

DEEP LEARNING APLICADO A LA DETECCIÓN AUTOMÁTICA DE DEFORESTACIÓN MEDIANTE IMÁGENES SATELITALES MULTITEMPORALES

Romina Paula Carmona · Tutora: Peregrina Eloína Coll Aliaga · Universitat Politècnica de València (UPV)

1. INTRODUCCIÓN

Deforestación, EUDR y teledetección

La deforestación constituye un problema ambiental global asociado a la pérdida de biodiversidad y al aumento de emisiones de gases de efecto invernadero. En 2023, la Unión Europea aprobó el Reglamento de Deforestación (EUDR), que exige verificar que determinados productos importados no proceden de tierras deforestadas después del 31 de diciembre de 2020. En este contexto, el aprendizaje profundo aplicado a imágenes satelitales multispectrales permite procesar grandes volúmenes de datos e identificar automáticamente áreas con pérdida de cobertura forestal.

2. OBJETIVOS

Objetivo general

Evaluar metodologías automáticas para detectar deforestación con imágenes Sentinel-2 multitemporales.

Objetivos específicos

- Diseñar y entrenar una arquitectura U-Net para segmentación binaria de cambios forestales.
- Evaluar el efecto de la superresolución espacial mediante SEN2SR-Lite.
- Comparar el modelo principal con un clasificador Random Forest basado en embeddings AlphaEarth.
- Analizar la variabilidad del rendimiento en cuatro contextos geográficos contrastados.

3. ÁREAS DE ESTUDIO

Cuatro contextos forestales contrastados

Se evaluaron cuatro regiones con patrones de deforestación contrastados, localizadas en la Figura 1, usando zonas de entrenamiento y test sin solapamiento espacial.

Brasil — Amazonia

Expansión de parcelas existentes y nuevos claros asociados a caminos.

T1: abril–junio 2020 | T2: abril–junio 2025

Paraguay — Gran Chaco

Geometrías muy regulares y organizadas.

T1: julio–sept 2020 | T2: julio–sept 2025

Indonesia — Sumatra

Nubosidad persistente; conversión a palma aceitera y renovación de plantaciones antiguas.

T1: junio–julio 2019 | T2: junio–julio 2025

R. D. Congo — Cuenca del Congo

Pérdida dispersa y progresiva, sin geometrías definidas.

T1: abril–junio 2020 | T2: abril–junio 2025




Figura 1. Localización de las áreas de estudio —Brasil, Paraguay, Indonesia y RDC— y ejemplo de deforestación observado en una zona analizada.

4. DATOS

Sentinel-2 L2A

5 Bandas espectrales + NDVI, por fecha (T1, T2)

Train/ validación: 156 parches

Test independiente 145 parches.

5. METODOLOGÍA

La metodología, detallada en la Figura 2, combinó dos enfoques: como línea principal, U-Net aplicada a composiciones multitemporales Sentinel-2; y, como comparación, Random Forest con embeddings AlphaEarth Foundations. Las imágenes T1–T2 se evaluaron en resolución original y con superresolución SEN2SR-Lite. Las máscaras binarias de cambio/no cambio, generadas por interpretación visual y digitalización manual, se usaron como referencia común. Los enfoques se compararon en zonas independientes mediante métricas de segmentación y clasificación.




Figura 2. Flujo metodológico para la comparación entre U-Net, U-Net con superresolución y Random Forest con embeddings AlphaEarth.

6. RESULTADOS

Resultados del modelo U-Net y comparación entre metodologías

La U-Net mostró un buen rendimiento global (Dice = 0,67), con mejores resultados en Paraguay y Brasil, mientras que la superresolución aportó mejoras locales y AlphaEarth + Random Forest fue competitivo en algunos contextos.

A. Ejemplo cualitativo




Figura 3: Ejemplo visual de segmentación de cambio con U-net Brasil

C. Comparación por país y metodología





Figura 4: Comparación por país y metodología a partir de métricas de evaluación y síntesis de resultados.

País	Resultado principal
Brasil	Destaca U-Net original
Paraguay	Los tres enfoques funcionan bien
R. D. Congo	Mejor con RF + AlphaEarth
Indonesia	U-Net detecta más; RF más precisa.

B. Desempeño global U-Net

El modelo presenta alta sensibilidad (Recall = 80 %), pero una precisión moderada (56 %), lo que indica buena capacidad de detección con cierta sobreestimación en contextos complejos.



D. Análisis espacial de errores

Los mapas de error permiten identificar diferencias espaciales en el comportamiento de los modelos según el contexto geográfico.

Paraguay | caso favorable para U-Net

R. D. Congo | comparación metodológica




Figura 5: Caso favorable: patrones de deforestación regulares.




Figura 6: Comparación metodológica en un paisaje más fragmentado y complejo.

7. CONCLUSIONES

- U-Net es viable para detectar deforestación con Sentinel-2 multitemporal.
- El desempeño depende del contexto: mejora en paisajes con patrones de deforestación regulares y disminuye en escenarios fragmentados o nubosos.
- La superresolución no aporta mejoras globales, pero puede ayudar localmente.

- Random Forest + AlphaEarth es una alternativa competitiva y eficiente en escenarios complejos, pero su frecuencia anual limita el monitoreo operativo.
- Los resultados confirman la necesidad de adaptar la metodología al tipo de paisaje y al objetivo del monitoreo EUDR.

8. REF. BIBLIOGRÁFICAS

[1] Parlamento Europeo y Consejo de la Unión Europea. Reglamento (UE) 2023/1115, relativo a productos libres de deforestación. *Diario Oficial de la Unión Europea*, 2023.

[2] Ronneberger, O., Fischer, P., & Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *MI/CAI 2015*, Springer, 2015.

[3] Md Jelas, I., Zulkifley, M. A., Abdullah, M., & Spraggon, M. (2024). Deforestation detection using deep learning-based semantic segmentation techniques: A systematic review. *Frontiers in Forests and Global Change*, 7, 1300060.

[4] Brown, C. F. et al. "AlphaEarth Foundations: An embedding field model for global mapping", 2025.