



UNIVERSIDAD NACIONAL DEL ALTIPLANO

ESCUELA DE POSGRADO

DOCTORADO EN CIENCIAS DE LA COMPUTACIÓN



TESIS

DETECCIÓN DE DEFORESTACIÓN DE BOSQUES EN IMÁGENES SATELITALES CON REDES NEURONALES CONVOLUCIONALES

PRESENTADA POR:

PABLO CESAR TAPIA CATAORA

PARA OPTAR EL GRADO ACADÉMICO DE:

DOCTOR EN CIENCIAS DE LA COMPUTACIÓN

PUNO, PERÚ

2023



Reporte de similitud

NOMBRE DEL TRABAJO

DETECCIÓN DE DEFORESTACIÓN DE BOSQUES EN IMÁGENES SATELITALES CON REDES NEURONALES CONVOLUCIONALES

AUTOR

PABLO CESAR TAPIA CATA CORA

RECUENTO DE PALABRAS

16055 Words

RECUENTO DE CARACTERES

91765 Characters

RECUENTO DE PÁGINAS

81 Pages

TAMAÑO DEL ARCHIVO

1.2MB

FECHA DE ENTREGA

Jul 31, 2023 10:19 PM GMT-5

FECHA DEL INFORME

Jul 31, 2023 10:20 PM GMT-5

● **8% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos

- 5% Base de datos de Internet
- Base de datos de Crossref
- 6% Base de datos de trabajos entregados
- 1% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Material citado
- Material citado
- Coincidencia baja (menos de 10 palabras)



Firmado digitalmente por TITO LIPA
Jose Panfili FAU 20145496170 hard
Motivo: Soy el autor del documento
Fecha: 04.08.2023 08:31:23 -05:00



Firmado digitalmente por HJATA
PANCA Percy FAU 20145496170 soft
Motivo: Soy el autor del documento
Fecha: 31.07.2023 22:23:29 -05:00

Resumen



UNIVERSIDAD NACIONAL DEL ALTIPLANO
ESCUELA DE POSGRADO
DOCTORADO EN CIENCIAS DE LA COMPUTACIÓN



TESIS

**DETECCIÓN DE DEFORESTACIÓN DE BOSQUES EN IMÁGENES
SATELITALES CON REDES NEURONALES CONVOLUCIONALES**

PRESENTADA POR:

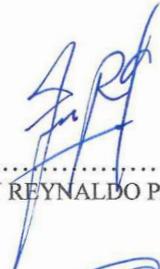
PABLO CESAR TAPIA CATACORA

PARA OPTAR EL GRADO ACADÉMICO DE:

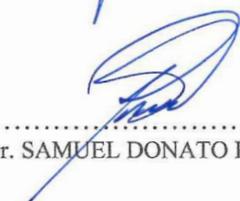
DOCTOR EN CIENCIAS DE LA COMPUTACIÓN

APROBADA POR EL JURADO SIGUIENTE:

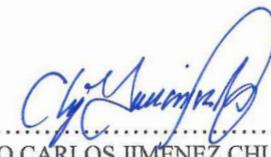
PRESIDENTE


.....
Dr. JUAN REYNALDO PAREDES QUISPE

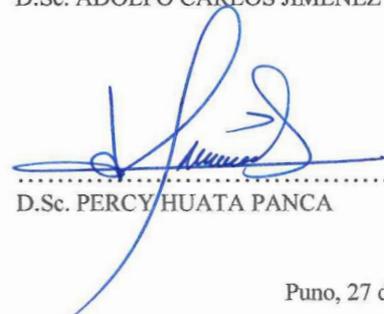
PRIMER MIEMBRO


.....
Dr. SAMUEL DONATO PEREZ QUISPE

SEGUNDO MIEMBRO


.....
D.Sc. ADOLFO CARLOS JIMENEZ CHURA

ASESOR DE TESIS


.....
D.Sc. PERCY HUATA PANCA

Puno, 27 de marzo de 2023

ÁREA : Ingeniería de Software

TEMA : Detección de deforestación de bosques en imágenes satelitales con redes neuronales convolucionales.

LÍNEA : Desarrollo de aplicaciones.



DEDICATORIA

A Cesar Fernando, Paola Xiomely Fernanda y a Emelina, son mis razones de vida.

A mi padre Claudio, mi madre Fabiana y mi hermano Tomas, con quienes aprendí y comparto la vida desde cuanto tengo recuerdo, y ahora me acompañan mientras camino en la vida profesional.

A todos los visionarios que comparten los ideales que nos llevan al éxito profesional.



AGRADECIMIENTOS

Primeramente, a Dios que, bajo su bendición y protección divina, recorrí y seguiré caminando en este mundo de cambio permanente y competitivo.

A la Universidad Nacional del Altiplano mi alma mater, al Programa de Doctorado en Ciencias de la Computación. Así mismo, a los docentes por darme la oportunidad de culminar mi formación doctoral.

A los Jurados de esta Tesis, Dr. Juan Reynaldo Paredes Quispe, Dr. Samuel Donato Perez Quispe, D.Sc. Adolfo Carlos Jimenez Chura y mi asesor D.Sc. Percy Huata Panca, por su paciencia y hacer más legible esta tesis.

A mis amigos de la universidad y hoy colegas en la Escuela Profesional de Ingeniería de Sistemas, en especial al M.Sc. William Eusebio Arcaya Coaquira, Dr. Edelfre Flores Velasquez, M.Sc. Marga Isabel Ingaluque Arapa, M.Sc. Lenin Huayta Flores, M.Sc. Magali Gianina Gonzales Paco, Dra. Zulema Lilian Mamani Huacani, M.Sc. Lilian Magnolia Benique Ruelas, Mg. Aldo Hernán Zanabria Gálvez, por brindarme fortalezas, ánimos, bromas y alientos, a quienes alcanzo mi agradecimiento.

A los amigos con quienes compartí experiencias profesionales de trabajo.

A todas las personas que se toman el tiempo para darme una recomendación, para seguir investigando en el curso de mi vida profesional.



ÍNDICE GENERAL

DEDICATORIA	iii
AGRADECIMIENTOS	iv
ÍNDICE GENERAL	v
ÍNDICE DE TABLAS	viii
ÍNDICE DE FIGURAS	ix
ÍNDICE DE ANEXOS	xi
RESUMEN	xii
ABSTRACT	xiii
INTRODUCCIÓN	14

CAPITULO I

REVISIÓN DE LITERATURA

1.1. Marco Teórico	16
1.1.1. Deforestación	16
1.1.2. Datos ráster	16
1.1.3. Inteligencia Artificial	17
1.1.4. Aprendizaje automático	17
1.1.5. Red Neuronal Convolutacional	17
1.1.6. Red neuronal U-Net	18
1.1.7. Convolución (Convolution)	19
1.1.8. Convolución transpuesta (Deconvolution)	20
1.1.9. Max-pooling	21
1.1.10. Función de activación	21
1.1.11. Dropout	22
1.1.12. Capa totalmente conectada (Fully connected layer)	22
1.1.13. Satélite Landsat-8	22
1.1.14. Imagen satelital multiespectral	22



1.1.15. Sensor OLI (Operational Land Imager)	23
1.1.16. Sensor TIRS (Thermal Infrared Sensor)	23
1.1.17. Nomenclatura de las imágenes de Landsat-8	24
1.1.18. Teledetección o percepción remota	24
1.2. Antecedentes	27
CAPÍTULO II	
PLANTEAMIENTO DEL PROBLEMA	
2.1. Identificación del problema	30
2.2. Enunciados del problema	31
2.3. Justificación	31
2.4. Objetivos	32
2.4.1. Objetivo general	32
2.4.2. Objetivos específicos	33
2.5. Hipótesis	33
2.5.1. Hipótesis general	33
CAPITULO III	
MATERIALES Y MÉTODOS	
3.1. Lugar de estudio	34
3.2. Población	35
3.3. Muestra	35
3.4. Método de investigación	36
3.5. Descripción detallada de métodos por objetivos específicos	38
CAPITULO IV	
RESULTADOS Y DISCUSIÓN	
4.1. Resultados	42
4.2. Discusiones	59
CONCLUSIONES	63



RECOMENDACIONES	65
BIBLIOGRAFÍA	66
ANEXOS	71



ÍNDICE DE TABLAS

Tabla 1	Nomenclatura de una imagen satelital de Landsat 8	24
Tabla 2	Resultados del entrenamiento de la red neuronal convolucional U-Net (precisión y función de pérdida), la mejor esta resaltado en negrita.	59

ÍNDICE DE FIGURAS

Figura 1.	Representación de un ráster en una imagen satelital.	16
Figura 2.	Arquitectura U-Net para segmentación de deforestación.	18
Figura 3.	Proceso de convolución de una imagen, a) imagen normalizada, b) kernel de 3x3, c) resultado despues de aplicar la convolución, d) aplicación de la función de activación ReLU, e) agrupamiento de características de deforestación.	19
Figura 4.	Convolución transpuesta (Conv2DTranspose), con una entrada de 2x2, filtro de 3x3, stride de 2x2 y su salida de 5x5	20
Figura 5.	Max-pooling con un stride de 2x2	21
Figura 6.	Esquema de un sistema de teledetección	25
Figura 7.	Lugar de estudio donde se realizó la investigación.	34
Figura 8.	Imágenes satelitales Landsat 8 de la Amazonía peruana.	35
Figura 9.	Imágenes satelitales Landsat 8 de los bosques de la Amazonía de los departamentos de Puno y Madre de Dios.	36
Figura 10.	Proceso de selección de imágenes, entrenamiento de la red neuronal U-Net y segmentación de deforestación en imágenes satelitales Landsat 8.	37
Figura 11.	Imagen recortada con su máscara para entrenamiento	39
Figura 12.	Imagen proporcionada a la red neuronal U-Net y su resultado.	41
Figura 13.	Precisión de entrenamiento y validación con epochs = 5	43
Figura 14.	Función de pérdida entrenada con 5 épocas (epochs = 5)	43
Figura 15.	A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net.	44
Figura 16.	A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net.	45

Figura 17. Precisión de entrenamiento y validación con epochs = 10	46
Figura 18. Función de pérdida entrenada con 10 épocas (epochs = 10)	47
Figura 19. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 10 épocas (epochs = 10).	48
Figura 20. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 10 épocas (epochs=10).	49
Figura 21. Precisión de entrenamiento y validación con epochs = 15	50
Figura 22. Función de pérdida entrenada con 15 épocas (epochs = 15)	51
Figura 23. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 15 épocas (epochs = 15).	52
Figura 24. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 15 épocas (epochs=15).	53
Figura 25. Precisión de entrenamiento y validación con epochs = 20	54
Figura 26. Función de pérdida entrenada con 20 épocas (epochs = 20)	55
Figura 27. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 20 épocas (epochs = 20)	56
Figura 28. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 20 épocas (epochs=20)	57



ÍNDICE DE ANEXOS

Anexo 1	Código fuente del core (núcleo) del modelo de la red Neuronal Convolutacional U-Net	72
Anexo 2	Modelo grafico de la Red Neuronal Convolutacional U-Net y su implementación con Keras de Tensorflow	74
Anexo 3	Modelo de Red Neuronal Convolutacional U-Net de la investigación	75
Anexo 4	Resultados del entrenamiento de la Red Neuronal Convolutacional U-Net de la Investigación	77
Anexo 5	Código fuente del core (núcleo) del modelo de la red Neuronal Convolutacional U-Net con Dropout	78
Anexo 6	Resultados del entrenamiento de la Red Neuronal Convolutacional U-Net con Dropout	80
Anexo 7	Predicción de la red neuronal U-Net con las imágenes de prueba (código fuente y las imágenes segmentadas).	81

RESUMEN

La deforestación de los bosques de la Amazonía tiene orígenes naturales o por las actividades humanas, visto desde el espacio, la deforestación se refleja en imágenes tomadas por satélite Landsat-8. Metodológicamente la investigación es de diseño cuasi experimental por ende busca segmentar la deforestación de los bosques de la Amazonía peruana presente en las imágenes satelitales, utilizando la red neuronal convolucional especializada en segmentación de imágenes denominada U-Net (red neuronal totalmente conectada). Inicia con la selección de imágenes satelitales de la Amazonía de Puno y Madre de Dios, luego un pre-procesamiento consistente en dividir las imágenes en tamaños de 256x256 píxeles acompañados de imágenes binarizadas (máscaras) entre bosques y deforestación, estas imágenes se dividen en grupos de entrenamiento y prueba y son las entradas de la red neuronal, el modelo de la U-Net que procesa y completa la tarea de segmentación, consta de 5 capas convolucionales y 4 de convolución transpuesta, un kernel de 3x3, funciones de activación ReLU y Sigmoid. Los resultados de la U-Net muestran un alto desempeño en la segmentación de la deforestación presente en las imágenes satelitales Landsat-8, alcanzando una precisión de 98% con imágenes de entrenamiento y 98.6% con imágenes de prueba. Segmentar la deforestación de bosques implica analizar las diferencias existentes entre cúmulos de píxeles, para ello, la red neuronal U-Net logra excelentes resultados en tareas de segmentación y su precisión depende del contraste existente entre los píxeles que representan a los bosques y áreas deforestadas.

Palabras clave: Amazonía peruana, deforestación, imágenes satelitales, satélite landsat-8, red neuronal totalmente convolucional, segmentación, U-Net.

ABSTRACT

The deforestation of the Amazon forests has natural origins or human activities, as seen from space, deforestation is reflected in images taken by Landsat-8 satellite. Methodologically, the research is of quasi-experimental design and therefore seeks to segment the deforestation of the Peruvian Amazon forests present in the satellite images, using the convolutional neural network specialized in image segmentation called U-Net (fully connected neural network). It began with the selection of satellite images of the Amazon of Puno and Madre de Dios, followed by a pre-processing consisting of dividing the images into sizes of 256x256 pixels accompanied by binarized images (masks) between forests and deforestation, These images are divided into training and test groups and are the inputs of the neural network, the U-Net model that processes and completes the segmentation task consists of 5 convolutional and 4 transposed convolution layers, a 3x3 kernel, ReLU, and Sigmoid activation functions. The U-Net results demonstrate high performance in segmenting deforestation present in Landsat-8 satellite images, reaching an accuracy of 98% with training images and 98.6% with test images. Segmenting forest deforestation involves analyzing the differences between clusters of pixels, for which the U-Net neural network achieves excellent results in segmentation tasks and its accuracy depends on the contrast between pixels representing forests and deforested areas.

Keywords: Deforestation, peruvian amazon, satellite images, segmentation, Landsat-8 satellite, U-Net neural network.

INTRODUCCIÓN

Utilizar el aprendizaje automático (machine learning) para estudiar uno de los peligros que asecha a los bosques de la Amazonía peruana fue la motivación de la presente investigación. Esto conllevó a explorar y aplicar varios campos de la Computación, esencialmente la Computación Gráfica combinado con el aprendizaje automático aplicado a la segmentación semántica de la deforestación presente en las imágenes satelitales de nuestra Amazonía. La segmentación se traduce como el procesamiento e interpretación píxeles que representan a los bosques y los píxeles que representan a la deforestación en las imágenes obtenidas por el satélite Landsat-8. Esta tarea de clasificación y posterior segmentación, lo realiza muy bien y con precisión una red neuronal convolucional U-Net aun cuando estas fueron diseñadas inicialmente para aplicaciones médicas. la investigación profundiza la aplicación de la U-Net en el campo medioambiental.

La presente investigación está organizada en seis secciones principales, los cuales inicia con el Capítulo I planteamos el sustento teórico y necesario de la presente investigación, así mismo, los avances de la inteligencia artificial en el campo del aprendizaje automático y su aplicación de las redes neuronales convolucionales en la solución de problemas e investigación. En el Capítulo II se describe el problema medioambiental y los vacíos existentes para su contención, y fue la motivación de la presente investigación, también se establece los objetivos por alcanzar e hipótesis a demostrar. En el Capítulo III nos centramos en determinar la ubicación del área a estudiar, determinar la cantidad de imágenes que cubren el área de estudio, una descripción de las herramientas necesarias y su aplicación en cada etapa del entrenamiento de la red neuronal. En el Capítulo IV recopilamos los resultados de la investigación en cuanto refiere a la eficiencia en la segmentación de deforestación y en la sección de discusiones lo comparamos nuestros



resultados con los obtenidos en otras investigaciones a fin de contrastar el rendimiento de la red neuronal U-Net. En la sección de Conclusiones, presentamos de forma resumida los resultados alcanzados después de entrenar la red neuronal U-Net, así como su aplicación en la detección de otras características superficiales presentes en la Amazonía. En la sección de las Recomendaciones incluimos entre las consideraciones a tener en cuenta al momento de entrenar la red neuronal, otras aplicaciones que pueden derivar del uso de la U-Net en otras áreas de investigación.

CAPITULO I

REVISIÓN DE LITERATURA

1.1. MARCO TEÓRICO

1.1.1. DEFORESTACIÓN

Según el diccionario de la Real Academia Española, deforestar está definida como despojar un terreno de plantas forestales (Real Academia Española, 2022). Esta actividad puede ocasionar las actividades humanas o bien por causas de la naturaleza (Oliveira y Siqueira, 2022), cuyo resultado se traduce en desaparición de bosques primarios de la Amazonía o parte de ella (Spracklen y Garcia-Carreras, 2015; Zemp et al., 2017).

1.1.2. DATOS RÁSTER

Ráster es una matriz de celdas (o píxeles) como se visualiza en la Figura 1, organizadas en filas y columnas (o una cuadrícula) (Environmental Systems Research Institute, 2022) en la que cada celda representa a un pixel y contiene valores que representa información o característica de alguna zona que puede ser analizada (Proyecto QGIS, 2022). Los rásters se obtienen a partir de fotos aéreas digitales, espectros de imágenes satelitales, imágenes digitales tomadas con cámara o mapas escaneados (Chang, 2018).

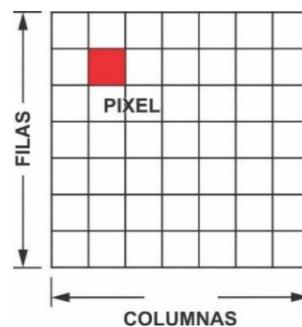


Figura 1. Representación de un ráster en una imagen satelital.

Nota. La grilla representa un raster, es un conjunto de pixeles organizados en filas y columnas, las filas no siempre son iguales a las columnas. Un pixel es una cuadrícula.

1.1.3. INTELIGENCIA ARTIFICIAL

La inteligencia artificial consiste en una variedad de tecnologías que ante las actuales tareas complejas a resolver como: la capacidad de comprender el lenguaje humano, interpretar ingentes cantidades de datos, realizar recomendaciones, traducir el lenguajes hablado y escrito, la capacidad de ver las realidades del mundo actual, entre otras (Callier y Sandel, 2021; Korteling et al., 2021). Esta variedad de tecnologías permiten que las computadoras puedan completar con éxito dichas tareas (Google Cloud, 2022). En el campo de la investigación, la inteligencia artificial es un conjunto de tecnologías cuyos pilares de soporte son el aprendizaje automático y profundo.

1.1.4. APRENDIZAJE AUTOMÁTICO

El aprendizaje automático (del inglés Machine Learning), siendo uno de los pilares de la inteligencia artificial, permite que un sistema (modelo) aprenda, ajuste y mejore por sí misma (Glaser et al., 2020; Janiesch et al., 2021), de forma autónoma y continua en base a las redes neuronales que acumulan experiencias mientras se les proporciona más datos (Google Cloud, 2022), por otro lado, con el aprendizaje profundo, aprenden los datos a identificar patrones comunes y con muy poca intervención puede tomar decisiones (Ponce Cruz, 2010).

1.1.5. RED NEURONAL CONVOLUCIONAL

Partiendo de la premisa que las redes neuronales convolucionales es una de las más utilizadas en la inteligencia artificial moderna, sobre todo en el campo de procesamiento de imágenes y visión computacional (Google Cloud, 2022). Está formada por una sucesión de capas convolucionales seguidas de otra capa de agrupación, esta tarea es con el fin de filtrar diferentes características para luego volver a unir las en otra capa totalmente conectada (Akeret et al., 2017). Estas características pueden ir desde los más simples a las más complejas (Ponce Cruz, 2010).

1.1.6. RED NEURONAL U-NET

Es un tipo de red neuronal totalmente convolucional diseñados para identificar morfologías o grupos de píxeles en imágenes médicas (Ronneberger et al., 2015). Consta de dos partes, la primera las convoluciones (contracción) que consiste en una serie de capas de convolución, función de activación ReLU y capas de max pooling, en esta parte se crean mapas de características (Moustafa et al., 2021). La segunda parte son las deconvoluciones (expansión) encargadas de precisar la localización de las morfologías o mapas de características (McGlinchy et al., 2019).

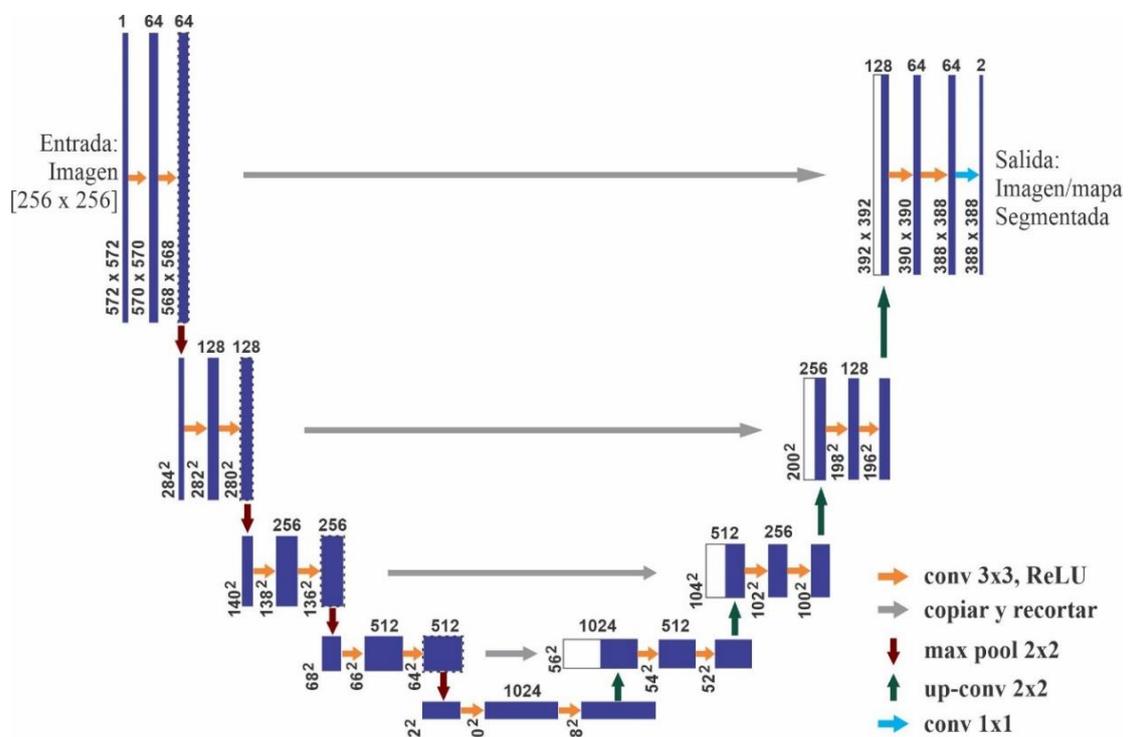


Figura 2. Arquitectura U-Net para segmentación de deforestación.

Nota. Es una red neuronal convolucional con forma de U, diseñada para segmentar imágenes médicas. Tomado de *U-NET Convolutional Networks for Biomedical Image Segmentation*, por Olaf Ronneberger, Philipp Fischer, Thomas Brox, 2015, Dept. of Computer Science, University of Freiburg.

En la Figura 2 los rectángulos representan los mapas de características multicanal, el número de canales se encuentran en la parte superior de cada rectángulo, el tamaño x-y en la parte inferior izquierda del rectángulo, los rectángulos en blanco son copias de los mapas de características, las flechas son las operaciones realizadas por la red neuronal.

La eficiencia de utilizar U-Net está en la precisión de los resultados, después de extraer y segmentar características en una imagen aun cuando estas son limitadas en cantidad.

1.1.7. CONVOLUCIÓN (CONVOLUTION)

Es una operación matemática de las redes neuronales convolucionales, la operación se inicia con la superposición de un kernel sobre una imagen, el mismo que recorre por todos los datos de la imagen (Gu et al., 2018). Como salida de esta operación matemática, retorna otra imagen con nuevos valores y menor dimensión (Khan et al., 2020).

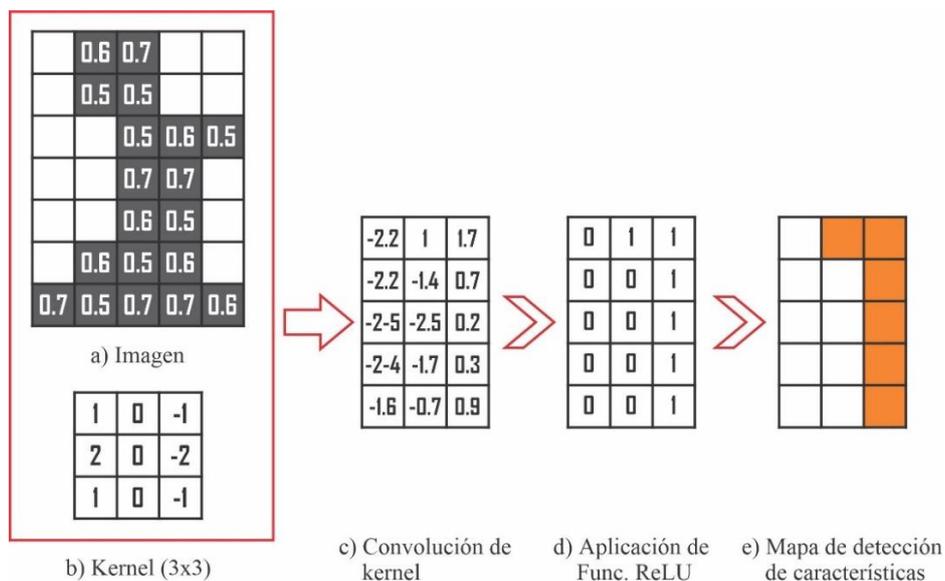


Figura 3. Proceso de convolución de una imagen, a) imagen normalizada, b) kernel de 3x3, c) resultado despues de aplicar la convolución, d) aplicación de la función de activación ReLU, e) agrupamiento de características de deforestación.

Nota. Procesamiento y segmentación de una imagen por una red neuronal convolucional.

1.1.8. CONVOLUCIÓN TRANSPUESTA (DECONVOLUTION)

La deconvolución es un proceso inverso a la convolución, se refiere a las operaciones matemáticas empleadas para la reconstrucción de imágenes a partir de datos procesados (entrada), muy similar a la ingeniería inversa de una compleja red neuronal (Gu et al., 2018). Este proceso se utiliza para extraer características presentes en una imagen, ello se logra mediante cálculos estimados en base a una entrada, un filtro, y un stride (como se muestra en la Figura 4). Como salida de este proceso, se obtiene una imagen con características mejoradas.

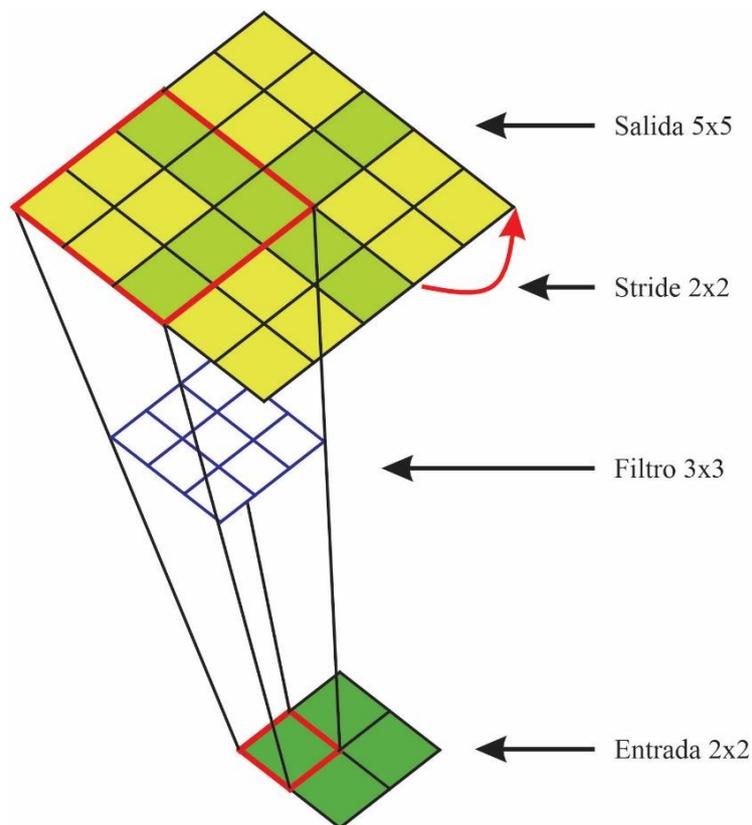


Figura 4. Convolución transpuesta (Conv2DTranspose), con una entrada de 2x2, filtro de 3x3, stride de 2x2 y su salida de 5x5

Nota. Proceso de reconstrucción de una imagen mediante una convolución transpuesta.

1.1.9. MAX-POOLING

La agrupación o max-pooling se utiliza para reducir el número de parámetros de una red neuronal convolucional U-Net, de esta forma aumentar la velocidad en el cálculo y procesamiento de una imagen. Este proceso de agrupamiento se completa estableciendo un filtro (kernel) y los saltos (strides) y como resultado devuelve una matriz con los valores máximos de la matriz de entrada.

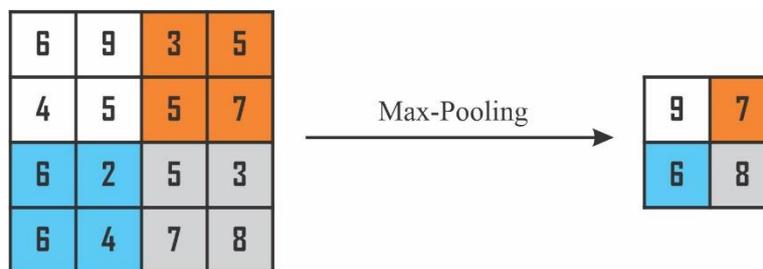


Figura 5. Max-pooling con un stride de 2x2

Nota. Proceso de agrupamiento y reducción de píxeles de una imagen.

En la Figura 5, se observa una matriz de entrada de dimensiones 4x4 y un stride de 2x2. Después de aplicarle la operación max-pooling, se obtiene como salida una matriz de dimensiones 2x2 con los valores: 9, 7, 6 y 8 que son los valores máximos de la matriz inicial.

1.1.10. FUNCIÓN DE ACTIVACIÓN

En el aprendizaje automático, la función de activación es la encargada de devolver una salida que es generada por una neurona al cual se proporcionó una entrada o conjunto de entradas (Khan et al., 2020). Las funciones de activación están directamente asociadas a las de capas de la red neuronal, permitiendo de esta forma predecir o bien reconstruir (IBM Cloud Education, 2020).

1.1.11. DROPOUT

En la red neuronal convolucional U-Net, Dropout es el proceso de omitir de forma aleatoria algunas unidades o conexiones basados en una cierta probabilidad (Guo et al., 2019). En las redes neuronales convolucionales, las conexiones aprenden de forma no lineal, provocando de esta forma un sobreajuste (overfitting). Este proceso de omitir las conexiones, ayuda a la U-Net a controlar los pesos en las entradas (Khan et al., 2020).

1.1.12. CAPA TOTALMENTE CONECTADA (FULLY CONNECTED LAYER)

Es la última capa de la red neuronal que se utiliza para la clasificación, es una operación global. Analiza los resultados extraídos de todas las capas anteriores para finalmente realizar una combinación no lineal de las características seleccionadas y son estas las que permiten clasificar los datos objetivos (Khan et al., 2020).

1.1.13. SATÉLITE LANDSAT-8

Es un satélite LDCM (Landsat Data Continuity Mission) de la serie Landsat diseñado para la captura de global de imágenes espaciales (Masek, n.d.). Cuenta con equipos instalados de detección remota que incluye: a) un radiómetro de barrido multicanal OLI (Operational Land Imager), opera en nueve longitudes de onda en el rango de 0.433-2.300 μ m y b) un radiómetro infrarrojo de dos canales TIRS (Thermal Infrared Sensor) (Ridwan et al., 2018; Roy et al., 2014).

1.1.14. IMAGEN SATELITAL MULTIESPECTRAL

Una imagen satelital multiespectral es la captura de datos en rangos específicos de longitud de ondas en base al espectro electromagnético reflejado. Estas longitudes de onda están separadas por filtros o mediante el uso de sensores a longitudes de onda particulares, incluida frecuencias de luz más allá del rango de espectro electromagnético visible al ojo humano, como el infrarrojo y ultravioleta.

Las imágenes espectrales permiten extraer información adicional que es imposible de ver por los humanos (Schowengerdt, 2012).

1.1.15. SENSOR OLI (OPERATIONAL LAND IMAGER)

El sensor OLI, mide en las porciones visibles, infrarrojas cercanas e infrarrojas de onda corta del espectro. Sus imágenes tienen resoluciones espaciales pancromáticas de 15 metros y multiespectrales de 30 metros a lo largo de una franja de 185 km de ancho, que cubre amplias áreas del paisaje de la Tierra y proporciona una resolución suficiente para distinguir características como los centros urbanos, granjas, bosques y otros usos de la tierra. Todo el globo terráqueo es visible con un ciclo de 16 días debido a la órbita casi polar del satélite Landsat 8.

1.1.16. SENSOR TIRS (THERMAL INFRARED SENSOR)

El sensor infrarrojo térmico (TIRS) es la encargada de recopilar datos de la temperatura superficial terrestre en dos bandas térmicas. Landsat 8 cuenta con nueva tecnología que permite utilizar los conceptos de la física cuántica para detectar el calor. Utiliza Quantum Well Infrared Photodetectors (QWIPs) para detectar largas longitudes de onda de luz emitidas por la Tierra y cuya intensidad refleja la temperatura superficial. Estas longitudes de onda llamadas infrarrojos térmicos, no está al alcance de la visión humana.

TIRS se agregó a la misión satelital Landsat 8 cuando los administradores estatales de recursos hídricos requerían rastrear el uso del agua y la tierra. La alta precisión en las mediciones de la energía térmica de la Tierra fue un complemento mejorado de Landsat 8 en comparación de sus predecesores.

1.1.17. NOMENCLATURA DE LAS IMÁGENES DE LANDSAT-8

La nomenclatura de una imagen satelital, permite identificar aspectos como: tipo de sensor, nivel de procesado, la zona geográfica, la fecha en la que fue tomada y procesada la imagen.

Tiene la siguiente estructura:

LXSS_LLLL_PPPRRR_YYYYMMDD_yyymmdd_CC_TX

En la siguiente tabla se explica el significado de las abreviaturas.

Tabla 1

Nomenclatura de una imagen satelital de Landsat 8

Abreviatura	Descripción
L	Landsat
X	Sensor de captura de la imagen. letra o letras para identificar el sensor que tomó la imagen. Estos son: C (OLI/TIRS), O (OLI), T (TIRS), E (ETM+), T (TM) y M (MSS)
SS	Generación del satélite, por ejemplo: Landsat 7, Landsat 8
LLLL	Nivel de procesado según su corrección geométrica (L1TP, L1GT o L1GS)
PPP	WRS-2 Path
RRR	WRS-2 Row
YYYYMMDD	Fecha de adquisición de la imagen (año/mes/día)
yyymmdd	Fecha de procesado de la imagen (año/mes/día)
CC	Número de colección
TX	Categoría de la colección: RT (Real Time), T1 (Tier 1) o T2 (Tier 2). Tier 1 presenta corrección en la precisión y radiometría. Los archivos Tier 2 no presentan correcciones en la geometría por la imprecisión de la órbita

1.1.18. TELEDETECCIÓN O PERCEPCIÓN REMOTA

La teledetección consiste en la medición de las propiedades de la superficie terrestre utilizando datos adquiridos por satélites o vehículos aéreos. Podemos aseverar que es una medición a distancia e in situ (Schowengerdt, 2012). Los datos de teledetección son

mediciones discretas, puntuales o de una zona en concreto, dentro de estos datos se puede encontrar patrones o características (López, 2020). Los sistemas de teledetección combinan sus principios con la visión artificial (Giraldo Henao, 2011), particularmente las imágenes tomadas por los satélites. Esto con el fin de monitorear los cambios que vienen ocurriendo y el impacto de dichos cambios (Santa María Pinedo et al., 2021).

Algunas de las aplicaciones importantes de la tecnología de teledetección son:

- Evaluación y monitoreo de los cambios ambientales a escala global.
- Predicción, erosión y rendimiento de la agricultura.
- Exploración de recursos no renovables (minerales, petróleo, gas natural)
- Recursos naturales renovables (humedales, suelos, bosques, océanos)
- Comportamiento meteorológico y mapeo de superficies.
- Vigilancia y reconocimiento militar (política estratégica, evaluación táctica)

Para medir las propiedades de la superficie terrestre, la teledetección presenta un esquema como se puede ver en la Figura 6.

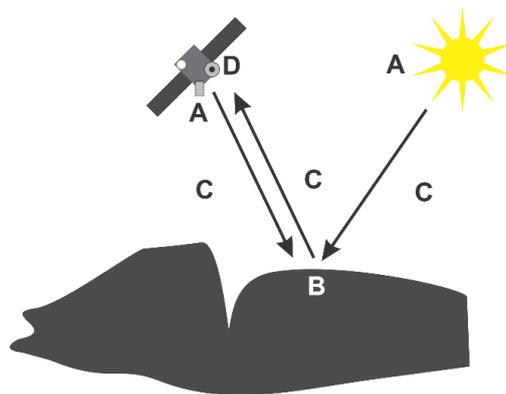


Figura 6. Esquema de un sistema de teledetección

Nota. Es el proceso de captura de datos de la radiación electromagnética reflejada desde la tierra mediante el sensor OLI-TIRs de Landsat-8, que se traduce en imagen satelital multiespectral.



Donde:

- A: Fuente de luz (natural o artificial) la más importante es la que deriva de la luz solar, ya que ella ilumina y refleja las características superficiales de la tierra, este flujo reflejado es recogido por un sensor, que luego es transmitida a los centros de datos.
- B: Superficie, las que reflejan/emiten e interactúan con la fuente de luz.
- C: La atmósfera, medio por el cual viaja la radiación desde la fuente hasta la superficie y viceversa. En ocasiones puede causar perturbaciones a la luz.
- D: Receptor, es la encargada de recoger la radiación y perturbación emitida desde la superficie terrestre. El receptor se encarga de generar una imagen en cuya matriz contienen valores como la intensidad de la radiación, dichos valores son indicadores del nivel y están definidas entre 1 y 255.

1.2. ANTECEDENTES

Los repositorios disponibles de datos multitemporales de imágenes satelitales como Copernicus, Sentinel-2, permiten mejorar el monitoreo de la superficie terrestre y la dinámica Amazónica, incluidos sus bosques. Por tanto, presenta un modelo de red neuronal U-Net como línea base para detectar la deforestación en la zona bosque-estepa de la región de Kharkiv de Ucrania (31 400 km²). El principal aporte de esta investigación es proporcionar un modelo de línea de base para detectar cambios forestales en Ucrania y mejorarlo agregando la capacidad de usar varias imágenes secuenciales como entrada del modelo de segmentación (Isaienkov et al., 2021).

Para abordar la creciente necesidad de minimizar la deforestación en los bosques. La solución desarrollada utiliza procesamiento de imágenes y técnicas de machine learning para identificar cambios en el patrón de la composición arbórea mediante el análisis de las imágenes satelitales. Paralelamente presenta una metodología de detección automática de deforestación en base a los datos satelitales multiespectrales y redes neuronales convolucionales (Katarki et al., 2019). A fin de abordar esta necesidad, también se puede probar y evaluar el uso de algoritmos del Deep Learning (DL), particularmente las redes neuronales convolucionales (CNN) aunque estas se utilizan en tareas de teledetección en los últimos años, se encuentran relativamente inexplorados en tareas de segmentación de deforestación (de Bem et al., 2020). En el dominio de la agricultura también se pueden realizar estudios con las redes CNN, que constituyen una clase específica de DL (Kamilaris y Prenafeta-Boldú, 2018). También hay que considerar que, en la Amazonía la agricultura es una de las fuentes de deforestación, lo que amerita su estudio utilizando el machine learning.

El seguimiento y detección temprana de la deforestación en los bosques de nuestra Amazonía es un proceso fundamental para la preservación. Las técnicas basadas en

imágenes satelitales Landsat 8 se encuentran entre las opciones más atractivas para esta aplicación (Adarme et al., 2020). Esto induce a los investigadores a utilizar un conjunto de datos del mundo real crear enfoques automatizados en base a redes neuronales convolucionales profundas espacio-temporales (Maretto et al., 2021).

Motivado por la creciente reducción de la biodiversidad en la Amazonía Legal Brasileña, se evaluaron diversos métodos para la detección automática de deforestación, específicamente la Red Convolucional de Fusión Temprana (EF), Red Convolucional Siamés (S-CNN) y la Máquina de Vector de Soporte (SVM). Se experimentaron con imágenes Landsat 8 adquiridas en 2016 y 2017 y el resultado fue que los enfoques basados en machine learning, superaron ampliamente los resultados obtenidos con la Máquina de Vector de Soporte (Ortega et al., 2019). Uno de los campos de aplicación de las S-CNN es la biometría facial (Alcaide Martínez, 2020), esto da lugar a considerar el modelo en la detección de la deforestación y comparar con los resultados de una S-CNN.

Visto las investigaciones anteriores y los recientes avances en el campo del procesamiento de imágenes con las Fully Convolutional Networks (FCNs), se busca evaluar el mejor desempeño de la arquitectura de red neuronal U-Net para el mapeo de la cobertura forestal e identificar los polígonos de deforestación en imágenes satelitales de alta resolución espacio-temporal. El resultado de esta arquitectura proporciona una configuración de geometrías de deforestación sin precedentes y son muy útiles para el desarrollo de sistemas y el monitoreo de cambios en la cobertura forestal (Bragagnolo et al., 2021).

Las redes neuronales convolucionales muestran un buen rendimiento en tareas de clasificación de imágenes, procesamiento natural de lenguaje, detección y seguimiento de objetos, detección de textos en imágenes y prominencia visual (elevaciones), etiquetado de escenas (Gu et al., 2018) entre otras. Los algoritmos y métodos basados en

modelos estadísticos involucran también metodologías para el procesamiento de información y resultan muy útiles cuando se busca detectar cambios recientes en imágenes (Aiazzi et al., 2018). Esto fortalece el uso combinado de las redes neuronales convolucionales y la geoestadística (Giraldo Henao, 2011) en la detección de deforestación presente en las imágenes satelitales de la Amazonía de Puno y Puerto Maldonado.

La detección de cambios en las plantaciones es uno de los campos que presenta desafíos para las tecnologías de procesamiento de imágenes (Van Der Walt et al., 2014), algunas se basan en la segmentación de los índices de color y con un costo computacional mucho más bajo comparado con otros algoritmos (Jin et al., 2021). Otro de los algoritmos utilizados es Field Programmable Gate Arrays (FPGAs) que incorpora un modelo de procesado personalizado con agrupamiento y filtrado Laplaciano o Gaussiano, ello a fin de reducir la carga de programación (Bailey, 2019). Tradicionalmente estas tareas de detección de anomalías en las plantaciones lo realizaban los humanos, ello implica costos, tiempo, en algunos casos sin resultados prácticos. Esto dio lugar a utilizar imágenes RGB (del inglés Red, Green, Blue) por su bajo costo y alta disponibilidad de cámaras digitales RGB. La precisión, recuperación, reconocimiento y especificidad, mejoró mucho con el uso de las redes neuronales convolucionales (Ngugi et al., 2021). Ello abre las posibilidades para investigar y mejorar los algoritmos utilizados hasta ahora.

La clave en el campo de la visión artificial procesamiento de imágenes se encuentra en la segmentación semántica (Minaee et al., 2022), de estas, se pueden derivar en aplicaciones como la comprensión de escenas, análisis de imágenes médicas, la percepción robótica, la videovigilancia y la interpretación de imágenes (Weng y Zhu, 2021). Para ello se puede elaborar algoritmos en base al etiquetado de píxeles convolucionales, enfoques basados en pirámides, redes recurrentes, modelos visuales y generativo.

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1. IDENTIFICACIÓN DEL PROBLEMA

Estudiar los bosques de la Amazonía y los peligros que lo amenazan mediante el uso imágenes satelitales y redes neuronales es muy escaso. Mientras la deforestación crece de forma continua, creando cambios en la composición arbórea de los bosques amazónicos de los departamentos de Puno y Madre de Dios.

En el entorno académico nos encontramos con una limitante y son las escasas investigaciones sobre el uso de las redes neuronales convolucionales para detectar la deforestación u otras características superficiales en los bosques de nuestra Amazonía, esto permite que se pueda ampliar el campo de aplicación del aprendizaje automático (Machine Learning).

Cuando se obtiene las imágenes satelitales de los bosques de nuestra Amazonía durante los meses de verano y otoño, la mayor parte de estas imágenes contienen una capa blanca como consecuencia de la presencia de nubes, esto no es bueno para la red neuronal en el momento de identificar y clasificar las zonas donde hay deforestación, ello es una consideración a tomar en cuenta al momento de seleccionar las imágenes satelitales. Además, la presencia de nubes es porque en la Amazonía las precipitaciones son muy frecuentes.

La precisión y segmentación de la deforestación depende mucho de la resolución de la imagen satelital, Perú tiene en órbita el satélite de observación denominado PeruSat-1 administrado por la Agencia Espacial del Perú denominada Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), las imágenes

captadas por este satélite tienen una resolución multiespectral de 2.80 m y una pancromática de 0.70 m. esto significa que un pixel de esta imagen, representa una superficie de $2.80 \times 2.80 \text{ m}^2$, sea de bosque, deforestación o combinación de ambos, en comparación con un pixel de una imagen de Landsat-8 representa una superficie de $30 \times 30 \text{ m}^2$. Resulta obvio que entrenar la red neuronal con las imágenes de PeruSat-1 tiene mejores resultados que cuando se entrena con una imagen de Landsat-8. El gran problema y limitante para la investigación es obtener una imagen satelital de PeruSat-1 mediante CONIDA, resulta ser un trámite muy largo y burocrático en comparación de una imagen de Landsat-8, se puede descargar de forma gratuita e inmediata desde su repositorio, basta con un registro en línea para obtener las credenciales de acceso para descargarlo.

2.2. ENUNCIADOS DEL PROBLEMA

Después de considerar la descripción enunciada en el ítem anterior, nos planteamos la siguiente interrogante:

¿Cómo una red neuronal convolucional U-Net puede ayudar a detectar y segmentar la proporción de la deforestación de los bosques de la Amazonía Peruana?

2.3. JUSTIFICACIÓN

La Amazonía es un recurso natural valioso con que cuenta un país. Su protección, cuidado y preservación depende de las políticas adoptadas por los gobiernos. Considerando esta perspectiva, con la presente investigación se buscó utilizar el gran potencial de la red neuronal totalmente convolucional U-Net, para clasificar y segmentar los cambios presentes en la composición arbórea de la selva de los departamentos de Puno y Madre de Dios, dichos cambios tienen relación con la deforestación y están plasmadas una imagen satelital Landsat 8. Esta segmentación

y clasificación permite contribuir con información precisa sobre la deforestación en nuestra Amazonía al gobierno. Del mismo modo, extender dicha información a las organizaciones medioambientales y organizaciones no gubernamentales, a fin de que puedan adoptar medidas adecuadas.

Inicialmente la U-Net se diseñó para su aplicación en el campo de la medicina y en la actualidad con todos los avances en el campo del Machine Learning para segmentar imágenes, es posible completar diversas tareas de operación sobre imágenes, ya que buscamos modelos de red neuronal que identifique con mejor precisión los patrones de cambio y la deforestación es uno de ellos. Esta investigación utilizó la red neuronal U-Net para visualizar en mapas temáticos la deforestación existente en una imagen de nuestra Amazonía tomada por el satélite Landsat 8 del Servicio Geológico de los Estados Unidos (USGS, por sus siglas en inglés) (<https://earthexplorer.usgs.gov/>).

Esta investigación siembra un precedente para las futuras investigaciones en el campo de procesamiento e interpretación de imágenes aéreas o satelitales. Para ello, el punto de partida es identificar patrones (deforestación y bosques) de cambio que se quiere estudiar y con esa información la U-Net llega a segmentar esos patrones de cambio, que para nuestro estudio fue segmentar los cambios en la composición arbórea de nuestra Amazonía, concretamente las imágenes que cubren la selva de los departamentos de Puno y Madre de Dios.

2.4. OBJETIVOS

2.4.1. OBJETIVO GENERAL

Determinar las proporciones de deforestación en los bosques de la Amazonía peruana, utilizando la red neuronal convolucional U-Net.

2.4.2. OBJETIVOS ESPECÍFICOS

- Compilar las imágenes satelitales multiespectrales de Landsat 8 de los bosques de la Amazonía peruana con presencia de deforestación.
- Diseñar un modelo de red neuronal convolucional U-Net para la detección y segmentación de las zonas con deforestación de los bosques en la Amazonía peruana.
- Examinar la eficiencia del modelo de red neuronal convolucional U-NET para la detección de deforestación de los bosques en la Amazonía peruana

2.5. HIPÓTESIS

2.5.1. HIPÓTESIS GENERAL

Las redes neuronales convolucionales U-Net ayudan a detectar y segmentar con precisión las proporciones de deforestación presentes en los bosques de la Amazonía peruana.

CAPITULO III

MATERIALES Y MÉTODOS

3.1. LUGAR DE ESTUDIO

La presente investigación se realiza en Perú, ubicado en la parte occidental de Sudamérica entre los paralelos $0^{\circ}2'$ y los $18^{\circ}21'34''$ de latitud sur y los meridianos $68^{\circ}39'7''$ y los $81^{\circ}20'13''$ de longitud, como se puede visualizar en la Figura 7, específicamente en la Amazonía peruana que cubre un 60% del total de su superficie. En esta investigación se analizó las imágenes satelitales de Landsat 8 que cubren los bosques de la Amazonía de los Departamentos de Puno y Puerto Maldonado.

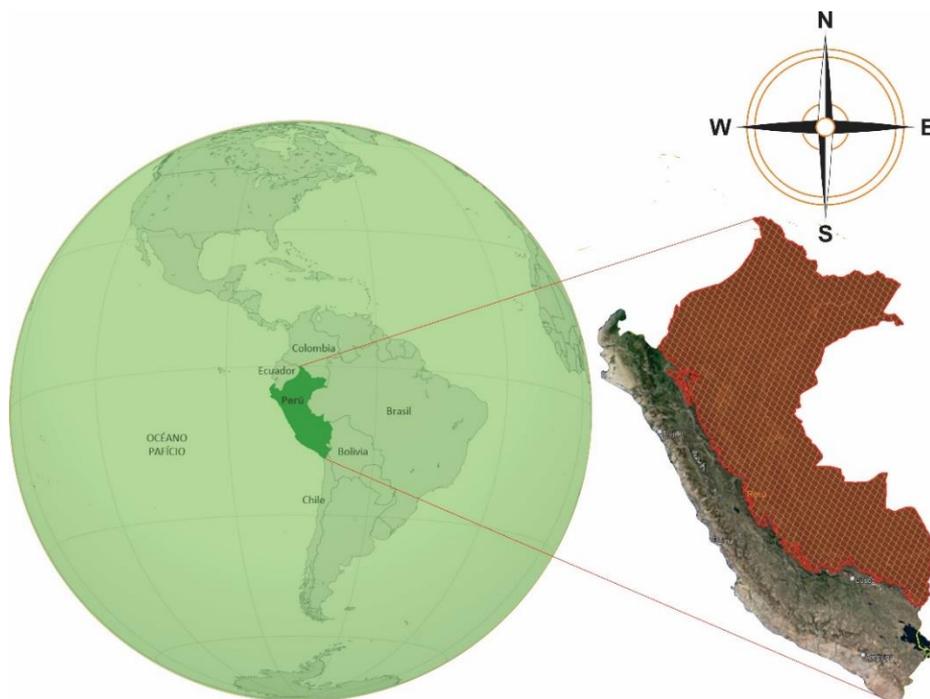


Figura 7. Lugar de estudio donde se realizó la investigación.

Nota. La investigación se desarrolló en América del Sur, teniendo en cuenta la Amazonía peruana, enfocándose en las áreas donde hay presencia de deforestación.

3.2. POBLACIÓN

La población de la investigación se basa en las imágenes satelitales Landsat 8 que cubren la Amazonía peruana, por tanto, se consideró un total de 42 imágenes satelitales. Donde cada imagen satelital es de 7621 x 7751 pixeles, cada pixel representa un área de 30 x 30 metros.

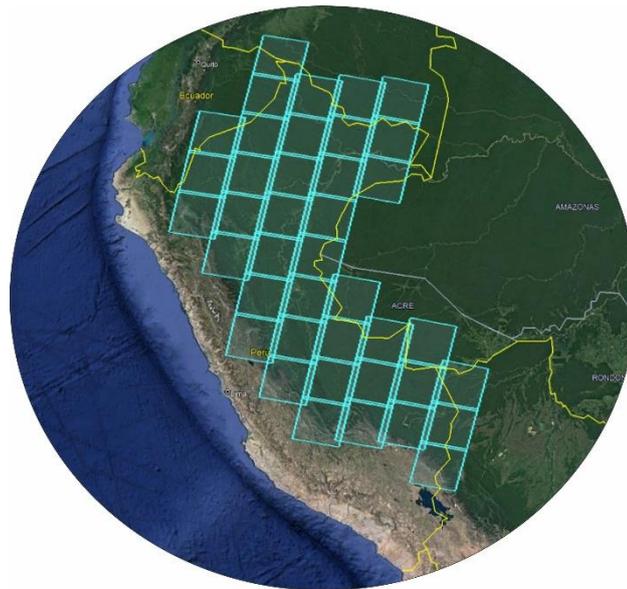


Figura 8. Imágenes satelitales Landsat 8 de la Amazonía peruana.

Nota. La figura muestra la población de las imágenes satelitales que cubren la Amazonía peruana, las cuadrículas corresponden a la configuración (path, row) del satélite Landsat-8 para capturar las imágenes satelitales de la Amazonía peruana, que luego son almacenados en su repositorio. La imagen es tomada de google earth y adaptada en base a la órbita polar del satélite Landsat-8.

3.3. MUESTRA

Considerando que la población es finita y considerando la investigación de tipo cuantitativa y las áreas con presencia de deforestación, se optó por utilizar el muestreo no probabilístico, por tanto, la muestra considerada en la investigación es 9 imágenes satelitales que cubren los bosques Amazónicos de los departamentos de Puno y Puerto Maldonado.



Figura 9. Imágenes satelitales Landsat 8 de los bosques de la Amazonía de los departamentos de Puno y Madre de Dios.

Nota. Las cuadrículas representan las imágenes de la muestra de la investigación, la imagen es tomada de Google Earth y adaptada en base a la órbita polar del satélite Landsat-8.

3.4. MÉTODO DE INVESTIGACIÓN

Por la naturaleza del estudio consistente en recopilar datos, analizar datos gráficos y realizar predicciones gráficas, la investigación es de tipo cuantitativo ya que buscó cuantificar la deforestación presente en los bosques amazónicos de Puno y Puerto Maldonado mediante la segmentación de imágenes que fueron obtenidas del repositorio de Landsat 8.

Durante la investigación se completaron los siguientes procesos:

- a) Selección de las imágenes con presencia de deforestación.
- b) Recorte, dimensionamiento de las imágenes a 256 x 256 píxeles.
- c) Binarización de las imágenes.
- d) Creación de las máscaras a partir de las imágenes binarizadas.

- e) Separación y clasificación de imágenes en bloques de entrenamiento (train) y prueba (test).
- f) Creación del modelo de red neuronal U-Net.
- g) Entrenamiento de la red neuronal U-Net con las imágenes de entrenamiento.
- h) Extracción de características mediante la prueba y predicción de las imágenes de prueba.
- i) Segmentación de deforestación en las imágenes de prueba (test).
- j) Procesamiento posterior de imágenes para evaluar la eficiencia de los resultados producidos por la red neuronal U-Net.

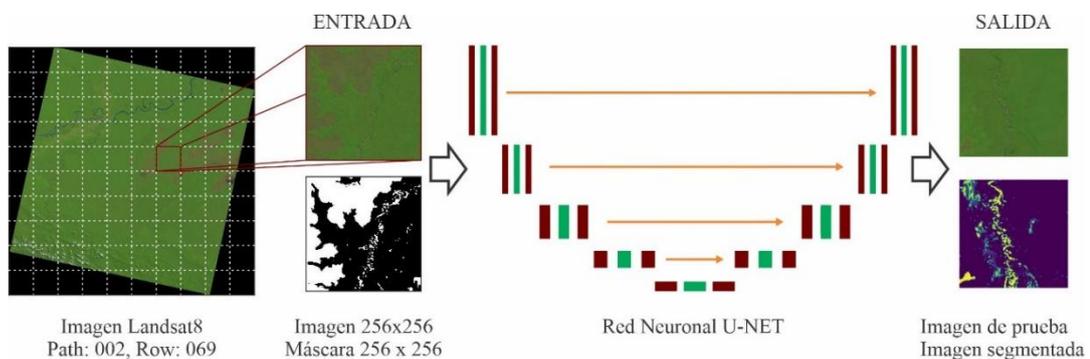


Figura 10. Proceso de selección de imágenes, entrenamiento de la red neuronal U-Net y segmentación de deforestación en imágenes satelitales Landsat 8.

Nota. La imagen de la izquierda es tomada de las imágenes del satélite Landsat-8 y adaptada para su pre-procesamiento, las imágenes de centro-izquierda son imágenes recortadas a tamaño de 256x256 con su respectiva máscara, es el preprocesamiento de las imágenes de entrada (entrenamiento y prueba). La imagen de la red neuronal U-Net es una forma resumida de la Figura 2 que representa el procesamiento de la red neuronal cuando

la imagen pasa por las diferentes capas y funciones, y la imagen de la derecha es la salida de la red neuronal cuando logra segmentar las zonas con presencia de deforestación.

3.5. DESCRIPCIÓN DETALLADA DE MÉTODOS POR OBJETIVOS ESPECÍFICOS

Para lograr nuestro primer objetivo específico: *Obtener las imágenes satelitales multiespectrales de Landsat 8 de los bosques de la Amazonía peruana con presencia de deforestación.*, se procedió como se describe a continuación.

La obtención (descarga) de las imágenes satelitales se realizó teniendo en cuenta las siguientes consideraciones:

- a) Selección de los WRS-2 Paths y WRS-2 Rows que cubren los bosques de la Amazonía de Puno y Puerto Maldonado, además que en estas imágenes se visualice la presencia de deforestación.
- b) Las imágenes satelitales a descargar tengan un máximo de 15% de nubosidad.
- c) Las imágenes satelitales hayan sido captadas entre los meses de mayo y agosto, en dichos meses la presencia de nubes en menor en la toda la Amazonía.

Una vez obtenida las imágenes satelitales, se procedió con el pre-procesamiento de las mismas consistentes en completar las siguientes tareas:

- a) Recortar las imágenes satelitales obtenidas en imágenes de 256 x 256 pixeles de tamaño.
- b) De las imágenes recortadas, se filtró las imágenes donde está presente la deforestación, representada con la variación de tonos de pixeles, llegando a obtener 1629 imágenes.
- c) Seleccionar de forma aleatoria las imágenes de entrenamiento (Train) y las imágenes de prueba (Test).

- d) Utilizando las técnicas de procesamiento de imágenes que proporciona la librería scikit-image de Scikit-learn, se continúa con la binarización de las imágenes recortadas.
- e) Con las imágenes binarizadas se procede con la generación de las máscaras de las zonas con presencia de deforestación, considerando un umbral base de 110 (Threshold = 110), como se puede observar en la Figura.

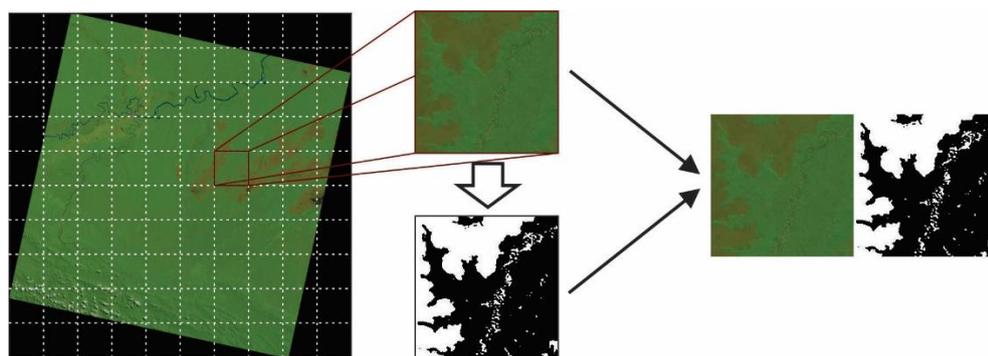


Figura 11. Imagen recortada con su máscara para entrenamiento

Nota. Representa la imagen satelital de Landsat-8 recortada a tamaño de 256x256 píxeles y son seleccionadas las que presenten deforestación, luego se crea la máscara con las zonas con deforestación (color blanco) y los bosques sin deforestación (color negro), que luego son ensambladas para la entrada (entrenamiento y prueba) de la red neuronal.

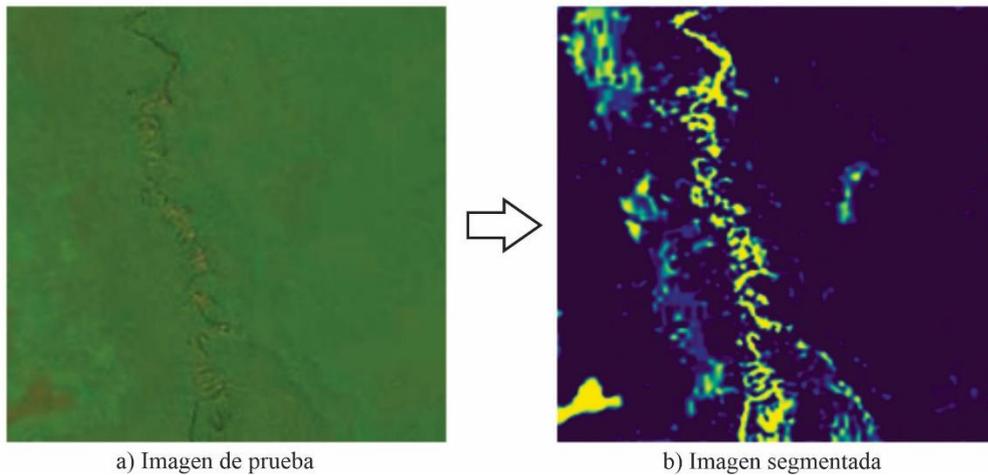
Para completar el segundo objetivo: *Diseñar un modelo de red neuronal convolucional U-Net para la detección y segmentación de las zonas con deforestación de los bosques en la Amazonía peruana.*

- a) Establecer los parámetros de entrada de la red neuronal: las imágenes de entrada a 256 píxeles de ancho y 256 píxeles de alto.
- b) Normalizar las imágenes de entrada.

- c) Establecer los parámetros para las capas de convolución (convolution: C64, C128, C256, C512, C1024) y deconvolución (transposed convolution: TC512, TC256, TC128, TC64) de la arquitectura de la red neuronal U-Net.
- d) Asignamos al modelo de red neuronal diseñada, las imágenes de entrenamiento (Train images) y las de prueba (Test images).
- e) Establecer los parámetros de compilación de la red neuronal U-Net con los siguientes datos: Optimizador (optimizer = Adam), Función de pérdida (loss = binary_crossentropy), Métrica de precisión (metrics = accuracy)

A fin de completar el tercer objetivo específico: *Validar la eficiencia del modelo de red neuronal convolucional U-NET para la detección de deforestación de los bosques en la Amazonía peruana*. Se completó con los siguientes procesos:

- a) Establecemos los parámetros de entrenamiento fijando los tamaños de los bloques (batch_size = 16) y el número de épocas (epochs: 5, 10, 15 y 20).
- b) Entrenamos el modelo de red neuronal convolucional U-Net diseñada.
- c) Al modelo entrenado, se proporciona una imagen de prueba para que pueda segmentar las zonas donde se haya presencia de deforestación, como se puede visualizar en la Figura 12.
- d) Establecemos la validación inicial de los resultados obtenidos por la red neuronal convolucional U-Net.



a) Imagen de prueba

b) Imagen segmentada

Figura 12. Imagen proporcionada a la red neuronal U-Net y su resultado.

Nota. La imagen representa los resultados de la red neuronal U-Net después de ser entrenada y su precisión al segmentar la deforestación presente en una imagen de la Amazonía peruana.

CAPITULO IV

RESULTADOS Y DISCUSIÓN

4.1. RESULTADOS

Con la finalidad de probar la eficiencia de la red neuronal convolucional U-Net en el campo de la detección de deforestación en los bosques amazónicos, la investigación evaluó el comportamiento de la red neuronal en cuatro escenarios de entrenamiento diferentes. Entrenamientos de 5, 10, 15 y 20 etapas (epochs).

Por la cantidad de imágenes a procesar y el alto consumo del recurso computacional, los experimentos (entrenamiento y predicción) se desarrollaron utilizando la plataforma Colaboratory de Google, ya que permite escribir y ejecutar código utilizando GPUs (Graphics Processing Unit). La implementación se realizó utilizando el lenguaje de programación Python, también se utilizó librerías, para el procesamiento de las imágenes la librería scikit-image, mientras que para el entrenamiento de la red neuronal y la predicción se utilizó Keras y TensorFlow.

PRIMER ESCENARIO DE ENTRENAMIENTO:

Entrenamiento de la red neuronal U-Net con 5 épocas

En la Figura 13, la precisión del entrenamiento y de validación están en ascenso constante, lo cual es un indicador que entrenar la red neuronal U-Net con 5 épocas (epochs = 5) tiene un buen desempeño al momento de segmentar la deforestación.

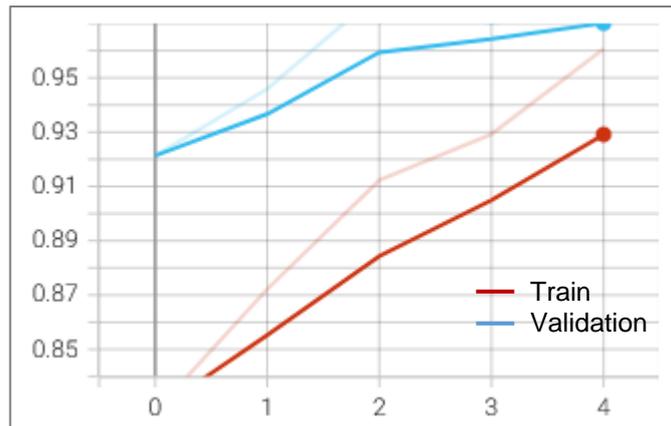


Figura 13. Precisión de entrenamiento y validación con epochs = 5

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 5 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de las métricas de precisión de la red neuronal U-Net.

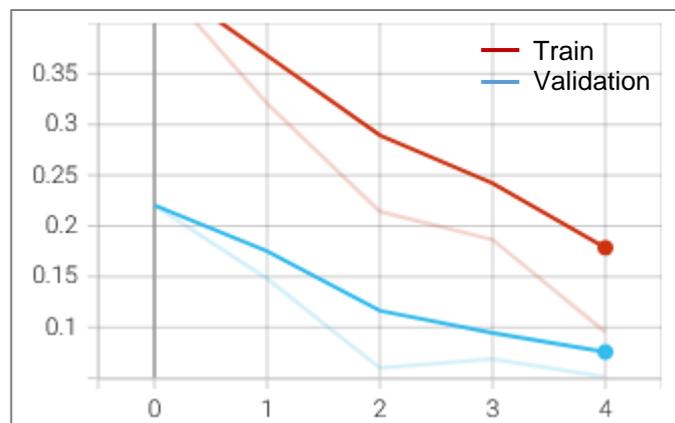


Figura 14. Función de pérdida entrenada con 5 épocas (epochs = 5)

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 5 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de clasificación binaria aplicados a las predicciones correctas de la red neuronal U-Net.

En la Figura 14, la función de pérdida para el entrenamiento y para la validación descenden de forma continua, con una tendencia hacia el cero, es otro indicador del buen desempeño de la red neuronal entrenada.

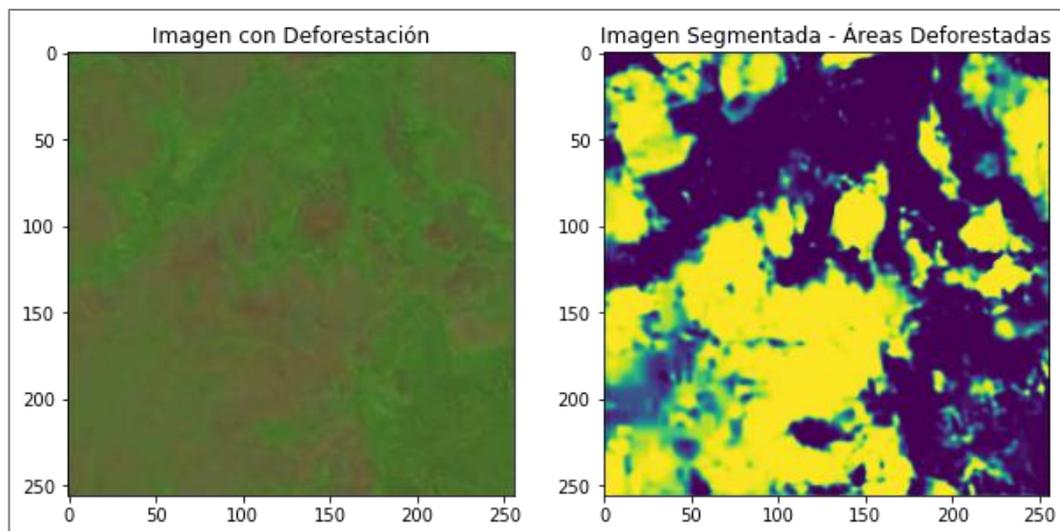


Figura 15. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net.

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 15, a la izquierda se muestra la imagen de prueba que contiene deforestación, esta imagen le proporcionamos a la red neuronal U-Net entrenada para que pueda predecir y segmentar las áreas deforestadas. Como resultado se obtiene la imagen de la derecha, en donde las zonas de color amarillo, representan la deforestación total y el color azul representa la presencia de vegetación (bosques). También se puede observar zonas de color amarillo tenue que representa zonas donde hay deforestación parcial o creciente.

Luego de interpretar los datos de precisión de entrenamiento, validación y de la función de pérdida, evaluamos sus resultados, para ello proporcionamos a la red neuronal U-Net las imágenes de prueba (Test) y visualizamos los siguientes resultados.

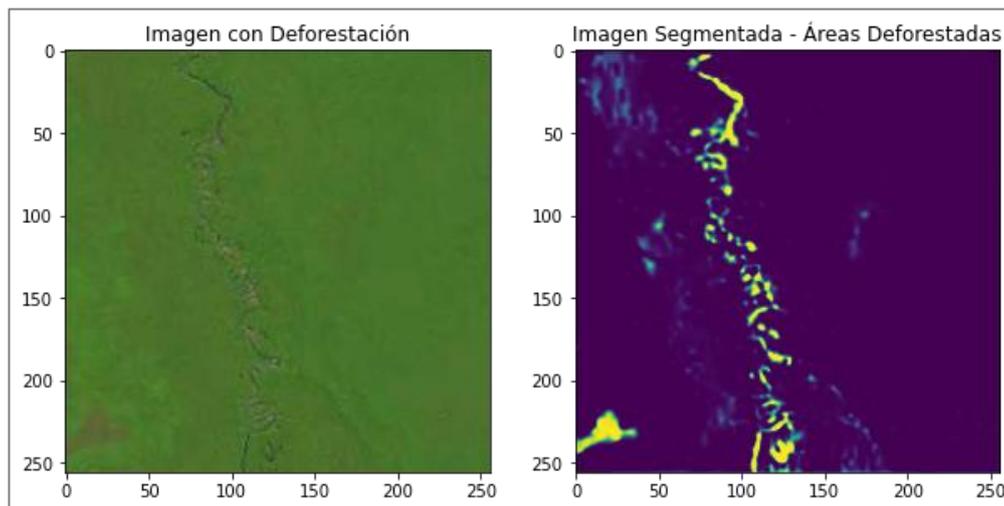


Figura 16. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net.

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles con presencia de un río, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 16, se puede observar que en la imagen satelital de entrada cruza un río y a su vez hay deforestación. Luego, a la derecha se visualiza los resultados de predicción de la red neuronal U-Net, donde se puede visualizar la segmentación de la deforestación total representada en color amarillo y donde la deforestación es parcial lo muestra de color amarillo tenue. Esto es otro indicador que la red neuronal U-Net tiene un buen desempeño cuando el objetivo es identificar la deforestación.

SEGUNDO ESCENARIO DE ENTRENAMIENTO:

Entrenamiento de la red neuronal U-Net con 10 épocas

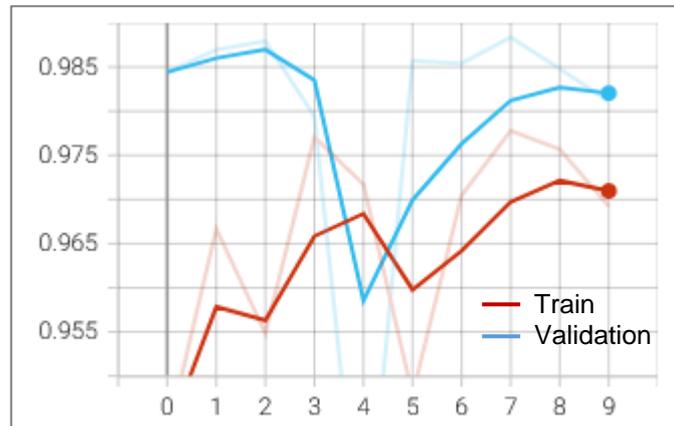


Figura 17. Precisión de entrenamiento y validación con epochs = 10

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 10 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de las métricas de precisión de la red neuronal U-Net.

En la Figura 17, a diferencia del entrenamiento con 5 épocas (como se visualiza en la Figura 13), las curvas de precisión del entrenamiento y de validación tienen comportamientos diferentes, ascensos y descensos diferentes, estos picos son resultado de la función de activación utilizada (ReLU para la investigación), ello es parte del proceso de entrenamiento ya que la red neuronal realiza ajustes en sus entradas. Tomando en cuenta la precisión de entrenamiento (Train), la red neuronal U-Net, alcanza un 96.5% de precisión. Esto nos indica que entrenar la red neuronal U-Net con 10 épocas (epochs = 10) tiene un mejor desempeño que uno entrenado con menos épocas al momento de segmentar la deforestación. Con dicha precisión se evita el sobreajuste u overfitting de la red neuronal.

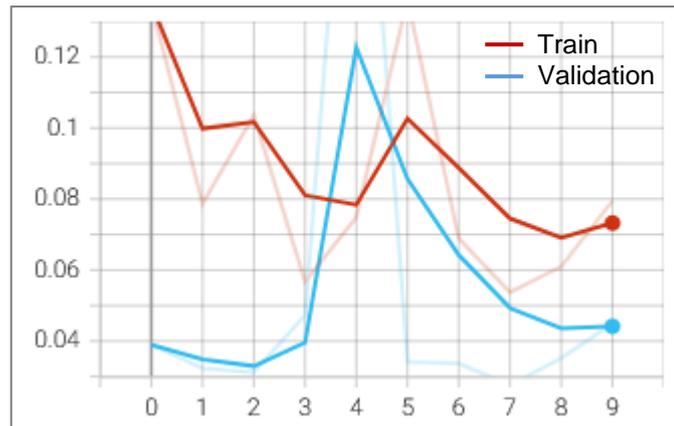


Figura 18. Función de pérdida entrenada con 10 épocas (epochs = 10)

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 10 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de clasificación binaria aplicados a las predicciones correctas de la red neuronal U-Net.

En la Figura 18, la función de pérdida para el entrenamiento y para la validación adquieren un comportamiento diferente en comparación con las entrenadas con 5 épocas (como se visualiza en la Figura 14), los picos de la función de pérdida se elevan entre las épocas 3 y 5 y son las épocas donde las precisiones de entrenamiento disminuyen. Estas variaciones vienen de los ajustes que la red neuronal realiza en sus entradas, estos comportamientos pueden reducir el buen desempeño de la red neuronal entrenada, pero al mismo tiempo evitan el sobreajuste u overfitting.

Luego de interpretar los datos de precisión de entrenamiento, validación y de la función de pérdida, evaluamos sus resultados, para ello proporcionamos a la red neuronal U-Net las mismas imágenes de prueba (Test) utilizados en las validaciones anteriores y visualizamos los siguientes resultados.

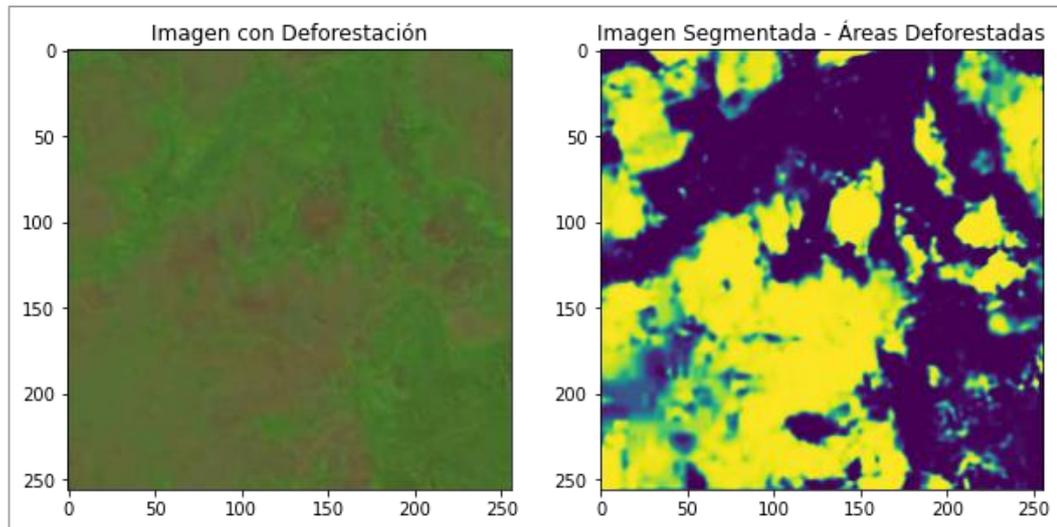


Figura 19. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 10 épocas (epochs = 10).

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 19, en la imagen de la derecha se visualiza una considerable mejora en la segmentación de la deforestación en comparación con los resultados obtenidos cuando la red neuronal U-Net se entrenó con 5 épocas (véase la Figura 15). Esto nos indica que el entrenamiento con mayor número de épocas, se obtiene mejoras en la segmentación de la deforestación en una imagen satelital.

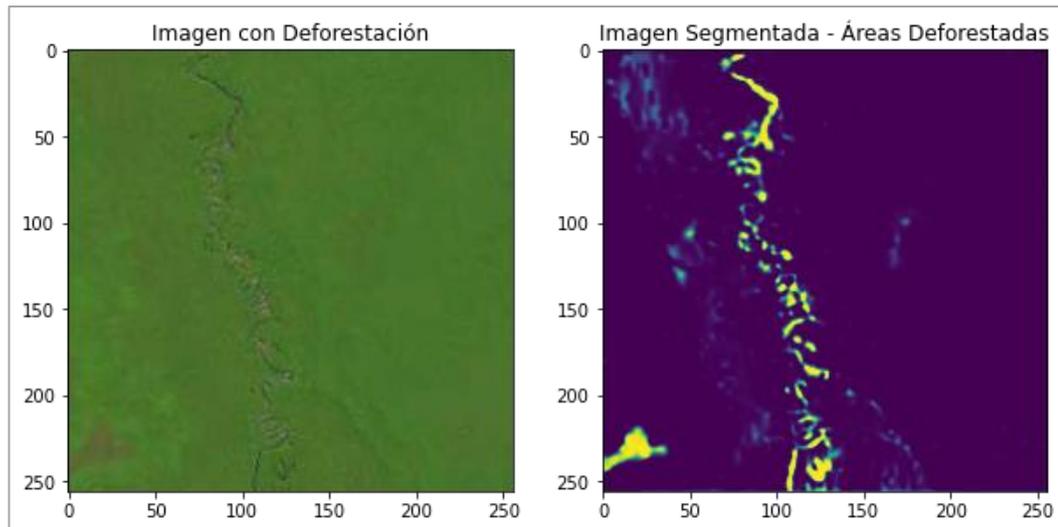


Figura 20. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 10 épocas (epochs=10).

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles con presencia de un río, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 20, en la imagen de la derecha se observa que tiene muy pocas diferencias de segmentación de la deforestación en comparación con los resultados obtenidos con la red neuronal U-Net entrenada con 5 épocas (véase la Figura 16). Por tanto, cuando buscamos mejorar la segmentación de la deforestación y esta se encuentra cerca a los cauces de los ríos de la Amazonía, no necesariamente se tiene que incrementar el número de épocas de entrenamiento de la red neuronal U-Net.

TERCER ESCENARIO DE ENTRENAMIENTO:

Entrenamiento de la red neuronal U-Net con 15 épocas

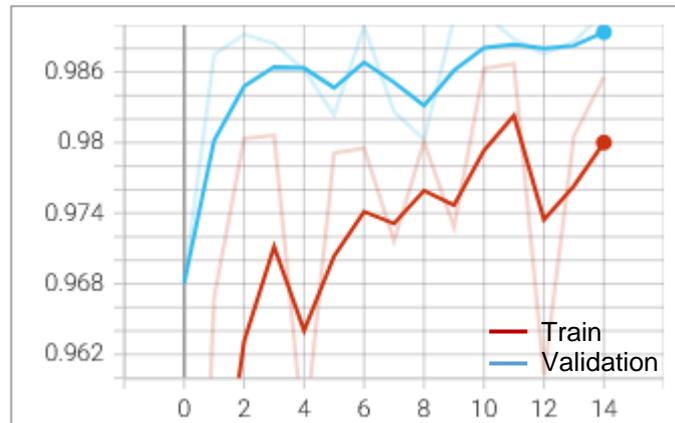


Figura 21. Precisión de entrenamiento y validación con epochs = 15

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 15 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de las métricas de precisión de la red neuronal U-Net.

En la Figura 21, a diferencia del entrenamiento con 5 y 10 épocas (como se visualiza en la Figura 13 y Figura 17), las curvas de precisión del entrenamiento y de validación tienen comportamientos casi similares, con ascensos y descensos ligeramente diferentes, estos picos son resultados de la función de activación utilizada (ReLU para la investigación), esta función permite el ajuste de las entradas de la red neuronal durante el entrenamiento. Esto nos indica que entrenar la red neuronal U-Net con 15 épocas (epochs = 15) o más, hace que la red neuronal tenga un mejor desempeño que uno entrenado con menos épocas. Además, la función de activación Sigmoid en la capa de salida ayuda a evitar el sobreajuste de la red neuronal.

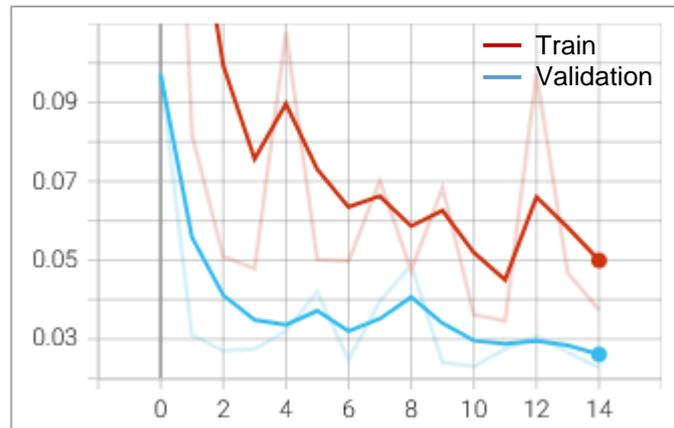


Figura 22. Función de pérdida entrenada con 15 épocas (epochs = 15)

Nota. La gráfica muestra los resultados de entrenamiento de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 15 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de clasificación binaria aplicados a las predicciones correctas de la red neuronal U-Net.

En la Figura 22, la función de pérdida para el entrenamiento y de validación adquieren un comportamiento ligeramente diferente en comparación con las entrenadas con 5 y 10 épocas (como se visualiza en la Figura 14 y Figura 18), los picos de la función de pérdida se elevan cuando los picos de las precisiones de entrenamiento disminuyen. Estas variaciones vienen de los ajustes que realiza la red neuronal en sus entradas mediante la función de activación, mientras se encuentran en descenso en un buen indicador del funcionamiento de la red neuronal, pero al mismo tiempo ayudan a evitar el sobreajuste u overfitting de la red neuronal.

Luego de interpretar los datos de precisión de entrenamiento, validación y de la función de pérdida, evaluamos sus resultados, para ello proporcionamos a la red neuronal U-Net las mismas imágenes de prueba (Test) utilizados en las validaciones anteriores y visualizamos los siguientes resultados.

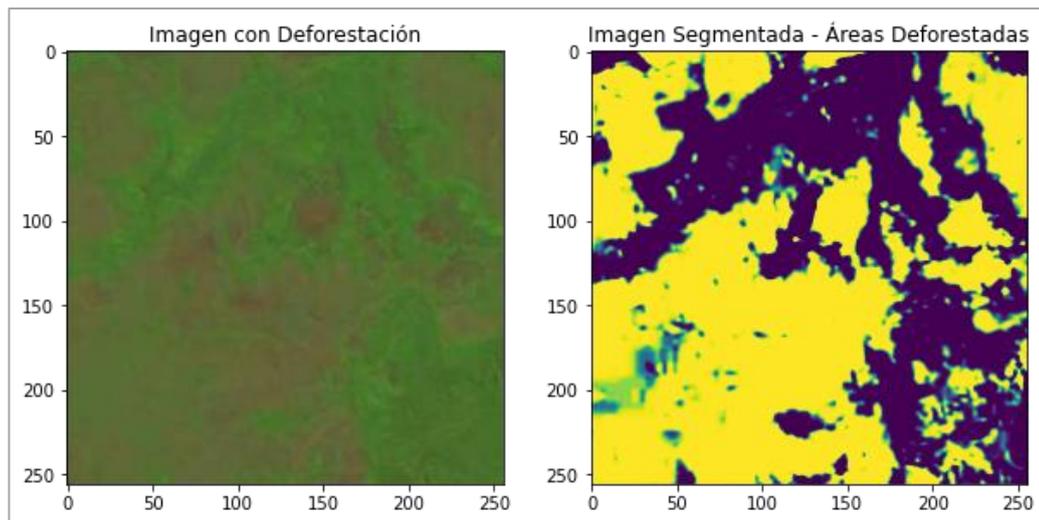


Figura 23. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 15 épocas (epochs = 15).

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 23, en la imagen de la derecha se visualiza una mejoría considerable en la segmentación de la deforestación en comparación con los resultados obtenidos cuando la red neuronal U-Net se entrenó con 5 y 10 épocas (véase la Figura 15 y la Figura 19). Esto nos indica que el entrenamiento con 15 o más épocas, se obtiene mejoras considerables en la segmentación de la deforestación presentes en una imagen satelital de los bosques de la Amazonía.

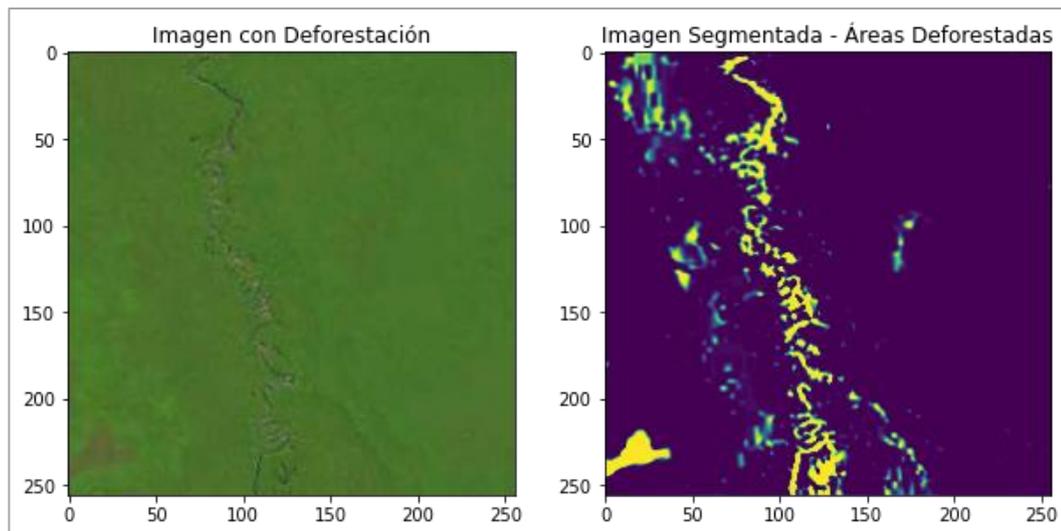


Figura 24. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 15 épocas (epochs=15).

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles con presencia de un río, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 24, en la imagen de la derecha se observa notables diferencias de segmentación de la deforestación en comparación con los resultados obtenidos con la red neuronal U-Net entrenada con 5 y 10 épocas (véase la Figura 16 y Figura 20). Por tanto, Entrenar la red neuronal U-Net con 15 o más épocas durante el entrenamiento, se obtiene mejores resultados cuando buscamos mejorar la segmentación de la deforestación que se encuentra cerca a los cauces de los ríos de la Amazonía.

CUARTO ESCENARIO DE ENTRENAMIENTO:

Entrenamiento de la red neuronal U-Net con 20 épocas

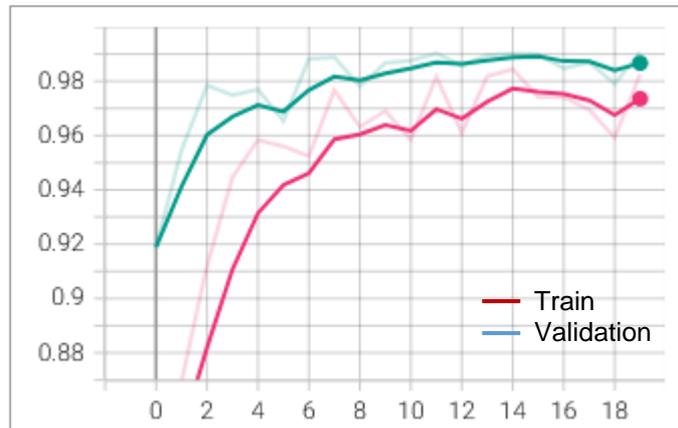


Figura 25. Precisión de entrenamiento y validación con epochs = 20

Nota. La gráfica muestra los resultados de entrenamiento mucho más estables de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 20 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de las métricas de precisión de la red neuronal U-Net.

En la Figura 25, a diferencia del entrenamiento con 5, 10 y 15 épocas (como se visualiza en la Figura 13, Figura 17 y Figura 21), las curvas de precisión del entrenamiento y de validación de imágenes tienen comportamientos ascendentes muy similares, con más ascensos y ligeros descensos, estos picos son por los ajustes que hace la red neuronal mediante la función de activación utilizada (ReLU). Este comportamiento de las curvas nos indica que entrenar la red neuronal U-Net con 20 épocas (epochs = 20), hace que la red neuronal tenga un alto desempeño que otros entrenados con menos número de épocas. Dando opción a la función de activación Sigmoid en la capa de salida a que pueda evitar el sobreajuste de la red neuronal.

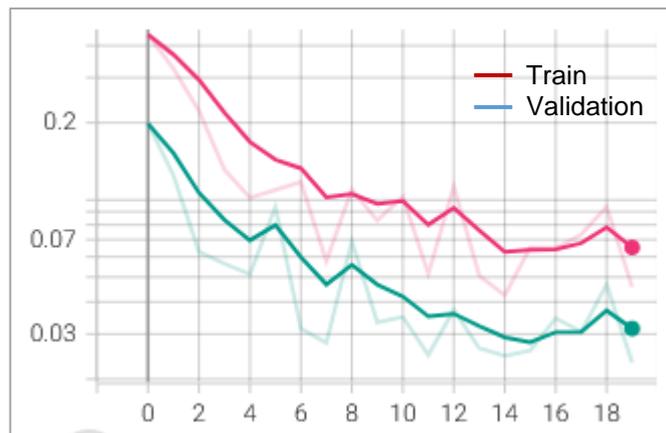


Figura 26. Función de pérdida entrenada con 20 épocas (epochs = 20)

Nota. La gráfica muestra los resultados de entrenamiento mucho más estables de la red neuronal U-Net, modelos diseñados como se visualiza en el Anexo 1 y Anexo 2, con 20 épocas de entrenamiento, la curva roja representa a los datos de entrenamiento y la curva azul representa a los datos de validación. La misma que se obtuvo del tensorboard de Google Colab con datos de clasificación binaria aplicados a las predicciones correctas de la red neuronal U-Net.

En la Figura 26, la función de pérdida para el entrenamiento y de validación de la red neuronal adquieren un comportamiento ligeramente diferente en comparación con las entrenadas con 10 y 15 épocas respectivamente (como se visualiza en la Figura 18 y Figura 22) y muy similar a la entrenada con 5 épocas (como se visualiza en la Figura 14), en todo momento la curva entra en descenso lo cual garantiza que la red neuronal está aprendiendo a segmentar la deforestación de forma eficiente y al mismo tiempo evitar el sobreajuste u overfitting de la U-Net.

Luego de interpretar los datos de precisión de entrenamiento, validación y de la función de pérdida, evaluamos sus resultados proporcionando imágenes a la red neuronal U-Net, las mismas imágenes de prueba (Test) utilizados en las validaciones anteriores, llegando a visualizar los siguientes resultados.

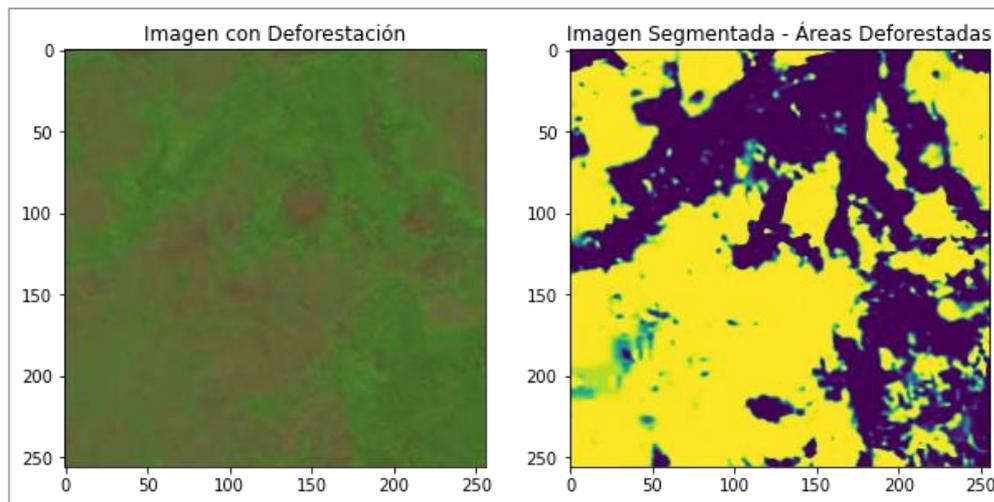


Figura 27. A la izquierda, imagen satelital con deforestación y a la derecha la imagen segmentada por la U-Net entrenada con 20 épocas (epochs = 20)

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 27, en la imagen de la derecha se visualiza una mejoría considerable en la segmentación de la deforestación inclusive se visualiza las zonas de avance de la deforestación en comparación con los resultados obtenidos cuando la red neuronal U-Net se entrenó con 5, 10 y 15 épocas (véase la Figura 15, la Figura 19 y la Figura 23). Esto nos indica que el entrenamiento con 20 o más épocas, se obtiene un alto rendimiento en la segmentación de la deforestación presentes en una imagen satelital de los bosques de la Amazonía.

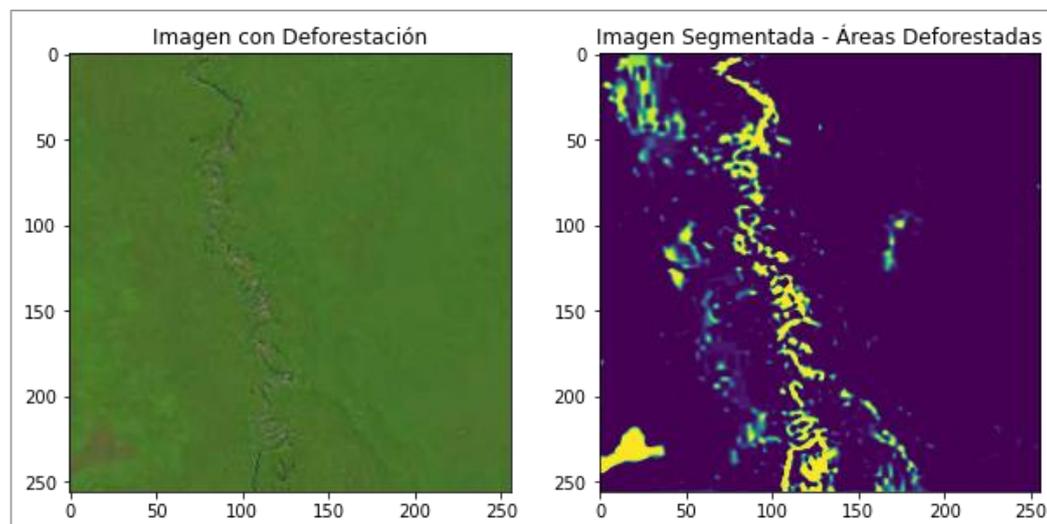


Figura 28. A la izquierda, imagen satelital de un río con deforestación y a la derecha imagen segmentada por la U-Net entrenada con 20 épocas (epochs=20)

Nota. La imagen de la izquierda es una imagen preprocesada de prueba (test) y recortada a 256x256 píxeles con presencia de un río, imagen procesada utilizando la librería Python Imaging Library (PIL). La imagen de la derecha es el resultado segmentado de la U-Net, modelo que se muestra en el Anexo 1 y Anexo 2. Cada píxel de la imagen representa un área de 30m x 30m.

En la Figura 28, en la imagen de la derecha se observa con mayor precisión la segmentación de la deforestación, mucho mejor que los resultados obtenidos con la red neuronal U-Net entrenada con 5, 10 y 15 épocas (véase la Figura 16, Figura 20 y la Figura 24). Por tanto, Entrenar la red neuronal U-Net con 20 o más épocas de entrenamiento, se obtiene resultados con alta precisión en la segmentación de la deforestación que se encuentra cerca a los cauces de los ríos de la Amazonía.

Después de evaluar los diferentes escenarios de entrenamiento de la red neuronal convolucional U-Net, llegamos a confirmar que la función de pérdida es un buen indicador de la eficiencia de la red neuronal, en la investigación en todos los escenarios se acercan al cero. El otro indicador es la precisión de entrenamiento y



validación, son curvas opuestas a la función de pérdida. Estas curvas de precisión cuando están en ascenso, son buenos indicadores de que la red neuronal U-Net está logrando la segmentación buscada, en la investigación la precisión llega a un 98.5% como máximo, lo cual es aceptable y esto ocurre porque en la capa de salida de la red neuronal, utilizamos la función Sigmoide como función de activación. Obteniendo un resultado nos indica que el grupo de píxeles segmentados pertenece a la deforestación o es un bosque Amazónico.

4.2. DISCUSIONES

Iniciamos esta sección mostrando los datos del entrenamiento de los 04 escenarios de nuestra red neuronal, como se visualiza en la Tabla 2, por otro lado, considerando que las aplicaciones de las U-Nets tienen su origen en la segmentación y ubicación de los tumores en imágenes médicas, la investigación propone crear un modelo de red neuronal U-Net, entrenarlo y aplicarlo en la segmentación de la deforestación presente y creciente en nuestra Amazonía.

Tabla 2

Resultados del entrenamiento de la red neuronal convolucional U-Net (precisión y función de pérdida), la mejor está resaltado en negrita.

Épocas (epochs)	Precisión (Accuracy)		Función de pérdida (loss)	
	Train	Validation	Train	Validation
epochs = 5	0.930	0.960	0.170	0.080
epochs = 10	0.970	0.978	0.070	0.040
epochs = 15	0.980	0.986	0.050	0.029
epochs = 20	0.982	0.990	0.045	0.023

Nota: Esta tabla resume los resultados obtenidos de la U-Net, después de haber sido entrenado con 1657 imágenes con sus respectivas máscaras.

En base a los resultados de la Tabla 2 se visualiza que cuando se entrena la red neuronal U-Net con 20 épocas ($epochs = 20$), se obtiene mejores resultados de entrenamiento, tal como muestran los valores de precisión y de función de pérdida.

K. Isaienkov et al. (2021) en su investigación utiliza imágenes satelitales de Sentinel-2, en base a ello precisa sus resultados en términos de métricas de calidad de segmentación en las imágenes de entrenamiento, de todos ellos destaca la red neuronal UNET basado en la ResNet-50, ya que su ratio de aprendizaje es 10^{-3} con el optimizador *Stochastic Gradient Descent* (SGD). Un segundo mejor modelo

basado en la validación es la UNET-50 cuyo ratio de aprendizaje alcanza 10^{-3} con el optimizador *Adam*. Estos resultados confirman la alta eficiencia de la U-Net en la segmentación semántica de deforestación.

Hay una consideración a tomar en cuenta, cuando las imágenes presentan características muy poco diferenciadas (entre deforestación y bosques) a causa de propiedades estacionales o muestreos espaciales, en esos casos se debe regular el umbral para la binarización u contraste de la imagen y posterior creación de la máscara.

G. Katarki et al. (2019) Utiliza una red neuronal convolucional para entrenar su modelo de detección de cambios forestales y probado con 280 imágenes positivas (140) y negativas (140). El modelo detecta cambios en las dos imágenes de entrada, y cuando encuentra diferencias, genera una tercera imagen con los cambios encontrados. Es una buena metodología para detectar los cambios en comparación a las obtenidas por la U-Net, además, depende mucho de la imagen obtenida. La resolución de las imágenes satelitales difiere mucho de una imagen aérea, ello puede ser un factor determinante en la detección de cambios. Es algo que la red neuronal U-Net aprende a segmentar con mejor precisión, como se puede visualizar en las Figuras 27 y 28.

En la investigación sobre las técnicas de machine learning para detectar la deforestación M. Adarme et al. (2020) evalúa 3 técnicas: Early Fusion (EF), Siamese Network (SN) y Convolutional SVM (CSVM). El experimento se hizo con 2 imágenes satelitales Landsat-8 adquiridas en fechas que difieren 1 año. Consideró cuatro escenarios diferentes utilizando uno, dos, tres y cuatro muestras. Como se esperaba, las cuatro técnicas mostraron mejoras en sus rendimientos, pero la mejora

notable mostró las técnicas EF y SN. La precisión obtenida por EF y SN en los experimentos alcanzaron entre 95% y 97% en términos de precisión general. En este tipo de investigación, la precisión alcanzada depende mucho de la zona de estudio, hay zonas donde la deforestación es total y hay zonas donde queda restos de vegetación, lo que dificulta la detección. Además, en la Amazonía la vegetación crece muy rápidamente. Eso es algo que para las U-Nets no representa dificultad alguna, ya que analiza cúmulos de píxeles para determinar si hay presencia de deforestación en la imagen de la zona de estudio.

La Amazonía en Sudamérica es única, en ese contexto R. Maretto et al. (2021) Realiza un estudio para mapear áreas deforestadas en la Amazonía brasileña utilizando imágenes satelitales de Landsat-8 y técnicas modernas de clasificación basadas en redes neuronales U-Net, logrando una precisión general de 95% en el mapeo. Esta investigación utiliza una técnica en particular, la fusión de dos imágenes multitemporales. Esta investigación refuerza una vez más que las redes neuronales U-Net tiene un buen rendimiento en la segmentación de deforestación en imágenes satelitales.

Los resultados de las redes neuronales convolucionales tienen resultados similares con lo cual se demuestra su idoneidad en la detección de cambios en la cubierta forestal. L. Bragagnolo et al. (2021) utilizó imágenes satelitales Landsat-8 para la detección de cambios en la deforestación de un área específico de la Amazonía con DeepLabv3+ (cuya precisión está entre 0.64–0.72) y luego contrastarlo con los resultados de las técnicas Early Fusion (EF) y Siamese Convolutional Neural Network (S-CNN). La propuesta de L. Bragagnolo fue más allá, utilizó la U-Net para contrastarlos. Sus resultados indican que las U-Nets son capaces de generar

resultados de alta fidelidad con amplias aplicaciones potenciales para el seguimiento de los cambios en la Amazonía brasileña.

Considerando la investigación con las de L. Bragagnolo y otras investigaciones citadas, podemos reafirmar que, en el contexto de cambios en la cobertura forestal Amazónica, la importancia de la detección temprana de deforestación y su monitoreo, radica en los tiempos cortos de respuesta ante continuos cambios. Si de cambios se trata, no se puede descartar el uso de arquitecturas de redes neuronales como: DeepLabV3+, FCN32, PspNet, ResNet50-SegNet, SegNet y Vgg-PspNet para detectar deforestación en la Amazonía, todos ellos obtienen resultados con alta precisión. Pero sobre la base de los resultados de rendimiento y tiempo de respuesta, se eligió la U-Net como la arquitectura de CNN aplicable en la segmentación y mapeo de los cambios sobre la cobertura amazónica. esta investigación así lo considera, en esencia por la precisión de los resultados alcanzados.

CONCLUSIONES

Después de ver y analizar los resultados obtenidos por la red neuronal U-Net, llegamos a las siguientes conclusiones:

La interpretación y clasificación de la deforestación en una imagen satelital consiste analizar las diferencias que existe entre cúmulos de pixeles, por un lado, los pixeles que representan a los bosques de la Amazonía y los pixeles que representan la deforestación presente. En este tipo de tareas de clasificación, la red neuronal U-Net tiene un alto nivel de desempeño para interpretar la deforestación presente en las imágenes satelitales de los bosques amazónicos.

Las redes neuronales convolucionales U-Net, funcionan muy bien para cualquier problema de clasificación. Casos como segmentación de incendios forestales, áreas de sembríos, inundaciones entre otras. La precisión depende mucho de la imagen de entrada a la red neuronal, cuanto mayor es el contraste y la resolución de la imagen, mejor será la clasificación.

Después de ver la precisión de los resultados de la red neuronal U-Net, con certeza podemos afirmar que se puede segmentar otras características superficiales presentes en la Amazonía como las cochas, lagunas y lo serpenteante de los ríos. Depende de entrenar la red neuronal con una máscara binaria muy bien segmentada.

Para obtener mejores resultados de segmentación, la red neuronal convolucional U-Net, debe entrenarse con al menos 15 épocas (epochs), los bloques de imágenes de entrada pueden ser de 8, 16 o bien 32, en esta investigación la red neuronal se entrenó con bloques de 16 imágenes, obteniendo como resultado una buena segmentación de la deforestación en las imágenes de prueba.



En imágenes satelitales Landsat 8, cuando se busca segmentar la deforestación en los bosques de la Amazonía, se debe evitar el sobreajuste u overfitting, para ello, en el modelo de la red neuronal convolucional U-Net se debe desactivar la dependencia de un cierto número de neuronas de forma aleatoria. En la investigación la mejor forma de evitar el sobreajuste fue utilizar el método Dropout con un valor (parámetro) entre 0.1 y 0.2, cuando este valor es superior a 0.2, se obtuvo resultados inesperados.

RECOMENDACIONES

Si bien el repositorio de la misión Landsat es gratuito previo registro, contiene imágenes satelitales multitemporales con resolución espacial baja en comparación con una imagen obtenida con el satélite PeruSat-1, este último satélite posee la capacidad de capturar imágenes satelitales multiespectrales de alta resolución espacial, siendo estas de 0.7m en Pancromático, 2.8m en multiespectral. Para segmentar la deforestación de la Amazonía es altamente recomendable utilizar las imágenes satelitales de PeruSat-1, también considerar el tiempo requerido para su obtención debido a las políticas restrictivas de la Agencia Espacial del Perú (CONIDA).

En segmentación de deforestación en imágenes satelitales, se debe evitar el sobreajuste u overfitting, cuando la precisión de entrenamiento llega a 1 o la función de pérdida se acerca al 0.001, se sugiere eliminar nodos aleatorios de la red neuronal utilizando el método dropout con un valor menor o igual a 0.2.

Si la imagen tiene un buen contraste, para generar las máscaras de las imágenes de entrenamiento se recomienda utilizar la transformada de Fourier 2D con filtros de paso alto y bajo en Uno y Cero. En caso que el contraste sea muy bajo, mejor utilizar la librería scikit-image ajustando el umbral de binarización.

BIBLIOGRAFÍA

- Adarme, M. O., Feitosa, R. Q., Happ, P. N., Almeida, C. A. De, & Gomes, A. R. (2020). Evaluation of deep learning techniques for deforestation detection in the brazilian amazon and cerrado biomes from remote sensing imagery. *Remote Sensing*, 12(6). <https://doi.org/10.3390/rs12060910>
- Aiazzi, B., Bovolo, F., Bruzzone, L., Garzelli, A., Pirrone, D., & Zoppetti, C. (2018). Change detection in multitemporal images through single- and multi-scale approaches. In *Signals and Communication Technology*. https://doi.org/10.1007/978-3-319-66330-2_8
- Akeret, J., Chang, C., Lucchi, A., & Refregier, A. (2017). Radio frequency interference mitigation using deep convolutional neural networks. *Astronomy and Computing*, 18, 35–39. <https://doi.org/10.1016/j.ascom.2017.01.002>
- Alcaide Martínez, A. (2020). Redes neuronales convolucionales aplicadas a la indentificación y medición automatizadas. *Universidad Carlos III de Madrid*, 99. https://e-archivo.uc3m.es/bitstream/handle/10016/32814/TFG_Asier_Alcaide_Martinez.pdf
- Bailey, D. G. (2019). Image processing using FPGAs. *Journal of Imaging*, 5(5). <https://doi.org/10.3390/jimaging5050053>
- Bragagnolo, L., da Silva, R. V., & Grzybowski, J. M. V. (2021). Amazon forest cover change mapping based on semantic segmentation by U-Nets. *Ecological Informatics*, 62. <https://doi.org/10.1016/j.ecoinf.2021.101279>
- Callier, P., & Sandel, O. (2021). Introduction to Artificial Intelligence. *Actualites Pharmaceutiques*, 60(611). <https://doi.org/10.1016/j.actpha.2021.10.005>
- Chang, K.-T. (2018). Introduction to Geographic Information Systems. In *Edis* (Vol. 2012, Issue 4). <https://doi.org/10.32473/edis-fr356-2012>
- de Bem, P. P., de Carvalho, O. A., Guimarães, R. F., & Gomes, R. A. T. (2020). Change detection of deforestation in the brazilian amazon using landsat data and convolutional neural networks. *Remote Sensing*, 12(6). <https://doi.org/10.3390/rs12060901>
- Environmental Systems Research Institute. (2022). *Datos Raster*.

<https://desktop.arcgis.com/es/arcmap/10.3/manage-data/raster-and-images/what-is-raster-data.htm>

Giraldo Henao, R. (2011). Introducción a la geoestadística. *Universidad Nacional de Colombia*.

Glaser, J. I., Benjamin, A. S., Chowdhury, R. H., Perich, M. G., Miller, L. E., & Kording, K. P. (2020). Machine learning for neural decoding. *ENeuro*, 7(4). <https://doi.org/10.1523/ENEURO.0506-19.2020>

Google Cloud. (2022). *Boletín informativo de Google Cloud*. <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=es-419>

Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77. <https://doi.org/10.1016/j.patcog.2017.10.013>

Guo, C., Szemenyei, M., Pei, Y., Yi, Y., & Zhou, W. (2019). SD-Unet: A Structured Dropout U-Net for Retinal Vessel Segmentation. *Proceedings - 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering, BIBE 2019*. <https://doi.org/10.1109/BIBE.2019.00085>

IBM Cloud Education. (2020). *Convolutional Neural Networks*. <https://www.ibm.com/cloud/learn/convolutional-neural-networks#toc-what-are-c-MWGVhUiG>

Isaienkov, K., Yushchuk, M., Khramtsov, V., & Seliverstov, O. (2021). 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. <https://doi.org/10.1109/JSTARS.2020.3034186>

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3). <https://doi.org/10.1007/s12525-021-00475-2>

Jin, X., Che, J., & Chen, Y. (2021). Weed identification using deep learning and image processing in vegetable plantation. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3050296>

Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. In *Journal of Agricultural Science* (Vol. 156, Issue

3). <https://doi.org/10.1017/S0021859618000436>

Katarki, G., Ranmale, H., Bidari, I., & Chickerur, S. (2019). Estimating Change Detection of Forest Area using Satellite Imagery. *2019 International Conference on Data Science and Communication, IconDSC 2019*. <https://doi.org/10.1109/IconDSC.2019.8816956>

Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8). <https://doi.org/10.1007/s10462-020-09825-6>

Korteling, J. E. (Hans., van de Boer-Visschedijk, G. C., Blankendaal, R. A. M., Boonekamp, R. C., & Eikelboom, A. R. (2021). Human- versus Artificial Intelligence. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.622364>

López, C. (2020). Fundamentos Básicos para la Teledetección Ambiental. *Universidad Católica Del Norte*, July.

Maretto, R. V., Fonseca, L. M. G., Jacobs, N., Körting, T. S., Bendini, H. N., & Parente, L. L. (2021). Spatio-Temporal Deep Learning Approach to Map Deforestation in Amazon Rainforest. *IEEE Geoscience and Remote Sensing Letters*, 18(5). <https://doi.org/10.1109/LGRS.2020.2986407>

Masek, J. G. (n.d.). *Landsat 8 Bands* « *Landsat Science*. Retrieved November 18, 2019, from <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-bands/>

McGlinchy, J., Johnson, B., Muller, B., Joseph, M., & Diaz, J. (2019). Application of UNET fully convolutional neural network to impervious surface segmentation in urban environment from high resolution satellite imagery. *International Geoscience and Remote Sensing Symposium (IGARSS), 2019-July*. <https://doi.org/10.1109/IGARSS.2019.8900453>

Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2022). Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7). <https://doi.org/10.1109/TPAMI.2021.3059968>

Moustafa, M. S., Mohamed, S. A., Ahmed, S., & Nasr, A. H. (2021). Hyperspectral

- change detection based on modification of UNet neural networks. *Journal of Applied Remote Sensing*, 15(02). <https://doi.org/10.1117/1.jrs.15.028505>
- Ngugi, L. C., Abelwahab, M., & Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. In *Information Processing in Agriculture* (Vol. 8, Issue 1). <https://doi.org/10.1016/j.inpa.2020.04.004>
- Oliveira, M. C., & Siqueira, L. (2022). Digitalization between environmental activism and counter-activism: The case of satellite data on deforestation in the Brazilian Amazon. In *Earth System Governance* (Vol. 12). <https://doi.org/10.1016/j.esg.2022.100135>
- 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(2/W7). <https://doi.org/10.5194/isprs-annals-IV-2-W7-121-2019>
- Ponce Cruz, P. (2010). *Inteligencia artificial con aplicacion a la ingeniería*.
- Proyecto QGIS. (2022). *Datos Raster*. https://docs.qgis.org/2.14/es/docs/gentle_gis_introduction/raster_data.html
- Real Academia Española. (2022). *Real Academia Española - RAE*. <https://dle.rae.es/deforestar>
- Ridwan, M. A., Radzi, N. A. M., Ahmad, W. S. H. M. W., Mustafa, I. S., Din, N. M., Jalil, Y. E., Isa, A. M., Othman, N. S., & Zaki, W. M. D. W. (2018). Applications of landsat-8 data: A Survey. *International Journal of Engineering and Technology(UAE)*, 7(4). <https://doi.org/10.14419/ijet.v7i4.35.22858>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net : Convolutional Networks for Biomedical*. 234–241. <https://doi.org/10.1007/978-3-319-24574-4>
- Roy, D. P., Wulder, M. A., Loveland, T. R., C.E., W., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8: Science and product vision for

- terrestrial global change research. *Remote Sensing of Environment*, 145. <https://doi.org/10.1016/j.rse.2014.02.001>
- Santa María Pinedo, J. C., Ríos López, C. A., Rodríguez Grández, C., & García Estrella, C. W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/rcsi.v1i2.131>
- Schowengerdt, R. A. (2012). Remote sensing: Models and methods for image processing: Second edition. In *Remote Sensing: Models and Methods for Image Processing: Second Edition* (Third Edit). Academic Press. <https://doi.org/10.1016/C2009-0-21902-7>
- Spracklen, D. V., & Garcia-Carreras, L. (2015). The impact of Amazonian deforestation on Amazon basin rainfall. *Geophysical Research Letters*, 42(21). <https://doi.org/10.1002/2015GL066063>
- Van Der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., & Yu, T. (2014). Scikit-image: Image processing in python. *PeerJ*, 2014(1). <https://doi.org/10.7717/peerj.453>
- Weng, W., & Zhu, X. (2021). INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3053408>
- Zemp, D. C., Schleussner, C. F., Barbosa, H. M. J., & Rammig, A. (2017). Deforestation effects on Amazon forest resilience. *Geophysical Research Letters*, 44(12). <https://doi.org/10.1002/2017GL072955>



ANEXOS

Anexo 1 Código fuente del core (núcleo) del modelo de la red Neuronal Convolutiva U-Net

```
# Definiendo la entrada al modelo
Image_input = Input((H, W, 3))
Image_in = Lambda(lambda x: x / 255)(Image_input)

# Capas de convolución (contracting path)
conv1 = Conv2D(64, (3, 3), activation='relu', padding='same')(Image_in)
conv1 = Conv2D(64, (3, 3), activation='relu', padding='same')(conv1)
maxp1 = MaxPooling2D((2, 2))(conv1)

conv2 = Conv2D(128, (3, 3), activation='relu', padding='same')(maxp1)
conv2 = Conv2D(128, (3, 3), activation='relu', padding='same')(conv2)
maxp2 = MaxPooling2D((2, 2))(conv2)

conv3 = Conv2D(256, (3, 3), activation='relu', padding='same')(maxp2)
conv3 = Conv2D(256, (3, 3), activation='relu', padding='same')(conv3)
maxp3 = MaxPooling2D((2, 2))(conv3)

conv4 = Conv2D(512, (3, 3), activation='relu', padding='same')(maxp3)
conv4 = Conv2D(512, (3, 3), activation='relu', padding='same')(conv4)
maxp4 = MaxPooling2D(pool_size=(2, 2))(conv4)

conv5 = Conv2D(1024, (3, 3), activation='relu', padding='same')(maxp4)
conv5 = Conv2D(1024, (3, 3), activation='relu', padding='same')(conv5)

# Capas de deconvolución (expansive path)
up6 = Conv2DTranspose(512, (2, 2), strides=(2, 2), padding='same')(conv5)
up6 = concatenate([up6, conv4])
conv6 = Conv2D(512, (3, 3), activation='relu', padding='same')(up6)
conv6 = Conv2D(512, (3, 3), activation='relu', padding='same')(conv6)

up7 = Conv2DTranspose(256, (2, 2), strides=(2, 2), padding='same')(conv6)
up7 = concatenate([up7, conv3])
conv7 = Conv2D(256, (3, 3), activation='relu', padding='same')(up7)
conv7 = Conv2D(256, (3, 3), activation='relu', padding='same')(conv7)

up8 = Conv2DTranspose(128, (2, 2), strides=(2, 2), padding='same')(conv7)
up8 = concatenate([up8, conv2])
conv8 = Conv2D(128, (3, 3), activation='relu', padding='same')(up8)
conv8 = Conv2D(128, (3, 3), activation='relu', padding='same')(conv8)

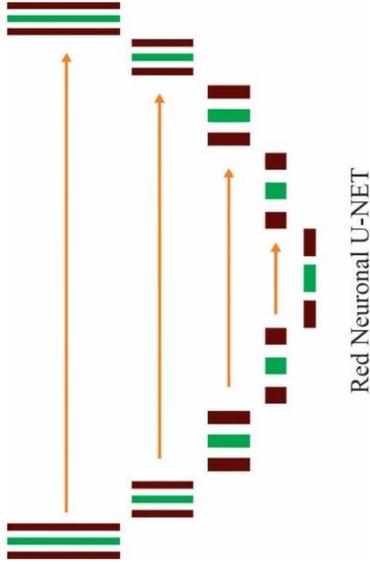
up9 = Conv2DTranspose(64, (2, 2), strides=(2, 2), padding='same')(conv8)
up9 = concatenate([up9, conv1], axis=3)
conv9 = Conv2D(64, (3, 3), activation='relu', padding='same')(up9)
conv9 = Conv2D(64, (3, 3), activation='relu', padding='same')(conv9)

# Capa de salida de la red neuronal U-Net
outputs = Conv2D(1, (1, 1), activation='sigmoid')(conv9)
```



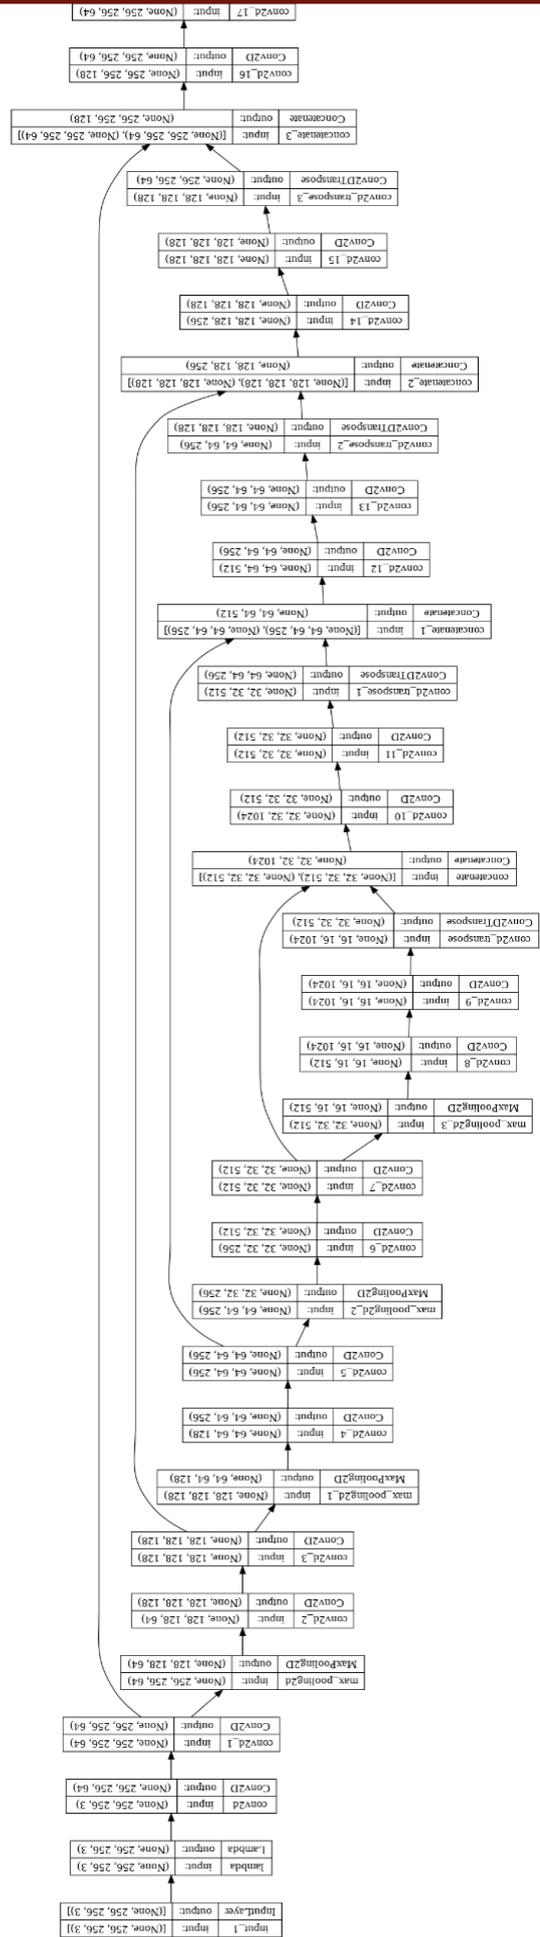
```
model = Model(inputs=[Image_input], outputs=[outputs])  
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])  
model.summary()
```

Anexo 2 Modelo grafico de la Red Neuronal Convocional U-Net y su implementación con Keras de Tensorflow



Red Neuronal U-NET

Compilación del diseño de la red neuronal U-Net para la clasificación y segmentación de la deforestación presente en la Amazonía peruana, diseño creado utilizando la librería Keras de Tensorflow. El mismo que se muestra en Anexo 1 en su forma gráfica, donde se logra visualizar las diferentes capas y funciones de activación utilizadas.



Anexo 3 Modelo de Red Neuronal Convolucional U-Net de la investigación

Model: "model_1"

Layer (type)	Output Shape	Param #	Connected to
input_7 (InputLayer)	[None, 256, 256, 3]	0	[]
lambda_4 (Lambda)	(None, 256, 256, 3)	0	['input_7[0][0]']
conv2d_76 (Conv2D)	(None, 256, 256, 64)	1792	['lambda_4[0][0]']
conv2d_77 (Conv2D)	(None, 256, 256, 64)	36928	['conv2d_76[0][0]']
max_pooling2d_16 (MaxPooling2D)	(None, 128, 128, 64)	0	['conv2d_77[0][0]']
conv2d_78 (Conv2D)	(None, 128, 128, 128)	73856	['max_pooling2d_16[0][0]']
conv2d_79 (Conv2D)	(None, 128, 128, 128)	147584	['conv2d_78[0][0]']
max_pooling2d_17 (MaxPooling2D)	(None, 64, 64, 128)	0	['conv2d_79[0][0]']
conv2d_80 (Conv2D)	(None, 64, 64, 256)	295168	['max_pooling2d_17[0][0]']
conv2d_81 (Conv2D)	(None, 64, 64, 256)	590080	['conv2d_80[0][0]']
max_pooling2d_18 (MaxPooling2D)	(None, 32, 32, 256)	0	['conv2d_81[0][0]']
conv2d_82 (Conv2D)	(None, 32, 32, 512)	1180160	['max_pooling2d_18[0][0]']
conv2d_83 (Conv2D)	(None, 32, 32, 512)	2359808	['conv2d_82[0][0]']
max_pooling2d_19 (MaxPooling2D)	(None, 16, 16, 512)	0	['conv2d_83[0][0]']
conv2d_84 (Conv2D)	(None, 16, 16, 1024)	4719616	['max_pooling2d_19[0][0]']
conv2d_85 (Conv2D)	(None, 16, 16, 1024)	9438208	['conv2d_84[0][0]']
conv2d_transpose_16 (Conv2DTranspose)	(None, 32, 32, 512)	2097664	['conv2d_85[0][0]']
concatenate_16 (Concatenate)	(None, 32, 32, 1024)	0	['conv2d_transpose_16[0][0]', 'conv2d_83[0][0]']
conv2d_86 (Conv2D)	(None, 32, 32, 512)	4719104	['concatenate_16[0][0]']
conv2d_87 (Conv2D)	(None, 32, 32, 512)	2359808	['conv2d_86[0][0]']
conv2d_transpose_17 (Conv2DTranspose)	(None, 64, 64, 256)	524544	['conv2d_87[0][0]']
concatenate_17 (Concatenate)	(None, 64, 64, 512)	0	['conv2d_transpose_17[0][0]', 'conv2d_81[0][0]']
conv2d_88 (Conv2D)	(None, 64, 64, 256)	1179904	['concatenate_17[0][0]']
conv2d_89 (Conv2D)	(None, 64, 64, 256)	590080	['conv2d_88[0][0]']

Layer (type)	Output Shape	Param #	Connected to
conv2d_transpose_18 (Conv2DTranspose)	(None, 128, 128, 128)	131200	['conv2d_89[0][0]']
concatenate_18 (Concatenate)	(None, 128, 128, 256)	0	['conv2d_transpose_18[0][0]', 'conv2d_79[0][0]']
conv2d_90 (Conv2D)	(None, 128, 128, 128)	295040	['concatenate_18[0][0]']
conv2d_91 (Conv2D)	(None, 128, 128, 128)	147584	['conv2d_90[0][0]']
conv2d_transpose_19 (Conv2DTranspose)	(None, 256, 256, 64)	32832	['conv2d_91[0][0]']
concatenate_19 (Concatenate)	(None, 256, 256, 128)	0	['conv2d_transpose_19[0][0]', 'conv2d_77[0][0]']
conv2d_92 (Conv2D)	(None, 256, 256, 64)	73792	['concatenate_19[0][0]']
conv2d_93 (Conv2D)	(None, 256, 256, 64)	36928	['conv2d_92[0][0]']
conv2d_94 (Conv2D)	(None, 256, 256, 1)	65	['conv2d_93[0][0]']

Total params: 31,031,745
Trainable params: 31,031,745
Non-trainable params: 0

Anexo 4 Resultados del entrenamiento de la Red Neuronal Convolucional U-Net de la Investigación

Época de Entrenamiento		Tiempo	Func. Pérdida	Precisión	Eval. Pérdida	Eval. Precisión
Epoch 1/20	94/94	[=====]	loss: 0.4416	accuracy: 0.8190	val_loss: 0.1987	val_accuracy: 0.9190
Epoch 2/20	94/94	[=====]	loss: 0.3249	accuracy: 0.8694	val_loss: 0.1244	val_accuracy: 0.9546
Epoch 3/20	94/94	[=====]	loss: 0.2222	accuracy: 0.9121	val_loss: 0.0628	val_accuracy: 0.9785
Epoch 4/20	94/94	[=====]	loss: 0.1313	accuracy: 0.9446	val_loss: 0.0565	val_accuracy: 0.9749
Epoch 5/20	94/94	[=====]	loss: 0.1020	accuracy: 0.9584	val_loss: 0.0514	val_accuracy: 0.9770
Epoch 6/20	94/94	[=====]	loss: 0.1095	accuracy: 0.9561	val_loss: 0.0939	val_accuracy: 0.9654
Epoch 7/20	94/94	[=====]	loss: 0.1174	accuracy: 0.9524	val_loss: 0.0315	val_accuracy: 0.9882
Epoch 8/20	94/94	[=====]	loss: 0.0578	accuracy: 0.9768	val_loss: 0.0277	val_accuracy: 0.9888
Epoch 9/20	94/94	[=====]	loss: 0.1099	accuracy: 0.9632	val_loss: 0.0690	val_accuracy: 0.9782
Epoch 10/20	94/94	[=====]	loss: 0.0832	accuracy: 0.9691	val_loss: 0.0333	val_accuracy: 0.9867
Epoch 11/20	94/94	[=====]	loss: 0.1031	accuracy: 0.9585	val_loss: 0.0350	val_accuracy: 0.9876
Epoch 12/20	94/94	[=====]	loss: 0.0515	accuracy: 0.9816	val_loss: 0.0248	val_accuracy: 0.9903
Epoch 13/20	94/94	[=====]	loss: 0.1129	accuracy: 0.9610	val_loss: 0.0373	val_accuracy: 0.9857
Epoch 14/20	94/94	[=====]	loss: 0.0507	accuracy: 0.9820	val_loss: 0.0264	val_accuracy: 0.9896
Epoch 15/20	94/94	[=====]	loss: 0.0425	accuracy: 0.9844	val_loss: 0.0246	val_accuracy: 0.9901
Epoch 16/20	94/94	[=====]	loss: 0.0653	accuracy: 0.9742	val_loss: 0.0258	val_accuracy: 0.9899
Epoch 17/20	94/94	[=====]	loss: 0.0649	accuracy: 0.9741	val_loss: 0.0346	val_accuracy: 0.9847
Epoch 18/20	94/94	[=====]	loss: 0.0733	accuracy: 0.9695	val_loss: 0.0307	val_accuracy: 0.9870
Epoch 19/20	94/94	[=====]	loss: 0.0939	accuracy: 0.9593	val_loss: 0.0468	val_accuracy: 0.9790
Epoch 20/20	94/94	[=====]	loss: 0.0458	accuracy: 0.9826	val_loss: 0.0232	val_accuracy: 0.9907

Anexo 5 Código fuente del core (núcleo) del modelo de la red Neuronal Convolutacional U-Net con Dropout

```
# Creamos un modelo U-Net con Dropout
# Definimos la entrada al modelo

inputs = Lambda(lambda x: x / 255)(Input((H, W, 3)))

#contracting path
conv1 = Conv2D(64, (3, 3), activation='relu', padding='same')(inputs)
conv1 = Dropout(0.1)(conv1)
conv1 = Conv2D(64, (3, 3), activation='relu', padding='same')(conv1)
maxp1 = MaxPooling2D((2, 2))(conv1)

conv2 = Conv2D(128, (3, 3), activation='relu', padding='same')(maxp1)
conv2 = Dropout(0.1)(conv2)
conv2 = Conv2D(128, (3, 3), activation='relu', padding='same')(conv2)
maxp2 = MaxPooling2D((2, 2))(conv2)

conv3 = Conv2D(256, (3, 3), activation='relu', padding='same')(maxp2)
conv3 = Dropout(0.2)(conv3)
conv3 = Conv2D(256, (3, 3), activation='relu', padding='same')(conv3)
maxp3 = MaxPooling2D((2, 2))(conv3)

conv4 = Conv2D(512, (3, 3), activation='relu', padding='same')(maxp3)
conv4 = Dropout(0.2)(conv4)
conv4 = Conv2D(512, (3, 3), activation='relu', padding='same')(conv4)
maxp4 = MaxPooling2D(pool_size=(2, 2))(conv4)

conv5 = Conv2D(1024, (3, 3), activation='relu', padding='same')(maxp4)
conv5 = Dropout(0.3)(conv5)
conv5 = Conv2D(1024, (3, 3), activation='relu', padding='same')(conv5)

#expansive path
up6 = Conv2DTranspose(512, (2, 2), strides=(2, 2), padding='same')(conv5)
up6 = concatenate([up6, conv4])
conv6 = Conv2D(512, (3, 3), activation='relu', padding='same')(up6)
conv6 = Dropout(0.2)(conv6)
conv6 = Conv2D(512, (3, 3), activation='relu', padding='same')(conv6)

up7 = Conv2DTranspose(256, (2, 2), strides=(2, 2), padding='same')(conv6)
up7 = concatenate([up7, conv3])
conv7 = Conv2D(256, (3, 3), activation='relu', padding='same')(up7)
conv7 = Dropout(0.2)(conv7)
conv7 = Conv2D(256, (3, 3), activation='relu', padding='same')(conv7)

up8 = Conv2DTranspose(128, (2, 2), strides=(2, 2), padding='same')(conv7)
up8 = concatenate([up8, conv2])
conv8 = Conv2D(128, (3, 3), activation='relu', padding='same')(up8)
```



```
conv8 = Dropout(0.1)(conv8)
conv8 = Conv2D(128, (3, 3), activation='relu', padding='same')(conv8)

up9 = Conv2DTranspose(64, (2, 2), strides=(2, 2), padding='same')(conv8)
up9 = concatenate([up9, conv1], axis=3)
conv9 = Conv2D(64, (3, 3), activation='relu', padding='same')(up9)
conv9 = Dropout(0.1)(conv9)
conv9 = Conv2D(64, (3, 3), activation='relu', padding='same')(conv9)

outputs = Conv2D(1, (1, 1), activation='sigmoid')(conv9)

model = Model(inputs=[inputs], outputs=[outputs])
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
model.summary()
```



Anexo 6 Resultados del entrenamiento de la Red Neuronal Convolutiva U-Net con Dropout

Época de Entrenamiento	Tiempo	Func. Pérdida	Precisión	Eval. Pérdida	Eval. Precisión
Epoch 1/20 94/94 [=====]	111s 959ms/step	loss: 3.1741	accuracy: 0.7892	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 2/20 94/94 [=====]	80s 847ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 3/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 4/20 94/94 [=====]	79s 846ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 5/20 94/94 [=====]	80s 847ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 6/20 94/94 [=====]	79s 846ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 7/20 94/94 [=====]	80s 849ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 8/20 94/94 [=====]	77s 820ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 9/20 94/94 [=====]	79s 844ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 10/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 11/20 94/94 [=====]	79s 846ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 12/20 94/94 [=====]	77s 818ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 13/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 14/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 15/20 94/94 [=====]	79s 846ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 16/20 94/94 [=====]	79s 846ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 17/20 94/94 [=====]	77s 818ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 18/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 19/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602
Epoch 20/20 94/94 [=====]	79s 845ms/step	loss: 3.1775	accuracy: 0.7940	val_loss: 2.1568	val_accuracy: 0.8602

Anexo 7 Predicción de la red neuronal U-Net con las imágenes de prueba (código fuente y las imágenes segmentadas).

```
# Probamos el modelo con alguna imagen de la carpeta Test
preds = model.predict(X_test)
# plt.imshow(preds[1])
plt.imshow(np.squeeze(preds[7]))
# plt.axis('off')
plt.show()
plt.imshow(X_test[7])
# plt.axis('off')
plt.show()
```

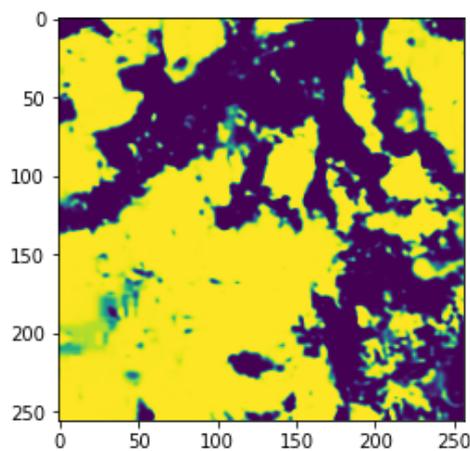


Imagen segmentada por la red neuronal U-Net

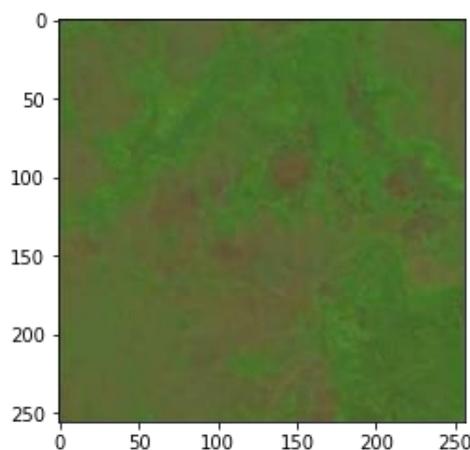


Imagen de entrada (test) de la red neuronal U-Net



DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo PABLO CESAR TAPIA CATACTORA,
identificado con DNI 40270043 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

CIENCIAS DE LA COMPUTACIÓN

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:
“ DETECCIÓN DE DEFORESTACIÓN DE BOSQUES EN IMÁGENES SATELITALES CON REDES NEURONALES

CONVOLUCIONALES

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno tres de agosto del 20 23



FIRMA (obligatoria)



Huella



AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo PABLO CESAR TAPIA CATACORA,
identificado con DNI 40270043 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

CIENCIAS DE LA COMPUTACIÓN

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ DETECCIÓN DE DEFORESTACIÓN DE BOSQUES EN IMÁGENES SATELITALES CON REDES

NEURONALES CONVOLUCIONALES ”

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno tres de agosto del 2023


FIRMA (obligatoria)



Huella