

AUTOENCODEUR VARIATIONNEL COMPLEXE POUR LA DÉTECTION DE CIBLES RADAR

Y. A. Rouzoumka^{1,2}, E. Terreaux¹, C. Morisseau¹, J.-P. Ovarlez^{1,2}, C. Ren²

¹ DEMR, ONERA, Université Paris-Saclay, F-91123 Palaiseau, France.

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

Résumé. Nous proposons une architecture d’*Autoencodeur Variationnel Complexe* (CVAE) dédiée à la détection de cibles radar, exploitant des représentations intrinsèquement complexes avec un *seul* canal latent. Contrairement aux VAE réels, qui nécessitent deux canaux latents pour coder séparément les parties réelle et imaginaire, le CVAE opère directement dans \mathbb{C} , préservant l’information de phase et la structure des échos radar. La stratégie de détection repose sur l’erreur de reconstruction, accrue en présence d’une cible hors-distribution (OOD), avec un seuil calibré pour garantir un taux de fausses alarmes fixé. Nous évaluons la méthode (i) sur des données simulées en fouillis *composé gaussien corrélé avec bruit thermique additif* (cCGN+AWGN), scénario difficile pour les estimateurs robustes, et (ii) sur des données réelles CSIR via des cartes P_d -SNR-Doppler. Les résultats montrent une robustesse compétitive face aux détecteurs classiques (AMF/ANMF) et un VAE réel, tout en améliorant la séparabilité des représentations latentes.

Mots-clés. autoencodeur variationnel, réseaux de neurones complexes, détection radar, détection OOD.

Abstract. We introduce a *Complex Variational AutoEncoder* (CVAE) tailored to radar target detection, leveraging intrinsically complex-valued representations with a *single* latent channel. Unlike real-valued VAEs that require two latent channels to encode real and imaginary parts separately, the proposed CVAE operates directly in \mathbb{C} , preserving phase information and the inherent structure of radar echoes. Detection uses the reconstruction error (higher for out-of-distribution target-containing inputs) and a decision threshold calibrated to enforce a prescribed false-alarm probability. We report experiments (i) on simulated *correlated compound-Gaussian clutter with additive thermal noise* (cCGN+AWGN), and (ii) on real CSIR data using P_d -SNR-Doppler maps. Results demonstrate strong robustness compared to classical adaptive/robust detectors and a real-valued VAE, while yielding a more structured latent separation.

Keywords. variational autoencoder, complex-valued neural networks, radar target detection, OOD detection.

1 Introduction

La détection de cibles radar est un problème central du traitement du signal [1], en particulier lorsque l’observation est contaminée par un fouillis hétérogène et du bruit thermique. Les détecteurs classiques tels que le Matched Filter et le Normalized Matched Filter (MF/NMF), ainsi que leurs variantes adaptatives (AMF/ANMF) [2–4], sont performants sous

hypothèses gaussiennes, mais leurs performances et/ou leur régulation des fausses alarmes se dégradent lorsque le fouillis s'écarte de la normalité (textures fluctuantes, impulsivité, non-stationnarités).

Les Autoencodeurs Variationnels (VAE) sont des modèles génératifs adaptés à la détection *out-of-distribution* (OOD) [5–7] : entraînés sous H_0 (fouillis+bruit), ils reconstruisent correctement les données *in-distribution* et échouent davantage en présence de cible, ce qui fournit un score de détection naturel via l'erreur de reconstruction. Dans ce travail, nous proposons un *VAE à valeurs complexes* (CVAE) opérant directement dans \mathbb{C} avec un *canal latent unique*, afin de préserver la phase et d'améliorer la structure de l'espace latent (par rapport à un VAE réel à deux canaux). Des architectures complexes ont montré leur intérêt en modélisation générative et apprentissage de représentations [8, 9], ainsi qu'en radar (ex. PolSAR) via une meilleure exploitation de la phase [10].

Notations. Les matrices sont en gras majuscule et les vecteurs en gras. Pour toute matrice \mathbf{A} , \mathbf{A}^T et \mathbf{A}^H désignent la transposée et la transposée hermitienne, et \mathbf{I} est l'identité. $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Gamma})$ et $\mathcal{CN}(\boldsymbol{\mu}, \boldsymbol{\Gamma})$ désignent des lois normale réelle et normale complexe circulaire. $\mathcal{T}(\rho)$ construit la matrice de Toeplitz $\{\mathcal{T}(\rho)\}_{i,j} = \rho^{|i-j|}$. \odot et \oslash désignent respectivement le produit et la division de Hadamard (opérations élément par élément). Pour un vecteur \mathbf{v} , $|\mathbf{v}|^\circ$, \mathbf{v}^{α} et $\log^\circ(\mathbf{v})$ désignent respectivement la valeur absolue, la puissance α et le logarithme *élément par élément*. Enfin, $\text{Re}(\cdot)$ et $\text{Im}(\cdot)$ désignent les parties réelle et imaginaire.

2 Modèle radar et détecteurs classiques

On observe $\mathbf{z} \in \mathbb{C}^m$ et l'on teste

$$H_0 : \mathbf{z} = \mathbf{c} + \mathbf{n}, \quad H_1 : \mathbf{z} = \alpha \mathbf{p} + \mathbf{c} + \mathbf{n},$$

où \mathbf{p} est connu, $\alpha \in \mathbb{C}$ inconnue, $\mathbf{n} \sim \mathcal{CN}(\mathbf{0}, \sigma^2 \mathbf{I})$ et \mathbf{c} est un fouillis. En milieu hétérogène, on utilise le modèle composé gaussien $\mathbf{c} = \sqrt{\tau} \mathbf{g}$ avec $\mathbf{g} \sim \mathcal{CN}(\mathbf{0}, \boldsymbol{\Sigma}_c)$ et $\tau \in \mathbb{R}^+$ (souvent $\mathbb{E}[\tau] = 1$). En notant $\boldsymbol{\Sigma} = \boldsymbol{\Sigma}_c + \sigma^2 \mathbf{I}$, la SNR (après blanchiment) vaut $\text{SNR} = |\alpha|^2 \mathbf{p}^H \boldsymbol{\Sigma}^{-1} \mathbf{p}$.

En bruit gaussien, le MF et le NMF s'écrivent respectivement

$$\Lambda_{\text{MF}}(\mathbf{z}) = \frac{|\mathbf{p}^H \boldsymbol{\Sigma}^{-1} \mathbf{z}|^2}{\mathbf{p}^H \boldsymbol{\Sigma}^{-1} \mathbf{p}} \underset{H_0}{\underset{H_1}{\gtrless}} \lambda, \quad \Lambda_{\text{NMF}}(\mathbf{z}) = \frac{|\mathbf{p}^H \boldsymbol{\Sigma}^{-1} \mathbf{z}|^2}{(\mathbf{p}^H \boldsymbol{\Sigma}^{-1} \mathbf{p})(\mathbf{z}^H \boldsymbol{\Sigma}^{-1} \mathbf{z})} \underset{H_0}{\underset{H_1}{\gtrless}} \lambda.$$

Quand $\boldsymbol{\Sigma}$ est inconnue, on l'estime à partir de K secondaires \mathbf{z}_k (sans cible), via la SCM $\hat{\boldsymbol{\Sigma}}_{\text{SCM}} = \frac{1}{K} \sum_{k=1}^K \mathbf{z}_k \mathbf{z}_k^H$ (AMF/ANMF-SCM) [2, 11]. Sous fouillis composé, une alternative robuste est l'ANMF avec estimateur de Tyler [12, 13], $\hat{\boldsymbol{\Sigma}}_{\text{FP}} = \frac{m}{K} \sum_{k=1}^K \frac{\mathbf{z}_k \mathbf{z}_k^H}{\mathbf{z}_k^H \hat{\boldsymbol{\Sigma}}_{\text{FP}}^{-1} \mathbf{z}_k}$. Cependant, l'additif thermique peut fragiliser l'invariance texture et la régulation CFAR, motivant une approche apprenante calibrée.

3 CVAE : apprentissage complexe et détection

Le *CVAE* apprend, sur des données H_0 , un modèle génératif *complexe* avec un *latent unique*. La Fig. 1 illustre la structure encodeur/décodeur : l'encodeur produit $(\boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\delta})$ avec $\boldsymbol{\mu} \in \mathbb{C}^q$, $\boldsymbol{\sigma} \in \mathbb{R}_+^q$ et $\boldsymbol{\delta} \in \mathbb{C}^q$ (pseudo-variance), puis le décodeur reconstruit $\hat{\mathbf{x}}$.

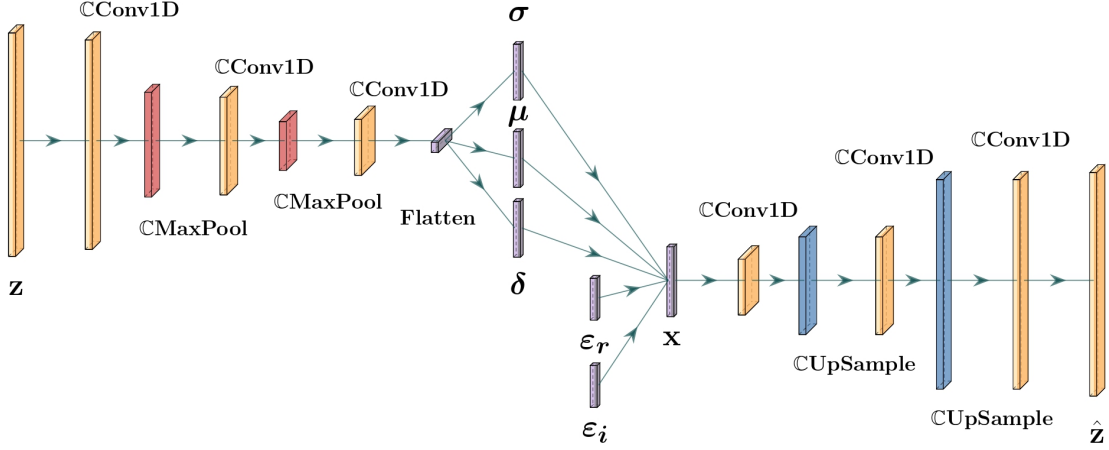


FIGURE 1 : Architecture du CVAE : encodeur-décodeur à couches et latent complexes.

On échantillonne ensuite $\mathbf{z} = \boldsymbol{\mu} + \mathbf{k}_r \odot \boldsymbol{\epsilon}_r + i \mathbf{k}_i \odot \boldsymbol{\epsilon}_i$, avec $\boldsymbol{\epsilon}_r, \boldsymbol{\epsilon}_i \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$, et

$$\mathbf{k}_r = \frac{1}{\sqrt{2}}(\boldsymbol{\sigma} + \boldsymbol{\delta}) \oslash (\boldsymbol{\sigma} + \text{Re}(\boldsymbol{\delta}))^{\circ\frac{1}{2}}, \quad \mathbf{k}_i = \frac{1}{2}(\boldsymbol{\sigma}^{\circ 2} - (|\boldsymbol{\delta}|^{\circ})^2)^{\circ\frac{1}{2}} \oslash (\boldsymbol{\sigma} + \text{Re}(\boldsymbol{\delta}))^{\circ\frac{1}{2}}.$$

Pour garantir $|\boldsymbol{\delta}|^{\circ} < \boldsymbol{\sigma}$, on reparamètre $\boldsymbol{\delta} = \boldsymbol{\alpha} \odot \boldsymbol{\sigma}$ avec $|\boldsymbol{\alpha}|^{\circ} < \mathbf{1}$.

L'entraînement minimise une ELBO adaptée au complexe,

$$\mathcal{L}_{\text{VAE}} = \|\mathbf{x} - \hat{\mathbf{x}}\|^2 + \beta \mathcal{D}_{\text{KL}}, \quad \mathcal{D}_{\text{KL}} = \|\boldsymbol{\mu}\|^2 + \mathbf{1}_q^T \left(\boldsymbol{\sigma} - \frac{1}{2} \log^{\circ}(\boldsymbol{\sigma}^{\circ 2} - (|\boldsymbol{\delta}|^{\circ})^2) \right).$$

En détection, on utilise $\mathcal{L}_{\text{rec}} = \|\mathbf{x} - \hat{\mathbf{x}}\|^2$ et la décision $\mathcal{L}_{\text{rec}} \underset{H_0}{\overset{H_1}{\geq}} \lambda_{\text{VAE}}$. Le seuil λ_{VAE} est calibré sur validation H_0 pour imposer une P_{fa} [14].

4 Résultats

Nous reportons (i) le scénario simulé **cCGN+AWGN** et (ii) des résultats sur données réelles **CSIR**, sous forme de cartes P_d -SNR-Doppler, ainsi que (iii) la séparation latente (t-SNE). Ici, **AWGN** (*additive white Gaussian noise*) désigne un bruit thermique additif blanc gaussien, et **cCGN** (*correlated compound-Gaussian noise/clutter*) désigne un fouillis composé gaussien *corrélé* (modèle texture \times gaussien corrélé).

Simulation cCGN+AWGN. La cible est $\alpha = \sqrt{\text{SNR}} e^{2j\pi\phi} / \sqrt{m}$, $\phi \in [0, 1]$, et $\mathbf{p} = (1, e^{2j\pi d/m}, \dots, e^{2j\pi d(m-1)/m})^T$ ($m = 16$). Le fouillis suit $\mathbf{c} = \sqrt{\tau} \mathbf{g}$ avec $\mathbf{g} \sim \mathcal{CN}(\mathbf{0}, \boldsymbol{\Sigma}_c)$, $\boldsymbol{\Sigma}_c = \mathcal{T}(\rho)$ ($\rho = 0.5$), $\tau \sim \Gamma(\mu, 1/\mu)$ ($\mu = 1$), et on ajoute un bruit thermique $\mathbf{n} \sim \mathcal{CN}(\mathbf{0}, \sigma^2 \mathbf{I})$. On utilise $K = 2m$ secondaires et on calibre à $P_{\text{fa}} = 10^{-2}$. Les réalisations H_1 sont obtenues en ajoutant la composante cible $\alpha \mathbf{p}$ aux observations H_0 .

CSIR. CSIR désigne ici un jeu de données radar réel en environnement maritime fournissant des cartes range-Doppler. Dans cette étude, nous utilisons des observations *clutter-only* comme données H_0 , puis nous générons des instances H_1 en *ajoutant* une cible synthétique selon le même modèle que dans la simulation (amplitude pilotée par la SNR et signature




FIGURE 2 : Simulation **cCGN+AWGN** : cartes P_d -SNR-Doppler (AMF-SCM, ANMF-FP, VAE réel, CVAE). $P_{fa} = 10^{-2}$, $\rho = 0.5$, $\mu = 1$, $m = 16$, $K = 32$.

Doppler). La Fig. 3 rapporte les cartes P_d -SNR-Doppler correspondantes. On retrouve une zone plus délicate autour de Doppler proche de 0 (fouillis dominant) pour tous les détecteurs, tandis que les approches VAE atteignent des P_d élevés à SNR modérées sur une large partie des bins.

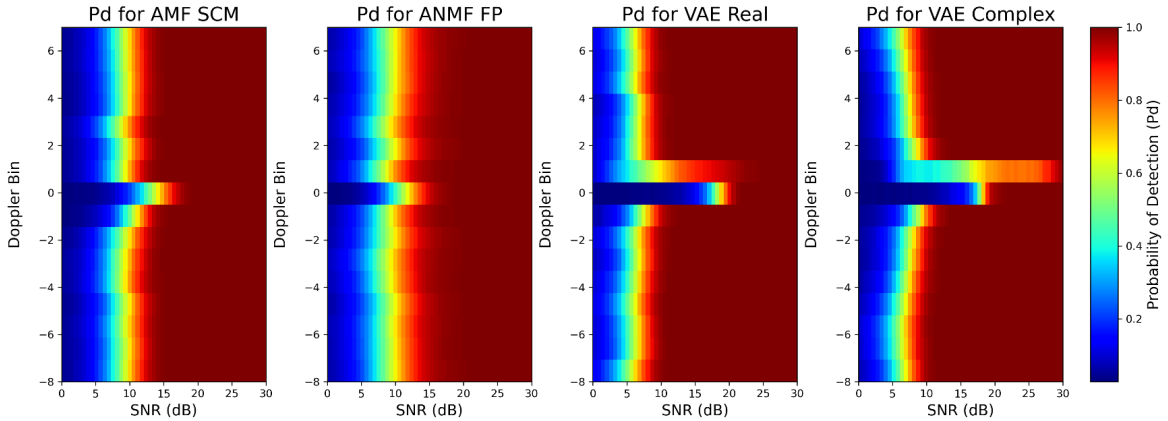


FIGURE 3 : CSIR : cartes P_d -SNR-Doppler (AMF-SCM, ANMF-FP, VAE réel, CVAE). $P_{fa} = 10^{-2}$, $m = 16$, $K = 32$.

Interprétation des cartes P_d -SNR-Doppler. Dans les Figs. 2–3, chaque panneau donne P_d en fonction de la SNR (axe horizontal) et du bin Doppler (axe vertical) : les couleurs chaudes indiquent une détection quasi-certaine, et la transition bleu→rouge marque le niveau SNR requis. On observe typiquement une zone plus difficile autour de Doppler ≈ 0 (fouillis dominant), où cette transition est difficile.

Séparation latente. Bien que les performances de détection (via \mathcal{L}_{rec}) entre RVAE et CVAE soient proches, la Fig. 4 montre que le CVAE induit une séparation plus structurée entre H_0 et H_1 (t-SNE), en cohérence avec l'intérêt d'une représentation intrinsèquement complexe.

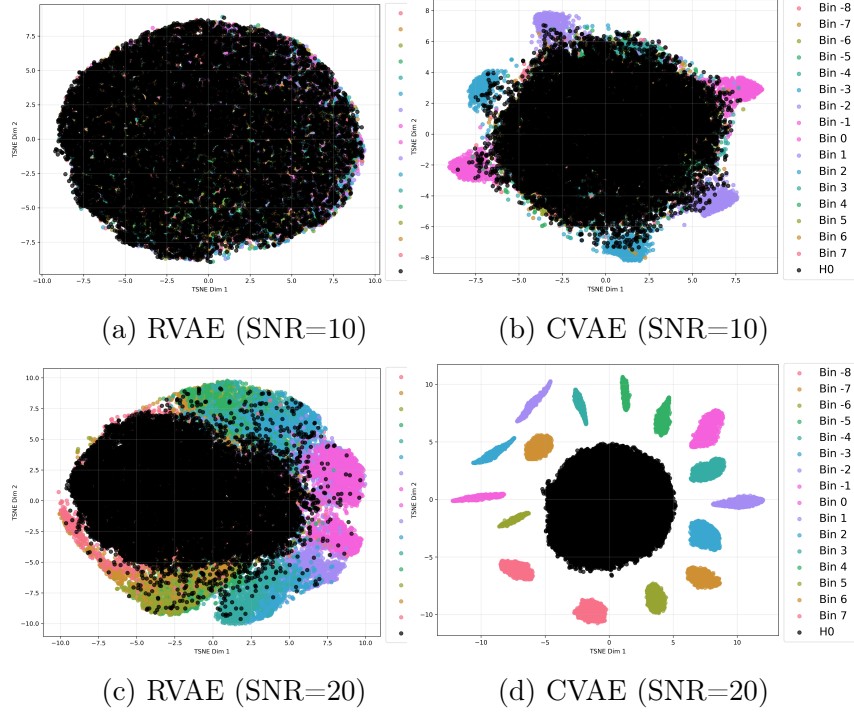


FIGURE 4 : Séparation de l'espace latent : RVAE vs CVAE (t-SNE).

5 Conclusion

Nous avons présenté un Autoencodeur Variationnel Complexe (CVAE) à canal latent unique pour la détection de cibles radar en présence de fouillis composé et de bruit thermique. Le CVAE opère directement dans \mathbb{C} , préserve l'information de phase, et permet une détection simple via l'erreur de reconstruction avec calibration garantissant une P_{fa} imposée. Les résultats sur le scénario simulé **cCGN+AWGN** et sur données réelles CSIR confirment la pertinence de l'approche, tout en montrant une séparation latente plus structurée que celle d'un VAE réel.

Références

- [1] M. S. Greco and A. De Maio, editors. *Modern Radar Detection Theory*. SciTech Publishing, Jan 2016.
- [2] F. C. Robey, D. R. Fuhrmann, E. J. Kelly, and R. Nitzberg. A CFAR adaptive matched filter detector. *IEEE Transactions on Aerospace and Electronic Systems*, 28 :208–216, 1992.
- [3] E. J. Kelly. An adaptive detection algorithm. *IEEE Transactions on Aerospace and Electronic Systems*, AES-22(2) :115–127, 1986.
- [4] L. L. Scharf and B. Friedlander. Matched subspace detectors. *IEEE Transactions on Signal Processing*, 42(8) :2146–2157, 1994.

- [5] X. Ran, M. Xu, L. Mei, Q. Xu, and Q. Liu. Detecting Out-of-Distribution samples via Variational Auto-Encoder with reliable uncertainty estimation. *Neural Networks*, 145 :199–208, 2022.
- [6] Y. A. Rouzoumka, E. Terreaux, C. Morisseau, J.-P. Ovarlez, and C. Ren. Out-of-distribution radar detection in compound clutter and thermal noise through variational autoencoders. In *2025 IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 1–5, 2025.
- [7] D. P. Kingma and M. Welling. An introduction to variational autoencoders. *Foundations and Trends® in Machine Learning*, 12(4) :307–392, 2019.
- [8] Y. Xiang, J. Tian, X. Hu, X. Xu, and Z. Yin. A deep representation learning-based speech enhancement method using complex convolution recurrent variational autoencoder. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 781–785, 2024.
- [9] A. Stanić, A. Gopalakrishnan, K. Irie, and J. Schmidhuber. Contrastive training of complex-valued autoencoders for object discovery. In A. Oh, T. Naumann, A. Globerson, K. Saenko, M. Hardt, and S. Levine, editors, *Advances in Neural Information Processing Systems*, volume 36, pages 11075–11101. Curran Associates, Inc., 2023.
- [10] J. A. Barrachina, C. Ren, C. Morisseau, G. Vieillard, and J.-P. Ovarlez. Comparison Between Equivalent Architectures of Complex-valued and Real-valued Neural Networks - Application on Polarimetric SAR Image Segmentation. *Journal of Signal Processing Systems*, July 2022.
- [11] S. Kraut, L. L. Scharf, and L. T. McWhorter. Adaptive subspace detectors. *IEEE Transactions on Signal Processing*, 49 :1–16, 2001.
- [12] D. E. Tyler. A distribution-free M-estimator of multivariate scatter. *Ann. Statist.*, 15(1) :234–251, 03 1987.
- [13] F. Pascal, Y. Chitour, J.-P. Ovarlez, P. Forster, and P. Larzabal. Covariance structure maximum-likelihood estimates in compound Gaussian noise : Existence and algorithm analysis. *IEEE Transactions on Signal Processing*, 56 :34–48, January 2008.
- [14] T. Diskin, Y. Beer, U. Okun, and A. Wiesel. CFARnet : Deep learning for target detection with constant false alarm rate. *Signal Processing*, 223 :109543, 2024.