

Modelo de segmentación semántica de imágenes satelitales basado en redes neuronales convolucionales para la clasificación de cobertura de la tierra en páramos

Marcela Reyes-Quintana^{*1}, Iván Lizarazo²

¹ Universidad Nacional de Colombia, sede Bogotá, Facultad de Ciencias Agrarias, Bogotá, Colombia.

² Universidad Nacional de Colombia, sede Bogotá, Facultad de Ciencias Agrarias, Grupo de Investigación Análisis Espacial del Territorio y del Cambio Global (AET-CG), Bogotá, Colombia.

Abstract: Los ecosistemas de páramo son esenciales para la regulación hídrica y la conservación de la biodiversidad en zonas montañosas. Sin embargo, enfrentan amenazas significativas debido al cambio climático y actividades humanas como agricultura, ganadería y minería. La ausencia de una delimitación clara y de sistemas de monitoreo continuo de sus coberturas dificultan su protección efectiva resaltando la necesidad de emplear técnicas digitales avanzadas que proporcionen información con alta exactitud y actualizada. Las redes neuronales convolucionales (CNNs, por sus siglas en inglés) se han posicionado como herramientas prometedoras para la segmentación semántica de imágenes satelitales. Esta investigación buscó evaluar el desempeño de dos modelos basados en arquitecturas de CNNs *U-Net++* y *DeepLabV3+* para clasificar las coberturas de la tierra en el complejo de páramos Tota-Bijagual-Mamapacha (TBM) en Colombia, utilizando imágenes *Landsat 8* del periodo 2017 a 2019 y etiquetas del mapa nacional de coberturas 1:100 000 del IDEAM de 2018. Los resultados mostraron que *U-Net++* alcanzó un κ de 0,60, mientras que *DeepLabV3+* obtuvo un κ de 0,59. En las coberturas de páramo, *U-Net++* logró un valor $F1$ del 78,43% para *Herbazal* y del 79,22% para *Bosques*, mientras que *DeepLabV3+* alcanzó un valor $F1$ del 75% y 74,27%, respectivamente, confirmando el potencial de las CNNs para la clasificación de coberturas en estos ecosistemas. Aunque ambos modelos presentaron tiempos de procesamiento similares, el desbalance de clases y la dependencia de etiquetas consistentes afectaron su rendimiento en coberturas heterogéneas. Esta investigación establece una base metodológica para futuros estudios y sugiere abordar estas limitaciones para mejorar la eficiencia y la exactitud temática en la clasificación y monitoreo de ecosistemas de páramo.

Key words: teledetección, páramo, redes neuronales convolucionales, segmentación semántica.

Convolutional neural network-based semantic segmentation model for land cover classification in páramo ecosystems

Resumen: Páramo ecosystems are essential for water regulation and biodiversity conservation in mountainous areas. However, they face significant threats due to climate change and human activities such as agriculture, livestock farming, and mining. The absence of clear boundaries and continuous monitoring systems for their land cover hinders effective protection highlighting the need to employ advanced digital techniques that provide highly accurate, up-to-date information. Convolutional neural networks (CNNs) have emerged as promising tools for semantic segmentation of satellite images. This research aimed to evaluate the performance of two CNN architectures *U-Net++* and *DeepLabV3+* for land cover classification in the Tota-Bijagual-Mamapacha (TBM) páramo complex in Colombia, using *Landsat 8* imagery from 2017 to 2019 and land cover labels from 1:100.000.

To cite this article: Reyes-Quintana, M., Lizarazo, I. 2025. Convolutional neural network-based semantic segmentation model for land cover classification in páramo ecosystems. *Revista de Teledetección*, 65, 21858. <https://doi.org/10.4995/raet.2025.21858>

* Corresponding author: nreyesq@unal.edu.co

national coverage map produced by IDEAM in 2018. The results showed *U-Net++* achieved a *kappa* of 0.60, while *DeepLabV3+* obtained a *kappa* of 0.59. In páramo covers, *U-Net++* achieved an *F1* of 78.43% for Herbazal and 79.22% for Forests, while *DeepLabV3+* achieved *F1* of 75% and 74.27%, respectively, confirming the potential of *CNNs* for land cover classification in these ecosystems. Although both models presented similar processing times, class imbalance and reliance on consistent labels affected their performance in heterogeneous covers. This research establishes a methodological foundation for future studies and suggests addressing these limitations to improve efficiency and thematic accuracy in the classification and monitoring in páramo ecosystems.

Keywords: remote sensing, páramo, convolutional neural networks, semantic segmentation.

1. Introduction

Los páramos son ecosistemas tropicales de alta montaña (Brück et al., 2023; Vásquez y Buitrago, 2011) situados entre el límite superior del bosque andino y el límite inferior de los glaciares (MADS, 2016). Son cruciales para la regulación hídrica y la conservación de la biodiversidad, además proveen agua a más del 70% de la población colombiana para consumo humano y actividades agropecuarias (Vergara, 2020). Colombia cuenta con aproximadamente tres millones de hectáreas de páramos lo que representa el 50% de estos ecosistemas a nivel mundial. Esto subraya su relevancia ecológica y la urgencia de implementar un monitoreo efectivo para su conservación (Brück et al., 2023).

Sin embargo, los páramos enfrentan presiones crecientes debido a la expansión agrícola, la ganadería, la minería y el cambio climático (Buytaert et al., 2006), lo que ha llevado a la degradación de más del 50% de los páramos en regiones como Boyacá (IDEAM et al., 2014; Brück et al., 2023). En Colombia, la clasificación oficial se realiza con métodos tradicionales de teledetección basadas en interpretación visual. Pese a que se producen mapas con alta exactitud temática, son costosos y requieren mucho tiempo para su realización (Suárez et al., 2017). Los recientes avances en aprendizaje de máquina (*machine learning*) y teledetección han impulsado la adopción de técnicas automáticas de clasificación digital (Ayala et al., 2017; Maxwell et al., 2018; Talukdar et al., 2020; Coca et al., 2021), con estudios como el de Poveda-Sotelo et al. (2022) que demuestran su aplicabilidad en páramos.

En este contexto, el aprendizaje profundo (*deep learning*), especialmente mediante redes neuronales convolucionales (*CNNs*), es una herramienta prometedora para la clasificación de coberturas

debido a su capacidad para detectar patrones complejos en imágenes multiespectrales (Kussul et al., 2017; Ma et al., 2019; Deepan y Sudha, 2020). Las *CNNs* simulan la visión humana procesando imágenes píxel a píxel a través de múltiples capas de convolución espacial. En las primeras capas, detectan características simples, mientras que en las capas posteriores reconocen patrones complejos (Deepan y Sudha, 2020).

Entre las arquitecturas más prometedoras para segmentación semántica se destacan *U-Net++* y *DeepLabV3+* (Yuan et al., 2021). Estas arquitecturas se componen de dos fases: durante la codificación, extraen las características más importantes de la imagen mediante capas de convolución y agrupamiento. En la decodificación, reconstruyen la imagen usando una técnica llamada convolución traspuesta, que restaura la resolución espacial necesaria para una segmentación detallada (Martin-Abadal et al., 2018).

U-Net++ (Navab et al., 2015) es eficaz en la segmentación debido a su capacidad para capturar detalles a nivel global y local (Zhou et al., 2018, 2019) (Figura 1a), mientras que *DeepLabV3+* (Ayhan et al., 2020; Chen et al., 2017; Liu et al., 2021) incorpora técnicas como la convolución *atrous* (convolución dilatada) y la agrupación de pirámides espaciales *atrous*, optimizando la segmentación en áreas heterogéneas (Figura 1b). A pesar de su potencial, las *CNNs* enfrentan desafíos en la segmentación semántica de imágenes satelitales (Yuan et al., 2021) como la falta de datos etiquetados de calidad, el desbalance de clases, la complejidad de las imágenes multiespectrales y los altos requerimientos computacionales (Chen et al., 2022; Iyer et al., 2021). A pesar de estos desafíos, tienen un gran potencial para mejorar la exactitud y eficiencia en la clasificación.

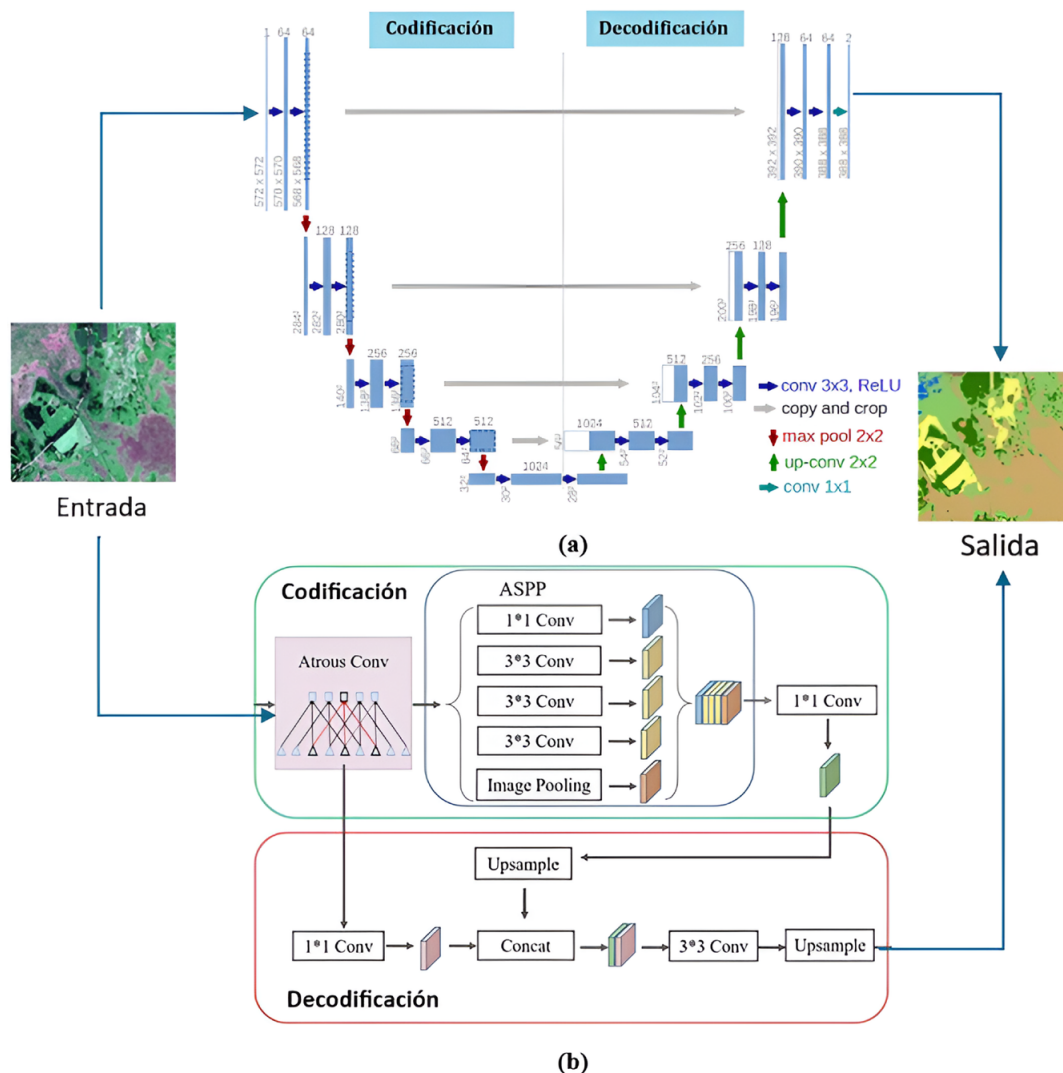


Figura 1. (a) U-Net++ y (b) DeepLabV3+. Adaptado de Navab et al. (2015) y Liu et al. (2021).

Este artículo evaluó el desempeño U-Net++ y DeepLabV3+ en la segmentación semántica de imágenes Landsat 8 para la clasificación de coberturas de páramos. Los modelos se evaluaron en términos de exactitud temática y eficiencia computacional, y se implementaron estrategias para mitigar el desbalance de clases y maximizar el uso de bandas espectrales. La estructura del resto del artículo se organiza así: (i) *Materiales y métodos*, describe el área de estudio, los datos y la metodología; (ii) *Resultados*, presentan los hallazgos; (iii) *Discusión*, analiza los resultados y sus implicaciones; y (iv) *Conclusiones*, resume los aportes y las limitaciones de este estudio.

2. Materiales

2.1. Área de estudio

El estudio se centró en el complejo de páramos Tota-Bijagual-Mamapacha (TBM), ubicado en la cordillera Oriental de Colombia entre las coordenadas aproximadas 5° 6' 0'' N y 6° 18' 0'' N de latitud y 72° 12' 0'' W y 73° 24' 0'' W de longitud. Este páramo es el cuarto más grande del país cubriendo una superficie de 151 247 hectáreas, lo que representa cerca del 60% de los páramos colombianos (MADS, 2016). Se extiende por 19 municipios de Boyacá y Cundinamarca, con altitudes que oscilan entre 2900 y 4000 m s.n.m.,

un clima frío y húmedo con temperaturas entre 6°C y 12°C y precipitaciones anuales de 1000 a 2500 mm.

Estas condiciones favorecen la diversidad vegetal y la presencia de especies endémicas. A pesar de que el 31% del complejo (46256 ha) está bajo protección, más del 57,3% ha sido modificado por actividades humanas como agricultura y ganadería, impactando negativamente la biodiversidad y los servicios ecosistémicos que el páramo proporciona (Buytaert et al., 2006; Morales et al., 2007). El área de estudio cubre 1914973,76 hectáreas (Figura 2), incluye el páramo TBM y otros complejos aledaños. Las coberturas predominantes son *Pastos* (27%), *Áreas agrícolas heterogéneas* (23%), *Bosques* (20%) y *Herbazales* (17%) (Castellanos et al., 2021). Este páramo fue elegido por su extensión, biodiversidad, provisión de agua, servicios ecosistémicos y grado de transformación antrópica (Cabrera y Ramírez, 2014).

2.2. Datos

Se utilizaron diversas fuentes de datos en esta investigación. Las imágenes satelitales *Landsat 8* de nivel 2 (reflectancia superficial) fueron obtenidas mediante *Google Earth Engine (GEE)*. A partir de estas se construyó un mosaico de mediana para el periodo comprendido entre el 1 de enero de 2017 y el 31 de julio de 2019. Estas imágenes tienen una resolución espacial de 30 metros y una resolución espectral de once bandas, de las cuales se utilizaron tres bandas del espectro visible y tres del infrarrojo (Tabla 1).

Además, se usó el Mapa Nacional de Coberturas (MNC) a escala 1:100000 (Castellanos et al., 2021) el más reciente disponible en el momento del estudio, para construir las etiquetas de referencia requeridas para entrenar y evaluar los modelos. También se utilizó el Modelo Digital de Elevación (*DEM Shuttle Radar Topography Mission (SRTM)* de la *NASA* con una resolución de 30

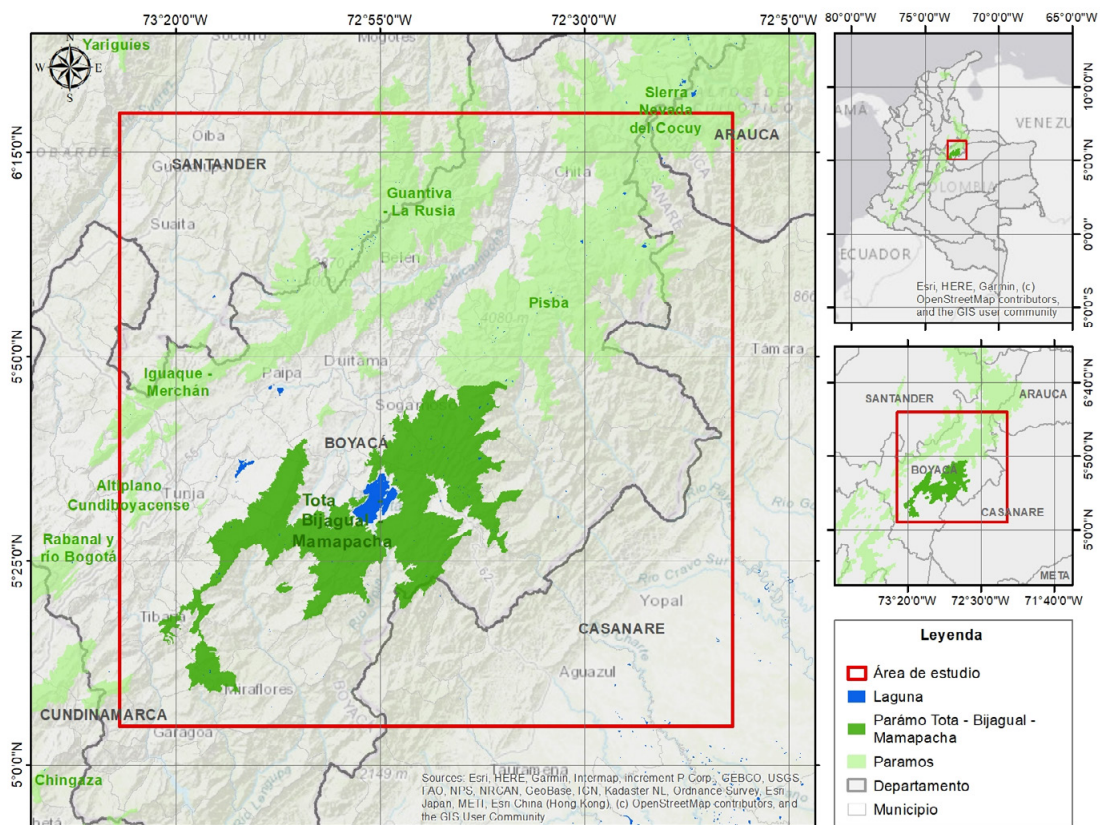


Figura 2. El área de estudio se delimita en color rojo. Fuente de datos MADS e IGAC, composición propia.

Tabla 1. Información de las bandas OLI de Landsat 8. Fuente: Earth Engine Data Catalog (2022).

Nombre	Longitud de onda (µm)	Descripción
B2	0,45 - 0,51	Azul
B3	0,53 - 0,59	Verde
B4	0,64 - 0,67	Rojo
B5	0,85 - 0,88	Infrarrojo cercano (NIR)
B6	1,57 - 1,65	Infrarrojo de onda corta 1 (SWIR 1)
B7	2,11 - 2,29	Infrarrojo de onda corta 2 (SWIR 2)

metros, para incluir las características altimétricas del área de estudio. A partir del mosaico de imágenes Landsat 8, se calculó el índice de vegetación de diferencia normalizada (NDVI) para incluirlo como covariable en la clasificación (Ayhan et al., 2020), mediante la ecuación:

$$NDVI = \frac{NIR - Rojo}{NIR + Rojo} \quad (1)$$

Donde: NIR = banda 5 y Rojo = banda 4.

3. Métodos

La metodología consta de tres etapas como se detalla en la Figura 3: preprocesamiento (PRE), procesamiento (PRO) y análisis (ANA).

3.2.1. Preprocesamiento (PRE)

Esta etapa se enfocó en la preparación y limpieza de los datos. En PRE1 (Figura 3) se obtuvieron todas las imágenes Landsat 8 (2017-2019) para el área de

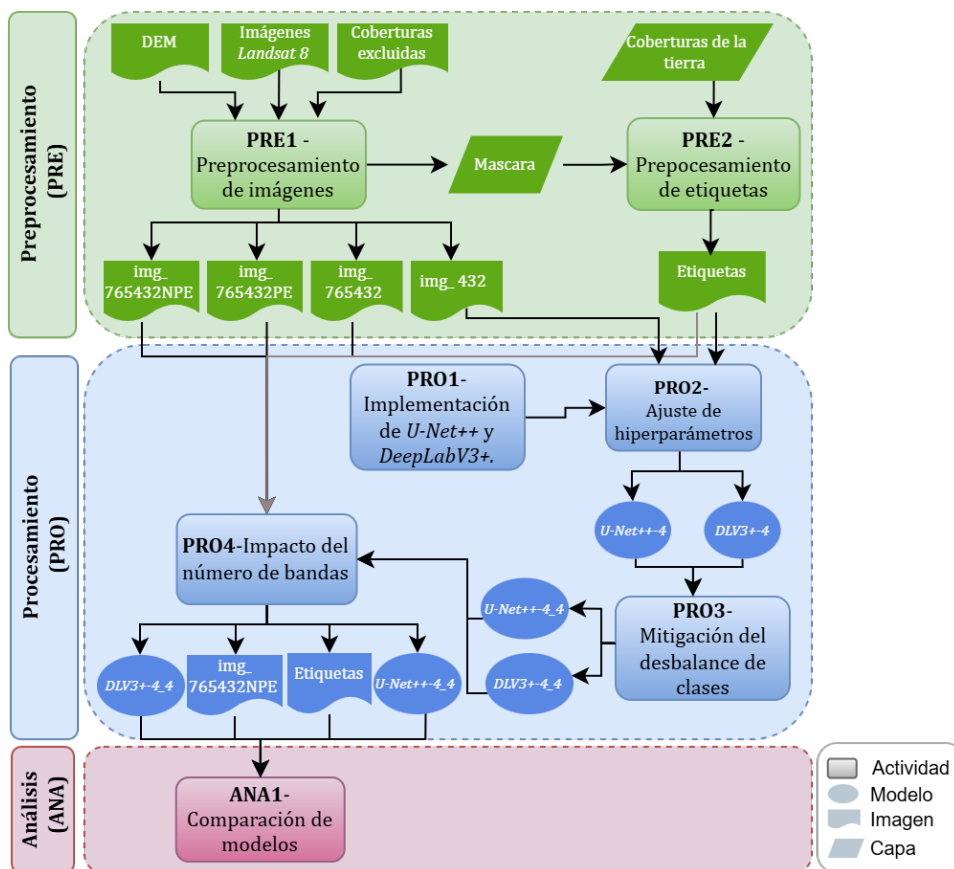








Figura 3. Diagrama de la metodología utilizada en la investigación. Fuente propia.

Tabla 2. Descripción de las coberturas CLC de nivel 3 presentes en los páramos. Fuente (IDEAM, 2010).

Cobertura	Descripción	Fotografía	Composición RGB 432
3.2.1. Herbazal	Áreas dominadas por especies herbáceas. La cobertura vegetal puede ser densa, cubriendo más del 70% del terreno, o más abierta, ocupando entre el 30% y el 70%.		
3.2.2. Arbustal	Zonas ocupadas por vegetación arbustiva, definida por plantas perennes y leñosas que miden entre 0,5 y 5 metros de altura.		
3.2.3. Vegetación secundaria o en transición	Coberturas vegetales que emergen tras la intervención humana o la destrucción de la vegetación primaria. Estas áreas están en proceso de recuperación.		

estudio, utilizando las bandas B2 a B7. Se aplicó una máscara de calidad (*pixel_qa*) para excluir píxeles afectados por nubes y sombras, y se eliminaron las superficies artificiales. Con la colección filtrada, se generaron cuatro composiciones de imágenes mediante la mediana por píxel en cada banda, incorporando como covariables: la pendiente (P), la elevación (E) y el *NDVI* (N). Las composiciones fueron nombradas según su configuración: *img_432* (bandas B4, B3 y B2), *img_765432* (bandas B7 a B2), *img_765432PE* (bandas B7 a B2 más pendiente y elevación) e *img_765432NPE* (bandas B7 a B2 más pendiente, elevación y *NDVI*). Estas combinaciones fueron diseñadas para optimizar las diferencias entre coberturas, morfología del terreno y características del suelo (Yuan et al., 2021; Castelo et al., 2022).

En PRE2 se seleccionaron las coberturas *Corine Land Cover (CLC)* de nivel 2 del MNC. Para un análisis más detallado de los páramos, se incluyeron coberturas de nivel 3: 3.2.1. *Herbazal*, 3.2.2. *Arbustal* y 3.2.3. *Vegetación secundaria o en transición* (Tabla 2). Se eliminaron las áreas como nubes, sombras y superficies artificiales utilizando la máscara generada previamente. A cada cobertura se le asignó un color *RGB* (0 a 255), se transformaron a formato ráster y se normalizaron en una escala de 0 a 11 (Tabla 3).

Las imágenes y sus etiquetas se dividieron en ventanas de 256×256 y 128×128 píxeles, obteniendo 324 y 1296 ventanas, respectivamente. Los datos se dividieron en tres conjuntos: entrenamiento, validación y prueba (Géron, 2019). Para

Tabla 3. Coberturas nivel 2 y 3 usadas en el estudio, extensión cubierta y color asignado. Fuente propia.

No	Cobertura	% Área	Composición RGB	Color
0	2.1. Cultivos transitorios	0,69%	250,200,100	Café claro
1	2.2 Cultivos permanentes	0,26%	200,200,0	Amarillo-verde
2	2.3. Pastos	27,50%	255, 255, 0	Amarillo
3	2.4. Áreas agrícolas heterogéneas	22,90%	255, 150, 0	Naranja
4	3.1. Bosques	18,37%	50, 150, 0	Verde oscuro
5	3.2.1. Herbazal	17,37%	50, 200, 50	Verde medio
6	3.2.2. Arbustal	4,28%	0, 255, 0	Verde
7	3.2.3. Vegetación secundaria o en transición	5,24%	250, 250, 150	Amarillo pálido
8	3.3. Áreas abiertas, sin o con poca vegetación	0,72%	200, 200, 200	Gris
9	4.1. Áreas húmedas continentales	0,01%	0, 255, 255	Cian
10	5.1. Aguas continentales	0,92%	0, 0, 255	Azul
11	No data	1,74%	0, 0, 0	Negro

el entrenamiento, se seleccionó aleatoriamente el 70% de las ventanas buscando garantizar una representatividad de todas las clases. El porcentaje restante de ventanas se distribuyó entre validación y prueba, con un 15% cada uno (Tabla 4).

Tabla 4. Distribución de ventanas utilizadas en entrenamiento, validación y pruebas. Cada ventana incluyó las covariable espectrales y altimétricas. Fuente propia.

Imágenes	Entrenamiento (70%)	Validación (15%)	Prueba (15%)
256×256	228	48	48
128×128	1036	130	130

3.2.2. Procesamiento (PRO)

Esta etapa se enfocó en el afinamiento de los modelos. En PRO1 se implementaron y entrenaron modelos con arquitecturas basadas en *U-Net++* y *DeepLabV3+*, utilizando imágenes *RGB* por defecto y pesos preentrenados (*ImageNet*) para optimizar el tiempo de procesamiento (Krizhevsky et al., 2012). Las arquitecturas se implementaron en *PyTorch*, en una estación de trabajo equipada con una *NVIDIA Quadro RTX™ 5000*.

En PRO2, para maximizar el rendimiento de los modelos se optimizaron algunos hiper-parámetros claves. Se utilizó la función de pérdida de entropía cruzada para medir la discrepancia entre las inferencias y las etiquetas, y el optimizador Adam que ajusta dinámicamente la tasa de aprendizaje durante el entrenamiento. La función de activación Softmax2D, adecuada para clasificación multi-clase, se empleó para normalizar las salidas en probabilidades. Se configuró una tasa de aprendizaje de 0,0001 para asegurar la convergencia y se aplicó la regularización de decaimiento de pesos con un valor de $1e-4$ para prevenir el sobreajuste y mejorar la capacidad de generalización del modelo (Alzubaidi et al., 2021) (Tabla 5). Posteriormente, se entrenaron los modelos *U-Net++-1*, *U-Net++-2*, *U-Net++-3*, *U-Net++-4*, *DLV3+_4*, *DLV3+_4*, *DLV3+_4* y *DLV3+_4* variando el codificador, el número de épocas y el tamaño de las ventanas, con

el objetivo de optimizar la exactitud temática y los tiempos de ejecución.

En PRO3, dado el desbalance de clases presentes en el área de estudio (Figura 4), se implementaron tres estrategias para mitigar el desbalance de clases. Primero, se expandió el área de estudio mediante un buffer de 10 km alrededor del páramo TBM. Sin embargo, dado que no se tenían suficientes etiquetas, se amplió el área de estudio incorporando otros páramos cercanos para aumentar la representatividad de todas las coberturas. En segundo lugar, se generaron 1036 ventanas adicionales mediante 15 transformaciones tales como rotación, inversión horizontal, recortes aleatorios, ajustes de brillo y contraste.




Figura 4. Representatividad de las coberturas en el área de estudio. Fuente propia.

Por último, se modificaron los modelos *U-Net++_4_4* y *DLV3+_4_3* para incorporar pesos diferenciados por coberturas, dando lugar a los modelos *U-Net++_4_1* a *U-Net++_4_4* y *DLV3+_4_1* a *DLV3+_4_4* con distintas configuraciones de pesos. Inicialmente, los pesos se calcularon según la inversa de la frecuencia de las clases para mejorar la representatividad de las coberturas menos representativas. Sin embargo, este enfoque sobrerrepresentó algunas coberturas y no estimó adecuadamente las clases con menor frecuencia. Tras varios ajustes, se logró un equilibrio que mejoró la representatividad general y mantuvo las métricas *F1* en niveles aceptables.

Tabla 5. Hiper-parámetros usados para la segmentación semántica de imágenes. Fuente propia.

Hiper-parámetro	Función de Pérdida	Optimizador	Función de activación	Tasa de Aprendizaje	Regularización
	Entropía cruzada ponderada	Adam	<i>softmax2d</i>	0,0001	Decaimiento de los pesos $1e-4$

En PRO4 se ajustaron las arquitecturas de los modelos *U-Net++_4_4* y *DLV3+_4_3* para permitir el uso de más de tres bandas. Esto implicó modificar la estructura interna de los modelos para que reconozcan nuevas bandas de entrada y calcule los pesos iniciales en función de la media y desviación estándar de cada banda. Con estas modificaciones, se entrenaron los modelos *U-Net++_4_4* y *DLV3+_4_3* utilizando las ventanas *img_765432*, *img_765432PE* e *img_765432NPE*.

3.2.3. Análisis (ANA)

Esta etapa se centró en evaluar los resultados de los dos modelos. En ANA1, se compararon los resultados de la clasificación de coberturas de los modelos *U-Net++_4_4* y *DLV3+_4_3* usando las ventanas *img_765432NPE*, evaluando la exactitud temática reportando los resultados de prueba, a partir de métricas generales como exactitud global (*OA*, por sus siglas en inglés) y *Kappa*, así como la exactitud temática por coberturas mediante *Intersection over Union (IoU)* y *F1-score (F1)* (Belyadi y Haghighat, 2021). Las métricas se calcularon utilizando las siguientes ecuaciones:

$$OA = \frac{TN + TP}{TN + FN + TP + FP} \quad (2)$$

$$Kappa = \frac{N \sum_{ij=1}^m D_{ij} - \sum_{ij=1}^m R_i \times C_j}{N^2 - \sum_{ij=1}^m R_i \times C_j} \quad (3)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

$$F1 = 2 \times \frac{\frac{TP}{TP + FP} \times \frac{TP}{TP + FN}}{\frac{TP}{TP + FP} + \frac{TP}{TP + FN}} \quad (5)$$

- Verdaderos Positivos (*TP*): Clasificaciones correctas de presencia.
- Verdaderos Negativos (*TN*): Clasificaciones correctas de ausencia.
- Falsos Positivos (*FP*): Clasificaciones incorrectas asignadas a una clase.
- Falsos Negativos (*FN*): Clasificaciones incorrectamente omitidas de su clase verdadera.

4. Resultados

4.1. Ajuste de hiper-parámetros

Se eligieron los valores de hiper-parámetros que lograron los mejores resultados en términos de *OA* y *Kappa* para los modelos *U-Net++_4* y *DLV3+_4*. Para obtener estos resultados, se utilizaron imágenes de menor tamaño, un tamaño del lote de 8, el modelo preentrenado *ImageNet* y se corrieron 40 épocas (Tabla 6).

La baja representatividad de ciertas clases en el área de estudio generó un desbalance que dificultó al modelo realizar inferencias en seis coberturas: 2.2 *Cultivos permanentes*, 3.2.1. *Herbazal*, 3.2.2. *Arbustal*, 3.2.3. *Vegetación secundaria o en transición*, 3.3. *Áreas abiertas, sin o con poca vegetación*, 4.1. *Áreas húmedas continentales* y 5.1. *Aguas continentales*, como se detalla en la Tabla 7.

4.2. Mitigación del desbalance de clases

Las tres estrategias implementadas lograron mejorar la representatividad de algunas coberturas menos prevalentes, siendo la asignación de pesos diferenciados la medida más efectiva para

Tabla 6. Hiper-parámetros de los modelos basado en las arquitecturas *CNNs*. Fuente propia.

Modelo	Codificador	Tamaño imagen	Tamaño Lote	Épocas	Preentrenado	OA	Kappa	Tiempo
<i>U-Net++-1</i>	<i>ResNet-152</i>	256x256	8	20	No	51,85%	0,37	36,12
<i>U-Net++-2</i>	<i>ResNet-18</i>	128x128	8	20	No	59,87%	0,48	38,48
<i>U-Net++-3</i>	<i>ResNet-152</i>	128x128	4	30	SI	62,83%	0,52	42,35
<i>U-Net++-4</i>	<i>ResNet-101</i>	128x128	8	40	Si	63,35%	0,52	48,35
<i>DLV3+ 1</i>	<i>ResNet-152</i>	256x 256	4	25	No	59,48%	0,49	35,12
<i>DLV3+ 2</i>	<i>ResNet-18</i>	128x128	8	20	No	59,56%	0,48	32,58
<i>DLV3+-3</i>	<i>ResNet-152</i>	128x128	4	20	No	60,25%	0,49	36,23
<i>DLV3+-4</i>	<i>ResNet-101</i>	128x128	8	40	Si	62,67%	0,52	42,18

Tabla 7. Métricas de las coberturas de *U-Net++-4* y *DLV3+-4*. Fuente propia.

Cobertura / Métricas de modelo	% Área	<i>U-Net++-4</i>		<i>DLV3+-4</i>	
		<i>F1</i>	<i>IoU</i>	<i>F1</i>	<i>IoU</i>
2.1. Cultivos transitorios	0,69%	0,20%	0,001	0,20%	0,001
2.2 Cultivos permanentes	0,26%	0%	0	0%	0
2.3. Pastos	27,50%	68,20%	0,52	67,00%	0,50
2.4. Áreas agrícolas heterogéneas	22,90%	54,80%	0,38	60,70%	0,44
3.1. Bosques	18,37%	74,00%	0,59	72,40%	0,57
3.2.1. Herbazal	17,37%	73,50%	0,58	72,50%	0,57
3.2.2. Arbustal	4,28%	0%	0	0%	0
3.2.3. Vegetación secundaria o en transición	5,24%	0%	0	0%	0
3.3. Áreas abiertas, sin o con poca vegetación	0,72%	0%	0	0%	0
4.1. Áreas húmedas continentales	0,01%	0%	0	0%	0
5.1. Aguas continentales	0,92%	0%	0	0%	0

incrementar las métricas por cobertura (*F1*, *IoU*). Con los modelos *U-Net++_4_4* y *DLV3+_4_3* se obtuvieron los mejores resultados al utilizar los pesos que se muestran en la Tabla 8. Por su parte, el aumento del conjunto de datos contribuyó a mejorar la generalización del modelo sin afectar significativamente los tiempos de procesamiento.

Los modelos *U-Net++_4_4* y *DLV3+_4_3* no lograron identificar ciertas coberturas, específicamente: 2.1. Cultivos transitorios, 2.2. Cultivos

permanentes, 3.3. Áreas abiertas sin o con poca vegetación y 4.1. Áreas húmedas continentales. Estas clases tienen una representatividad inferior al 1% en el área de estudio (IDEAM et al., 2014), por lo que fueron excluidas de los análisis posteriores. Sin embargo, una mayor representatividad no siempre se traduce en mayor exactitud, como ocurrió con las clases 2.3 Pastos y 2.4 Áreas agrícolas heterogéneas, tal como se muestra en la Figura 5.

Tabla 8. Pesos diferenciados por cobertura para mitigar el desbalance de clases.

Cobertura	Pesos	Cobertura	Pesos
2.1. Cultivos transitorios	1,0	3.2.2. Arbustal	0,6
2.2 Cultivos permanentes	1,0	3.2.3. Vegetación secundaria o en transición	0,5
2.3. Pastos	0,2	3.3. Áreas abiertas, sin o con poca vegetación	1,0
2.4. Áreas agrícolas heterogéneas	0,2	4.1. Áreas húmedas continentales	1,0
3.1. Bosques	0,3	5.1. Aguas continentales	1,0
3.2.1. Herbazal	0,3	No data	0,7

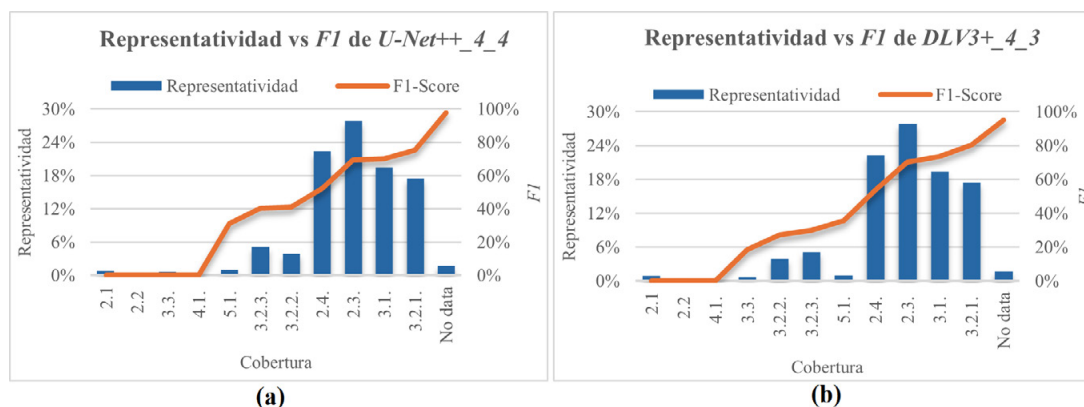


Figura 5. Representatividad de las coberturas vs *F1*. (a) *U-Net++_4_4* y (b) *DLV3+_4_3*. Fuente propia.

4.3. Incremento de bandas

El rendimiento de los modelos mejoró gradualmente al aumentar el número de bandas espectrales en las ventanas de entrada, obteniendo las mejores métricas al usar la composición con más bandas (*img_765432NPE*), como se muestra en la Figura 6. En el caso de *U-Net++_4_4*, el *F1* aumentó aproximadamente un 5% al añadir más bandas, especialmente en coberturas como 3.2.2 *Arbustal* y 3.2.1 *Herbazal*.

Sin embargo, el aumento en el número de bandas también implicó mayores tiempos de ejecución, como se observa en la Tabla 9, debido a los mayores requerimientos computacionales.

Tabla 9. Desempeño computacional de *U-Net++_4_4* y *DLV3+_4_3* por composición. Fuente propia.

Modelo	<i>U-Net++_4_4</i>	<i>DLV3+_4_3</i>
<i>img_765432</i>	65,24 min	56,46 min
<i>img_765432PE</i>	75,15 min	64,55 min
<i>img_765432NPE</i>	80,21 min	69,36 min

4.4. Comparación de modelos

Comparando los modelos, *U-Net++_4_4* alcanzó una *OA* del 68,07% y un *kappa* de 0,6, mientras que *DLV3+_4_3* logró una *OA* del 67,29% y un *kappa* de 0,591. En cuanto al desempeño computacional, *U-Net++_4_4* requirió 80,21 minutos, mientras que *DLV3+_4_3* fue un 13,53% más eficiente con un tiempo de 69,36 minutos. *U-Net++_4_4* presentó mejores métricas de *F1* en coberturas como 5.1. *Aguas continentales* (90,17%), 3.2.1. *Herbazal* (78,43%) y 3.1. *Bosques* (75%), aunque enfrentó dificultades con 3.2.2. *Arbustal* (*F1* de 54,24% y *kappa* de 0,29). *DLV3+_4_3* obtuvo valores similares de *F1* en 5.1. *Aguas continentales* (89,07%), 3.2.1. *Herbazal* (79,22%) y 3.1. *Bosques* (74,27%), pero enfrentó dificultades en 3.2.2. *Arbustal* con un *F1* de 55,72% y un *kappa* de 0,28 (Tabla 10).

Ambos modelos se desempeñaron mejor en coberturas extensas y homogéneas, como 5.1 *Aguas continentales*, beneficiándose de la alta representatividad en el área de estudio. Sin embargo, enfrentaron dificultades en coberturas menos representadas, como 3.2.2 *Arbustal*, lo cual

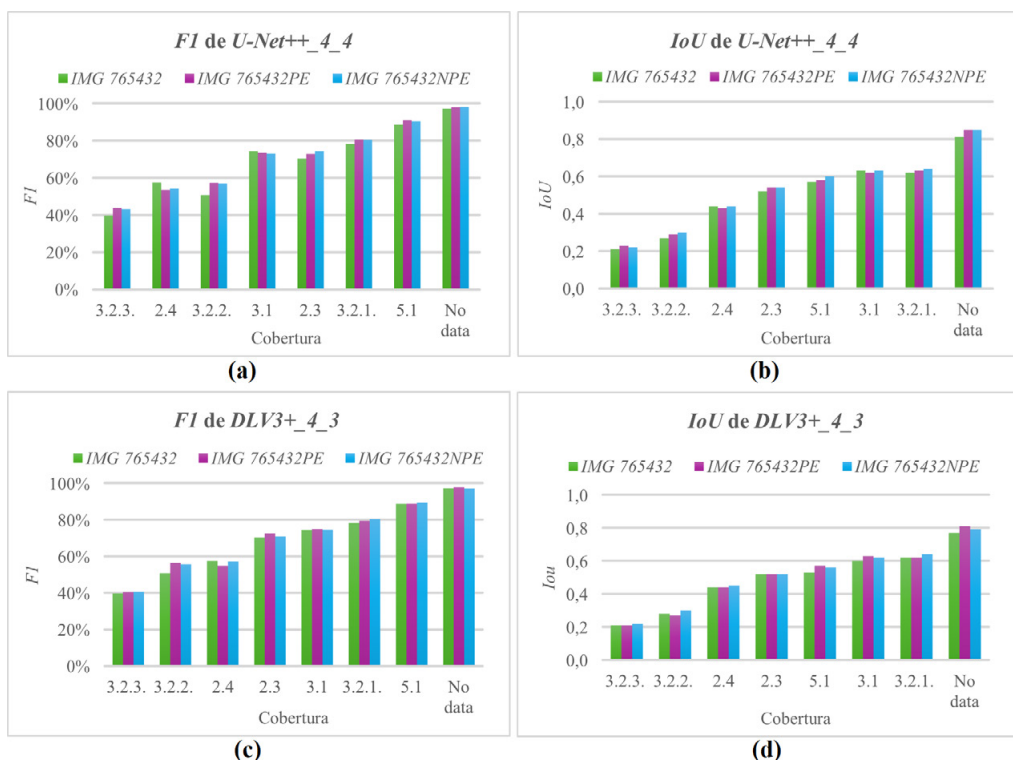


Figura 6. Métricas de exactitud por coberturas: (a) *F1* y (b) *IoU* de *U-Net++_4_4*. (c) *F1* y (d) *IoU* de *DLV3+_4_3*. Fuente propia.

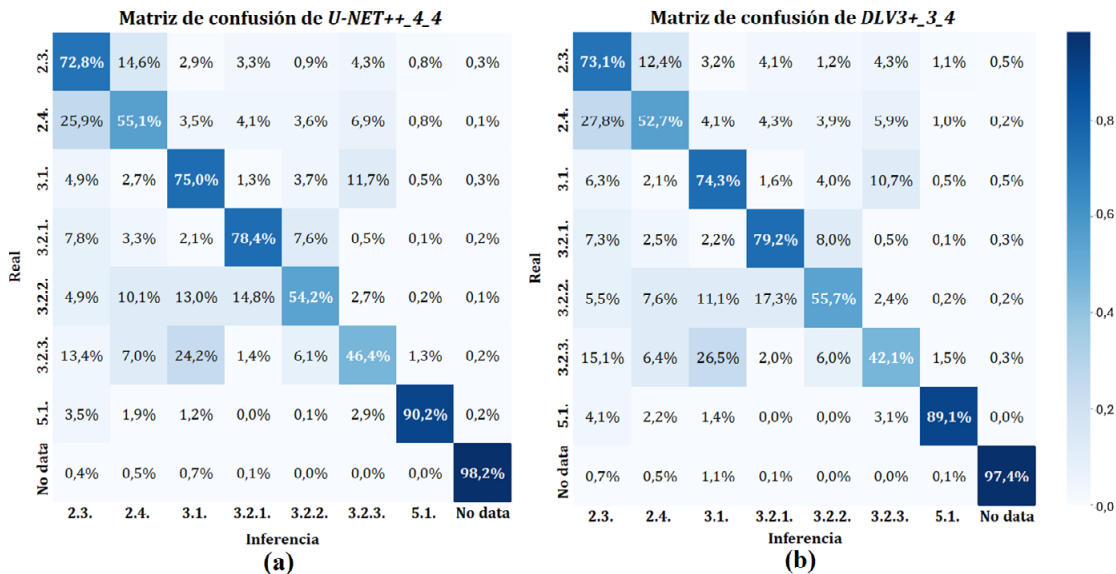


Figura 7. Matriz de confusión del modelo (a) U-Net++_4_4 y (b) DLV3+_4_3. Fuente propia.

Tabla 10. Comparación de las métricas de exactitud por cobertura de U-Net++_4_4 y DLV3+_4_3. Fuente propia.

Cobertura	U-Net++ 4 4		DLV3+ 4 3	
	F1	IoU	F1	IoU
2.3. Pastos	72,85%	0,54	73,14%	0,53
2.4. Áreas agrícolas heterogéneas	55,12%	0,44	52,70%	0,44
3.1. Bosques	75%	0,63	74,27%	0,61
3.2.1. Herbazal	78,43%	0,64	79,22%	0,63
3.2.2. Arbustal	54,24%	0,29	55,72%	0,28
3.2.3. Vegetación secundaria o en transición	46,40%	0,23	42,08%	0,22
5.1. Aguas continentales	90,17%	0,6	89,07%	0,56
No data	98,22%	0,85	97,43%	0,79

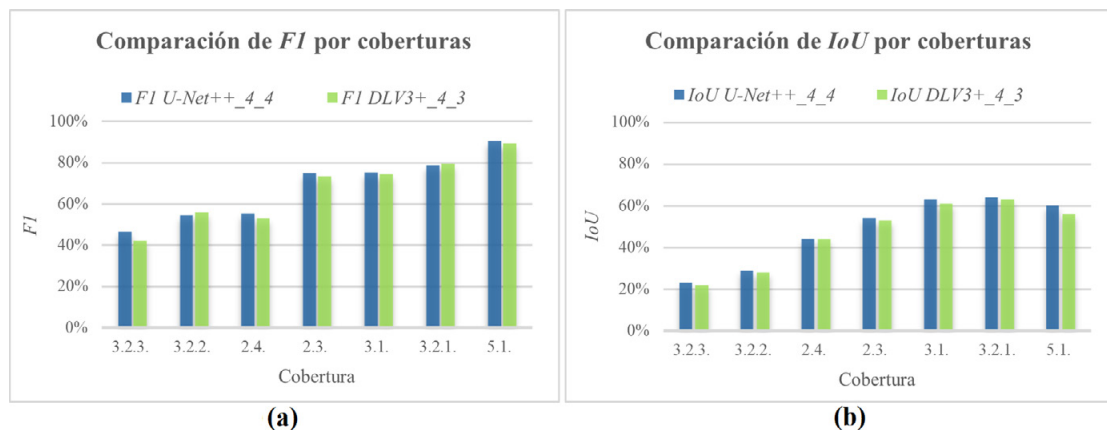


Figura 8. Comparación de las métricas por coberturas: (a) F1 y (b) IoU de U-Net++_4_4, y (c) F1 y (d) IoU de DLV3+_4_3. Fuente propia.

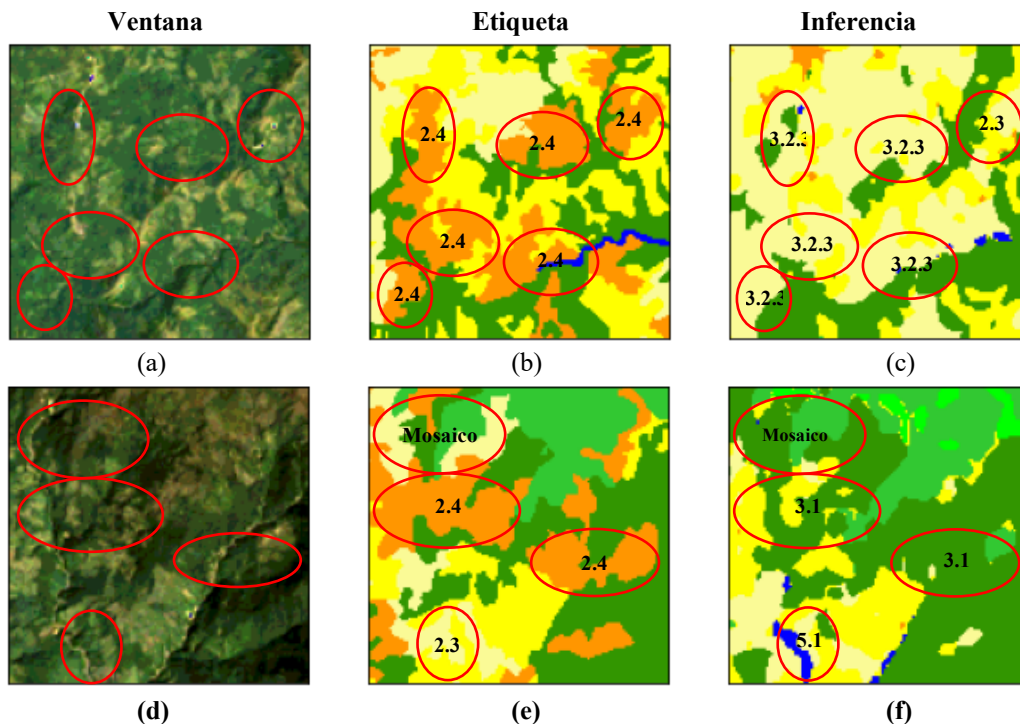


Figura 9. Problemas en la clasificación de las coberturas: (a) y (d) Ventana de *img_765432NPE*, (b) y (e) Etiqueta, Inferencia de (c) *U-Net++_4_4* y (e) *DLV3+_4_3*. Fuente propia.

afectó la segmentación. En otras coberturas más heterogéneas, como 3.3 *Áreas abiertas con poca vegetación* y 2.4 *Áreas agrícolas heterogéneas*, el rendimiento fue inferior.

Ambos modelos tuvieron dificultades en áreas pequeñas o mosaicos de coberturas como 3.2.2 *Arbustal*. *U-Net++_4_4* clasificó erróneamente 2.4 *Áreas agrícolas heterogéneas* como 2.3 *Pastos* o 3.2.3 *Vegetación secundaria*, debido a la variabilidad de las prácticas agrícolas (Figura 9c). *DLV3+_4_3* también presentó errores de clasificación en coberturas de mosaicos, confundiendo 2.4 *Áreas agrícolas heterogéneas* y 2.3 *Pastos* con 3.1 *Bosques* (Figura 9d).

5. Discusión

5.1. Desempeño de los modelos en la clasificación de coberturas

En este estudio, *U-Net++* y *DeepLabV3+* lograron un rendimiento sólido en coberturas homogéneas y representativas, como *Pastos* y *Bosques*, pero

enfrentaron dificultades en coberturas minoritarias y heterogéneas, como *Arbustal* y *Vegetación secundaria*, lo cual es consistente con estudios previos (Castelo et al., 2022) que señalan dificultades similares en la clasificación de coberturas en ecosistemas de alta montaña debido a la variabilidad espacial y espectral.

Castelo et al. (2022) indica que los métodos basados en objetos capturan bien la variabilidad espacial y la textura en los páramos. Si bien *U-Net++* y *DeepLabV3+* demostraron ser efectivos en coberturas homogéneas y frecuentes, la combinación con técnicas de análisis de objetos podría optimizar la clasificación en clases heterogéneas y menos representadas. La combinación de *CNNs* y análisis basados en objetos aplicado a ecosistemas de alta complejidad puede ser objeto de investigación en futuros estudios de monitoreo y conservación de los páramos.

5.2. Efecto del desbalance de clases y estrategias de mitigación

El desbalance de clases afecta de manera negativa el rendimiento de los modelos de *CNNs* al introducir sesgos hacia las clases mayoritarias. Estudios recientes han demostrado que el desbalance afecta no solo la exactitud global, sino también la capacidad del modelo para generalizar correctamente las clases menos representadas (Buda et al., 2018; Chen et al., 2022; Iyer et al., 2021). Para abordar este problema, Chen et al. (2022) proponen el uso de ensambles balanceados de clases, que integran clasificadores auxiliares en distintas capas de la red para corregir errores y reducir el sesgo hacia las clases mayoritarias. Buda et al., (2018) recomiendan el sobremuestreo (*oversampling*) para equilibrar las clases y el ajuste de umbrales de salida (*thresholding*) para mejorar la clasificación en clases menos representadas.

En este estudio se implementaron técnicas de sobremuestreo y ponderación de clases para reducir el sesgo hacia las clases mayoritarias, lo que resultó en mejoras en la clasificación de algunas coberturas minoritarias. Sin embargo, la incorporación de enfoques adicionales como los ensambles balanceados de clases podría potenciar el rendimiento del modelo en otras coberturas minoritarias y heterogéneas, facilitando una clasificación más exacta y equilibrada. La implementación de una estructura de ensambles auxiliares que permita concentrar el aprendizaje en las clases minoritarias representaría una extensión prometedora, especialmente en el monitoreo de ecosistemas de alta diversidad como los páramos.

5.3. Impacto del incremento de bandas espectrales en la exactitud del modelo

El uso de bandas espectrales adicionales, como el *NIR* y el índice *NDVI*, contribuyeron significativamente a mejorar la exactitud en la clasificación de coberturas vegetales en ecosistemas complejos. Ayhan et al. (2020) demostraron que al incluir la banda *NIR* en modelos de *DeepLabV3+* se incrementó la exactitud en la detección de vegetación al aportar una sensibilidad espectral más alta, lo que optimizó métricas claves como el *IoU*. Castelo et al. (2022) destacaron que, en páramos el uso de estas bandas en combinación con análisis basado en objetos (*GEObIA*) mejoró la diferenciación

de clases en coberturas vegetales heterogéneas, capturando la variabilidad espectral y espacial característica de estos ecosistemas de alta montaña.

Por su parte, Poveda Sotelo et al. (2022) encontraron que combinar bandas como el *NIR* con variables de terreno como altitud refuerza la capacidad de los modelos para identificar patrones en coberturas de vegetación frente a coberturas no vegetales, como se comprobó en el presente estudio. La integración de otras bandas adicionales junto con métodos híbridos se plantea como una estrategia para futuras investigaciones, permitiendo capturar la complejidad estructural y espectral de los ecosistemas de páramo, mejorando así la exactitud en la clasificación de coberturas.

5.4. Limitaciones del estudio y sugerencias para investigaciones futuras

Esta investigación enfrentó limitaciones en el uso *CNNs* para la clasificación en ecosistemas de páramo, especialmente debido a la dependencia de grandes volúmenes de datos etiquetados cuya obtención es particularmente compleja en estas zonas. Ayhan et al. (2020) destacaron que la falta de datos de alta calidad limita el rendimiento de las *CNNs* y obtener estos datos implica costos elevados y un proceso laborioso.

Para mejorar la segmentación en futuros estudios, Yuan et al. (2021) recomiendan la integración de enfoques híbridos como el análisis basado en objetos y el uso de variables auxiliares, lo que permitiría enfrentar los desafíos actuales en la clasificación de ecosistemas complejos.

6. Conclusiones

Los modelos *U-Net++* y *DeepLabV3+* demostraron ser herramientas viables para la clasificación de coberturas en ecosistemas de páramo, alcanzando resultados comparables en términos de *OA* y *Kappa*. Aunque *DeepLabV3+* fue un 13,53% más eficiente en tiempo de procesamiento que *U-Net++*, ambos modelos mostraron un rendimiento similar, lo que indica que su aplicabilidad depende de la disponibilidad de recursos computacionales y del objetivo específico del estudio.

El desbalance de clases representó una limitación significativa, especialmente en coberturas de menor representatividad como *Arbustal y Vegetación secundaria*. Este estudio demuestra que, aunque el sobremuestreo y la ponderación de clases mejoraron parcialmente la clasificación de clases minoritarias, es necesario explorar técnicas más avanzadas para mitigar el sesgo en la clasificación.

La incorporación de bandas espectrales adicionales, especialmente el uso de *NIR* y *NDVI*, mejoró significativamente el *F1* de las coberturas vegetales. Estos resultados coinciden con estudios previos que resaltan la efectividad de utilizar un espectro amplio de información para captar la variabilidad espectral y estructural en ecosistemas de alta complejidad como el páramo.

Ambos modelos mostraron un buen rendimiento en la clasificación de coberturas homogéneas, como *Bosques y Herbazales*, pero enfrentaron dificultades en coberturas complejas y de baja representatividad. Este hallazgo sugiere la necesidad de integrar enfoques híbridos que combinen *CNNs* con técnicas de análisis basadas en objetos (*GEOBIA*).

Existen limitaciones computacionales asociadas con el uso de redes neuronales profundas como *U-Net++* y *DeepLabV3+*, que requieren alta capacidad de procesamiento y grandes volúmenes de datos para entrenar los modelos de manera efectiva. Esta dependencia computacional limita su escalabilidad y representa un obstáculo para aplicaciones en tiempo real y estudios de monitoreo a gran escala.

Las limitaciones en los datos de entrada, en particular la calidad y disponibilidad de etiquetas de entrenamiento y la resolución de las imágenes, impactan la exactitud del modelo en el contexto de páramos. La adquisición de etiquetas de calidad y la generación de datos auxiliares podrían ayudar a mitigar este problema, facilitando estudios más exactos en condiciones ambientales complejas y remotas.

Para evaluar la adaptabilidad de estos modelos a otros contextos ambientales, se propone expandir la metodología a distintos complejos de páramos en Colombia. Esto no solo permitirá refinar la exactitud de los modelos en diversas condiciones, sino que también contribuirá a fortalecer

programas nacionales de monitoreo y conservación ambiental.

7. Agradecimientos

Agradecemos al profesor Joaquín Guillermo Ramírez por el apoyo brindado al permitirnos utilizar los equipos del laboratorio de Biomodelación de la universidad Nacional de Colombia y a Fabián Peña por todo su apoyo y orientación.

Referencias

- Alzubaidi, L., Zhang, J., Humaidi, A., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-Amidie, M., Farhan, L. 2021. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Ayala, J.E., Márquez, C.O., García, V.J., Recalde, C.G., Rodríguez, M.V., Damián, D.A. 2017. Land cover classification in an ecuadorian mountain geosystem using a random forest classifier, spectral vegetation indices, and ancillary geographic data. *Geosciences (Switzerland)*, 7(2). <https://doi.org/10.3390/geosciences7020034>
- Ayhan, B., Kwan, C., Budavari, B., Kwan, L., Lu, Y., Perez, D., Li, J., Skarlatos, D., Vlachos, M. 2020. Vegetation detection using deep learning and conventional methods. *Remote Sensing*, 12(15). <https://doi.org/10.3390/RS12152502>
- Belyadi, H., Haghighat, A. 2021. Model Evaluation. In *Machine Learning Guide for Oil and Gas Using Python* (pp. 349–380). Elsevier. <https://doi.org/10.1016/b978-0-12-821929-4.00009-3>
- Brück, S.A., Medina, B.D., Teixeira, M. de L. 2023. The Ecuadorian paramo in danger: What we know and what might be learned from northern wetlands. In *Global Ecology and Conservation* (Vol. 47). Elsevier B.V. <https://doi.org/10.1016/j.gecco.2023.e02639>
- Buda, M., Maki, A., Mazurowski, M.A. 2018. A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>
- Buytaert, W., Céleri, R., De Bièvre, B., Cisneros, F., Wyseure, G., Deckers, J., Hofstede, R. 2006. Human impact on the hydrology of the Andean páramos. *Earth-Science Reviews*, 79(1–2), 53–72. <https://doi.org/10.1016/j.earscirev.2006.06.002>

- Cabrera, M., Ramírez, W. 2014. Restauración Ecológica de los páramos de Colombia: Transformación y herramientas para su conservación. *Instituto de Investigación de Recursos Biológicos Alexander von Humboldt (IAvH)*, 296.
- Castelo, M., Piedra, J.A., Ayala, R. 2022. Deep learning for land use and land cover classification from the Ecuadorian Paramo. *International Journal of Digital Earth*, 15(1), 1001–1017. <https://doi.org/10.1080/17538947.2022.2088872>
- Castellanos, H., Gómez, W.F., Mayorga, N. 2021. *Mapa nacional de coberturas de la tierra, escala 1:100.000, periodo 2018*. Metodología Corine Land Cover adaptada para Colombia. Memoria técnica y resultados. Instituto de Hidrología, Meteorología y Estudios Ambientales (Ideam). Bogotá, D. C., Colombia.
- Chen, L.C., Papandreou, G., Schroff, F., Adam, H. 2017. Rethinking Atrous Convolution for Semantic Image Segmentation. *ArXiv*, [abs/1706.05587](https://arxiv.org/abs/1706.05587). <http://arxiv.org/abs/1706.05587>
- Chen, Z., Duan, J., Kang, L., Qiu, G. 2022. Class-Imbalanced Deep Learning via a Class-Balanced Ensemble. *IEEE Transactions on Neural Networks and Learning Systems*, 33(10), 5626–5640. <https://doi.org/10.1109/TNNLS.2021.3071122>
- Coca, A., Zaraza, M., Benavides, Y., Montilla, Y., Posada, H., Avendaño, A., Hernández, H., Garzón, S., Franco, C.A. 2021. Evaluación de algoritmos de clasificación en la plataforma Google Earth Engine para la identificación y detección de cambios de construcciones rurales y periurbanas a partir de imágenes de alta resolución. *Revista de Teledetección*, 58, 71. <https://doi.org/10.4995/raet.2021.15026>
- Deepan, P., Sudha, L.R. 2020. Object Classification of Remote Sensing Image Using Deep Convolutional Neural Network. In *The Cognitive Approach in Cloud Computing and Internet of Things Technologies for Surveillance Tracking Systems* (pp. 107–120). Elsevier. <https://doi.org/10.1016/b978-0-12-816385-6.00008-8>
- Earth Engine Data Catalog. 2022. USGS Landsat 8 Level 2, Collection 2, Tier 2 | Earth Engine Data Catalog | Google Developers. https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C01_T2_SR
- Géron, A. 2019. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Inc.
- Instituto de Hidrología, M. y E.A. (IDEAM). 2010. Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover adaptada para Colombia, escala 1:100.000. In *Area: Vol. TH-62-04-1* (Issue 257).
- Instituto de Hidrología, M. y E.A. (IDEAM), Instituto de Investigación de Recursos Biológicos Alexander von Humboldt (IAVH), Ministerio de Ambiente y Desarrollo Sostenible (MADS), Ministro de Hacienda y Crédito Público (MinHacienda). 2014. *Informe final componente coberturas de la tierra en los páramos priorizados a escala 1:25.000 (metodología corine land cover adaptada para Colombia)* (Vol. 000, Issue 13).
- Iyer, P., A, S., Lal, S. 2021. Deep learning ensemble method for classification of satellite hyperspectral images. *Remote Sensing Applications: Society and Environment*, 23, 100580. <https://doi.org/10.1016/J.RSASE.2021.100580>
- Krizhevsky, B.A., Sutskever, I., Hinton, G.E. 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 60(6), 84–90.
- Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A. 2017. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778–782. <https://doi.org/10.1109/LGRS.2017.2681128>
- Liu, M., Fu, B., Xie, S., He, H., Lan, F., Li, Y., Lou, P., Fan, D. 2021. Comparison of multi-source satellite images for classifying marsh vegetation using DeepLabV3 Plus deep learning algorithm. *Ecological Indicators*, 125, 107562. <https://doi.org/10.1016/j.ecolind.2021.107562>
- 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. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 152, pp. 166–177). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Martin-Abadal, M., Guerrero-Font, E., Bonin-Font, F., Gonzalez-Cid, Y. 2018. Deep Semantic Segmentation in an AUV for Online Posidonia Oceanica Meadows Identification. *IEEE Access*, 6, 60956–60967. <https://doi.org/10.1109/ACCESS.2018.2875412>
- Maxwell, A.E., Warner, T.A., Fang, F. 2018. Implementation of machine-learning classification in remote sensing: An applied review. In *International Journal of Remote Sensing* (Vol. 39, Issue 9, pp. 2784–2817). Taylor and Francis Ltd. <https://doi.org/10.1080/01431161.2018.1433343>

- Ministerio de Ambiente y Desarrollo Sostenible (MADS). 2016. Resolución No 1771 de 2016. In *Diario Oficial de Colombia. Ministerio de Ambiente y Desarrollo Sostenible, Bogotá, Colombia*. <https://www.minambiente.gov.co/documento-normativa/resolucion-1771-de-2016/>
- Morales, M., Otero, J., Van der Hammen, T., Torres, A., Cadena, C., Pedraza, C., Rodríguez, N., Franco, C., Betancourth, J.C., Olaya, E., Posada, E., Cárdenas, L. 2007. Atlas de páramos de Colombia. In *Instituto de Investigación de Recursos Biológicos Alexander von Humboldt (IAVH)*. (Vol. 16, Issue 1). <https://doi.org/10.1111/j.1365-2303.2004.00206.x>
- Navab, N., Hornegger, J., Wells, W.M., Frangi, A.F. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science, 9351(Cvd)*, 12–20. <https://doi.org/10.1007/978-3-319-24574-4>
- Poveda Sotelo, Y., Bermúdez Cella, M.A., Gil Leguizamón, P. 2022. Evaluation of supervised classification methods for the estimation of spatiotemporal changes in the Merchán and Telecom paramos, Colombia. *Boletín de Geología, 44(2)*, 51–72. <https://doi.org/10.18273/revbol.v44n2-2022002>
- Suárez, A.S., Jiménez, A.F., Castro, M., Cruz, A.A. 2017. Clasificación y mapeo automático de coberturas del suelo en imágenes satelitales utilizando Redes Neuronales Convolucionales. *Orinoquia, 21(1 Sup)*, 64–75. <https://doi.org/10.22579/20112629.432>
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y.A., Rahman, A. 2020. Land-use land-cover classification by machine learning classifiers for satellite observations-A review. In *Remote Sensing* (Vol. 12, Issue 7). MDPI AG. <https://doi.org/10.3390/rs12071135>
- Vásquez, A., Buitrago, A.C. 2011. *El gran libro de los páramos*. Instituto de Investigación de Recursos Biológicos Alexander von Humboldt. <http://hdl.handle.net/20.500.11761/31389>
- Vergara, P.A. 2020. Estrategias implementadas por el Sistema Nacional de Áreas Protegidas de Colombia para conservar los páramos. *Revista de Ciencias Ambientales, 54(1)*, 167–176. <https://doi.org/10.15359/rca.54-1.9>
- 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*. <https://doi.org/10.1016/j.eswa.2020.114417>
- Zhou, Z., Siddiquee, M.M. R., Tajbakhsh, N., Liang, J. 2018. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. *Lecture Notes in Computer Science*. <http://arxiv.org/abs/1807.10165>
- Zhou, Z., Siddiquee, M.M. R., Tajbakhsh, N., Liang, J. 2019. UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation. *IEEE Transactions on Medical Imaging*. <https://doi.org/10.1109/TMI.2019.2959609>