

Détection de signaux radar LPI par YOLO en présence d'interférences et de signaux inconnus

Reihan MAZOUZ^{1,2} José PICHERAL¹ Abigaël TAYLOR² Jonathan BOSSE² Sylvie MARCOS¹

¹Laboratoire des Signaux et Systèmes, 2 rue Joliot Curie, 91190 Gif sur Yvette, France

²DEMR, ONERA, Université Paris-Saclay, F-91120 Palaiseau, France

Résumé – Dans un contexte de guerre électronique, la détection de signaux radar à faible probabilité d'interception (LPI) représente un défi majeur, en particulier en présence d'interférences ou face à des formes d'ondes inédites. Cela souligne la nécessité de développer des modèles d'apprentissage profond robustes et adaptatifs. Ce travail explore les capacités du modèle YOLOv8 dans deux situations critiques : la détection sous interférences et la généralisation à de nouvelles modulations LPI. Les résultats expérimentaux montrent que YOLOv8 conserve une bonne probabilité de détection et un taux de fausses alarmes faible, même en conditions dégradées, soulignant ainsi son potentiel pour des applications en environnement opérationnel.

Abstract – In electronic warfare, reliable Low Probability of Intercept (LPI) radar signals detection is a major challenge—especially under interference or when dealing with not previously encountered waveform types. This underscores the need for robust and adaptive deep learning models. This work investigates the YOLOv8 model in two critical scenarios: detection under interference and generalization to novel LPI waveforms. Experimental results demonstrate that YOLOv8 maintains high detection performance and low false alarm rates even under degraded conditions, confirming its potential for real-world operational applications.

1 Introduction

L'interception des signaux radar constitue un enjeu stratégique majeur dans le domaine de la guerre électronique. Elle vise à capter, analyser et exploiter les émissions radar ennemies à des fins de renseignement, de brouillage ou de contre-mesures. Cependant, les progrès technologiques récents ont conduit à l'émergence de formes d'ondes de plus en plus sophistiquées, rendant leur détection particulièrement complexe pour les systèmes de surveillance actuels [1].

Les radars à *Faible Probabilité d'Interception* (LPI) illustrent parfaitement cette évolution technologique. Conçus pour minimiser leur détection par des capteurs adverses, ils utilisent des techniques telles que l'émission à faible puissance, l'étalement de spectre ou encore des modulations évolutives. Ces procédés permettent de diluer l'énergie du signal dans le domaine temps-fréquence, le rendant difficile à distinguer du bruit ambiant [1]. Un autre procédé consiste à dissimuler le signal dans des bandes de télécommunication, rendant la tâche d'interception d'autant plus complexe.

Les approches conventionnelles, reposant sur des techniques d'analyse temps-fréquence ou sur la cyclostationnarité, atteignent rapidement leurs limites face à cette complexité croissante. L'essor des réseaux de neurones convolutifs (CNN) a ouvert la voie à des méthodes plus robustes, capables d'analyser directement des représentations temps-fréquence sans nécessiter d'extraction manuelle de caractéristiques [2, 3]. Parmi ces approches, les modèles de type YOLO (*You Only Look Once*) se distinguent dans des travaux récents [4, 5, 6], qui ont confirmé leur pertinence pour la détection de signaux LPI.

Toutefois, la majorité de ces derniers s'appuie sur des contextes de simulation fortement simplifiés, où les classes de formes d'ondes sont bien connues et limitées en nombre, de plus l'environnement est relativement peu perturbé. Or, dans

des scénarios réalistes de guerre électronique, les conditions d'interception sont plus complexes. D'une part, les signaux LPI peuvent adopter des morphologies inconnues, ne suivant aucun schéma déterministe connu. D'autre part, l'environnement opérationnel est souvent marqué par de fortes interférences. Ces contraintes imposent de concevoir des détecteurs robustes, capables d'opérer efficacement dans un cadre non coopératif, sans hypothèse forte sur la structure des signaux à intercepter.

Dans [5], différentes configurations d'interférences ont été explorées. Cependant, aucune comparaison n'est réalisée entre un modèle entraîné avec interférences et un autre sans. Par ailleurs, les niveaux d'interférences considérés restent relativement modérés. De même, [6] propose une version améliorée de YOLOv8 pour de la reconnaissance LPI en présence de bruit coloré, mais ne compare pas la robustesse face à des formes d'ondes inédites et ne réalise pas explicitement la détection des interférences. De plus, les résultats sont uniquement présentés pour des fort RSB. Enfin, bien que [7] traite la problématique de détection de classes inconnues avec YOLO, cette étude se concentre sur les véhicules autonomes, un domaine éloigné de la détection de signaux radar.

Contrairement aux approches précédentes, le présent article met en évidence l'importance de l'entraînement sous interférences, en comparant les performances d'un modèle qui y est exposé avec celles d'un modèle qui en est exempt. Nous explorons également la capacité du détecteur à généraliser face à des formes d'ondes non présentes lors de l'apprentissage.

L'organisation de cet article est la suivante. La Section II décrit les signaux LPI considérés et le prétraitement réalisé. La Section III présente l'architecture YOLOv8 et IV le protocole expérimental mis en œuvre, ainsi que les résultats et l'analyse de ces derniers. Enfin, la Section V conclut cette étude.

2 Modèle de signal

2.1 Modélisation du signal radar

L'objectif de ce travail est de détecter un ou plusieurs signaux inconnus, immergés dans un environnement bruité par un bruit blanc additif gaussien. Mathématiquement, le signal reçu peut s'écrire sous la forme :

$$y(n) = \sum_{i=1}^M x_i(n) + w(n) + z(n), \quad n = 0, \dots, T-1 \quad (1)$$

où T désigne la durée totale (en échantillons) de l'observation. Ici x_i représente l'un des M signaux déterministes à détecter, w est un bruit blanc additif gaussien de variance connue et z représente les signaux d'interférences (explicité en section 4.2).

L'ensemble des signaux considérés couvre différentes formes de modulations couramment utilisées dans les systèmes radar. On distingue notamment la modulation linéaire de fréquence (LFM), la modulation non linéaire de fréquence (NLFM), principalement basée sur des lois en S, ainsi que la modulation par saut de phase (PSK), regroupant les codes P1, P2, P3, P4 et Frank. S'ajoutent à cela les modulations à saut de phase à intervalles temporels non constants, dites polytime, incluant les codes T1, T2, T3 et T4, et enfin la modulation par saut de fréquence (FSK), dont notamment les codes de Costas [1].

Le principal défi réside dans la détection de la présence de ces signaux, ainsi que dans l'extraction de leurs caractéristiques distinctives à partir d'observations bruitées.

2.2 Prétraitement

Le signal reçu est d'abord transformé dans le domaine temps-fréquence à l'aide de la Transformée de Fourier à Court Terme (STFT), afin de faciliter son analyse et la détection des signaux d'intérêt. La STFT discrète est définie par :

$$Y(m, k) = \sum_{n=0}^{N_t-1} y(n + mN_t) e^{-j2\pi kn/N_f}, \quad (2)$$

où m est l'indice de la fenêtre temporelle glissante¹ et k l'indice fréquentiel. En pratique, on choisit N_t et N_f afin d'obtenir des spectres temps-fréquence de dimension 640×512 pixels, correspondant respectivement à 640 échantillons temporels et 512 échantillons fréquentiels.

Une fois le spectre temps-fréquence obtenu, celui-ci est converti en image afin d'être utilisé comme entrée du modèle YOLOv8. La conversion consiste à normaliser l'amplitude du spectrogramme, puis à appliquer une conversion logarithmique. Le spectre est ensuite limité dans une plage dynamique allant de -2 à 5 dB, normalisé, puis converti en image 16 bits.

3 Structure et utilisation de YOLOv8

YOLOv8² est l'une des dernières versions de l'architecture YOLO, obtenant des résultats remarquables dans la détection

¹Des fenêtres apodisées (Hann, Hamming, etc.) peuvent aussi être employées.

²Des versions plus récentes (YOLOv9/10) existent.

de signaux LPI selon l'état de l'art [5, 4]. Cette section décrit brièvement la structure de ce modèle, qui, à l'instar de ses prédécesseurs, repose sur trois composantes principales : le **Backbone**, le **Neck** et le **Head**.

Le *Backbone* est chargé d'extraire les caractéristiques pertinentes à partir de l'image d'entrée. Il s'appuie sur une succession de couches de convolution et d'opérations de mise à l'échelle, qui réduisent progressivement les dimensions spatiales tout en augmentant la profondeur de représentation.

Le *Neck*, inspiré des architectures de type *Path Aggregation Network*, assure la fusion et le transfert d'informations entre les différentes échelles de représentation produites par le Backbone. Il intègre des opérations de suréchantillonnage (*upsampling*) et de concaténation afin de préserver la richesse sémantique des caractéristiques.

Enfin, le *Head* constitue la dernière étape du processus de détection. Il exploite les caractéristiques combinées issues du *Neck* pour prédire, pour chaque zone de l'image, la présence d'un objet, les coordonnées de la boîte englobante correspondante, ainsi qu'un score de confiance associé à cette prédiction.

Dans l'approche proposée, nous utilisons YOLOv8s (la version dite *small* de YOLOv8) pour détecter et localiser les émissions radar. Nous ne conservons que les coordonnées des boîtes englobantes prédites ainsi que le score de confiance associé à chaque détection.

Un exemple de détection et des boîtes englobantes associées est illustré en Fig. 1.

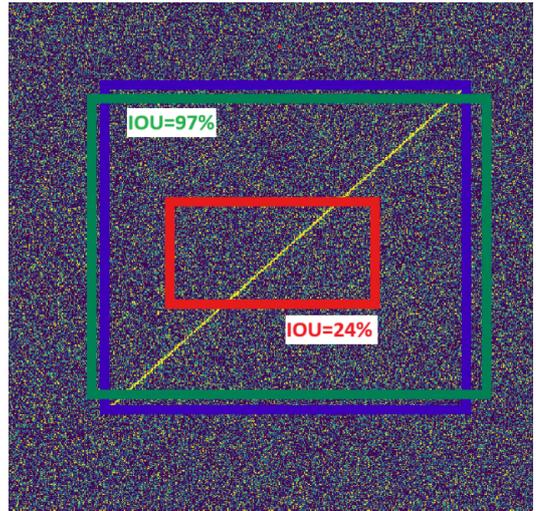


FIGURE 1 : Boîtes englobantes réelles (en bleu) et prédites pour un signal LFM à -10 dB de RSB. En rouge une fausse alarme et en vert une bonne détection.

4 Expérimentations numériques

4.1 Métriques de détection et de fausses alarmes

L'évaluation des performances du modèle YOLOv8 repose sur deux critères principaux : la capacité à localiser correctement les signaux radar à l'aide de boîtes englobantes, et la maîtrise du nombre de fausses alarmes.

Une détection est considérée comme correcte si la boîte prédite présente une intersection sur union (IoU) d'au moins

90% avec la boîte réelle. Ce seuil élevé permet de garantir non seulement la localisation spatiale du signal, mais également la précision de l'estimation de sa dimension.

À l'inverse, toute prédiction qui ne respecte pas cette condition est comptabilisée comme une fausse alarme ou une mauvaise détection. Cela inclut à la fois les boîtes sans correspondance réelle et celles dont le recouvrement est insuffisant. Un exemple illustratif de bonne et de mauvaise détection est présenté en Fig. 1.

4.2 Jeux de données

En l'absence de bases de données réelles accessibles, un simulateur radar a été développé afin de générer l'ensemble des données nécessaires à l'entraînement et à l'évaluation du modèle YOLOv8. Chaque observation est représentée sous forme d'image temps-fréquence normalisée, de dimensions fixes 640×512 pixels.

Le jeu de données couvre une plage de RSB allant de -30 dB à -10 dB. Un total de 200,000 images est généré pour l'apprentissage du modèle, et 20,000 pour son évaluation. Dans chaque ensemble, la moitié des images intègre des signaux d'interférences, modélisés sous forme de signaux continus à phase aléatoire de type DSSS (*Direct Sequence Spread Spectrum*), caractéristiques de certaines transmissions de télécommunication. Leur niveau d'énergie est ajusté afin de maintenir un rapport signal sur interférence (SIR) inférieur de 10 dB au RSB, garantissant ainsi que l'interférence masque systématiquement le signal.

Enfin, les paramètres des formes d'ondes radar sont tirés aléatoirement afin de varier leur largeur de bande, leur durée, leur fréquence porteuse et leur temps d'arrivée. Les labels, quant à eux, contiennent aussi bien les signaux radars d'intérêt que les interférences et sont décrits par la localisation et la dimension de la boîte englobante et par l'index de classification.

4.3 Taux de fausses alarmes

En plus des jeux de données d'apprentissage et d'évaluation, un ensemble de 10 000 images temps-fréquence constituées uniquement de bruit blanc additif gaussien permettent d'évaluer le taux de fausses alarmes (P_{FA}) du modèle. En l'absence de signaux, toute détection produite par le modèle est alors interprétée comme une fausse alarme.

Afin de contrôler ce paramètre, le modèle YOLOv8 associe à chaque détection un score de confiance. Comme proposé dans [4], nous exploitons ce score pour ajuster le seuil de décision et fixer la probabilité de fausse alarme à une valeur cible. Plus le seuil est élevé, plus le modèle se montre sélectif, réduisant ainsi la P_{FA} au détriment d'une perte des performances de détection.

Dans notre étude, le seuil a été fixé de manière à garantir une P_{FA} de 1×10^{-3} . Cette valeur a été déterminée en tenant compte des limitations inhérentes à la taille du jeu de données de bruit utilisée pour l'estimation statistique.

Malgré cette contrainte, ce taux de fausse alarme est considéré comme représentatif dans le cadre de la détection de signaux radar LPI. En effet, les conditions de détection extrêmes propres à ces scénarios rendent acceptable une P_{FA} légèrement plus élevée que dans les systèmes radar classiques, en échange d'une probabilité de détection satisfaisante.

4.4 Détection de signaux inconnus

Cette série d'expérimentations a pour objectif d'évaluer la capacité du modèle YOLOv8 à détecter des formes d'ondes inconnues, en particulier les modulations polytime, absentes des données d'entraînement initiales.

Pour cela, le modèle λ_1 , entraîné sans aucun signal polytime, est confronté à un jeu de test contenant ces modulations. En parallèle, un second modèle, λ_2 , entraîné sur une base enrichie incluant les formes polytime, est utilisé comme référence afin de mesurer l'impact de l'exposition à ces signaux pendant l'apprentissage. On précise qu'ici les interférences sont absentes du jeu de données.

Les résultats présentés en Fig. 2 indiquent que le modèle λ_1 est capable de détecter en partie les signaux polytime, malgré leur absence lors de l'apprentissage. L'écart observé avec le modèle λ_2 est d'environ 2 dB de RSB pour des performances similaires, ce qui demeure acceptable au regard du caractère inédit de ces modulations pour λ_1 .

On observe également que, même à fort RSB, la probabilité de détection plafonne à environ 90%. Cette saturation s'explique en partie par la rigueur de la métrique utilisée : la détection n'est considérée comme valide que si l'erreur de localisation reste inférieure à 10% de l'IoU, ce qui pénalise fortement les erreurs de caractérisation, notamment pour les formes complexes.

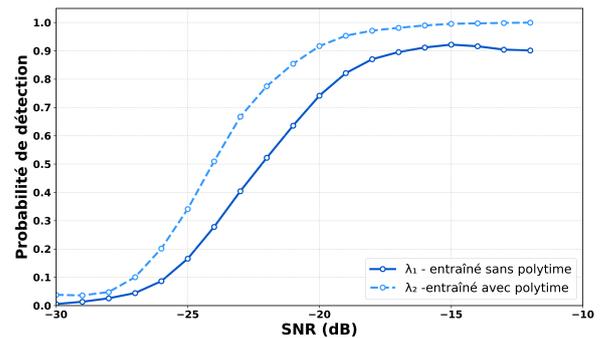


FIGURE 2 : Probabilité de détection en fonction du RSB pour différentes formes d'ondes polytime. Comparaison entre deux configurations de modèles : λ_1 (sans polytime à l'entraînement) et λ_2 (avec polytime à l'entraînement).

Ces observations mettent en évidence une capacité de généralisation partielle du modèle YOLOv8 aux formes d'ondes non vues. L'adoption d'une métrique de détection moins stricte, ou une gestion plus souple des fausses alarmes, pourrait permettre d'exploiter davantage ce potentiel.

4.5 Détection sous interférences

Cette série d'expérimentations vise à évaluer la robustesse du modèle YOLOv8 dans un environnement perturbé par des interférences (cette fois les polytime ne sont pas considérés dans le jeu de données). Deux configurations d'entraînement ont été comparées : le modèle λ_1 , entraîné sur un jeu de données sans interférences, et le modèle λ_3 , entraîné avec des interférences. Chacun de ces modèles a ensuite été testé dans les deux environnements : avec et sans interférences.

La Fig. 3 illustre la probabilité moyenne de détection, toutes formes d'ondes confondues, en fonction du RSB pour ces

quatre scénarios. On observe que lorsque le modèle λ_1 est testé sur un ensemble contenant des interférences, ses performances se dégradent, avec une perte maximale de 4 dB en RSB à détection équivalente. Cette baisse reste toutefois relativement modérée, indiquant que le modèle conserve une certaine capacité de détection malgré les perturbations.

En revanche, en entraînant le modèle en présence d'interférences, cette perte est considérablement réduite. Lorsque λ_3 est testé sur des données avec interférences, la dégradation maximale observée est limitée à 1 dB de RSB par rapport à un test sans interférences. Cet écart réduit confirme que l'entraînement sous interférences confère au modèle une bien meilleure robustesse face à ces perturbations.

Enfin, pour les deux modèles testés sur des ensembles avec interférences, on retrouve une limite asymptotique à 97% de probabilité de détection au-delà de -17 dB. Cette limite est due au fait qu'environ 3% des signaux sont entièrement recouverts par les interférences dans le plan temps-fréquence, le SIR étant si faible qu'ils sont totalement masqués.

Ces résultats sont particulièrement encourageants : ils montrent qu'un entraînement sous interférences permet de préserver une performance de détection élevée malgré des conditions d'acquisition fortement perturbées. Par ailleurs, même en présence de perturbations inédites non rencontrées lors de l'entraînement, les pertes de performance restent modérées, soulignant la capacité du modèle à s'adapter à des environnements variés.

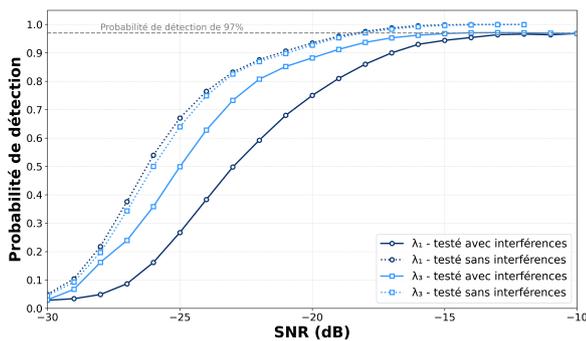


FIGURE 3 : Probabilité moyenne de détection en fonction du RSB. Comparaison entre les modèles λ_1 et λ_3 testés avec et sans interférences.

Des exemples de détection sont illustrés en Fig. 4, où l'on visualise les prédictions du modèle λ_3 sous conditions d'interférences.

5 Conclusion

Cette étude a mis en évidence l'efficacité du modèle YOLOv8 pour la détection de signaux radar LPI, y compris dans des environnements fortement perturbés. L'entraînement en présence d'interférences permet de préserver une haute probabilité de détection en minimisant l'impact des perturbations. De plus, le modèle se montre robuste face à des signaux d'interférences non rencontrés lors de l'apprentissage, et conserve une capacité de détection élevée sur des formes d'ondes inédites, bien que ses performances soient naturellement réduites dans ces cas.

Ces résultats confirment la pertinence de YOLOv8 pour

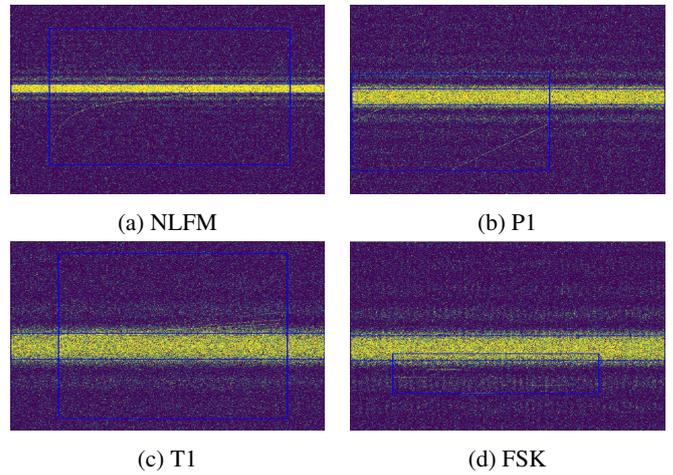


FIGURE 4 : Exemples de détection par le modèle λ_3 à $RSB = -18$ dB et $SIR = -8$ dB, les interférences sont des DSSS de largeur de bande et de fréquence porteuse variable. Les boîtes bleues représentent les prédictions du modèle.

les applications de guerre électronique, où la résilience aux interférences et la capacité d'adaptation aux signaux inconnus sont essentielles.

Références

- [1] P. Pace, Detecting and Classifying Low Probability of Intercept Radar, Second Edition, Artech, 2008.
- [2] D.-H. Park; M.-W. Jeon; D.-M. Shin; H.-N. Kim, LPI Radar Detection Based on Deep Learning Approach with Periodic Autocorrelation Function. Sensors 2023, 23, 8564.
- [3] D. -H. Park, J. -H. Bang, J. -H. Park and H. -N. Kim, "A Fast and Accurate Convolutional Neural Network for LPI Radar Waveform Recognition," 2022 19th European Radar Conference (EuRAD), Milan, Italy, 2022, pp. 89-92.
- [4] R. Mazouz, J. Picheral, S. Marcos, A. Taylor, and J. Bosse, "Low probability of intercept radar signals detection : comparison of a YOLOv8 model and a conventional signal processing method," in Proc. RADAR 2024, Rennes, France, Oct. 2024.
- [5] S. Sarkar, D. Guo, D. Cabric, "RadYOLOLet : Radar Detection and Parameter Estimation Using YOLO and WaveLet", 2023.
- [6] H. Ma, Y. Liao, C. Ren, "Low probability of interception radar overlapping signal modulation recognition based on an improved you-only-look-once version 8 network, Engineering Applications of Artificial Intelligence", 2024.
- [7] E. S. Honorato, M. A. S. Uchida, T. H. S. Silva, and D. F. Wolf, "Out-of-Distribution Object Detection in Autonomous Vehicles With YOLO Model," in IEEE Intelligent Vehicles Symposium (IV), 2022.