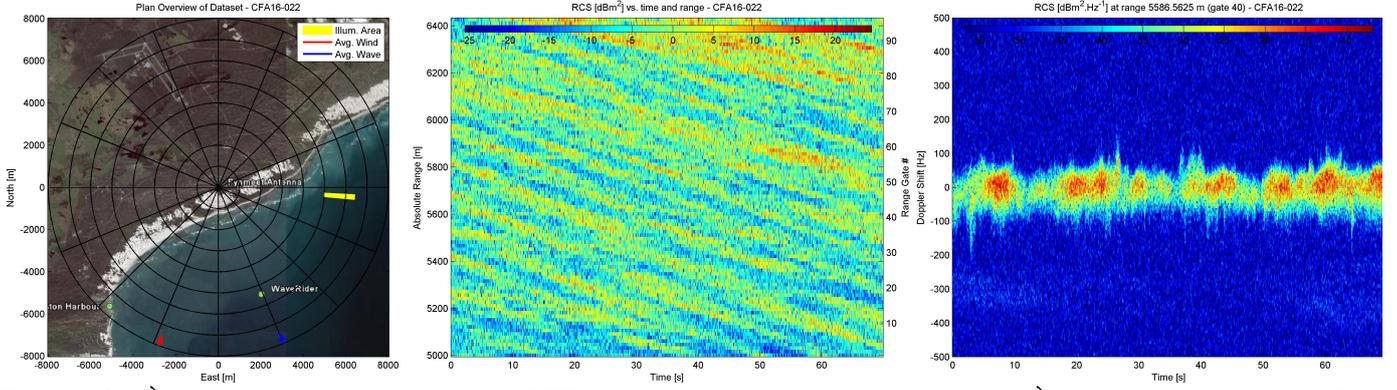


FIGURE 2 : À gauche : zone de surveillance CSIR. Au centre : carte distance–impulsion. À droite : spectrogramme Doppler–impulsion pour la case distance 40.

de l'espace latent, où μ_i et σ_i sont respectivement le $i^{\text{ème}}$ élément de $\boldsymbol{\mu}$ et $\boldsymbol{\sigma}$. L'hyperparamètre β contrôle le compromis entre ces deux composantes.

3.2 Stratégie de détection et régulation de la fausse alarme

Lors de l'inférence, le VAE traite les données radar contenant des cibles potentielles. Étant donné que le VAE a été entraîné exclusivement sur des données ne contenant que du bruit, il peine à reconstruire les signaux contenant des cibles, ce qui entraîne une MSE plus élevée lorsqu'une cible est présente. Ainsi, le test de détection est $\mathcal{L}_{\text{rec}}(\mathbf{z}, \hat{\mathbf{z}}) \geq \lambda_{\text{VAE}}$, où le seuil est calibré à l'aide d'un ensemble de validation composé uniquement des données de fouillis et de bruit, distinctes de l'ensemble d'entraînement. Le seuil λ_{VAE} est choisi pour régler la probabilité de fausse alarme P_{fa} . En analysant la distribution de la MSE sur l'ensemble de validation constitué uniquement de bruit, nous déterminons un seuil qui permet de maintenir le niveau de fausse alarme [2] à un niveau acceptable. Cette stratégie de détection exploite la capacité du VAE à modéliser des distributions complexes, permettant ainsi d'obtenir une détection robuste des cibles tout en assurant un contrôle strict de la fausse alarme, élément crucial pour garantir la fiabilité du système dans des environnements radar impulsifs et complexes.

4 Résultats et simulations

Dans cette section, nous évaluons les performances de détection du VAE 1D par rapport aux détecteurs radar classiques : ANMF-FP et AMF-SCM. Les performances sont analysées dans différents scénarios de bruit : bruit gaussien corrélé plus bruit blanc additif gaussien (cGN + AWGN), bruit gaussien composé corrélé (cCGN), bruit gaussien composé corrélé avec bruit blanc additif gaussien (cCGN + AWGN), et données réelle de fouillis de mer (CSIR). La performance de détection est mesurée en termes de probabilité de détection P_d en fonction du SNR, avec un P_{fa} fixé à 10^{-2} .

4.1 Caractéristiques du signal et du bruit

Pour simuler la cible, nous avons modélisé l'amplitude de l'écho par $\alpha = \sqrt{\text{SNR}} e^{2j\pi\phi} / \sqrt{m}$ où $\phi \in [-\frac{1}{2}; \frac{1}{2}]$ est la fréquence Doppler normalisée de la cible. Le *steering* vecteur est de la forme $\mathbf{p} = (1, e^{2j\pi d/m}, \dots, e^{2j\pi d(m-1)/m})^T$ avec

$m = 16$ cellules, où $d \in \llbracket -\frac{m}{2}; \frac{m}{2} - 1 \rrbracket$ désigne la case de Doppler. Les paramètres du bruit et des perturbations dans la simulation sont modélisés avec $\boldsymbol{\Sigma}_c = \mathcal{T}(\rho)$, avec $\rho = 0.5$. Les textures τ et τ_k sont échantillonnées selon une distribution Gamma $\Gamma(\mu, 1/\mu)$ avec $\mu = 1$. Pour les détecteurs adaptatifs, la matrice de covariance est estimée en utilisant les méthodes SCM et Tyler avec $K = 2m$ données secondaires.

Le jeu de données du CSIR a été collecté lors de deux campagnes de mesures des échos radar du fouillis marin et des cibles navales par l'unité Défense, Paix, Sécurité et Sûreté du Council for Scientific and Industrial Research (CSIR) le long de la côte sud-ouest de l'Afrique du Sud en juillet 2006 et novembre 2007. Il contient un volume important de données d'échos de fouillis marin et de cibles, couvrant une large combinaison de paramètres (différentes formes d'onde émises, azimuts et distances) dans des conditions environnementales variées (voir Fig. 2).

Ici, P_d est estimé comme la fréquence d'identification correcte des $N_{\text{test}} = 5000$ échantillons contenant chacun une cible (une seule par profil). Le seuil de décision λ de chaque détecteur est pré-calibré sur un jeu de validation de la même taille sans cible, de sorte que la fréquence des fausses alarmes corresponde bien au $P_{fa} = 10^{-2}$ ciblé.

4.2 Configuration de l'entraînement du VAE

Pour chaque scénario mentionné ci-dessus, le VAE est entraîné sur des profils Doppler contenant uniquement du fouillis et du bruit. L'ensemble des données \mathcal{D}_{H_0} contient $N = 15000$ échantillons, dont $2/3$ sont utilisés pour l'entraînement et $1/3$ pour la validation. L'entraînement est effectué sur 50 époques à l'aide de l'optimiseur Adam [7], avec un taux d'apprentissage de 10^{-3} . La fonction de perte d'entraînement est \mathcal{L}_{VAE} , calculée avec $\beta = 10^2$. La dimension de l'espace latent est fixée à $q = 12$. Une fois entraîné, le test de détection est basé sur \mathcal{L}_{rec} pour fixer $P_{fa} = 10^{-2}$ à partir d'un ensemble d'évaluation contenant 5000 échantillons générés indépendamment de l'ensemble d'entraînement, comme expliqué dans la section 3.2.

4.3 Résultats sur toutes les cases Doppler

L'analyse sur l'ensemble des cases Doppler considérées montre que, dans le cas du bruit gaussien corrélé et du bruit thermique (Fig. 3-(a)), le VAE offre de bonnes performances indépendamment des cases Doppler et surpasse les détecteurs adaptatifs comme l'ANMF-FP et l'AMF-SCM, démontrant

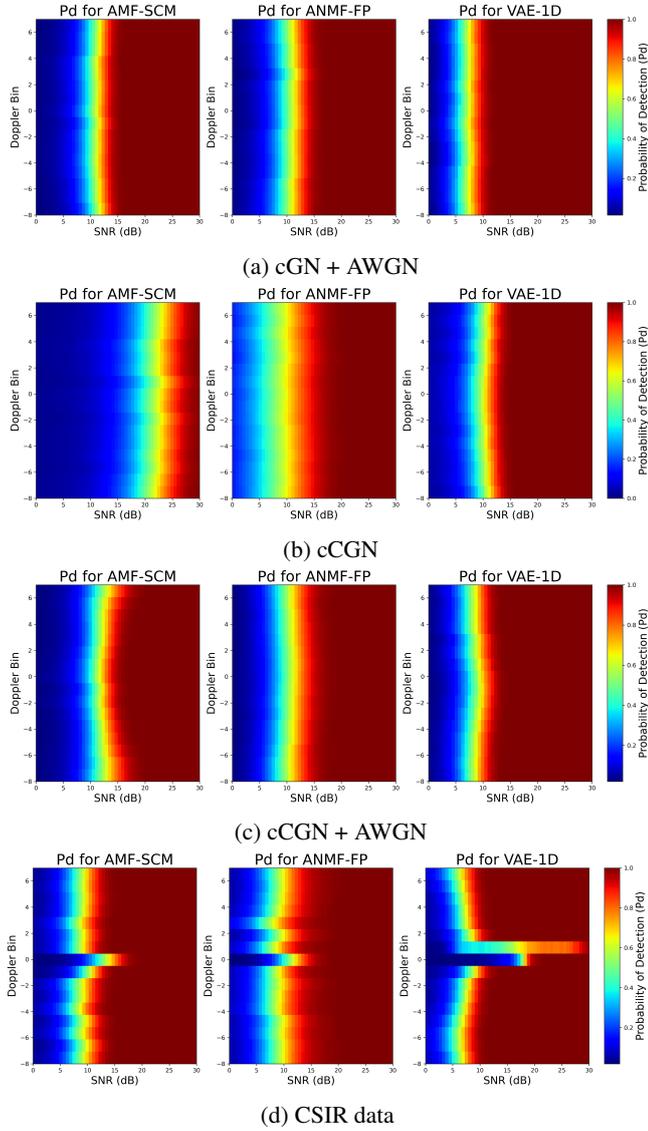


FIGURE 3 : Carte P_d en fonction du SNR et des cases Doppler, comparant le VAE à l'AMF et à l'ANMF dans différents scénarios de bruit.

ainsi son insensibilité aux caractéristiques du bruit et ses avantages potentiels dans certaines situations. Pour le bruit gaussien composé, comme illustré en Fig. 3-(b), le VAE rivalise avec l'ANMF-FP pour des valeurs de SNR moyennes à élevées et surpasse l'AMF-SCM sur l'ensemble des cases Doppler, en particulier dans des conditions difficiles. Cette analyse suggère que le VAE constitue une alternative robuste, notamment lorsqu'il opère dans des environnements défavorables.

Dans un environnement combinant bruit gaussien composé et bruit thermique, la Fig. 3-(c) montre que le VAE surpasse significativement les détecteurs adaptatifs sur l'ensemble des cases Doppler. Cette performance robuste, particulièrement en présence de bruit complexe, souligne l'efficacité du VAE dans des conditions où les détecteurs traditionnels peuvent être mis en défaut.

Dans le cas des données réelles du CSIR (Fig.3-(d)), les premiers résultats indiquent que le VAE surpasse l'AMF-FP et l'ANMF-FP sur toutes les cases Doppler, à l'exception de celles situées autour de 0. Cette diminution de performance s'explique par la forte présence du fouillis dans cette région Doppler, ce qui rend la détection plus difficile (voir Fig. 2).

5 Conclusion

Les résultats présentés dans cette étude démontrent l'efficacité du VAE pour la détection de cibles radar dans diverses conditions de bruit. Le VAE surpasse systématiquement les méthodes de détection traditionnelles, en particulier dans les scénarios impliquant du bruit impulsif, du bruit corrélé et du fouillis réel. Ses performances supérieures s'expliquent par sa capacité à modéliser des distributions de données complexes, le rendant ainsi plus robuste pour la détection de cibles radar dans des environnements difficiles.

6 Remerciements

Une partie de ce travail a été réalisé pour l'ANR-ASTRID NEPTUNE 3 (ANR-23-ASM2-0009).

Références

- [1] Z. BUKHSH et A. SAEED : On out-of-distribution detection for audio with deep nearest neighbors. *In IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1–5, 2023.
- [2] T. DISKIN, Y. BEER, U. OKUN et A. WIESEL : CFARnet : Deep learning for target detection with constant false alarm rate. *Signal Processing*, 223:109543, 2024.
- [3] I. J. GOODFELLOW, Y. BENGIO et A. COURVILLE : *Deep Learning*. MIT Press, Cambridge, MA, USA, 2016.
- [4] M. S. GRECO et A. DE MAIO, éditeurs. *Modern Radar Detection Theory*. SciTech Publishing, Jan 2016.
- [5] S. M. KAHYA, M. S. YAVUZ et E. STEINBACH : MCROOD : Multi-class radar out-of-distribution detection. *In IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1–5, 2023.
- [6] E. J. KELLY : An adaptive detection algorithm. *IEEE Transactions on Aerospace and Electronic Systems*, AES-22(2):115–127, 1986.
- [7] D. KINGMA et J. BA : Adam : A method for stochastic optimization. *In International Conference on Learning Representations (ICLR)*, San Diego, CA, USA, 2015.
- [8] D. P. KINGMA et M. WELLING : An introduction to variational autoencoders. *Foundations and Trends® in Machine Learning*, 12(4):307–392, 2019.
- [9] S. N. MARIMONT et G. TARRONI : Anomaly detection through latent space restoration using vector quantized variational autoencoders. *In 2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*, pages 1764–1767, 2021.
- [10] E. OLLILA, D. E. TYLER, V. KOIVUNEN et H. V. POOR : Complex elliptically symmetric distributions : Survey, new results and applications. *IEEE Transactions on Signal Processing*, 60(11):5597–5625, 2012.
- [11] J.-P. OVARLEZ, F. PASCAL et A. BRELOY : Asymptotic detection performance analysis of the robust Adaptive Normalized Matched Filter. *In IEEE 6th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, pages 137–140, 2015.
- [12] X. RAN, M. XU, L. MEI, Q. XU et Q. LIU : Detecting Out-of-Distribution samples via Variational Auto-Encoder with reliable uncertainty estimation. *Neural Networks*, 145:199–208, 2022.
- [13] F. C. ROBEY, D. R. FUHRMANN, E. J. KELLY et R. NITZBERG : A CFAR adaptive matched filter detector. *IEEE Transactions on Aerospace and Electronic Systems*, 28:208–216, 1992.
- [14] L. L. SCHARF et B. FRIEDLANDER : Matched subspace detectors. *IEEE Transactions on Signal Processing*, 42(8):2146–2157, 1994.
- [15] D. E. TYLER : A distribution-free M-estimator of multivariate scatter. *Ann. Statist.*, 15(1):234–251, 03 1987.
- [16] J. YANG, K. ZHOU, Y. LI et Z. LIU : Generalized out-of-distribution detection : A survey. *International Journal of Computer Vision*, Jun 2024.