

Une approche IA pour la détection de RSO à bord

Pierre-Jean Coquard¹, François De Vieilleville¹, Mathieu Verm¹, Nicolas-Marcel Lemoine¹, Nimesh Tahalooa¹

¹ AGENIUM Space

pierre-jean.coquard@agenium.com, francois.devieilleville@agenium.com, mathieu.verm@agenium.com,
nicolas-marcel.lemoine@agenium.com, nimesh.tahalooa@agenium.com

Résumé

Nous présentons une méthode de deep learning pour la détection de resident space object (RSO) à partir d'images space-to-space. Nous posons le contexte général et les limitations en présentant l'intérêt de la méthode IA. Nous passerons en revue les résultats et performances obtenus sur des images synthétiques sur SocFPGA spatialisable haut de gamme.

Mots-clés

Deep Learning, FPGA, resident space object (RSO), space situational awareness (SSA)

Abstract

We here present one AI-driven method for Resident Space Object (RSO) detection using space-to-space images. The general context and limitations will be presented and the benefit of the AI approach will be highlighted. We will review current achievable results and performances on synthetic images using high-end space HW.

Keywords

Deep Learning, FPGA, resident space object (RSO), space situational awareness (SSA)

1 Introduction

La surveillance de l'espace repose historiquement sur des chaînes de traitement au sol. Elles nécessitent le transfert des images acquises au sol et engendrent de fortes contraintes de bande passante, de latence et de coût. Une alternative permettant de s'affranchir de, ou au moins réduire, ces limites est d'utiliser ces algorithmes à bord des satellites. Ils permettent de présélectionner les données les plus pertinentes, voire d'effectuer la détection à bord. Cela réduit considérablement le volume de données transmises au sol.

Dans ce domaine, les algorithmes classiques basés sur des hypothèses statistiques, des a priori ou des seuils sont limités face à la variabilité du bruit et des conditions d'acquisition des images [1]. Les Deep Neural Networks (DNNs) offrent une solution capable de modéliser ces conditions complexes [3,4,5][3]. Dans notre cas d'étude, l'utilisation de DNNs nous permet d'obtenir de très bonnes performances pour la détection de RSO, mais également d'être exécuté directement sur un SocFPGA représentatif. Ce pipeline réduit les besoins de bande passante du bord vers le sol.

1.1 Travaux antérieurs

Nom	Etoiles	RSO
Inertial	Points	Streaks
RSO tracking	Streaks	Points

Tableau 1: Apparence des objets selon le scénario

Nos travaux sur la SSA, illustrés par les projets ci-dessous, traitent des DNNs pour la détection des objets, de l'amélioration de la qualité image et du portage à bord d'algorithmes de détection.

SpotGEO : Challenge de l'ESA (2019), remporté par Agenium Space, l'objectif était de détecter des satellites géostationnaires sur des images de télescopes amateurs. Nous avons utilisé une approche hybride incorporant des DNNs.

RT-Détection : CNES (2024) Détection de RSO dans des séquences d'images space to space pour différents scénarios. On visait la performance maximale par des DNNs.

RT-Astro : CNES (2026) Simulation de données pour l'étude de l'impact du débruitage sur la détection d'objets par algorithme classique ou approche par deep learning.

BodyGuard : EDF (2026) Détection de RSO à faible SNR sur des séquences d'acquisitions space to space en mode tracking et inertiel. Déploiement des DNNs à bord de SoC FPGA avec objectif de débit/performances élevés.

2 Méthode

Cette section présente notre méthodologie pour l'entraînement de DNNs de détection sur les RSO.

2.1 Base de données

Les données d'entraînement sont des images de simulation de fond spatial, sur lesquelles sont ajoutés des RSO de longueur et SNR variables. Ce générateur permet de définir différents éléments qui influent sur l'acquisition des images : éléments optiques, bruit du capteur, convertisseur analogique-numérique. Le simulateur permet également de modifier des paramètres essentiels de l'acquisition d'image : l'exposition et le mouvement du satellite. Le premier influe sur la longueur des raies observées pour les objets en mouvement et le deuxième est paramétré selon deux scénarios présentés dans le Tableau 1. Il permet également de générer des séquences temporelles multi-image cohérentes.

2.2 Entraînement des DNNs

Les entraînements opèrent sur des images 512 x 512 issues de la base de données présentée ci-dessus. Durant




Figure 2: Exemple d'images LSNR (6 dB de SNR moyen) et MSNR (12 dB de SNR moyen) en fausse couleur (échelle log.)




Figure 1: Rappel selon le SNR et la longueur apparente des RSO

SNR	F1 Mono-image	F1 Multi-image
LSNR	52%	63%
LSNR + MSNR	71%	91%
MSNR	86%	95%

Tableau 2: Performances du meilleur DNN en inférence sur différents niveaux de SNR moyen

l'entraînement, les modèles voient environ 7 millions de RSO. Les images sont générées avec des paramètres aléatoires de PSF, de bruit et de conversion analogique-numérique dans le but de rendre les DNNs le plus robuste possible.

Les réseaux utilisés sont des modèles « customs » basés sur l'architecture Fcos [1] pour le cas des modèles mono-images. Pour les séquences d'images, nous avons adapté les convolutions 3D, pour traiter à la fois les dimensions spatiales et temporelle, par une suite de convolutions. Cette simplification donne des modèles suffisamment légers (entre 200k et 15M de paramètres) quantifiables en uint8 pour être portés sur FPGA avec des bonnes performances.

3 Résultats

3.1 Performance des DNNs

Nous recensons ici les performances des DNNs entraînés en mono-image ou avec des séquences de 5 images. Chaque RSO est caractérisé par deux paramètres principaux : sa taille apparente en pixels et son signal-to-noise ratio (SNR), calculé selon l'Équation 1.

$$\text{SNR} = 20 \log_{10} \left(1 + \frac{S}{N} \right)$$

S le contraste de l'objet avec le fond, N l'écart type du fond

Équation 1: Signal-to-noise ratio (SNR) en décibels

Les résultats présentés sont des inférences effectuées sur des sets de test avec deux niveaux de bruit moyen : LSNR à 6 dB de moyenne et MSNR à 12 dB de moyenne, illustrés sur la Figure 2. Le Tableau 2 montre les F1-score¹ obtenus selon la visibilité des RSO. Ces résultats montrent systématiquement un gain autour de 10% de F1 score en utilisant un modèle multi-image par rapport au mono-image.

La Figure 1 montre que le DNN multi-image performe significativement mieux sur les objets de petite taille (inférieure à 20 pixels).

3.2 Performances sur FPGA

Ces DNNs ont été portés sur un dev-kit AMD VERSAL (VEK280) à l'aide de VITIS AI. Pour illustrer les performances sur ce FPGA, le DNN multi-image atteint 100 fps pour des séquences de 5 images 512x512, soit environ 1.5 fps pour des séquences de 5 images 5Kx5K.

4 Conclusion

Les résultats de cette étude confirment le potentiel des approches par DNN pour la détection de RSO. Ces résultats illustrent également la faisabilité des DNNs embarqués pour la SSA. Des travaux futurs pourront porter sur l'amélioration du débit et des performances de détection.

5 Références

- [1] Tian, Z. et al, *Fcos: Fully convolutional one-stage object detection* In *Proceedings of the IEEE/CVF international conference on computer vision*, 2019
- [2] Suthakar V, Sanvido AA, Qashoa R, Lee RSK, *Comparative Analysis of Resident Space Object (RSO) Detection Methods*, Sensors, 2023
- [3] AlDahoul, N. et al, *Localization and classification of space objects using EfficientDet detector for space situational awareness*, Scientific Reports, 2022
- [4] Tsapraillis, K. et al, *Survey mode: A review of machine learning in resident space object detection and characterization*, AIAA SCITECH 2024 Forum, 2024.
- [5] Duev et al. *DeepStreaks: identifying fast-moving objects in the Zwicky Transient Facility data with deep learning*, Monthly Notices of the Royal Astronomical Society, 2019

¹ <https://en.wikipedia.org/wiki/F-score>