

Rapport de comité de suivi de thèse de 3ème année

*Détection, caractérisation et classification de signaux radar LPI
par des méthodes d'intelligence artificielle*

Mazouz Reihan

L2S, CentraleSupélec, Université Paris-Saclay

October 6, 2025

Contents

1	Introduction et rappel du contexte	2
2	Bilan des travaux depuis la version précédente	2
3	Approche conventionnelle	3
3.1	Limites du <i>clustering</i> post-GLRT	3
3.2	Détection et caractérisation par Hidden Markov Models sur le plan TF . .	4
3.2.1	Rappel et motivations	4
3.2.2	Formalisation et choix de modélisation	4
3.2.3	Résultats et limites	5
3.2.4	Améliorations explorées	5
4	Approche Deep Learning	5
4.1	Motivation	5
4.2	Vers une approche multi-résolution	6
4.3	Architecture proposée	6
4.4	Résultats expérimentaux	7
5	Perspectives et Planning previsionnel	9

1 Introduction et rappel du contexte

Les travaux présentés s'inscrivent dans la continuité du CSI précédent, au cours duquel les problématiques de détection, de caractérisation et de classification de signaux radar à faible probabilité d'interception (LPI) ont été formalisées.

Un radar à faible probabilité d'interception (*Low Probability of Intercept*, LPI) vise à réduire la probabilité d'être détecté par un intercepteur passif, tout en maintenant ses capacités de détection de cibles. Pour cela, il met en œuvre des formes d'onde dont l'énergie est volontairement répartie sur une large bande de fréquence et/ou sur une longue durée temporelle, de sorte que la densité spectrale de puissance instantanée reste faible. Les signaux LPI reposent le plus souvent sur des modulations continues de phase ou de fréquence (par exemple des signaux LFM/NLFM ou polyphases), parfois associées à un codage pseudo-aléatoire (radar de bruit) ou à des sauts de fréquence (FH). De plus, les paramètres d'émission de ces radars — tels que la fréquence porteuse, la largeur de bande, la durée d'impulsion, la modulation ou l'intervalle de répétition des impulsions (PRI) — peuvent varier d'une impulsion à l'autre. Cette variabilité intra-trame renforce la difficulté de détection et de caractérisation, en rendant le signal globalement non stationnaire dans le plan temps-fréquence.

Deux approches principales ont été étudiées au cours des travaux précédant le dernier CSI :

- **Un traitement conventionnel**, fondé sur des tests de vraisemblance généralisés (GLRT).
- **Des architectures d'apprentissage profond**, basées sur le modèle de détection d'objets YOLOv8.

Les travaux précédents ont ainsi mis en évidence, d'une part, les limites du GLRT par boîtes dans des contextes bruités sans modélisation structurelle, et d'autre part, la capacité des architectures YOLO à améliorer significativement la robustesse et la généralisation en détection [5].

Objectif de l'année écoulée. L'objectif des recherches menées cette année a été double : (i) **étendre le traitement conventionnel fondé sur le GLRT** pour aller au-delà de la simple détection et viser également la *caractérisation* des signaux (durée, bande, trajectoire TF), et (ii) **renforcer les architectures d'apprentissage profond** en exploitant la *multi-résolution temps-fréquence*, afin de limiter la dépendance au choix unique d'une fenêtre STFT et d'améliorer la robustesse dans des contextes complexes.

2 Bilan des travaux depuis la version précédente

Synthèse

- **Traitement conventionnel.** Plusieurs stratégies de *clustering post-détection* ont été explorées pour passer de la détection à la caractérisation (bande, durée, position

TF). Malgré des prototypes fonctionnels, elles se sont révélées peu convaincantes en pratique: *trop de paramètres empiriques* à régler, *coûts de calcul élevés*, et *dégradation de P_D* sur des scènes difficiles. Nous avons alors ré-orienté la chaîne vers une détection structurée par Hidden Markov Models (HMM) (suivi de chemins dans le plan TF) afin d'exploiter des contraintes de régularité et de continuité.

- **Architecture Deep Learning.** Conception d'un modèle inspiré de YOLO mais conçu nativement pour la multi-résolution TF, appelé **MRS-YOLO** (*Multi-Resolution Spectrogram YOLO*). Le modèle *utilise en entrée* plusieurs STFT de résolutions complémentaires et apprend une fusion hiérarchique pour améliorer la localisation à faible SNR et réduire la sensibilité au choix de fenêtre.

Principales contributions

1. **Chaîne conventionnelle à base de HMM.** Nous avons proposé une approche de détection et de caractérisation reposant sur des *Modèles de Markov Cachés (HMM)* appliqués aux spectrogrammes temps-fréquence. L'idée est de modéliser le signal recherché comme une succession d'états fréquentiels reliés par des transitions contraintes (continuité ou sauts brusques), et d'extraire ensuite le chemin le plus probable via l'algorithme de Viterbi. Cette méthode fournit directement une trajectoire TF du signal, et donc non seulement sa détection mais aussi sa durée et sa bande. Ces travaux ont été validés expérimentalement et ont conduit à une publication à **CAMSAP 2025** [6].
2. **YOLO en contexte complexe.** Nous avons évalué YOLOv8 sur des scénarios intégrant interférences et signaux inconnus, afin d'étudier sa robustesse hors conditions idéales. Cette étude a donné lieu à une communication à la conférence **GRETSI 2025** [4].
3. **Chaîne Deep Learning : MRS-YOLO.** Nous avons développé un modèle de type YOLO adapté nativement aux spectrogrammes multi-résolutions (*MRS-YOLO*). L'approche exploite simultanément plusieurs représentations STFT calculées avec différentes fenêtres, afin de maintenir une bonne résolution en temps et en fréquence. Chaque résolution est traitée par une branche spécifique, puis les informations sont fusionnées pour produire une décision robuste, moins sensible au choix unique de fenêtre. Les résultats montrent une meilleure robustesse à bas SNR et une localisation plus précise qu'avec les YOLO classiques mono-résolution. Deux articles sont issus de ces travaux : un soumis à **ICLR 2026** [7] pour la présentation de MRS-YOLO, et un soumis à **ICASSP 2026** [8].

3 Approche conventionnelle

3.1 Limites du *clustering* post-GLRT

Après un GLRT pixel par pixel du spectre temps-fréquence, plusieurs stratégies de regroupement ont été testées (GLRT+DBSCAN, GLRT+k-NN, GLRT+Extension, GLRT+Paths,

GLRT+Hough Transform). Elles se sont révélées limitées par :

- **Paramètres instables:** seuils et tolérances sensibles au SNR, à la résolution et à la forme d'onde;
- **Complexité élevée:** approches multi-pass coûteuses sur de grandes images temps fréquence;
- **Perte de détection:** fragmentation des chemins courbes ou non linéaires.

Ces limites nous ont conduits à explorer un cadre probabiliste plus robuste, déjà utilisé en traitement radar pour la poursuite de cibles : les **Modèles de Markov Cachés (HMM)**.

3.2 Détection et caractérisation par Hidden Markov Models sur le plan TF

3.2.1 Rappel et motivations

Un HMM [1] modélise une séquence d'états cachés $\{x_t\}$ évoluant selon une chaîne de Markov, et produisant des observations $\{y_t\}$ distribuées selon des lois conditionnelles. Il est entièrement défini par trois éléments : la matrice de transition $A = [a_{ij}]$ qui régit les dynamiques fréquentielles, la matrice d'émission $B = [b_i(y_t)]$ qui relie chaque état fréquentiel aux observations STFT, et enfin la distribution initiale π des états.

Ce cadre est adapté à notre problème car il permet non seulement la **détection** d'un signal mais aussi sa **caractérisation** précise (trajectoire temps-fréquence de la forme d'onde).

3.2.2 Formalisation et choix de modélisation

Émissions. Les probabilités d'émission sont définies à partir des coefficients STFT $Y_t(i)$. Sous hypothèse bruit, ces coefficients suivent une loi gaussienne complexe centrée. Lorsqu'un signal est présent dans une bande i , le modèle introduit un décalage centré autour de la composante du signal. Pour contourner l'inconnue de l'amplitude exacte, une estimation au maximum de vraisemblance est utilisée.

Transitions. Deux modèles de transitions sont conçus en fonction des dynamiques fréquentielles attendues :

- **HMM de continuité** (λ_1): les transitions entre états fréquentiels voisins sont favorisées via un noyau gaussien, caractérisé par un paramètre σ_C contrôlant la variation fréquentielle attendue. Ce modèle capture efficacement les signaux continus (LFM, NLFM, PSK).
- **HMM de discontinuité** (λ_2): conçu pour les signaux à sauts brusques (FSK), il favorise la persistance dans une sous-bande mais autorise des transitions instantanées vers d'autres fréquences. Le paramètre clé p_{stay} est relié au nombre de sauts attendus sur la durée d'émission.

Architecture duale et fusion. Les deux modèles (λ_1, λ_2) sont exécutés en parallèle, et leurs chemins optimaux estimés par l'algorithme de Viterbi. Une étape de **fusion** sélectionne, en cas de recouvrement, le chemin présentant l'énergie maximale. Ce schéma dual permet ainsi de couvrir à la fois les signaux continus et les signaux à sauts de fréquence.

3.2.3 Résultats et limites

Dans des contextes simulés simples, sans interférences ni recouvrement fréquentiel, l'approche HMM atteint des performances comparables à celles de YOLOv8 sur plusieurs formes d'onde et surpasse largement le GLRT cellulaire. Elle offre trois atouts principaux : une sortie unifiée qui combine détection et caractérisation (durée, bande et trajectoire fréquentielle), une interprétabilité directe grâce aux matrices de transition définies sur des bases physiques, et une robustesse accrue aux faibles SNR sans nécessité de données annotées.

Ces résultats restent toutefois limités par le cadre des expériences. Les tests ont été menés dans des conditions simplifiées, sans interférences ni signaux se chevauchant. En présence d'overlap fréquentiel, les HMM classiques privilégient systématiquement le signal le plus puissant, ce qui réduit leur capacité à détecter des émissions concurrentes. De plus, la complexité étant quadratique en fonction du nombre d'états, la résolution fréquentielle reste contrainte.

3.2.4 Améliorations explorées

Pour dépasser ces limites, nous avons proposé de faire tourner plusieurs HMM en parallèle et d'introduire un paramètre d'exclusion dans l'algorithme de Viterbi, de manière à forcer les chemins estimés à diverger entre modèles. Cette stratégie vise à détecter des signaux se recouvrant partiellement en fréquence et à éviter que la détection ne se limite systématiquement au signal le plus puissant.

Malgré cet enrichissement, la méthode reste confinée à certaines classes d'ondes, en particulier celles qui n'occupent qu'une seule bande fréquentielle par colonne temporelle.

4 Approche Deep Learning

4.1 Motivation

Afin d'évaluer la pertinence des approches de Deep Learning en conditions réalistes, nous avons d'abord testé plusieurs modèles récents sur des bases de données plus complexes intégrant recouvrements fréquentiels, interférences et formes d'ondes inédites par rapport à l'entraînement. Dans ce cadre, les performances de détection restent convaincantes, même si une légère dégradation est observée face à ces difficultés supplémentaires.

Avant de traiter spécifiquement le problème multi-résolution, nous avons comparé différentes architectures de l'état de l'art, notamment YOLOv8 à YOLOv12 ainsi que RT-DETR, sur notre base complexe. Les résultats montrent que YOLOv11 constitue un compromis intéressant : sa complexité calculatoire est modérée, sa précision de détection

reste élevée, et son architecture conserve une simplicité proche de celle de YOLOv8. Ces caractéristiques en font un candidat naturel pour servir de base à nos développements.

4.2 Vers une approche multi-résolution

L'analyse des résultats a confirmé une limite importante : la performance des modèles YOLO appliqués aux spectrogrammes STFT dépend fortement de la résolution choisie, qui reflète le compromis entre précision temporelle et fréquentielle. Pour surmonter cette sensibilité et exploiter des indices complémentaires, nous avons conçu une architecture spécifiquement multi-résolution : **MRS-YOLO**.

4.3 Architecture proposée

Les travaux menés cette année ont conduit à la conception du modèle **MRS-YOLO** (*Multi-Resolution Spectrogram YOLO*), une architecture de détection inspirée de YOLOv11 et spécifiquement adaptée à la détection de formes d'onde radar dans le plan temps-fréquence. Cette architecture introduit plusieurs contributions majeures : (i) l'intégration explicite de plusieurs spectrogrammes, de résolutions différentes, en entrée d'un modèle de détection d'objets, (ii) un bloc d'attention temps-fréquence permettant de réduire le coût de calcul tout en renforçant la détection, (iii) une architecture de fusion multi-résolution intégrée au backbone, et (iv) une évaluation approfondie sur une base de données réaliste comprenant des interférences et des signaux entrelacés.

L'architecture repose sur un principe simple : chaque spectrogramme d'entrée, calculé à une résolution donnée, est traité par une branche de type *backbone*. Ces backbones sont conçus pour ramener chaque spectrogramme à une représentation de dimension commune, malgré des rapports temps/fréquence très différents. Pour cela, nous utilisons un **down-sampling anisotrope**, où les strides appliqués sur l'axe temps et sur l'axe fréquence sont ajustés en fonction des dimensions initiales du spectrogramme. Ainsi, qu'il s'agisse d'un spectre très « large en temps » ou au contraire « fin en fréquence », sa sortie est normalisée sur une grille homogène, comparable entre branches.

Un point clé de l'architecture réside dans l'introduction du **bloc d'attention temps-fréquence (TF-Attn)**, inséré au sein des backbones et de la neck. Contrairement aux mécanismes d'attention classiques opérant sur des cartes spatiales, le TF-Attn exploite les dépendances séparées entre les axes temps et fréquence à l'aide de convolutions séparables et légères. Ce schéma permet de renforcer sélectivement les structures spectro-temporelles pertinentes tout en réduisant la complexité computationnelle, offrant ainsi un compromis favorable entre précision et coût.

Les représentations issues des différents backbones sont ensuite fusionnées hiérarchiquement au sein d'une **architecture de fusion multi-résolution intégrée au backbone**. Cette stratégie de fusion, basée sur un bloc d'attention synergétique spatiale-canal (SCSA), permet de combiner de manière cohérente les informations complémentaires issues de chaque échelle temps-fréquence. L'ensemble assure une meilleure robustesse aux variations de résolution et de structure spectrale, tout en maîtrisant la complexité du modèle.

Enfin, la fusion alimente une tête de détection **anchor-free** de type YOLOv11, utilisant la régression par **Distribution Focal Loss (DFL)**. L'ensemble de l'architecture est illustré à la Fig. 4.1, qui met en évidence les branches multi-résolution, les blocs d'attention TF-Attn et SCSA, ainsi que le schéma de fusion hiérarchique aboutissant à la tête de détection.

Le modèle a été évalué sur une base de données enrichie incluant des interférences et des signaux entrelacés, afin de tester la robustesse de l'approche dans des conditions proches des scénarios opérationnels. Les performances comparatives sont présentées dans le Tableau 4.1.




Figure 4.1: Architecture globale du modèle **MRS-YOLO**, intégrant les branches multi-résolution, le bloc TF-Attn, le module de fusion SCSA et la tête de détection YOLOv11.

4.4 Résultats expérimentaux

Pour évaluer MRS-YOLO, nous avons utilisé cinq spectrogrammes en parallèle, calculés avec des tailles de fenêtre $L \in 128, 256, 512, 1024, 2048$ échantillons, correspondant à des représentations aux compromis temps/bande complémentaires. Chaque scène de la base de test est donc représentée par cinq vues multi-résolutions.

Les résultats mettent en évidence plusieurs bénéfices. MRS-YOLO offre une meilleure stabilité des prédictions aux très faibles SNR (jusqu'à -15 dB) et réduit significativement les faux positifs liés aux artefacts de fenêtre. Les localisations temporelles et fréquentielles sont plus précises, notamment pour les signaux complexes tels que les NLFM ou les codes de Costas. Comme le montre le Tableau 4.1, le modèle surpasse l'ensemble des versions mono-résolution ainsi que l'« oracle-OR » combinant idéalement les meilleurs détecteurs séparés à chaque résolution. Ces résultats confirment la pertinence d'une approche native multi-résolution pour la détection robuste de signaux LPI en environnement dégradé.

Table 4.1: Résultats globaux en moyenne de précision (mAP) et rappel pour différents seuils de SNR.

Model	Params (M)	GFLOPs	mAP50	mAP50:95	Recall _{SNR$\geq$-10 dB}	Recall _{SNR$\geq$0 dB}	Recall _{SNR$\geq$10 dB}
Oracle-OR	5×2.38	5×1.71	0.40	0.37	0.58	0.76	0.88
1024x64	2.38	1.71	0.14	0.11	0.37	0.52	0.64
512x128	2.38	1.71	0.25	0.21	0.49	0.66	0.79
256x256	2.38	1.71	0.32	0.27	0.53	0.69	0.82
128x512	2.38	1.71	0.30	0.25	0.39	0.51	0.62
64x1024	2.38	1.71	0.20	0.15	0.19	0.24	0.29
MRS-YOLO	2.29	2.77	0.54	0.44	0.62	0.75	0.83

5 Perspectives et Planning prévisionnel

- **HMMs multi-pistes et multi-résolutions** : nous avons exploré des variantes intégrant une exclusion mutuelle souple entre chemins parallèles. Ces travaux pourraient être enrichis par une étape de classification des signaux détectés, ouvrant la voie à une publication spécifique. Néanmoins, ces approches restent limitées par la complexité calculatoire, quadratique en nombre d'états, et par la restriction aux formes d'ondes détectables par ce cadre.
- **Améliorations Deep Learning** : plusieurs directions apparaissent prometteuses. D'abord, le Non-Maximum Suppression (NMS) utilisé dans YOLO n'est pas optimal en contexte radar. Deux options sont envisageables : adopter un modèle sans NMS (YOLO10, YOLO26 annoncé) ou concevoir un NMS cohérent exploitant la redondance des signaux radar (corrélation croisée, têtes d'attention dédiées). Ensuite, la caractérisation pourrait être raffinée en repassant dans le domaine IQ après la détection, ou bien via des modèles de segmentation temps-fréquence qui extrairaient directement les structures complètes du signal.

Planning prévisionnel (Octobre 2025 – Mai 2026)

- **Octobre – Décembre 2025** : Consolidation des résultats expérimentaux sur MRS-YOLO, avec génération de nouvelles expériences pour enrichir l'article soumis à ICLR 2026 (phase de revue prévue en novembre-décembre). Les résultats porteront à la fois sur la base interne simulée et sur des bases de données publiques (radar ou non), afin de démontrer la généricité du modèle. En parallèle, des résultats complémentaires seront obtenus sur TF-ATTN-YOLO (ICASSP 2026) pour illustrer l'apport de l'attention temps-fréquence par rapport aux YOLO classiques. **Poursuite des travaux sur YOLO et début d'un axe exploratoire sur les perspectives identifiées : amélioration du NMS pour la détection radar et enrichissement de la caractérisation (retraitement IQ ou segmentation temps-fréquence).**
- **Janvier – Mars 2026** : Rédaction du manuscrit de thèse, envoi aux rapporteurs pour fin-mars 2026.
- **Avril – Mai 2026** : **Rédaction des publications, préparation de la soutenance et écriture de la documentation destinée à l'entreprise.**

Bibliography

- [1] L. Rabiner, “A Tutorial on Hidden Markov Models,” *Proceedings of the IEEE*, 1989.
- [2] H. V. Poor, *An Introduction to Signal Detection and Estimation*, ch. on sequential detection.
- [3] J. Terven, D. Cordova-Esparza, “A Comprehensive Review of YOLO Architectures in Computer Vision,” 2023.
- [4] R. Mazouz, J. Picheral, A. Taylor, J. Bosse, S. Marcos, “Détection de signaux radar LPI par YOLO en présence d’interférences et de signaux inconnus,” *GRETSI*, 2023. [En ligne] : <https://gretsi.fr>
- [5] R. Mazouz, J. Picheral, S. Marcos, A. Taylor, J. Bosse, “Low Probability of Interception Radar Signals Detection, Comparison of a YOLOv8 Model and a Conventional Signal Processing Method,” *2024 International Radar Conference (RADAR)*, pp. 1–6, IEEE, Oct. 2024.
- [6] R. Mazouz, J. Picheral, S. Marcos, A. Taylor, J. Bosse, “A Dual-HMM Design for Detection of LPI Radar Signals,” *CAMSAP 2025*.
- [7] R. Mazouz, J. Picheral, S. Marcos, A. Taylor, J. Bosse, “MRS-YOLO: A YOLO model for signal detection in multi-resolution spectrograms,” soumis à ICLR 2026.
- [8] R. Mazouz, J. Picheral, A. Taylor, J. Bosse, S. Marcos, C. Belafdil, “Multi-Resolution Spectrograms Detection of LPI RADAR with Time-Frequency Attention augmented YOLO,” soumis à ICASSP 2026.

Appendix

Articles disponibles en ligne

- R. Mazouz, J. Picheral, A. Taylor, J. Bosse, S. Marcos, “Détection de signaux radar LPI par YOLO en présence d’interférences et de signaux inconnus,” *GRETSI 2023*. [PDF en ligne] : https://gretsi.fr/data/colloque/pdf/2025_mazouz1579.pdf
- R. Mazouz, J. Picheral, S. Marcos, A. Taylor, J. Bosse, “Low Probability of Interception Radar Signals Detection, Comparison of a YOLOv8 Model and a Conventional Signal Processing Method,” *2024 International Radar Conference (RADAR)*, IEEE. [En ligne] : https://ieeexplore.ieee.org/abstract/document/10993803?casa_token=MJC30EFeLHgAAAAA:6-ss3B11AHseu7MY_ZhsA8qT25Ep9-g7cxs7mSUPcsWzjWRybsaAJ9uSE
- R. Mazouz, J. Picheral, S. Marcos, A. Taylor, J. Bosse, “MRS-YOLO: A YOLO model for signal detection in multi-resolution spectrograms,” soumis à *ICLR 2026*. [OpenReview] : <https://openreview.net/forum?id=ehbcigJ6wH¬eId=ehbcigJ6wH>

Articles soumis

Les versions PDF des articles suivants, actuellement soumis et/ou acceptés, seront fournies directement en annexe du rapport :

- “A Dual-HMM Design for Detection of LPI Radar Signals,” *CAMSAP 2025*.
- “Multi-Resolution Spectrograms Detection of LPI RADAR with Time-Frequency Attention augmented YOLO,” soumis à *ICASSP 2026*.

Documents complémentaires

Un document interne intitulé “**Document Atos récapitulant les travaux réalisés jusqu’au 1er janvier 2025**” est également fourni dans cette annexe.