



**HAL**  
open science

## Modèle et jeu de données pour la détection multi-spectrale de feux de forêt à bord de satellites

Housseem Farhat, Lionel Daniel, Michaël Benguigui, Adrien Girard

### ► To cite this version:

Housseem Farhat, Lionel Daniel, Michaël Benguigui, Adrien Girard. Modèle et jeu de données pour la détection multi-spectrale de feux de forêt à bord de satellites. Conférence Nationale en Intelligence Artificielle 2022 (CNIA 2022), Jun 2022, Saint-Etienne, France. hal-03866412

**HAL Id: hal-03866412**

**<https://hal.science/hal-03866412>**

Submitted on 22 Nov 2022

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Modèle et jeu de données pour la détection multi-spectrale de feux de forêt à bord de satellites

H. Farhat<sup>1,2</sup>, L. Daniel<sup>1</sup>, M. Benguigui<sup>1,3</sup>, A. Girard<sup>1</sup>

<sup>1</sup> Institut de Recherche Technologique Saint-Exupéry

<sup>2</sup> AViSTO

<sup>3</sup> Activeeon

Contact : houssem.farhat@irt-saintexupery.com

## Résumé

*Le nombre de feux de forêts risque d'augmenter de +50% d'ici à 2100. Dans cet article, nous nous intéressons à la télédétection de ces feux à bord d'un satellite afin de lever des alertes précoces directement depuis l'espace. Dans ce cadre, nous avons entraîné un réseau de neurones UNet-MobileNetV3 à segmenter des images multispectrales de Sentinel-2, que nous avons annotées semi-automatiquement puis vérifiées manuellement. Nous avons ensuite déployé ce réseau sur un GPU embarquable sur un satellite en orbite basse. Les données et le réseau entraîné sont disponibles ici : [www.irt-saintexupery.com/firesat](http://www.irt-saintexupery.com/firesat)*

## Mots-clés

*Détection feux de forêts, Imagerie satellite, IA embarquée, Surveillance permanente.*

## Abstract

*The number of wildfires will likely increase by 50% before the end of the century. In this article, we focus on detecting wildfires onboard satellites to raise early warnings directly from space. In this context, we trained a neural network UNetMobileNetV3 to segment multispectral Sentinel-2 images, which we annotated semi-automatically and verified manually. We then deployed this network to a GPU that can be embedded into a low-orbit satellite. We provide our dataset and the trained network here : [www.irt-saintexupery.com/firesat](http://www.irt-saintexupery.com/firesat)*

## Keywords

*Wildfire detection, Satellite imagery, Embedded AI, Permanent monitoring.*

## 1 Introduction

### 1.1 Gestion intégrée des forêts : la prévention

La biodiversité des forêts est riche mais en proie aux activités anthropiques. Entre 2001 et 2015, c'est plus de 5 fois la superficie de la France qui a été déforestée sur Terre[15]. La gestion des forêts est intimement liée à la localisation de l'agriculture et appelle à une optimisation conjointe globale[7].

En effet, la déforestation est due à 27% à l'expansion permanente de l'agriculture, des mines, et des infrastructures liées à l'énergie, portion qu'il convient de distinguer de la déforestation temporaire composée de l'exploitation forestière (26%), de la jachère longue (24%) et des feux de forêt (23%); l'urbanisation (<1%) n'a que peu participé à la perte nette d'arbres à l'échelle mondiale. Les effets de cette perte forestière sur la biodiversité se combinent avec des effets plus complexes et moins visibles. Ainsi, [40] insiste sur la nécessité de réguler le transport des végétaux pour éviter la diffusion de nuisibles non-endémiques dont les effets s'opèrent sur des dizaines d'années : 30 ans ont suffi à un champignon pour réduire de 99% la surface forestière des noisetiers des Appalaches, imposant aux espèces qui en dépendent de s'adapter ou disparaître. Enfin, la perte de biodiversité ne se résume pas à la perte d'une essence ou espèce : au niveau individuel, chaque arbre centenaire tué est une perte génétique *inestimable*[13].

Le nombre de feux de forêts devrait augmenter de +50% d'ici à 2100[9]. Leur détection précoce et leur suivi permettra d'anticiper leur progression et de coordonner les moyens d'actions. Les vigies, les patrouilles, et les appels téléphoniques des citoyens peuvent suffire à détecter rapidement et exhaustivement les feux dans les zones habitées, mais la surveillance permanente de larges zones inhabitées nécessite d'autres moyens d'observation tels que les satellites. Cartographier précisément ces feux à une échelle spatiale et temporelle globale est aujourd'hui difficile [38], mais nécessaire pour alimenter les modèles prospectivistes qui éclaireront nos décideurs sur les politiques d'occupation des sols. Notons pour être complet que tous les feux n'appellent pas forcément de réaction précoce. Ainsi les incendies dans des zones tampons permettent de protéger la forêt de 95% des feux de savane en Afrique centrale[14] et ne doivent pas être éteints. Certaines essences comme les séquoias géants profitent de petits feux[29]. Un rapport de mars 2021 des nations unies recommande un renversement de notre politique globale de gestion des feux, en privilégiant la prévention des feux à leur suppression[37], incluant notamment l'écobuage et la prévention des incivilités[38].

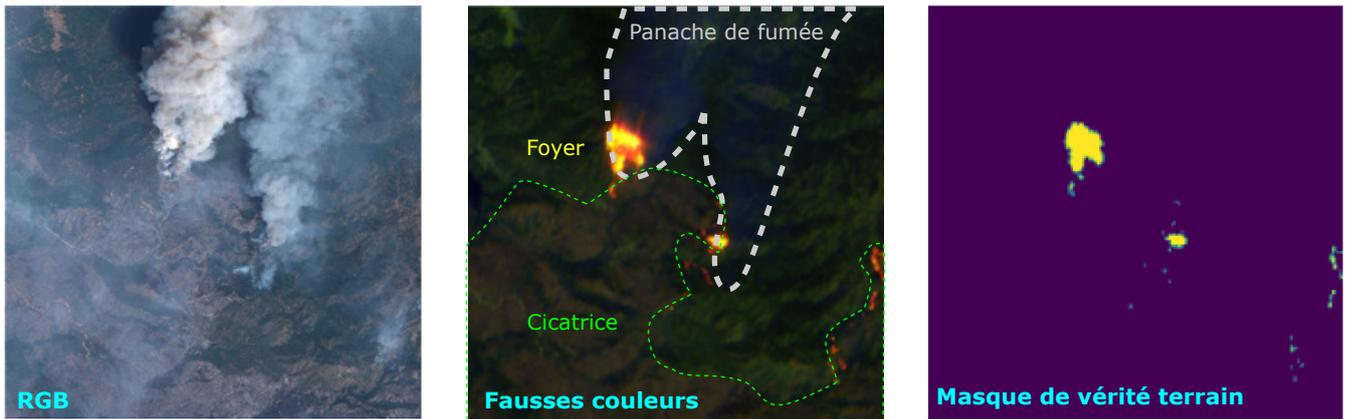


FIGURE 1 – Image Sentinel-2 en RGB (rouge=B04, vert=B03, bleu=B02) à gauche, fausses couleurs (rouge=B12, vert=B11, bleu=B04) au milieu, et le masque vérité terrain des foyers à droite ; l’image en fausse couleur présente un panache de fumée en gris, un foyer en jaune et une cicatrice en vert.

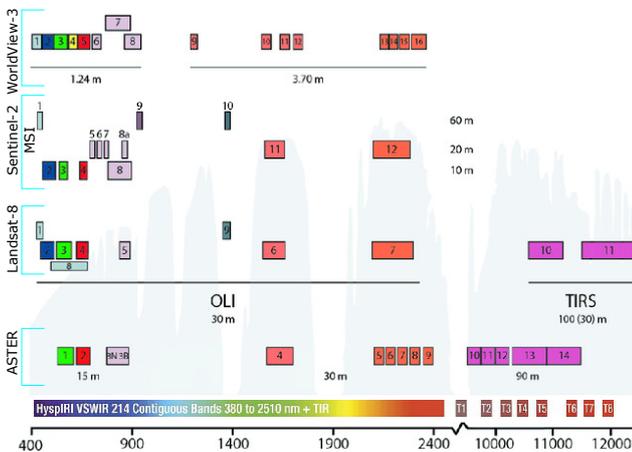


FIGURE 2 – Combinaison de deux figures extraites de [12, 11] comparant les différentes bandes spectrales de satellites d’observation. Dans cet article nous avons utilisé principalement les bandes 11 et 12 de Sentinel-2 MSI. Le fond de la figure représente la transmittance atmosphérique estivale aux latitudes moyennes.

## 1.2 Surveillance spatiale des incendies

Une zone d’incendie se décompose en trois objets, comme indiqué sur la figure 1 : les foyers, aussi appelés points chauds, le panache de fumée, et la cicatrice, aussi appelée zone brûlée. Cet article se focalise sur la *détection des foyers* à partir d’images satellitaires acquises par l’instrument multi-spectral de Sentinel-2. Cet instrument observe la Terre de 442 à 2202nm et nous utilisons les bandes spectrales rouge (B4) et proche infrarouge (B11 et B12) dans lesquelles les foyers sont les mieux observables. La figure 2 compare ces bandes à celles d’autres satellites. Les images acquises par Sentinel-2 sont disponibles sur les plateformes DIAS (Data and Information Access Service) financées par la commission européenne et couramment utilisées par la communauté scientifique de l’observation de la Terre.

Les techniques d’apprentissage automatique, en particulier

l’apprentissage profond de réseaux de neurones convolutifs (CNN), sont déjà employées pour analyser des images satellitaires hyper-spectrales [2, 32], notamment pour détecter les feux de forêt actifs [34, 43]. L’augmentation progressive de la disponibilité et de la précision des données multi-spectrales fournies par les séries de satellites MODIS, Landsat-8 et Sentinel-2, a créé de nouvelles opportunités d’études scientifiques sur la gestion des incendies [24, 18, 35, 42, 31, 44]. Des approches basées sur l’apprentissage automatique ont été introduites dans [19, 6] afin d’identifier les zones brûlées. [17] propose une approche basée sur l’apprentissage supervisé pour estimer automatiquement la sévérité des dégâts des zones affectées après l’extinction d’un feu de forêt en utilisant deux réseaux de neurones de type Unet. Le premier effectue une classification binaire de chaque pixel pour déterminer l’appartenance à une zone brûlée. Le second applique une régression pour estimer le niveau de gravité. Cette estimation est cruciale pour rapidement évaluer les pertes financières et efficacement mettre en place la restauration des zones affectées. [16] utilise des CNN afin d’améliorer la résolution des bandes infrarouges à ondes courtes (SWIR) et obtenir des cartes plus détaillées des feux de forêt actifs.

La fumée est un signal précoce de combustion de la biomasse. Elle joue donc un rôle important dans la détection précoce des incendies de forêt et la limitation de leurs impacts. Malheureusement, la détection des fumées en imagerie satellitaire demeure difficile, de par la diversité des formes, des couleurs, des étendues et des chevauchements spectraux de celles-ci [26, 46, 25]. Il est donc difficile de distinguer la fumée des autres types de textures, telles que les nuages, la poussière, la brume. Ainsi, le CNN SmokeNet [4] intègre l’information spatiale via un channel-wise-attention afin d’améliorer la représentation des caractéristiques pour la classification d’image avec ou sans fumée.

La détection de foyers a reçu davantage d’attention : [41, 30, 23] proposent des algorithmes basés sur des approches statistiques avec un seuil fixe. Leurs données sont multi-

spectrales avec une bande infrarouge sensible au feu (bande 7) et six bandes dans le visible et le proche infrarouge (1-6); ces données sont fournies par l'instrument Operational Land Imager (OLI) de Landsat-8. Sur le même concept, [22] propose l'algorithme AFD-S2 pour détecter les foyers sur des données Sentinel-2. Cet algorithme reconnaît les petits points de feu actifs avec une erreur moyenne de commission (CE) et une erreur moyenne d'omission (OE) sur 8 images Sentinel-2 autour de 0,14 et 0,04 respectivement. Cependant, ces approches à seuil fixe ont une précision limitée en raison de la complexité de la mise en place des seuils. Ainsi, [27] propose une petite architecture de réseau de neurones entièrement connectés avec 1 couche d'entrée, 3 couches cachées et 1 couche de sortie. Leur modèle a été entraîné en exploitant un sous-ensemble de 4 bandes (1, 5, 6 et 7) de Landsat-8. Ce choix de bandes est basé sur les analyses faites par [41] pour déterminer la forte corrélation de ces bandes avec les applications de détection d'incendie. Ensuite, [27] a comparé leur modèle avec l'algorithme à seuil fixe proposé par [41]. [33] propose trois architectures différentes basées sur l'architecture UNet avec des données de Landsat8. Le premier UNet est entraîné sur les 10 canaux de landsat8. Le deuxième est entraîné sur les 3 canaux B7, B6 et B4. Le dernier, aussi entraîné avec ces 3 bandes, est un UNet réduit appelé UNet-Light. Leur vérité terrain a été construite à partir des algorithmes [41, 30, 23], et l'architecture UNet-Light a obtenu le meilleur score IoU de 89%. Des réseaux de neurones à base de convolutions de type DeepLabV3 et DCPA+HRNetV2, ont été utilisés [45] pour segmenter sémantiquement et binairement (feu ou non-feu pour chaque pixel) des images Sentinel-2 en utilisant les bandes B12, B11 et B04. C'est aussi ce sous-ensemble de bandes que nous avons choisi l'année dernière lorsque nous avons commencé notre étude; cependant, nous avons choisi une architecture de CNN efficace afin de l'embarquer dans un satellite qui transmettrait ses alertes incendie aux intervenants sans passer par des infrastructures au sol.

### 1.3 Nos contributions

Cet article présente les contributions suivantes :

- Un jeu d'images multispectrales de 13 bandes spectrales provenant du satellite Sentinel-2, dont la résolution spatiale au sol varie de 40 à 80m, et où les foyers ont été pré-annotés automatiquement puis corrigés manuellement.
- L'entraînement d'un CNN embarquable référent sur ce jeu d'images atteignant une IoU de 94%.
- Une implémentation C++/TensorRT du segmenteur de foyers sur Nvidia Jetson Nano et NX, et donc compatible du Jetson TX2i embarquable à bord de satellites en orbite basse.

### 1.4 Plan de l'article

Cet article décrit la collecte et l'annotation des images puis, dans un second temps, l'entraînement, le déploiement, et l'évaluation du modèle utilisé. Une évaluation succincte de l'impact environnemental de cette étude est exposée après la conclusion.



FIGURE 3 – Géolocalisation de nos 90 scènes.

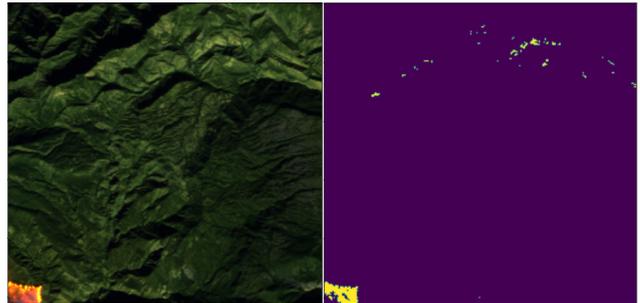


FIGURE 4 – Image en fausses couleurs, à gauche, où la formule de Pierre Markuse[28] génère un masque, à droite, contenant de nombreux faux positifs sur la moitié haute.

## 2 Expérimentation

### 2.1 Collection des données

Dans cette section, nous présentons comment nous avons utilisé le Web Coverage Service (WCS) de l'API OGC Sentinel-Hub[6, 18] pour télécharger les scènes satellitaires. Nous détaillons ensuite comment nous avons pré-annoté ces scènes avec le script de Pierre Markuse, puis finalement créé la base de données annotées qui a servi à notre expérimentation.

#### 2.1.1 Sélection des incendies

A partir de divers moteurs de recherche, nous avons identifié le lieu et la date d'une liste d'incendies, comme le montre la carte de la Figure 3. Chaque incendie a ensuite été recherché sur le portail Sentinel-Hub, et pour chaque image identifiant l'incendie, l'aperçu de la zone au format GéoTIFF a été manuellement téléchargé, et ce à plusieurs moments. Au total, nous avons téléchargé 90 aperçus correspondant à des scènes acquises entre 2016 et 2020 par l'instrument MSI des satellites Sentinel-2a et 2b.

#### 2.1.2 Téléchargement des scènes L1C

Ensuite, nous avons automatisé le téléchargement de la scène correspondant à chacun des aperçus géolocalisés; le but étant d'embarquer nos algorithmes sur satellite, nous avons choisi le niveau de traitement L1C qui est le plus proche de la sortie brute de l'instrument MSI [10]. Notre automatisation, programmée en Python, utilise le service WCS de l'API OGC. Les contraintes de WCS imposent une limite haute d'environ 5000x5000 pixels sur la taille

des scènes téléchargeables. Notre programme Python génère donc des requêtes WCS où le GSD (Ground Sampling Distance, en mètre par pixel) est augmenté itérativement jusqu'à ce que la zone d'intérêt soit suffisamment petite pour être téléchargeable ; le GSD de nos scènes varie ainsi entre 40m et 80m, et une possible conséquence est que notre CNN soit moins sensible au changement de GSD et se focalise davantage sur la dimension spectrale. A noter que WCS sur-échantillonne les bandes dont le GSD est plus faible que celui requêté : ainsi, au sein d'une même scène, toutes les bandes ont le même GSD. Au final, chaque scène téléchargée est composée des 13 bandes spectrales de MSI, de B01 à B12, voir figure 2, enregistrée en TIFF où les pixels sont codés en entier-16 bits.

### 2.1.3 Présentation du script de Pierre Markuse

Le script de Pierre Markuse[28] est un programme Javascript créé pour visualiser les feux actifs sur la plateforme de Sentinel-hub. Il est basé sur une formule simple, qui utilise les bandes B11 et B12 pour faire ressortir les feux. Cette formule, appliquée à chaque pixel, consiste à sommer les valeurs de la bande B11 et B12 puis classifier un pixel comme feu si et seulement si ce résultat est strictement supérieur à 1.

$$\text{feu} \Leftrightarrow B11 + B12 > 1 \quad (1)$$

### 2.1.4 Annotation des scènes

Pour pré-annoter ces scènes, nous utilisons la formule 1 de Pierre Markuse qui est conservative : elle permet de classifier correctement quasiment tous les pixels qui représentent un feu, mais avec un taux de faux positifs assez élevé comme illustré dans la figure 4. Nous avons appliqué en Python cette formule sur les scènes après les avoir converties en flottant avec des valeurs comprises entre 0 et 1. Une fois le masque binaire généré, nous l'avons ouvert dans un calque semi-transparent d'un logiciel de retouche raster, superposé à un calque contenant la scène en fausses couleurs (canal rouge=B12, canal vert=B11 et canal bleu=B04) et un calque contenant la scène en RGB (canal rouge=B04, canal vert=B03 et canal bleu=B02), voir figure 1. Jongler entre ces scènes nous permet de mieux estimer la classification de chaque pixel, notamment en regardant la fumée et les cicatrices visibles en RGB. Une fois ces pré-annotations corrigées, elles sont enregistrées au format TIFF où chaque pixel est un entier-non-signé 8-bits avec les valeurs possibles 0=non-feu et 255=feu ; ces masques sont ainsi notre vérité-terrain.

## 2.2 Entraînement du CNN de segmentation

### 2.2.1 Génération d'images à partir des scènes

Les scènes annotées doivent être tuilées avant l'entraînement pour des raisons de dépassement mémoire GPU et de diversité par batch. Le tuilage consiste à découper la scène en images de 256x256 avec une zone de recouvrement de 128 pixels. Si l'image contient plus de 15 pixels de feu, au regard de la vérité terrain, alors elle est ajoutée au *dataset*, qui est notre jeu de données servant à entraîner, valider et tester les modèles. Si elle contient entre 0 et 14 pixels, alors elle est rejetée car considérée comme trop peu sûr

	nombre de scènes	nombre d'images	ratio pixels feu/non-feu
dataset	90	2244 feu + 1104 non-feu	0.162%
trainset	72	2742	0.143%
valset	9	312	0.360%
testset	9	294	0.136%

TABLE 1 – Déséquilibre des classes feu/non-feu du dataset

qu'il y ait un feu, et pas assez sûr qu'il n'y en ait pas. Si elle contient 0 pixel de feu, alors elle est ajoutée avec une probabilité de 0.05 au dataset afin d'augmenter la diversité de terrain sans trop accentuer le déséquilibre entre les classes feu et non-feu. Même avec cette stratégie, le dataset obtenu contient seulement 0.162% de pixels de feux. Le partitionnement du dataset en trois sous-ensembles a été réalisé de manière aléatoire au niveau des scènes dans les proportions indiquées dans la table 1, assurant ainsi qu'aucune donnée d'entraînement ne soit utilisée pour la validation ou le test.

### 2.2.2 Description du modèle UNetMobileNetV3

U-Net[39] est un CNN développé pour segmenter des images biomédicales, mais aussi utilisé pour segmentation de nuages à bord de satellite[5]. Son architecture est composée d'un encodeur et d'un décodeur. Le but de l'encodeur est de capturer le contexte tandis que le rôle du décodeur est de calculer le masque de segmentation. Pour des raisons d'efficacité, nous avons remplacé l'encodeur original par MobileNet-v3-small[21], en prenant le soin de relier ce nouvel encodeur au décodeur. Le décodeur a été simplifié à 5 blocs de déconvolution puis une couche de Convolution et une activation Sigmoid permettant d'aboutir à un masque ayant la même taille que l'image d'entrée. Les 4 premiers des 5 blocs du décodeur sont composés d'une couche de Convolution Transposée, une couche de BatchNormalisation, et une couche de Dropout suivie d'une activation Relu. La sortie de chacun de ces 4 blocs est concaténée avec celles de l'encodeur. Ainsi, notre UNetMobileNetV3 possède 4 693 553 paramètres dont 1 529 968 pour l'encodeur mobilenetv3-small et 3 163 585 pour notre décodeur.

### 2.2.3 Procédure d'entraînement

Nous avons entraîné notre UNetMobileNetV3 sur deux GPU Nvidia GTX 1080 Ti avec les hyperparamètres suivants :

- Fonction de perte : Dice + Jaccard + Focal
- Poids des classes : feu=400, non-feu=1
- Initialisation des poids : encodeur mobilenetv3-small=ImageNet, decoder=aléatoire
- Gel des poids : non
- Taille du Batch : 128, soit 64 par GPU
- Optimiseur : Adam
- Learning rate initial : 0.01
- Strategies : Earlystopping + ReduceOnPlateau
- Max Epochs : 1000, mais s'arrête à ~400 epochs

La figure 5 montre que l'entraînement converge en moins de 400 epochs et présente un léger sur-apprentissage.

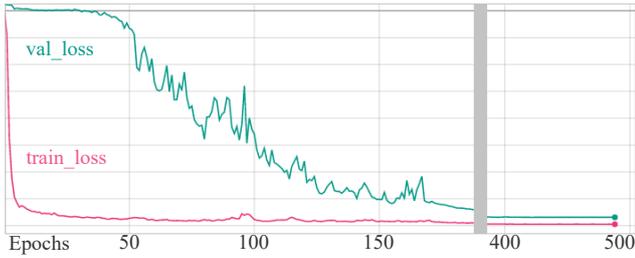


FIGURE 5 – Valeur des fonctions de perte au fil des epochs

	Puissance	Débit en MPixel/s	6711 km <sup>2</sup> GSD=40m
Jetson Nano	<10W	1.87	2.236 s
Jetson NX	<20W	8.99	0.466 s

TABLE 2 – Vitesse du segmenteur de feu embarqué sur Jetson et évalué sur 52 batchs de 64 imagettes de 256<sup>2</sup> pixels.

### 2.3 Déploiement sur électronique embarquée

Nous avons converti notre modèle tf.keras, représentant 2.98 milliards de MAC (Multiplieur-accumulateur), vers onnx puis nous l'avons compilé avec TensorRT entièrement en C++. Nous avons évalué ses performances sur les Jetson Nano et NX comme indiqué à la table 2. Afin de mettre ces performances en perspective, nous avons calculé qu'il est capable de segmenter en moins de 2 secondes et à un GSD de 40m les 5000km<sup>2</sup> du département de la Loire.

### 2.4 Évaluation des résultats

Pour mesurer la qualité de notre modèle, nous avons utilisé les métriques de la table 3 calculées à partir des masques générés soit par TF.keras en float-32, soit par TensorRT avec une quantification en float-16 lors du déploiement sur les deux Jetson. A partir du nombre de pixels de ces masques évalués comme vrais ou faux positifs (TP ou FP) et vrais ou faux négatifs (TN ou FN), nous définissons les quatre métriques suivantes : Rappel=TP/(TP+FN), Précision=TP/(TP+FP), F1-score=2TP/(2TP+FP+FN), IoU=TP/(TP+FP+FN). Ces résultats sont illustrés par la figure 6. Notre modèle possède une bonne capacité de généralisation en atteignant plus de 94% d'IoU sur le jeu de test, composé de scènes Sentinel-2 utilisées ni dans le trainset ni dans le valset; cette capacité est notamment due aux fonctions de pertes dédiées à compenser le fort déséquilibre des classes (ratio de pixels feu/non-feu=0.162%). La quantification réalisée par TensorRT introduit un léger biais en manquant moins de pixel feu mais en introduisant plus de faux positifs, ce qui augmente le Rappel et baisse la Précision.

## 3 Discussion & conclusion

Notre base de scènes Sentinel-2 de feux de forêts *annotés* semble être la première librement disponible, et nous espérons qu'elle servira de référence pour comparer différentes approches algorithmiques, telles que notre segmenteur qui semble aussi être le premier à être embarquable

Model	Rappel	Preci.	F1-score	IoU
TensorRT (test)	0.990	0.949	0.969	0.940
TF.keras (test)	0.973	0.975	0.974	0.950
TF.keras (val)	0.961	0.987	0.974	0.949
TF.keras (train)	0.998	0.999	0.999	0.997
P. Markuse (test)	1.000	0.871	0.931	0.871

TABLE 3 – Evaluation de Unet-mobilenet-v3 sur le testset, trainset et valset en TensorFlow.Keras, et en TensorRT sur Nvidia Jetson NX et Nano.

dans un satellite. A noter que ce segmenteur, entraîné sur des images avec un GSD de 40 à 80m, permet d'être embarqué sur des satellites ayant une orbite elliptique. Comme les satellites Sentinel ne peuvent pas être modifiés pour exécuter nos algorithmes, nous espérons que de prochaines versions embarqueront des électroniques le permettant. Concernant l'algorithme, son léger sur-apprentissage (valset IoU=94.9% < trainset IoU=99.7%) dû au manque de données d'entraînement et de régularisation fera l'objet d'un prochain travail, tout comme l'évaluation de notre segmenteur sur des images sur-résolues, voire acquises par d'autres satellites.

### Déclaration de conflit d'intérêt

Les auteurs déclarent que le contenu de cet article n'a pas été influencé par d'autres conflits d'intérêt que ceux engendrés par une vie exposée aux incendies, sécheresses, déforestation, et effondrement de la biodiversité en général.

### Remerciements

Ces travaux sont menés dans le projet CIAR (Chaîne Image Autonome et Réactive) de l'Institut de Recherche Technologique Saint-Exupéry. Les auteurs remercient les partenaires industriels et académiques du projet : Activeeon[1], Avisto, ELSYS Design, Geo4i, Inria, LEAT/CNRS, MyDataModels, Thales Alenia Space et TwinswHeel.

### Impact environnemental

La part du numérique est projeté à plus de 14% des émissions globales de CO<sub>2</sub> en 2040 et, d'après [36], l'IA en représenterait une part croissante. Donc, bien que l'objectif principal de notre travail soit d'embarquer à bord de futurs satellites un détecteur de feux de forêts efficace, nous nous interrogeons sur l'impact environnemental de notre étude, comme recommandé par [20], et sur les moyens de les mesurer[3] et de les minimiser. Des pistes sont proposées dans la figure 7. Nous estimons que l'ensemble de nos travaux représentent environ 6,5 tCO<sub>2</sub> en se basant sur l'empreinte carbone d'un français de 9 tCO<sub>2</sub>/an ayant travaillé 9 mois-homme sur ce projet. Sans compter l'impact de la fabrication, maintenance et l'impossible "recyclage" du matériel, et en ignorant tout sauf la consommation des deux GPUs Nvidia GTX 1080Ti, nous estimons que les 140 heures d'entraînement représentent 35 kWh, ce qui équivaut à moins de 2 kgCO<sub>2</sub> si le mix énergétique français est

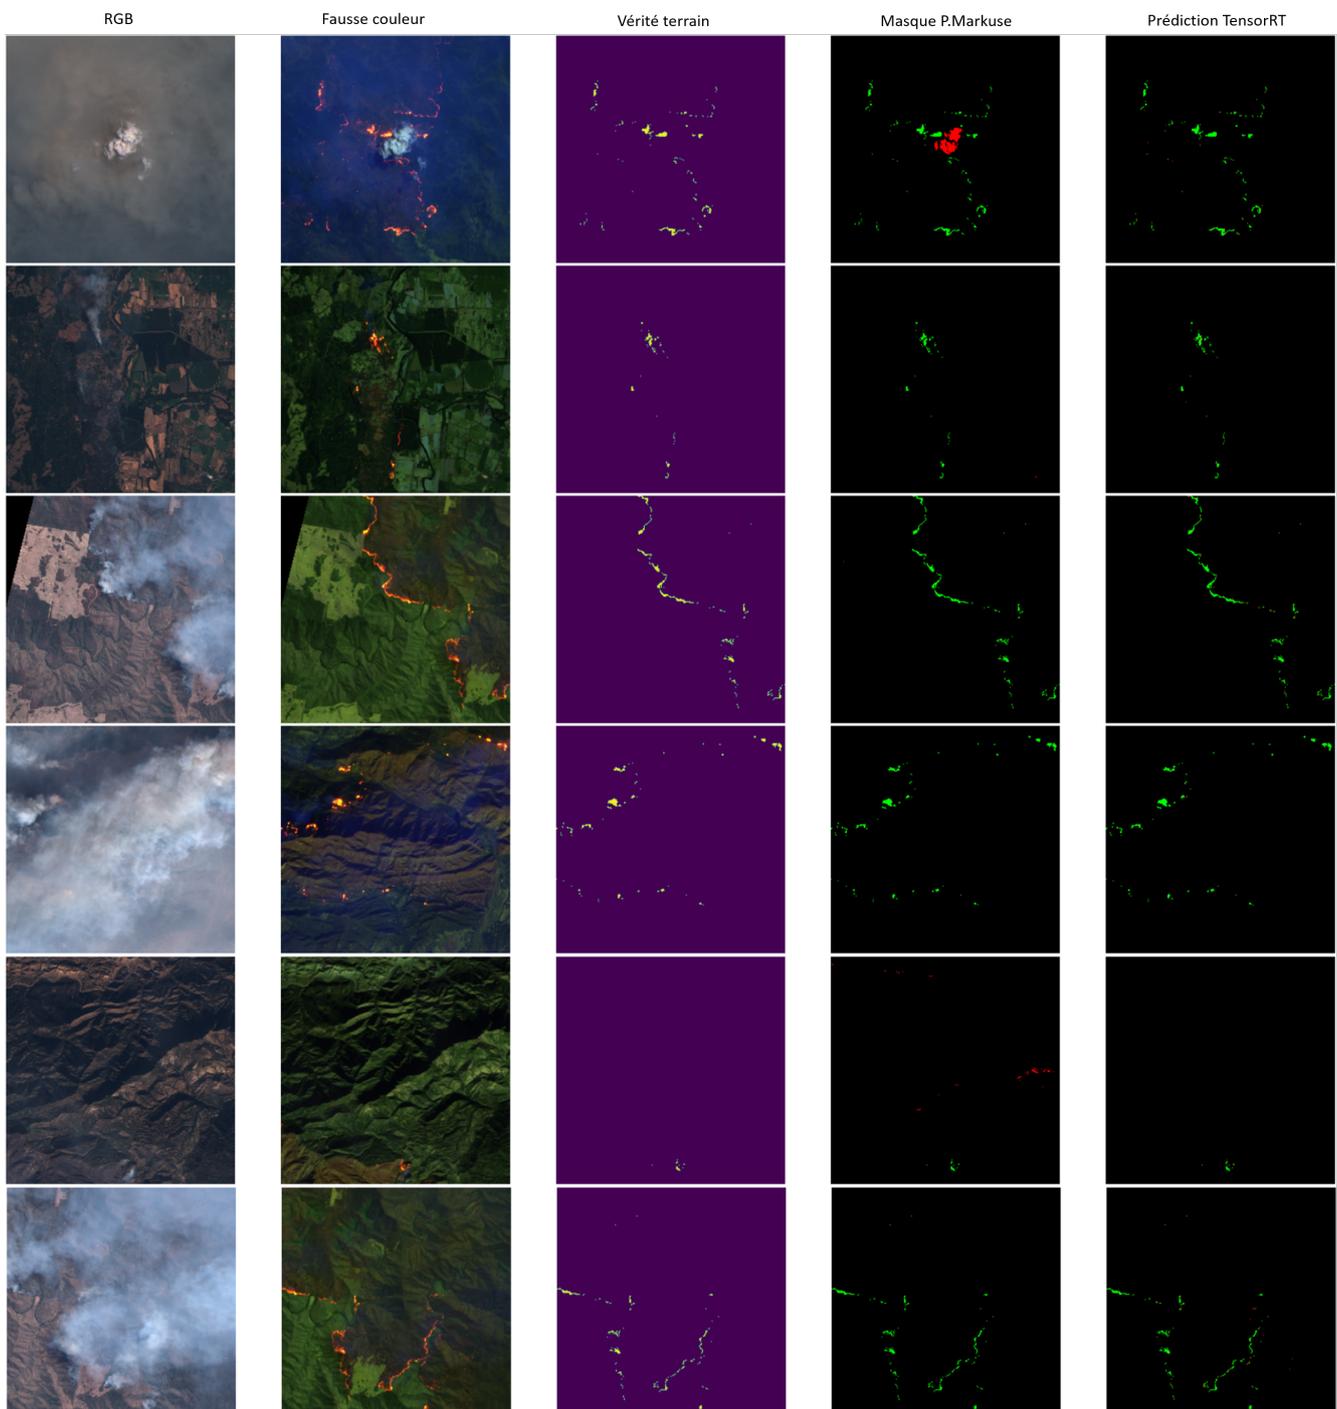


FIGURE 6 – Exemples de prédictions du modèle Unet-mobileNetV3 sur six imageries appartenant au testset. Images de gauche à droite : image en RGB, image en fausse couleur donnée en entrée du modèle, vérité terrain, masque de Pierre Markuse, et masque prédit par le modèle TensorRT embarqué sur Jetson. Légende des couleurs des masques : les pixels noir, vert et Rouge représentent respectivement les vrais négatifs, les vrais positifs et les erreurs de classifications (faux positifs et faux négatives).



FIGURE 7 – Éco-actions pour les (neuro)scientifiques[36]

d'environ 50 gCO<sub>2</sub>/kWh[8].

## Références

- [1] ProActive: Job Scheduling & Workload Automation technologies. [Online; accessed 16. Mar. 2022].
- [2] Adrian Albert, Jasleen Kaur, and Marta Gonzalez. Using convolutional networks and satellite imagery to identify patterns in urban environments at a large scale. *arXiv*, Apr 2017.
- [3] Lasse F. Wolff Anthony, Benjamin Kanding, and Raghavendra Selvan. Carbontracker : Tracking and Predicting the Carbon Footprint of Training Deep Learning Models. *arXiv*, Jul 2020.
- [4] Rui Ba, Chen Chen, Jing Yuan, Weiguo Song, and Siuming Lo. SmokeNet : Satellite Smoke Scene Detection Using Convolutional Neural Network with Spatial and Channel-Wise Attention. *Remote Sens.*, 11(14) :1702, Jul 2019.
- [5] Gaetan Bahl, Lionel Daniel, Matthieu Moretti, and Florent Lafarge. Low-power neural networks for semantic segmentation of satellite images. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*, Oct 2019.
- [6] Yifang Ban, Puzhao Zhang, Andrea Nascetti, Alexandre R. Bevington, and Michael A. Wulder. Near Real-Time Wildfire Progression Monitoring with Sentinel-1 SAR Time Series and Deep Learning. *Sci. Rep.*, 10(1322) :1–15, Jan 2020.
- [7] Robert M. Beyer, Fangyuan Hua, Philip A. Martin, Andrea Manica, and Tim Rademacher. Relocating croplands could drastically reduce the environmental impacts of global food production. *Commun. Earth Environ.*, 3(49) :1–11, Mar 2022.
- [8] EDF, Feb 2022. [Online; accessed 15. Mar. 2022].
- [9] Spreading like Wildfire : The Rising Threat of Extraordinary Landscape Fires, Feb 2022. [Online; accessed 15. Mar. 2022].
- [10] Products and Algorithms – Sentinel-2 MSI Technical Guide – Sentinel Online - Sentinel Online, Mar 2022. [Online; accessed 16. Mar. 2022].
- [11] Comparison between ASTER, Landsat 8, Sentinel-2, and WorldView-3 bands (Figure 4.), Mar 2022. [Online; accessed 15. Mar. 2022].
- [12] Landsat-9 - Search EO Satellite Missions, Mar 2022. [Online; accessed 15. Mar. 2022].
- [13] Charles H. Cannon, Gianluca Piovesan, and Sergi Munné-Bosch. Old and ancient trees are life history lottery winners and vital evolutionary resources for long-term adaptive capacity. *Nat. Plants*, 8 :136–145, Feb 2022.
- [14] Anabelle W. Cardoso, Imma Oliveras, Katharine A. Abernethy, Kathryn J. Jeffery, Sarah Glover, David Lehmann, Josué Edzang Ndong, Lee J. T. White, William J. Bond, and Yadvinder Malhi. A distinct ecotonal tree community exists at central African forest–savanna transitions. *J. Ecol.*, 109(3) :1170–1183, Mar 2021.
- [15] Philip G. Curtis, Christy M. Slay, Nancy L. Harris, Alexandra Tyukavina, and Matthew C. Hansen. Classifying drivers of global forest loss. *Science*, 361(6407) :1108–1111, Sep 2018.
- [16] D. A. G. Dell’Aglia, M. Gargiulo, A. Iodice, D. Riccio, and G. Ruello. Active Fire Detection in Multispectral Super-Resolved Sentinel-2 Images by Means of Sam-Based Approach. In *2019 IEEE 5th International forum on Research and Technology for Society and Industry (RTSI)*, pages 124–127. IEEE, Sep 2019.
- [17] Alessandro Farasin, Luca Colomba, and Paolo Garza. Double-Step U-Net : A Deep Learning-Based Approach for the Estimation of Wildfire Damage Severity through Sentinel-2 Satellite Data. *Appl. Sci.*, 10(12) :4332, Jun 2020.
- [18] Federico Filippini. Exploitation of Sentinel-2 Time Series to Map Burned Areas at the National Level : A Case Study on the 2017 Italy Wildfires. *Remote Sens.*, 11(6) :622, Mar 2019.
- [19] Louis Giglio, Luigi Boschetti, David P. Roy, Michael L. Humber, and Christopher O. Justice. The Collection 6 MODIS burned area mapping algorithm and product. *Remote Sens. Environ.*, 217 :72–85, Nov 2018.
- [20] Peter Henderson, Jieru Hu, Joshua Romoff, Emma Brunskill, Dan Jurafsky, and Joelle Pineau. Towards the Systematic Reporting of the Energy and Carbon Footprints of Machine Learning. *arXiv*, Jan 2020.
- [21] Andrew Howard, Mark Sandler, Grace Chu, Liang-Chieh Chen, Bo Chen, Mingxing Tan, Weijun Wang, Yukun Zhu, Ruoming Pang, Vijay Vasudevan, Quoc V. Le, and Hartwig Adam. Searching for MobileNetV3, 2019. [Online; accessed 16. Mar. 2022].
- [22] Xikun Hu, Yifang Ban, and Andrea Nascetti. Sentinel-2 MSI data for active fire detection in major fire-prone biomes : A multi-criteria approach. *DIVA*, 101, 2021.

- [23] S. S. Kumar and D. P. Roy. Global operational land imager Landsat-8 reflectance-based active fire detection algorithm. *Int. J. Digital Earth*, 11(2) :154–178, Feb 2018.
- [24] Rosa Lasaponara, Biagio Tucci, and Luciana Ghermandi. On the Use of Satellite Sentinel 2 Data for Automatic Mapping of Burnt Areas and Burn Severity. *Sustainability*, 10(11) :3889, Oct 2018.
- [25] Xiaolian Li, Weiguo Song, Liping Lian, and Xiaoge Wei. Forest Fire Smoke Detection Using Back-Propagation Neural Network Based on MODIS Data. *Remote Sens.*, 7(4) :4473–4498, Apr 2015.
- [26] Zhanqing Li, A. Khananian, R. H. Fraser, and J. Cihlar. Automatic detection of fire smoke using artificial neural networks and threshold approaches applied to AVHRR imagery. *IEEE Trans. Geosci. Remote Sens.*, 39(9) :1859–1870, Sep 2001.
- [27] Z. Liu, K. Wu, R. Jiang, and H. Zhang. A SIMPLE ARTIFICIAL NEURAL NETWORK FOR FIRE DETECTION USING LANDSAT-8 DATA. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2020 :447–452, Aug 2020.
- [28] Pierre Markuse. Visualizing Wildfires and Burn Scars with the Sentinel Hub EO Browser V2, April 2018. [Online; accessed 14. Mar. 2022].
- [29] Marc D. Meyer and Hugh D. Safford. Giant Sequoia Regeneration in Groves Exposed to Wildfire and Retention Harvest. *Fire Ecol.*, 7(2) :2–16, Aug 2011.
- [30] Sam W. Murphy, Carlos Roberto de Souza Filho, Rob Wright, Giovanni Sabatino, and Rosa Correa Pabon. HOTMAP : Global hot target detection at moderate spatial resolution. *Remote Sens. Environ.*, 177 :78–88, May 2016.
- [31] Fiona Ngadze, Kudzai Shaun Mpakairi, Blessing Kavhu, Henry Ndaimani, and Monalisa Shingirayi Maremba. Exploring the utility of Sentinel-2 MSI and Landsat 8 OLI in burned area mapping for a heterogenous savannah landscape. *PLoS One*, 15(5) :e0232962, May 2020.
- [32] Taekjun Oh, Myung Jin Chung, and Hyun Myung. Accurate Localization in Urban Environments Using Fault Detection of GPS and Multi-sensor Fusion. In *Robot Intelligence Technology and Applications 4*, pages 43–53. Springer, Cham, Switzerland, Jul 2016.
- [33] Gabriel Henrique de Almeida Pereira, André Minoro Fusioka, Bogdan Tomoyuki Nassu, and Rodrigo Minnetto. Active Fire Detection in Landsat-8 Imagery : a Large-Scale Dataset and a Deep-Learning Study. *arXiv*, Jan 2021.
- [34] Alessandro Piscini and Stefania Amici. Fire detection from hyperspectral data using neural network approach. *ResearchGate*, page 963721, Oct 2015.
- [35] Luca Pulvirenti, Giuseppe Squicciarino, Elisabetta Fiori, Paolo Fiorucci, Luca Ferraris, Dario Negro, Andrea Gollini, Massimiliano Severino, and Silvia Puca. An Automatic Processing Chain for Near Real-Time Mapping of Burned Forest Areas Using Sentinel-2 Data. *Remote Sensing*, 12(4) :674, Feb 2020.
- [36] Charlotte L. Rae, Martin Farley, Kate J. Jeffery, and Anne E. Urai. Climate crisis and ecological emergency : Why they concern (neuro)scientists, and what we can do. *Brain Neurosci. Adv.*, 6 :23982128221075430, Jan 2022.
- [37] François-Nicolas Robinne. UNFF16 background paper : Impacts of disasters on forests, in particular forest fires. *ResearchGate*, Apr 2021.
- [38] Marcos Rodrigues, María Zúñiga-Antón, Fermín Alcasena, Pere Gelabert, and Cristina Vega-García. Integrating geospatial wildfire models to delineate landscape management zones and inform decision-making in Mediterranean areas. *Saf. Sci.*, 147 :105616, Mar 2022.
- [39] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-Net : Convolutional Networks for Biomedical Image Segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pages 234–241. Springer, Cham, Switzerland, Nov 2015.
- [40] B. Roy, H. M. Alexander, J. Davidson, F. Campbell, J. Burdon, R. Sniezko, and C. Brasier. Increasing forest loss worldwide from invasive pests requires new trade regulations. *undefined*, 2014.
- [41] Wilfrid Schroeder, Patricia Oliva, Louis Giglio, Brad Quayle, Eckehard Lorenz, and Fabiano Morelli. Active fire detection using Landsat-8/OLI data. *Remote Sens. Environ.*, 185 :210–220, Nov 2016.
- [42] Daniela Smiraglia, Federico Filippini, Stefania Mandrone, Antonella Tornato, and Andrea Taramelli. Agreement Index for Burned Area Mapping : Integration of Multiple Spectral Indices Using Sentinel-2 Satellite Images. *Remote Sens.*, 12(11) :1862, Jun 2020.
- [43] Nguyen Thanh Toan, Phan Thanh Cong, Nguyen Quoc Viet Hung, and Jun Jo. A deep learning approach for early wildfire detection from hyperspectral satellite images. In *2019 7th International Conference on Robot Intelligence Technology and Applications (RiTA)*, pages 38–45. IEEE, Nov 2019.
- [44] Daan van Dijk, Sorosh Shoaie, Thijs van Leeuwen, and Sander Veraverbeke. Spectral signature analysis of false positive burned area detection from agricultural harvests using Sentinel-2 data. *Int. J. Appl. Earth Obs. Geoinf.*, 97 :102296, May 2021.
- [45] Qi Zhang, Linlin Ge, Ruiheng Zhang, Graciela Isabel Metternicht, Chang Liu, and Zheyuan Du. Towards a Deep-Learning-Based Framework of Sentinel-2 Imagery for Automated Active Fire Detection. *Remote Sens.*, 13(23) :4790, Nov 2021.
- [46] Tom X.-P. Zhao, Steve Ackerman, and Wei Guo. Dust and Smoke Detection for Multi-Channel Imagers. *Remote Sens.*, 2(10) :2347–2368, Oct 2010.