

## Rilevamento operativo di attività di deforestazione nella foresta pluviale tramite serie temporali SAR in banda X e reti neurali convoluzionali

Dennis Dell'Ara<sup>1</sup>, Filippo Britti<sup>‡</sup>, Vittorio Gentile<sup>‡</sup>, Giacomo Donato Cascarano<sup>‡</sup>,  
Bianchia Scappatura<sup>‡</sup>, Federica Peralice<sup>‡</sup>, Davide Pirrone<sup>‡</sup>, Saverio Rutigliano<sup>‡</sup>

<sup>1</sup> e-GEOS, via Tiburtina 965, 00155 Rome (Italy), [dennis.dellara@e-geos.it](mailto:dennis.dellara@e-geos.it)

<sup>‡</sup> e-GEOS, via Tiburtina 965, 00155 Rome (Italy)

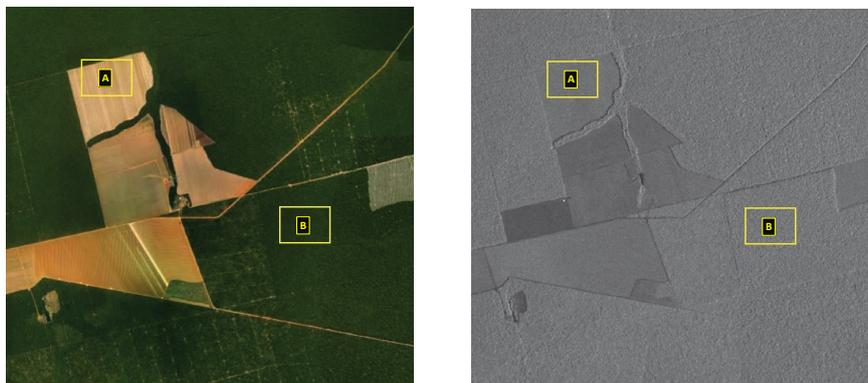
**Abstract.** La foresta pluviale tropicale, con la sua biodiversità, è un bene naturale inestimabile, importante per l'esistenza del nostro pianeta e per il suo equilibrio climatico. Purtroppo, è tutt'ora minacciata da attività umane come la deforestazione. Motivati da questi scenari, il lavoro presentato mostra lo sviluppo di un modello di intelligenza artificiale (DRIAS) che con l'utilizzo di dati radar ad apertura sintetica (SAR) ad alta risoluzione forniti dalle costellazioni COSMO-SkyMed ha il compito di supportare il monitoraggio delle foreste pluviali tropicali. Verranno inoltre illustrati i principali risultati della sua integrazione in una catena di fornitura di servizi operativi.

**Index Terms** — X-Band SAR, COSMO-SkyMed, Amplitude change detection, Segmentazione, Deforestazione, Deep learning.

### 1. Introduzione

Le missioni SAR (Synthetic Aperture Radar), rispetto ai sensori elettro-ottici, sono in grado di raccogliere dati indipendentemente dalle condizioni di illuminazione e dalla presenza di “artefatti” atmosferici quali nuvole o foschia. In particolare, i sistemi in banda X come COSMO-SkyMed di prima (CSK) e seconda generazione (CSG) hanno una elevata sensibilità alle caratteristiche della superficie, comprese le strutture tridimensionali, la texture e le proprietà dielettriche delle aree forestali. La Figura 1 illustra qualitativamente l'utilità dei dati SAR in banda X per la mappatura delle foreste, dove le aree non forestali e quelle forestali presentano rispettivamente texture “lisce” e “ruvide”. Inoltre, costellazioni di satelliti SAR interferometrici, come CSK-CSG, forniscono sia un'elevata frequenza di rivisitazione sia una copertura di un'ampia area, necessaria per monitorare correttamente possibili anomalie nelle aree forestali. Questo potrebbe essere fondamentale per le grandi foreste tropicali, come l'Amazzonia, che sono spesso coperte da nuvole per lunghi periodi dell'anno e gravemente colpite dalla deforestazione. Il lavoro presentato è stato diviso in due parti principali: la prima riguarda lo sviluppo, l'addestramento e la validazione di una rete neurale convoluzionale adatta alla segmentazione di aree deforestate su coppie di immagini d'ampiezza SAR in banda X (DRIAS, Deforestation with SAR and artIficiAl intelligence from Space), mentre la seconda si concentra sull'integrazione del modello sviluppato all'interno di una catena di servizi operativi per il monitoraggio della foresta pluviale tropicale con serie temporali CSK-CSG, fornendo prodotti informativi sulla deforestazione agli utenti finali interessati. In particolare, l'uso operativo di DRIAS è stato ottenuto grazie alla piattaforma e-GEOS brAInt ©. Tale integrazione è in grado di generare prodotti di

deforestazione di facile utilizzo, conforme ai requisiti degli utenti finali, a partire da piani di acquisizione di enormi quantità di data satellitari reali.



**Fig. 1.** Confronto tra immagine ottica e immagine di ampiezza SAR in una stessa area geografica. Rettangolo A: area non forestale (superficie “liscia” nell’immagine SAR). Rettangolo B: area forestale (superficie “ruvida” nell’immagine SAR). Immagine COSMO-SkyMed ©ASI, elaborata e distribuita da e-GEOS.

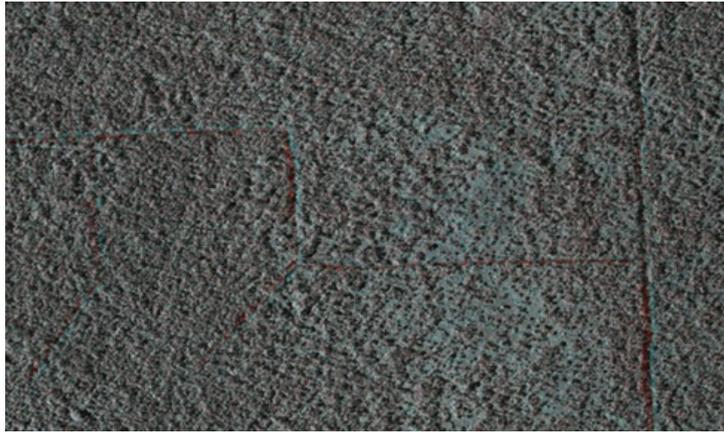
## 2. Training e validazione del modello DRIAS

L’algoritmo di intelligenza artificiale proposto sarà progettato per rilevare automaticamente i disturbi forestali - con un focus specifico sulla deforestazione - da coppie di ampiezza SAR acquisite da CSK e CSG (modalità HImage/Stripmap), per supportare la salvaguardia delle foreste pluviali tropicali. È importante notare che, anche se l’informazione di fase e la coerenza interferometrica sono disponibili grazie alla pianificazione dell’acquisizione, non sono state incluse nell’analisi. Ciò è dovuto alla decorrelazione temporale indotta sull’interferogramma di fase SAR in banda X dalla fitta vegetazione, caratterizzante dello scenario di interesse, che non trasmette ulteriori contenuti informativi rilevanti. Pertanto, l’addestramento del modello di intelligenza artificiale si è concentrato solo su prodotti di sola ampiezza SAR. Negli ultimi anni, le tecniche di deep learning hanno prodotto risultati eccezionali in diversi campi di applicazione grazie alla loro capacità di estrarre automaticamente feature rilevanti e di alto livello dai dati [1]-[3]. Le capacità degli approcci di deep learning per il rilevamento di aree forestali sono state dimostrate principalmente su scenari ottici [4]-[6], mentre i pochi articoli riguardanti il contesto SAR sono limitati dall’utilizzo di immagini a bassa risoluzione (ad esempio, i dati Sentinel-1) [7]. Il presente lavoro integra una metodologia basata sull’intelligenza artificiale per il rilevamento automatico della deforestazione [8] in un contesto operativo, utilizzando dati SAR in banda X CSK-CSG ad alta risoluzione.

## 3. Generazione del training dataset

Nel contesto del deep learning, la disponibilità di un dataset che contenga esempi di aree deforestate è essenziale per addestrare (e validare) una rete neurale per identificare le attività di deforestazione: per questo motivo, un team di esperti fotointerpreti è stato coinvolto nella generazione del dataset necessario, recuperando dagli archivi dati

coppie CSK e CSG raccolte in diverse aree della foresta amazzonica. In dettaglio, il set di dati generato è composto da diverse coppie di immagini SAR co-registrate in ampiezza (polarizzazione HH), calibrate e orto-corrette, ossia un prodotto di “Amplitude Change Detection” (ACD), come mostrato in Figura 2.



**Fig. 2.** Esempio di prodotto ACD, CSK HImage (pixel spacing 3m). L'immagine a “falsi colori” è ottenuta caricando nel canale rosso la prima immagine della coppia e nei canali verde e blu la seconda. Immagine COSMO-SkyMed ©ASI, elaborata e distribuita da e-GEOS.

Tenendo in considerazione le osservazioni fatte sulla coerenza interferometrica, quest'ultima non è stata inclusa tra gli input per l'addestramento del modello DRIAS. Il dataset di addestramento utilizzato per l'apprendimento neurale è stato ottenuto dalla “tassellatura” del dataset precedente, selezionando poi i ritagli più rappresentativi (~4000 patch, dimensioni 400x400 pixel, pixel spacing 3m), tra cui:

- tutti i campioni positivi di attività di deforestazione,
- campioni negativi di assenza di taglio netto,
- campioni negativi di presenza di layover,
- campioni negativi di “forti artefatti” atmosferici.

A causa della complessità dell'interpretazione delle immagini SAR e della capacità dei fotointerpreti esperti di identificare con certezza le aree di disturbo forestale, i campioni positivi sono costituiti da poligoni con un'area superiore a 1 ettaro; i casi evidenti con poligoni inferiori a 1 ettaro sono stati inclusi nel dataset come attività a best-effort. Invece, gli ultimi due tipi di campioni negativi dell'elenco precedente sono stati inclusi nel dataset poiché, durante una prima campagna di test del modello, diversi falsi positivi associati a questi scenari sono stati erroneamente classificati dal modello. Vale la pena sottolineare che, dopo il re-addestramento neurale con questo set di dati aumentato, le prestazioni del modello sono migliorate, come previsto, evitando i precedenti comportamenti errati.

#### 4. Design dell'architettura di DRIAS

Considerando la deforestazione come un problema di rilevamento e delimitazione delle aree di disturbo forestale, il modello DRIAS è stato sviluppato per risolvere un compito di segmentazione. In questo scenario, l'architettura U-Net è una popolare rete neurale convoluzionale usata per la segmentazione semantica: originariamente sviluppata per le immagini mediche [9], ha avuto un grande successo in questo campo, ma dalle immagini satellitari ai caratteri scritti a mano, l'architettura ha migliorato le prestazioni in una vasta gamma di tipi di dati.

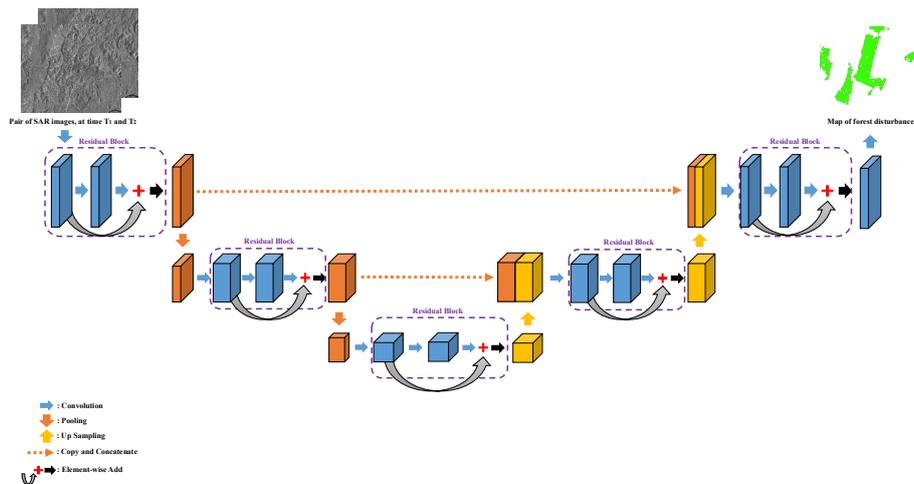


Fig. 3. U-net residuale nel contesto della deforestazione.

Le potenzialità di questa tipologia di rete neurale sono state utilizzate per il rilevamento dei disturbi forestali: più precisamente, una U-Net con unità residuali e “skip connections” è stata scelta per definire l'architettura del modello DRIAS (vedi Figura 3). Questa combinazione ci offre tre vantaggi:

- l'unità residuale faciliterà l'addestramento neurale [10];
- le “skip connections” di cui consentono la “back-propagation” senza degradare l'informazione, rendendo possibile la progettazione di un modello di intelligenza artificiale con meno parametri;
- rispetto alle reti neurali convoluzionali più “profonde”, questa architettura potrebbe ottenere prestazioni comparabili e migliori nella segmentazione semantica.

Nel dettaglio, la rete è composta da tre parti: “encoder”, “bridge” e “decoder”. La prima parte codifica le immagini della coppia in ingresso in feature compatte, mentre l'ultima ricostruisce le feature per una classificazione pixel per pixel, ossia la segmentazione dell'area deforestata. La parte centrale è essenzialmente un “ponte” che unisce “encoder” e “decoder”. Tutte e tre le parti sono costruite con unità residuali: ogni unità prende in input una feature  $x$  e restituisce l'output  $F(x) + x$ , dove  $F(\cdot)$  è il risultato di due blocchi di convoluzione consecutivi. Ogni blocco di convoluzione comprende un

layer di attivazione ReLU e un layer convolutivo. Tutte le operazioni di “down-sampling” sono di tipo “Max-pooling” con kernel di dimensione 2 x 2. Le parti di encoder e decoder hanno entrambi due unità residuali.

Prima di ogni unità residuale nel decoder, si effettua un “up-sampling” delle features del livello inferiore e una concatenazione con le features dell’encoder corrispondenti. Dopo l’ultimo livello di decoder, viene utilizzato un layer di convoluzione 3x3 e con attivazione sigmoideale per proiettare le features finali nella maschera di segmentazione desiderata. Tutte le informazioni relative ai parametri e alle dimensioni dell’output di ciascuna fase di DRIAS sono riportate nella Tabella 1.

Tabella 1. Architettura del modello DRIAS.

Section	Layer	Output shape	Filter kernel size
<i>Input</i>	Input	(400, 400, 2)	---
<i>Encoding</i>	Residual Unit I	(400, 400, 64)	9 x 9
	Down-sampling	(200, 200, 64)	---
	Residual Unit II	(200, 200, 128)	7 x 7
	Down-sampling	(100, 100, 128)	---
<i>Bridge</i>	Residual Unit III	(100, 100, 256)	5 x 5
<i>Decoding</i>	Up-sampling	(200, 200, 256)	---
	Residual Unit IV	(200, 200, 128)	7 x 7
	Up-sampling	(400, 400, 128)	---
	Residual Unit V	(400, 400, 64)	9 x 9
<i>Output</i>	Sigmoid convolution	(400, 400, 1)	3 x 3

Dopo la selezione dell’architettura DRIAS, si affronta la fase di addestramento della rete neurale.

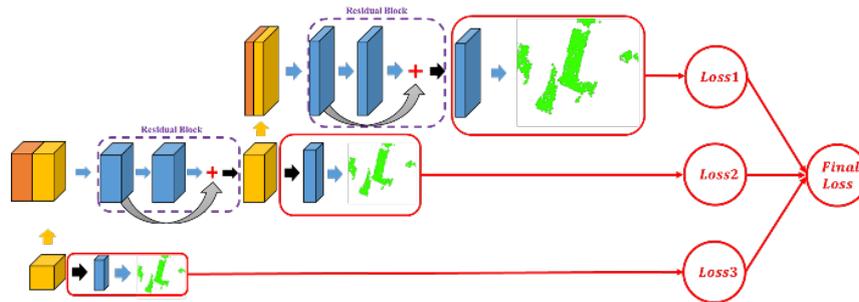
### 5. Training, validazione e test

Il dataset descritto nella sezione 3 è stato suddiviso in tre parti: training, validation e test dataset (rispettivamente 70%, 20%, 10%). Considerando il dataset di addestramento dei dati di input e le corrispondenti maschere di segmentazione di verità a terra  $\{I_i, GT_i\}$ , l’obiettivo è stimare i parametri  $W$  della rete neurale al fine di ottenere buone prestazioni nella segmentazione delle aree di disturbo forestale: ciò viene affrontato minimizzando una funzione di perdita (loss) tra la maschera generata dalla rete, cioè  $Net(I_i; W)$  e la verità a terra  $GT_i$ . Una tipica funzione di loss adottata è data da una somma ponderata della “binary cross entropy” (CE) e della “dice loss” (DICE) tra  $Net(I_i; W)$  e  $GT_i$  [11].

$$Loss(I_i, W, GT_i) = CE(Net(I_i; W), GT_i) + \alpha \cdot DICE(Net(I_i; W), GT_i) \quad (1)$$

La loss così definita non è stata utilizzata solamente per confrontare l’output finale della rete con la verità a terra, ma è stata implementata a tutti i livelli della U-net per integrare pienamente le informazioni multiscale fornite da DRIAS (vedi Figura 4). Le maschere

di segmentazione in scala ridotta sono ottenute dal down-sampling (Max-pooling con kernel di dimensione 2 x 2) della verità a terra  $GT_i$ . Nell'equazione (1), il parametro  $\alpha$  è impostato a 0.5, mentre per addestrare la rete neurale si utilizza la discesa del gradiente dell'ottimizzazione Adam.



**Fig. 4.** Loss multiscala utilizzata in DRIAS. Per ogni livello di scala, l'addestramento confronta il prodotto del livello corrente (ultimo blocco in blu) con la verità a terra (in verde).

Le prestazioni sul test dataset, a livello di pixel, sono riportate nella Tabella 2.

**Tabella 2.** Performance sul test dataset.

Confusion Matrix		OUTPUT DRIAS	
		No Cambiamento	Cambiamento
VERITA'	No Cambiamento	60.075.495 (TN)	663.137 (FP)
	Cambiamento	555.792 (FN)	1.425.576 (TP)

	Accuratezza	Recall	Precisione	IoU
Equazione	$\frac{TN + TP}{TN + TP + FN + FP}$	$\frac{TP}{TP + FN}$	$\frac{TP}{TP + FP}$	$\frac{TP}{TP + FN + FP}$
Valore	98 %	72 %	68 %	54 %

È importante notare che questi risultati devono essere valutati considerando il forte sbilanciamento tra la classe cambiamento e non cambiamento: infatti, i pixel associati alle aree di taglio forestale sono il ~3% dei pixel totali del dataset di test.

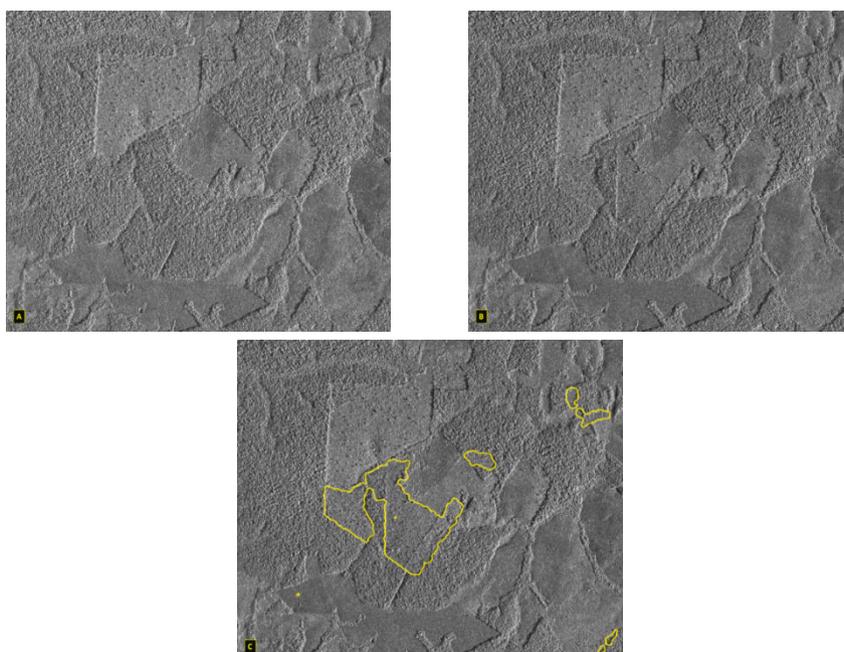
### 6. Integrazione del modello DRIAS in una catena operativa

L'ultima fase dell'attività si concentra sull'integrazione del modello addestrato all'interno di una catena operativa dedicata alla fornitura di servizi di monitoraggio della foresta tropicale. Di seguito sono descritte le fasi principali della pipeline sviluppata:

- 1) Raccolta dei dati CSK-CSG dai canali di origine e catalogazione;
- 2) Identificazione, generazione e catalogazione delle coppie di ACD;

- 3) Inferenza del modello DRIAS;
- 4) Controllo di qualità e consegna finale dei poligoni rilevati del disturbo forestale.

Questa attività è stata svolta sfruttando la piattaforma e-GEOS brAInt © (<https://www.e-geos.it/digital-platforms/brain/>). L'integrazione del modello nella piattaforma ha richiesto diversi interventi sia a livello algoritmico che software per conformarsi all'architettura orientata ai servizi della piattaforma. Questa integrazione operativa è stata un'importante opportunità per portare DRIAS a un livello operativo rilevante e ha permesso di estendere i test e la validazione con grandi quantità di dati reali. È importante notare che il modello DRIAS è in grado di rilevare aree di deforestazione di qualsiasi dimensione anche in ambienti operativi (cfr. Figura 5). Tuttavia, ricordando lo sbilanciamento dimensionale associato alle aree di deforestazione (cioè, per lo più superiori a 1 ettaro) è suggerito l'utilizzo dei soli poligoni predetti con area maggiore di 1 ettaro. In questo modo, anche in fase operativa le prestazioni del modello saranno affini a quelle ottenute sul test dataset (Tabella 2).



**Fig. 5.** Esempio operativo di ACD (A=immagine pre-taglio, B=immagine post-taglio) e di output del modello DRIAS (C=poligoni di disturbo forestale rilevati). Immagine COSMO-SkyMed ©ASI, elaborata e distribuita da e-GEOS.

## 7. Conclusioni

In questo studio è stata sviluppata una rete neurale per identificare la deforestazione su immagini SAR COSMO-SkyMed (Himage, modalità Stripmap, polarizzazione HH). I risultati riportati dimostrano che la combinazione di dati in banda X ad alta risoluzione e reti neurali convoluzionali è utile per supportare efficacemente il monitoraggio della

foresta pluviale tropicale nei casi in cui non è possibile l'utilizzo di sensori ottici. Sviluppi futuri puntano ad un aumento del dataset considerando anche diversi tipi di alberi (non solo la foresta amazzonica) per addestrare un modello a riconoscere in modo più generale attività di deforestazione. In aggiunta, i prodotti multi-polarimetrici CSG saranno maggiormente investigati per migliorare la caratterizzazione dei fenomeni di deforestazione. Infine, verranno studiate architetture neurali più complesse per definire un modello di intelligenza artificiale più performante per questo caso d'uso.

## 8. Riconoscimenti

e-GEOS, una società ASI (20%) / Telespazio (80%) soggetta alla direzione e al coordinamento congiunto di Leonardo S.p.A e Thales S.A, è un operatore leader a livello internazionale nel settore dell'osservazione della Terra (EO) e dell'informazione geo-spaziale che offre un portafoglio unico di servizi applicativi ([www.e-geos.it](http://www.e-geos.it)).

## Riferimenti bibliografici

1. Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE geoscience and remote sensing magazine*, 5(4), 8-36.
2. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.
3. Yuan, X., Shi, J., & Gu, L. (2021). A review of deep learning methods for semantic segmentation of remote sensing imagery. *Expert Systems with Applications*, 169, 114417.
4. Ortega, M. X., Bermudez, J. D., Happ, P. N., Gomes, A., & Feitosa, R. Q. (2019). Evaluation of deep learning techniques for deforestation detection in the amazon forest. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 121-128.
5. Lee, S. H., Han, K. J., Lee, K., Lee, K. J., Oh, K. Y., & Lee, M. J. (2020). Classification of landscape affected by deforestation using high-resolution remote sensing data and deep-learning techniques. *Remote Sensing*, 12(20), 3372.
6. Isaienkov, K., Yushchuk, M., Khramtsov, V., & Seliverstov, O. (2020). Deep learning for regular change detection in Ukrainian forest ecosystem with sentinel-2. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 364-376.
7. Ortega Adarme, M., Doblaz Prieto, J., Queiroz Feitosa, R., & De Almeida, C. A. (2022). Improving Deforestation Detection on Tropical Rainforests Using Sentinel-1 Data and Convolutional Neural Networks. *Remote Sensing*, 14(14), 3290.
8. Dell'Ara, D., Britti, F., Gentile, V., Cascarano, G. D., Scappatura, B., Pieralice, F., ... & Rutigliano, S. Operative Automatic Detection of Tropical Rainforest Disturbances in X-Band SAR Time-Series Based on Convolutional Neural Network. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS) 2024* (pp. 10096-10100). IEEE.
9. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18* (pp. 234-241). Springer International Publishing.
10. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *IEEE conference on computer vision and pattern recognition* (pp. 770-778).
11. Jadon, S., A survey of loss functions for semantic segmentation. In *2020 IEEE conference on computational intelligence in bioinformatics and computational biology (CIBCB)* (pp. 1-7). IEEE.