

Rapport de comité de suivi de thèse de 2ème année

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

Mazouz Reihan

L2S, CentraleSupélec, Université Paris-Saclay

December 12, 2024

Contents

1	Introduction et rappel du contexte de cette thèse	2
2	Formalisation du problème de détection, caractérisation et classification des signaux LPI	4
2.1	Détection des Signaux LPI	4
2.2	Caractérisation des Signaux LPI	4
2.3	Classification des Signaux LPI	5
2.4	Représentation Temps-Fréquence et PSNR	5
3	Comparaison d'une méthode conventionnelle et d'une méthode de Deep Learning	7
3.1	Détection par YOLOv8	7
3.2	Méthode Conventionnelle : Détecteur GLRT	8
3.3	Résultats et Comparaison des Performances	8
3.4	Conclusion de la Comparaison	9
4	Travaux actuels et perspectives futures	11
A	Annexes	13
A.1	Détails du Détecteur GLRT	13
A.2	Calculs pour le Détecteur à Grille	14
A.3	Performances des Différents Modèles YOLO sur le CocoDataset	15
A.4	Modèle Intégrant Plusieurs Résolutions de STFT	15

1. Introduction et rappel du contexte de cette thèse

La détection et l'interception de signaux radar sont des éléments essentiels de la guerre électronique, qui est au cœur des stratégies militaires contemporaines. Dans ce domaine, il est crucial de pouvoir capter et analyser les émissions radar ennemies pour des activités de renseignement, de brouillage, ou de mise en place de contre-mesures. Avec l'évolution rapide des technologies radar, ces signaux deviennent de plus en plus sophistiqués, rendant leur détection et interception par les systèmes de surveillance existants extrêmement complexe. Il est donc impératif de développer de nouvelles méthodes capables de relever ces défis. Cette thèse s'inscrit précisément dans cette perspective, en visant à proposer des solutions innovantes pour la détection, la caractérisation et la classification des signaux radar LPI (Low Probability of Interception).

Les signaux LPI sont conçus pour échapper à la détection, par exemple en dispersant leur énergie sur de larges bandes de fréquences et de longues durées d'émission, ce qui réduit leur densité spectrale de puissance instantanée et les rend difficilement discernables du bruit ambiant. Cette furtivité complexifie la tâche des systèmes de surveillance passive traditionnels, qui reposent sur des hypothèses simplificatrices ou des connaissances a priori. Les méthodes conventionnelles de détection, telles que l'intégration temps-fréquence, le seuillage d'autocorrélation, ou l'utilisation de détecteurs de filtres en quadrature, tentent de tirer parti de caractéristiques supposées des signaux tel qu'illustré sur la Figure 1.1. Cependant, ces techniques se révèlent souvent limitées face à la complexité et à l'évolution des signaux LPI modernes, mettant en évidence la nécessité de développer des approches plus robustes et adaptatives.




Figure 1.1: Diagramme de bloc comparant la chaîne de détection conventionnelle avec la chaîne basée sur le Deep Learning.

L'apparition des techniques d'apprentissage profond (Deep Learning) ouvre de nouvelles perspectives pour surmonter ces limitations. En permettant le traitement direct des données brutes sans dépendre de l'extraction préalable de caractéristiques ou d'hypothèses rigides sur les propriétés du signal, les réseaux de neurones convolutifs (CNNs) offrent une capacité unique à extraire des informations pertinentes à partir de données hautement dimensionnelles et complexes. Ces modèles, qui comportent de nombreuses couches de traitement non linéaire, se sont montrés particulièrement efficaces pour les tâches de

détection dans des environnements incertains, notamment dans le domaine de la vision par ordinateur. De récentes études ont démontré que les approches basées sur les CNNs peuvent obtenir des résultats prometteurs pour la détection de signaux LPI [1–3].

Cette thèse vise donc à développer de nouvelles approches basées sur l'apprentissage profond pour améliorer la détection, la caractérisation et la classification des signaux radar LPI. En combinant des techniques de traitement du signal avec des modèles de Deep Learning, l'objectif académique est de repousser les limites des méthodes existantes, tout en offrant des solutions robustes et adaptatives adaptées aux besoins industriels dans des environnements de guerre électronique de plus en plus complexes. Ce travail de recherche se concentre sur l'élaboration de méthodes innovantes capables de s'adapter à la diversité des signaux LPI et de surmonter les défis posés par leur furtivité et leur variabilité.

2. Formalisation du problème de détection, caractérisation et classification des signaux LPI

2.1 Détection des Signaux LPI

Le problème de détection des signaux LPI consiste à identifier la présence d'un signal radar dans un environnement bruité, sans connaissance a priori des paramètres du signal émis. Le signal reçu par un intercepteur passif peut être modélisé comme suit :

$$s(t) = x(t) \cdot A(t) + n(t) = A(t) \exp j(2\pi f(t)t + \Phi(t)) + n(t) \quad (2.1)$$

où $x(t)$ est le signal radar émis, et $n(t)$ représente le bruit blanc gaussien dans le canal de réception. L'amplitude du signal $A(t)$ est une fonction dépendante du temps indiquant que le signal radar n'est présent que sur une partie de l'acquisition. Les termes $f(t)$ et $\Phi(t)$ désignent respectivement la fréquence porteuse et la phase instantanées.

La détection consiste à déterminer si le signal $x(t)$, modulé par $A(t)$, est présent ou non dans la séquence d'acquisition. En d'autres termes, il s'agit de déterminer si une impulsion radar est présente ou absente.

2.2 Caractérisation des Signaux LPI

Une fois la détection effectuée, la caractérisation du signal LPI détecté est essentielle pour extraire ses propriétés spécifiques. Ces caractéristiques sont cruciales pour déterminer la nature du signal et adapter les stratégies de contre-mesures. Les caractéristiques importantes des signaux LPI comprennent :

- **Bande passante** : La largeur de la bande fréquentielle occupée par le signal.
- **Durée d'émission** : La durée pendant laquelle le signal est actif dans la fenêtre d'acquisition.
- **Localisation temporelle** : Le moment précis de l'émission du signal dans le domaine temporel.
- **Localisation fréquentielle** : La position de l'énergie du signal dans le domaine fréquentiel.

La caractérisation précise de ces paramètres permet de différencier les signaux et d'optimiser la réponse du système de guerre électronique.

2.3 Classification des Signaux LPI

La classification des signaux LPI consiste à attribuer à chaque signal détecté et caractérisé une étiquette correspondant à son type de modulation ou à sa nature. Cette étape est cruciale pour identifier le type exact de signal et déterminer la meilleure réponse. Les différentes formes d'ondes considérées dans cette étude incluent :

- **Modulations à fréquence linéaire (LFM)** : Signaux dont la fréquence varie linéairement avec le temps.
- **Modulations à fréquence non linéaire (NLFM)** : Signaux dont la fréquence varie de manière non linéaire.
- **Modulations à codes polyphases** : Types de signaux utilisant des codes de phase spécifiques tels que les codes P1, P2, P3, P4 ou encore les codes de Frank et de Barker.
- **Modulations à codes de fréquence** : Signaux dont les fréquences varient de façon discrète tels que les codes de Costas.

Ces formes d'ondes peuvent se présenter sous forme d'impulsions ou d'ondes continues (CW), et leur identification correcte est essentielle pour l'efficacité de l'analyse et des contre-mesures en guerre électronique.

2.4 Représentation Temps-Fréquence et PSNR

Afin d'extraire le signal du bruit, nous avons choisi d'utiliser la Transformée de Fourier à Court Terme (STFT) car ne présupposant aucune caractéristiques temps-fréquence du signal, elle disperse l'énergie du bruit de façon égale sur chacune de ses composantes spectrales. Le signal ayant une durée et une largeur de bande finie, il sera plus concentré sur le plan temps-fréquence que le bruit. La STFT est définie par :

$$Z[t_i, f_j] = \sum_{k=1}^N s[t_k] \cdot w[t_k - t_i] \cdot e^{-i2\pi k \frac{f_j}{f_s}} \quad (2.2)$$

où $w[t_k - t_i]$ est la fenêtre d'acquisition temporelle et f_s la fréquence d'échantillonnage.

Pour évaluer la qualité de la représentation temps-fréquence du signal par rapport au bruit, nous utilisons le Peak Signal-to-Noise Ratio (PSNR). Le PSNR mesure le rapport entre la puissance maximale du signal et la puissance moyenne du bruit dans une image temps-fréquence. Il est défini par :

$$PSNR = 10 \log_{10} \left(\frac{\max_{f,s} |Z_s(t, f)|^2}{\frac{1}{T_w B_w} \sum_{i=1}^{N_t} \sum_{j=1}^{N_f} |Z_b(t_i, f_j)|^2} \right) \quad (2.3)$$

où $Z_s(t, f)$ et $Z_b(t_i, f_j)$ représentent respectivement les cellules de l'image temps-fréquence du signal et du bruit. N_t et N_f sont respectivement le nombre d'échantillons

temporels T_w dans la fenêtre d'acquisition et le nombre de bandes de fréquence dans sa largeur de bande B_w .

L'image après normalisation du spectre est particulièrement adaptée aux approches de Deep Learning et notamment aux algorithmes Yolo [2].

3. Comparaison d'une méthode conventionnelle et d'une méthode de Deep Learning

Nous avons mené une comparaison entre une méthode conventionnelle basée sur le Test de Rapport de Vraisemblance Généralisé ou GLRT (Generalized Likelihood Ratio Test) et une méthode de Deep Learning basée sur l'architecture YOLOv8. Cette comparaison a donné lieu à la publication d'un article [6], car elle n'était pas présente dans l'état de l'art, offrant ainsi une contribution originale aux recherches actuelles. La Figure 3.1 ci-dessous illustre la chaîne de détection conventionnelle et Deep Learning mise en place, qui seront toutes deux détaillées dans la suite.




Figure 3.1: Diagramme de bloc d'une méthode de détection conventionnelle et celle de détection par Deep Learning.

3.1 Détection par YOLOv8

Au début de cette thèse, YOLOv8 était la version la plus récente de l'architecture YOLO, largement utilisée pour les tâches de détection d'objets et atteignant les résultats de l'état de l'art sur des bases de données publiques de détection d'objets tel que Cocodataset [4, 5]. YOLOv8, comme ses prédécesseurs, est structuré en trois parties principales : le **Backbone**, le **Neck**, et la **Head**.

- **Backbone** : Extraire les caractéristiques de l'image d'entrée de taille fixe.
- **Neck** : Connecte les informations entre les différentes parties extraites par le Backbone.
- **Head** : Prédit les classes d'objets, les boîtes englobantes et les scores de confiance.

Une représentation simplifiée de cette architecture est présentée en Figure 3.2.

Dans le cadre de cette étude, YOLOv8 a été adapté pour détecter et localiser les émissions radar dans des images temps-fréquence. Le modèle a été entraîné sur une base




Figure 3.2: Architecture du modèle YOLOv8.

de données de 10 000 signaux par forme d'onde, avec un SNR variant entre -20 dB et 0 dB.

3.2 Méthode Conventionnelle : Détecteur GLRT

Pour comparer les performances du modèle YOLOv8, nous avons développé un algorithme de détection basé sur le Test de Rapport de Vraisemblance Généralisé (GLRT). Ce détecteur regroupe les cellules de l'image temps-fréquence (TFI) sous forme de boîtes et calcule un ratio de vraisemblance pour déterminer si un signal est présent ou non dans chaque boîte. Le GLRT est particulièrement efficace lorsque la proportion de cellules de signal est élevée par rapport aux cellules de bruit.

Le GLRT maximise la probabilité de détection pour une fausse alarme donnée. Le test compare la vraisemblance que les données proviennent uniquement du bruit à celle que les données contiennent un signal plus du bruit. Le seuil de détection est fixé pour obtenir une probabilité de fausse alarme souhaitée. Pour rester cohérent avec la méthode de comparaison avec YOLOv8, nous avons divisé la TFI en grilles de différentes tailles (8*8, 16*16, et 32*32 pixels) et appliqué le test GLRT sur chacune d'elles. La probabilité agrégée de fausse alarme et de détection est calculée en considérant chaque grille comme un essai indépendant. Les expressions mathématiques détaillées et les calculs de probabilités sont fournis en Annexe A.1.

3.3 Résultats et Comparaison des Performances

Pour comparer les performances de détection des deux algorithmes, nous avons fixé la même probabilité de fausse alarme pour le modèle YOLOv8 et le détecteur GLRT, à savoir 1×10^{-3} . Ce seuil est considéré comme réaliste pour la détection de signaux LPI, où les taux de fausse alarme sont plus élevés que dans les scénarios classiques.

Pour le modèle YOLOv8, la probabilité de fausse alarme s'est réglée de façon empirique en seillant sur le score de confiance d'appartenance d'un objet à une boîte englobante. Un seuil de confiance de 0,28 a été utilisé pour atteindre cette probabilité de fausse alarme sans réduction significative de la probabilité de détection pour chaque forme d'onde. La

Figure 3.3 présente la probabilité de fausse alarme du modèle YOLOv8 en fonction des scores de confiance, ainsi que la probabilité de détection des différentes formes d'onde.




Figure 3.3: Probabilité de fausse alarme (P_{FA}) et de détection (P_D) de YOLOv8 par forme d'onde en fonction du seuil de confiance.

Comparé au détecteur GLRT, le modèle YOLOv8 montre une meilleure capacité à détecter les signaux LPI à faible PSNR (Peak Signal-to-Noise Ratio), tout en étant moins sensible à la forme d'onde émise. Comme illustré dans la Figure 3.4, le modèle YOLOv8 est capable de détecter des impulsions à un PSNR très faible, même lorsque le détecteur conventionnel échoue. Cependant, il est important de relativiser face aux résultats du détecteur conventionnel qui pourrait être amélioré en intégrant sur des directions privilégiées.

La dispersion des résultats par forme d'onde est faible pour le modèle YOLOv8 par rapport au détecteur conventionnel. En général, le modèle YOLOv8 est capable de détecter des impulsions à un PSNR de 0 dB pour les modulations LFM, SFM, et à décalage de phase, un seuil où même un annotateur humain est incapable de distinguer les signaux dans l'image temps-fréquence (Figure 3.5).

3.4 Conclusion de la Comparaison

Les résultats montrent que le modèle YOLOv8 est plus performant que le détecteur à grille GLRT pour la détection de signaux LPI, surtout à des PSNR faibles. Cette étude a mis en évidence l'efficacité des approches de Deep Learning pour la détection de signaux LPI, justifiant la nécessité d'une exploration plus approfondie dans ce domaine.




Figure 3.4: Comparaison de la probabilité de détection en fonction du PSNR entre YOLOv8 en bleu et le détecteur conventionnel (CD) en vert.




Figure 3.5: Une illustration des détections de YOLOv8 en bleu par rapport à la vraie localisation en vert en fonction du PSNR.

4. Travaux actuels et perspectives futures

Les travaux actuels et les perspectives futures de cette thèse se concentrent sur plusieurs axes de recherche pour améliorer la détection, la caractérisation et la classification des signaux radar LPI.

Travaux actuels :

- **Mettre à jour notre modèle de détection :** Yolov8 était au démarrage de cette thèse le modèle le plus récent de type Yolo. Depuis, certains nouveaux modèles (Yolov9 et Yolov10) semblent avoir de meilleurs résultats sur les bases de données publiques de détection d'objet (A.3). Dans cette optique, nous appliquons les nouvelles architectures à notre problème.
- **Limiter l'impacte de la résolution du spectrogramme :** En fonction des caractéristiques temps fréquence du signal à détecter, certaines résolutions de spectrogrammes sont plus pertinentes que d'autres. Dans cette optique nous avons conceptualisé un prétraitement permettant à notre modèle de Deep Learning de considérer plusieurs résolutions de STFT par donnée. Voir A.4.

Perspectives futures :

- **Caractérisation et classification des signaux LPI :** S'étant principalement focalisé sur la détection de signaux LPI, il nous manque une étude approfondie de la caractérisation et de la classification.
- **Complexification des acquisitions radar :** Intégration de scénarios avec plusieurs signaux par acquisition, tels que des trains d'impulsions, des signaux entremêlés et des interférences (ex. : télécom) pour tester la robustesse des modèles dans des environnements plus réalistes.
- **Exploration de nouvelles transformées temps-fréquence :** Étudier l'utilisation d'autres types de transformées (ondelettes, Wigner-Ville, etc.) pour améliorer la séparation du signal du bruit dans des environnements à faible SNR.
- **Optimisation de l'architecture des modèles Deep Learning :** Adapter les architectures de modèles pour mieux répondre aux spécificités des signaux RF (radiofréquence), avec des modifications potentielles des couches de convolution et des mécanismes d'attention. On se pose notamment la question : Comment peut-on profiter de la redondance d'informations entre les impulsions d'un même émetteur afin d'améliorer nos performances en utilisant un modèle de Deep Learning.

Conclusion : Cette première année de thèse a permis d'introduire le sujet des signaux LPI et, à travers notre publication, de contribuer à l'état de l'art en comparant des méthodes de détection conventionnelles et de Deep Learning. De nombreuses perspectives de recherche s'ouvrent pour approfondir nos résultats de détection, de caractérisation et de classification.

Bibliography

- [1] Park, D.-H.; Jeon, M.-W.; Shin, D.-M.; Kim, H.-N. LPI Radar Detection Based on Deep Learning Approach with Periodic Autocorrelation Function. *Sensors* 2023, 23, 8564.
- [2] 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.
- [3] S. Sarkar, D. Guo, D. Cabric, "RadYOLOLet: Radar Detection and Parameter Estimation Using YOLO and WaveLet", 2023.
- [4] J. Terven, D. Cordova-Esparza, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS" 2023.
- [5] D. Reis, J. Kupec, J. Hong, A. Daoudi, "Real-Time Flying Object Detection with YOLOv8", 2023.
- [6] 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", *RadarConf*, 2024.
- [7] A. van den Bos, "The multivariate complex normal distribution-a generalization," in *IEEE Transactions on Information Theory*, vol. 41, no. 2, pp. 537-539, March 1995.
- [8] H. V. Poor, "An Introduction to Signal Detection and Estimation", chap III,B, p53.

A. Annexes

A.1 Détails du Détecteur GLRT

Soit $\mathbf{Z}$ un vecteur composé de N cellules STFT, établi dans (2.2), suivant une distribution normale complexe gaussienne blanche circulaire : $\mathbf{Z} \sim \mathbb{CN}(\mathbf{M}_z, \mathbf{\Gamma})$. $\mathbf{M}_z$ est la moyenne et $\mathbf{\Gamma}$ la matrice de covariance définie dans [7].

L'objectif est de déterminer si un signal déterministe avec des paramètres inconnus est présent ou absent à tous les points de $\mathbf{Z}$ ou, selon (2.1), si $s(t) \neq n(t)$.

Le test d'hypothèse binaire suivant est considéré :

- H_0 : $\mathbf{M}_z = \mathbf{0}_N$
- H_1 : $\mathbf{M}_z \neq \mathbf{0}_N$

Les fonctions de densité de probabilité pour les hypothèses H_0 et H_1 sont définies comme suit :

$$f_0(\mathbf{Z}) = \frac{1}{\pi^N |\mathbf{\Gamma}|^N} \exp(-\mathbf{Z}^* \mathbf{\Gamma}^{-1} \mathbf{Z})$$

$$f_1(\mathbf{Z}) = \frac{1}{\pi^N |\mathbf{\Gamma}|^N} \exp(-(\mathbf{Z} - \mathbf{M}_z)^* \mathbf{\Gamma}^{-1} (\mathbf{Z} - \mathbf{M}_z))$$

$\mathbf{M}_z$ étant inconnu, nous appliquons le test de maximum de vraisemblance généralisé (GLRT). L'hypothèse H_1 est sélectionnée si le rapport de vraisemblance dépasse un seuil γ :

$$L(\mathbf{Z}) = \frac{\max_{\mathbf{M}_z} f(\mathbf{Z}; H_1)}{f(\mathbf{Z}; H_0)} > \gamma$$

Dans cette étude, nous avons utilisé une fenêtre sans chevauchement w dans (2.2) pour avoir une indépendance statistique entre les cellules STFT dans $\mathbf{Z}$. Ainsi, $\mathbf{\Gamma} = E_w \sigma^2 \mathbf{I}_N$, où E_w est l'énergie de la fenêtre STFT w , et σ^2 est la variance du bruit.

La probabilité de maximum de vraisemblance pour $\mathbf{M}_z$ sous H_1 est atteinte pour $\mathbf{M}_z = \mathbf{Z}$.

Finalement :

$$L(\mathbf{Z}) > \gamma \iff |\mathbf{Z}| > \sqrt{\frac{\log(\gamma) E_w \sigma^2}{N}} = \gamma'$$

Les probabilités de fausse alarme (P_{FA}) et de détection (P_D) sont calculées selon les distributions statistiques des variables sous les hypothèses H_0 et H_1 . Pour plus de détails, voir [8].

Sous H_0 , $|\mathbf{Z}|^2$ suit une distribution centrée χ^2 avec $2N$ degrés de liberté et une variance $\frac{\sigma^2}{2N}$.

La probabilité de fausse alarme est donnée par :

$$P_{FA} = P\left(\frac{\gamma'}{\sigma^2}, N\right) \quad (\text{A.1})$$

Où P est la fonction gamma régularisée.

Sous H_1 , $|\mathbf{Z}|^2$ suit une distribution non centrée khi-carré avec $2N$ degrés de liberté. P_D est sa fonction de densité de probabilité cumulée à γ' .

A.2 Calculs pour le Détecteur à Grille

Pour rester cohérent avec notre méthode de comparaison avec le modèle YOLOv8, notre détecteur final est une combinaison de détections GLRT par boîte sur chaque ancre du modèle. Le TFI est ainsi divisé en grilles de 16, 32 et 64, que nous nommerons G3, G4, G5 (correspondant à P3, P4, P5), et sur chacune de ces grilles, le GLRT par boîte est appliqué.

Nous considérons qu'il y a une fausse alarme s'il existe une grille dont le rapport de vraisemblance dépasse le seuil et qui n'intersecte pas avec la boîte englobante du signal. Inversement, si l'une des grilles qui intersecte la boîte englobante du signal a son rapport de vraisemblance au-dessus du seuil, nous considérons qu'il s'agit d'une détection.

La probabilité agrégée de fausse alarme P_{aFA} sur plusieurs grilles est modélisée par une distribution binomiale, chaque grille étant considérée comme un essai où une fausse alarme, donnée dans (A.1), peut se produire indépendamment. La probabilité totale d'au moins une fausse alarme se produisant dans l'une des grilles est donnée par :

$$P_{aFA} = 1 - \prod_{i=3}^5 (1 - P_{FA,G_i})^{N_i} \quad (\text{A.2})$$

où N_i est le nombre total de grilles de bruit dans G_i et P_{FA,G_i} est la probabilité de fausse alarme pour une seule grille de G_i .

La probabilité de détection pour les grilles agrégées est la suivante :

$$P_{aD} = 1 - \prod_{i=3}^5 P_{0,G_i}$$

où P_{0,G_i} est la probabilité qu'aucune grille ne dépasse le seuil :

$$P_{0,G_i} = \prod_{j=0}^{N_i} (1 - P_{D,G_i}(\mu_{j,G_i}, P_{FA,G_i}))$$

Ici, P_{D,G_i} représente la probabilité de détecter un signal dans G_i composé de N_i grilles. Cette probabilité dépend de la probabilité de fausse alarme spécifiée, ainsi que de l'énergie du signal dans la grille. Cela dépend à son tour de divers facteurs, notamment de la forme d'onde, de la puissance du signal et des paramètres utilisés pour le fenêtrage STFT. Cette probabilité de détection sera estimée numériquement.

A.3 Performances des Différents Modèles YOLO sur le CocoDataset

La Figure A.1 montre les performances des différentes versions des modèles YOLO (YOLOv3, YOLOv4, YOLOv5, YOLOv8, etc.) sur la base de données publique CocoDataset. Ces performances sont mesurées en termes de précision moyenne (mAP) en fonction de la vitesse d'inférence (FPS) et du nombre de paramètres.




Figure A.1: Performances des différents modèles YOLO sur le CocoDataset en termes de précision moyenne (mAP) et de vitesse d'inférence (FPS).

A.4 Modèle Intégrant Plusieurs Résolutions de STFT

Pour améliorer la robustesse du modèle YOLO face aux signaux LPI avec différentes caractéristiques temps-fréquence, nous avons développé un modèle qui intègre plusieurs résolutions de STFT dans l'architecture YOLO. La Figure A.2 illustre ce modèle, qui prend en entrée plusieurs images STFT avec des résolutions différentes et les fusionne.




Figure A.2: Architecture du modèle YOLO intégrant plusieurs résolutions de STFT pour améliorer la détection de signaux LPI.