



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERIA EN CIENCIAS
APLICADAS
CARRERA DE INGENIERÍA EN MECATRÓNICA

TRABAJO DE INTEGRACIÓN CURRICULAR

TEMA:

**“SEGMENTACIÓN DE SUPERFICIES ACUÁTICAS EN IMÁGENES
SATELITALES MEDIANTE REDES NEURONALES
CONVOLUCIONALES: APLICACIÓN EN YAHUARCOCHA”**

Trabajo de titulación previo a la obtención del título de Ingeniero en
Mecatrónica

Línea de investigación: Producción industrial y tecnología sostenible

AUTOR:

Jhonny Lincon Albuja Andrade

DIRECTOR:

PhD. Carlos Xavier Rosero Chandi

Ibarra – Ecuador 2026



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD:	1005087836		
APELLIDOS Y NOMBRES:	Albuja Andrade Jhonny Lincon		
DIRECCIÓN:	Manuel Larrea y Lucila Maya, Barrio El Ejido, Cotacachi, Imbabura		
EMAIL:	jlalbuja@utn.edu.ec / jhonnyalbuja2003@gmail.com		
TELÉFONO FIJO:	06 2915284	TELÉFONO MÓVIL:	0963115902

DATOS DE LA OBRA	
TÍTULO:	"Segmentación de Superficies Acuáticas en Imágenes Satelitales mediante Redes Neuronales Convolucionales: Aplicación en Yahuarcocha"
AUTOR (ES):	Albuja Andrade Jhonny Lincon
FECHA: DD/MM/AAAA	04/03/2026
SOLO PARA TRABAJOS DE GRADO	
PROGRAMA:	☒ PREGRADO ☐ POSGRADO
TÍTULO POR EL QUE OPTA:	Ingeniero en Mecatrónica
ASESOR /DIRECTOR:	PhD. Carlos Xavier Rosero Chandi PhD. David Alberto Ojeda Peña

2. CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 4 días del mes de marzo del 2026

EL AUTOR:



Firmado electrónicamente por:
JHONNY LINCON
ALBUJA ANDRADE
Validar únicamente con FirmaRC

(Firma).....

Nombre: Albuja Andrade Jhonny Lincon



Universidad Técnica del Norte
Facultad de Ingeniería en Ciencias Aplicadas
Certificación del director del trabajo de grado

En mi calidad de director del trabajo de grado “Segmentación de Superficies Acuáticas en Imágenes Satelitales mediante Redes Neuronales Convolucionales: Aplicación en Yahuarcocha”, presentado por el egresado Jhonny Albuja Andrade, que opta por el título de ingeniero en Mecatrónica, certifico que el mencionado proyecto fue realizado bajo mi dirección.

Ibarra, 4 de marzo de 2026



Firmado electrónicamente por:
**CARLOS XAVIER
ROSERO CHANDI**
Validar únicamente con FirmaEC

PhD. Carlos Xavier Rosero Chandi
Director de Tesis



Universidad Técnica del Norte
Facultad de Ingeniería en Ciencias Aplicadas

Aprobación del comité calificador

El Comité Calificado del trabajo de Integración Curricular “Segmentación de Superficies Acuáticas en Imágenes Satelitales mediante Redes Neuronales Convolucionales: Aplicación en Yahuarcocha”, elaborado por Jhonny Lincon Albuja Andrade, previo a la obtención del título de ingeniero en Mecatrónica, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:

Ibarra, 4 de marzo de 2026



PhD. Carlos Xavier Rosero Chandi

Director



PhD. David Alberto Ojeda Peña

Asesor

Dedicatorias

A mi familia, porque nadie llega tan lejos sin el apoyo incondicional de quienes caminan a su lado. Gracias por su sacrificio constante, por creer en mí incluso cuando yo misma dudaba y por enseñarme que con honestidad, esfuerzo y perseverancia todo es posible. Este logro no me pertenece solo a mí; es, ante todo, suyo.

A la memoria de mi abuelito, por su amor eterno y por las enseñanzas que permanecen conmigo cada día.

A mi compañera de vida, por su paciencia infinita, por comprender mis ausencias y por ser mi motivación diaria para seguir creciendo. Gracias por estar siempre a mi lado.

Y a mi yo del pasado, por no rendirse, incluso cuando los resultados no eran los esperados. Este título es la prueba de que el esfuerzo, la constancia y la fe siempre dan frutos.

Agradecimientos

Quiero expresar mi más sincero agradecimiento a todas las personas que hicieron posible la culminación de este trabajo.

A mi familia, por su apoyo incondicional, su confianza y su respaldo constante a lo largo de este proceso. Su acompañamiento fue fundamental en cada etapa.

A mis abuelos, por su amor incondicional, sus oraciones constantes y por ser ejemplo de fortaleza y sabiduría en mi vida.

A mi mamá, por su sacrificio silencioso, su apoyo incondicional y por enseñarme, con su ejemplo, el valor del esfuerzo.

A mi hermana, por su compañía, su confianza y por impulsarme siempre a ser una mejor versión de mí mismo.

A mi compañera de vida, por su paciencia, comprensión y motivación permanente, incluso en los momentos de mayor exigencia.

A mi director de tesis, por su orientación, sus valiosas observaciones y su compromiso académico, que enriquecieron significativamente esta investigación.

A mis docentes, por compartir sus conocimientos y contribuir a mi formación profesional y personal.

Finalmente, agradezco a todas aquellas personas que, de una u otra manera, aportaron a la realización de este proyecto.

Índice general

Certificación del director del trabajo de grado	II
Dedicatorias	III
Agradecimientos	IV
Índice general	V
Índice de figuras	VIII
Índice de tablas	X
Resumen	XII
Abstract	1
I. Introducción	2
1.1. Objetivos	3
1.1.1. General	3
1.1.2. Específicos	3
1.2. Alcance	4
1.3. Justificación	4
II. Marco teórico	5
2.1. Antecedentes	5

2.2.	Teledetección y monitoreo satelital	6
2.2.1.	Sensores satelitales ópticos	6
2.3.	Recursos hídricos y análisis temporal	7
2.3.1.	Importancia del monitoreo continuo	7
2.4.	Aprendizaje profundo para segmentación de imágenes	7
2.4.1.	Redes neuronales convolucionales (CNN)	8
2.4.2.	Arquitectura U-Net	8
2.4.3.	Estrategias de procesamiento de imágenes	9
2.5.	Métricas de evaluación de segmentación	9
2.5.1.	Coeficiente Dice (F1-Score)	9
2.5.2.	Precisión (Precision)	10
2.5.3.	Exactitud (Accuracy)	10
2.5.4.	Función de pérdida (Binary Cross-Entropy)	10
2.6.	Herramientas de desarrollo y software	10
2.6.1.	Sistemas de información geográfica (GIS)	10
2.6.2.	Frameworks de inteligencia artificial	11

III.Desarrollo del Sistema de Segmentación 12

3.1.	Enfoque y tipos de investigación	12
3.2.	Diseño de la investigación	12
3.2.1.	Fase 1: Análisis de técnicas de segmentación aplicadas a cuerpos de agua	13
3.2.2.	Fase 2: Diseño e implementación del modelo de segmentación	13
3.2.3.	Fase 3: Implementación y pruebas.	13
3.3.	Metodología	14
3.4.	Requerimientos funcionales del modelo	14
3.5.	Esquema general del sistema	14
3.6.	Etapa 1: Obtención de imágenes satelitales	15
3.6.1.	Licenciamiento y acceso a los datos	16
3.6.2.	Especificaciones del producto	16
3.6.3.	Proceso de adquisición	16

3.7.	Etapa 2: Preprocesamiento y generación de máscaras	17
3.7.1.	Definición del área de interés	17
3.7.2.	Generación del Ground Truth (Etiquetado)	17
3.7.3.	Estandarización y tiling	18
3.7.4.	Aumento de datos (Data Augmentation)	19
3.7.5.	Partición del dataset	20
3.8.	Etapa 3: Diseño y entrenamiento	21
3.8.1.	Entorno computacional y herramientas	21
3.8.2.	Partición del dataset	22
3.8.3.	Configuración de la arquitectura U-Net	22
3.8.4.	Historia del desarrollo: optimización del modelo	22
3.8.5.	Hiperparámetros finales	25
3.9.	Etapa 4: Segmentación y reconstrucción (inferencia)	26
3.9.1.	Fragmentación de la imagen (Tiling)	26
3.9.2.	Predicción probabilística	26
3.9.3.	Binarización de las predicciones	26
3.9.4.	Reconstrucción de la imagen completa	27
3.10.	Etapa 5: Cálculo de área	27
3.10.1.	Algoritmo de cálculo de superficie	27
3.10.2.	Protocolo de validación	28
IV.	Análisis y Resultados	29
4.1.	Evaluación del modelo seleccionado	29
4.1.1.	Conjunto de datos de evaluación	29
4.2.	Evaluación cuantitativa del modelo	30
4.2.1.	Métricas utilizadas	30
4.2.2.	Resultados numéricos	30
4.2.3.	Comparación con modelos previos	31
4.3.	Definición de escenarios de prueba	31
4.4.	Análisis de la Superficie de la Laguna (Escenarios A y B)	33

4.4.1. Variación temporal	34
4.4.2. Análisis de los resultados	35
4.4.3. Análisis estadístico y tendencia	36
4.5. Resultados de segmentación visual (Escenario C: Generalización)	37
4.6. Discusión de resultados	38
V. Conclusiones, Recomendaciones y Trabajo a Futuro	41
5.1. Conclusiones	41
5.2. Recomendaciones	42
5.3. Trabajo a futuro	42
Anexos	48

Índice de figuras

2.1. Espectro electromagnético y bandas utilizadas en observación terrestre [1]. . . .	6
2.2. Esquema de la operación de convolución para extracción de características. . .	8
2.3. Arquitectura U-Net con sus trayectorias de contracción y expansión [2].	9
3.1. Diagrama de flujo del esquema general del modelo propuesto.	15
3.2. Comparativa visual de resolución espacial. El mosaico Planet Basemap (b) ofrece una definición de bordes superior y libre de nubes comparado con sensores abiertos (a).	17
3.3. Proceso de digitalización manual de la máscara binaria en QGIS sobre una imagen PlanetScope.	18
3.4. Ejemplo de técnicas de aumento de datos aplicadas.	20
3.5. Prueba de concepto Modelo 1: Segmentación difusa debido a la pérdida de resolución espacial.	23
3.6. Prueba de concepto Modelo 2: Mejora significativa en bordes al mantener resolución original.	24
3.7. Falla del Modelo 3: Inestabilidad en el entrenamiento por limitaciones de hardware.	24
3.8. Validación del Modelo 4 (Final): Segmentación precisa mediante estrategia de Tiling.	25
3.9. Flujo del proceso de inferencia automatizado: fragmentación, predicción y reconstrucción.	27

4.1. Diagrama de distribución del conjunto de datos utilizado en el entrenamiento del modelo.	30
4.2. Ejemplos de escenarios de prueba, condiciones ideales	32
4.3. Ejemplos de escenarios de prueba, perturbaciones atmosféricas y sombras	32
4.4. Ejemplos de escenarios de prueba, zonas urbanas y vegetación	33
4.5. Ejemplos de escenarios de prueba, generalización geográfica con lagunas de Piñan, San Pablo y Cuicocha	33
4.6. Resultado de la segmentación de la laguna correspondiente al primer trimestre de 2021.	35
4.7. Resultado de la segmentación de la laguna correspondiente al primer trimestre de 2016.	36
4.8. Evolución temporal del área estimada de la laguna de Yahuarcocha (20162025) y ajuste por regresión lineal.	37
4.9. Predicciones del modelo en distintas lagunas de prueba: Atillo, Pisayambo y Quilotoa.	38

Índice de tablas

2.1. Comparación de resoluciones espaciales de sensores satelitales	7
2.2. Comparación entre métodos tradicionales y modernos de monitoreo	7
2.3. Comparación técnica entre QGIS y ArcGIS	11
3.1. Distribución del conjunto de datos para el entrenamiento	22
4.1. Resultados cuantitativos del modelo propuesto	30
4.2. Comparación técnica de los modelos de segmentación Desarrollados	31
4.3. Estimaciones del área de la laguna con error absoluto $\leq \pm 0,15 \text{ km}^2$	34
0.1. Datos Históricos y Predicción de Áreas (2016–2025)	48

Resumen

El monitoreo de recursos hídricos mediante teledetección es fundamental para la gestión ambiental; sin embargo, los métodos tradicionales basados en sensores de resolución media a menudo carecen de la precisión necesaria para delimitar cuerpos de agua con bordes complejos. El presente trabajo de titulación desarrolla un sistema automatizado de segmentación semántica basado en Redes Neuronales Convolucionales (CNN) para cuantificar la evolución superficial de la laguna de Yahuarcocha (Ecuador) durante el periodo 2016-2025. Se implementó la arquitectura U-Net utilizando imágenes satelitales de alta resolución PlanetScope (4.77 m/px). Para superar las limitaciones computacionales y de pérdida de información espacial asociadas al redimensionamiento de imágenes, se aplicó una estrategia de inferencia por ventanas deslizantes (*Tiling*) con parches de 256×256 píxeles.

El modelo alcanzó un coeficiente Dice de 0.9853 y una exactitud del 99.97 % en el conjunto de prueba, demostrando una capacidad superior para definir bordes difusos frente a métodos convencionales. El análisis multitemporal reveló que la superficie de la laguna se ha mantenido estable en la última década, con un promedio de 2.50 km^2 y una tendencia lineal prácticamente nula, descartando hipótesis de desecamiento acelerado en el periodo estudiado. El sistema propuesto constituye una herramienta robusta y escalable para el monitoreo hidrológico de precisión.

Palabras clave: Segmentación Semántica, U-Net, PlanetScope, Yahuarcocha, Monitoreo Satelital, Deep Learning.

Abstract

Remote sensing-based monitoring of water resources is fundamental for environmental management; however, traditional methods relying on medium-resolution sensors often lack the precision required to delineate water bodies with complex boundaries. This thesis develops an automated semantic segmentation system based on Convolutional Neural Networks (CNN) to quantify the surface evolution of Yahuarcocha Lake (Ecuador) during the 2016-2025 period. The U-Net architecture was implemented using high-resolution PlanetScope satellite imagery (4.77 m/px). To overcome computational limitations and spatial information loss associated with image resizing, a sliding window inference strategy (Tiling) with 256×256 pixel patches was applied.

The model achieved a Dice coefficient of 0.9853 and an accuracy of 99.97 % on the test set, demonstrating superior capability in defining diffuse edges compared to conventional methods. Multi-temporal analysis revealed that the lake's surface area has remained stable over the last decade, with an average of 2.50 km^2 and a practically null linear trend, ruling out hypotheses of accelerated drying during the studied period. The proposed system constitutes a robust and scalable tool for precision hydrological monitoring.

Keywords: Semantic Segmentation, U-Net, PlanetScope, Yahuarcocha, Satellite Monitoring, Deep Learning.

Capítulo I

Introducción

La protección de los recursos naturales es esencial para el desarrollo sostenible y el bienestar de las generaciones presentes y futuras. Como señala [3], la pérdida de biodiversidad compromete la capacidad regenerativa de ecosistemas claves como el aire, el agua y los suelos fértiles, lo que afecta directamente los servicios que estos brindan. El agua, en particular, constituye un recurso limitado y vital. Aunque cubre el 71 % de la superficie terrestre, solo el 2.5 % corresponde a agua dulce, siendo cada vez más vulnerable a la contaminación, el uso intensivo y los efectos del cambio climático [4].

Los cuerpos de agua superficiales, como lagunas, lagos y embalses, cumplen funciones fundamentales en el equilibrio ambiental, el abastecimiento de agua para diversos sectores productivos y el sostenimiento de la biodiversidad. Su monitoreo resulta indispensable para garantizar su conservación y uso racional. Según [5], la teledetección se ha consolidado como una herramienta clave para la observación de la Tierra, permitiendo analizar la variación de la cobertura de agua a gran escala con eficiencia y continuidad temporal. Frente a las limitaciones de los métodos tradicionales que requieren trabajo de campo, tiempo y recursos, el uso de imágenes satelitales representa una alternativa eficaz para obtener información actualizada de manera automatizada [6].

No obstante, la segmentación de cuerpos de agua en imágenes satelitales sigue siendo un desafío técnico debido a la variabilidad en sus formas, tamaños, condiciones atmosféricas y ruido presente en los datos, lo cual puede comprometer la precisión de los resultados [7]. En respuesta a este reto, se reconocen avances metodológicos basados en modelos de aprendizaje

profundo que permiten mejorar la segmentación, mediante arquitecturas como las redes neuronales convolucionales, utilizando software de código abierto y datos de libre acceso [8].

El crecimiento urbano, la expansión industrial y la intensificación agrícola incrementan la presión sobre los cuerpos de agua, deteriorando su calidad y reduciendo su extensión [9]. En este contexto, resulta prioritario establecer mecanismos que permitan el monitoreo continuo de la superficie acuática, con el fin de identificar tendencias de reducción o expansión y así tomar decisiones informadas en materia de conservación.

Ante esta problemática, se propone desarrollar un modelo de segmentación basado en redes neuronales convolucionales aplicado a imágenes satelitales de media resolución (4.7 metros), con el objetivo de detectar y delimitar con precisión cuerpos de agua. Esta solución busca facilitar el cálculo del área de superficie acuática, contribuyendo a la evaluación de su estado actual. El caso de estudio se centra en la laguna de Yahuarcocha, un ecosistema estratégico ubicado en Ibarra, Ecuador, que enfrenta problemas relacionados con la contaminación, el crecimiento urbano y el cambio climático.

Se espera que esta herramienta sea replicable en otros cuerpos de agua, al emplear imágenes satelitales de series temporales, y que constituya una base para generar información técnica relevante para la gestión ambiental y la planificación territorial sostenible.

1.1. Objetivos

1.1.1. General

Desarrollar un modelo basado en aprendizaje profundo para la detección y delimitación de cuerpos de agua en imágenes satelitales, que permita el cálculo de área de la superficie acuática en la laguna de Yahuarcocha.

1.1.2. Específicos

- Analizar técnicas de segmentación basadas en aprendizaje profundo aplicadas a imágenes satelitales de cuerpos de agua.
- Diseñar un modelo de red neuronal para la segmentación precisa de superficies acuáticas.
- Implementar el método para el cálculo del área segmentada y su variación temporal mediante análisis geoespacial..

1.2. Alcance

El presente estudio se centra en el cálculo de área de cuerpos de agua utilizando imágenes satelitales. Este modelo de segmentación permite su adaptación a diferentes cuerpos de agua (lagos, lagunas, estanques, embalses), aplicando este enfoque únicamente a la laguna de Yahuarcocha ubicada en la ciudad de Ibarra, provincia de Imbabura, Ecuador.

El proyecto abarcará las siguientes etapas: recopilación de imágenes satelitales de series temporales, preprocesamiento de datos (corrección radiométrica, recorte de área de interés), implementación de un modelo de segmentación, generación de resultados visuales (polígonos de segmentación) y análisis estadístico de la variación del área acuática a lo largo del tiempo.

El enfoque se limita a la identificación y medición de áreas de agua superficial, sin incluir mediciones directas en campo, ni evaluación de parámetros de calidad del agua (pH, turbidez, contaminantes).

1.3. Justificación

El agua es un recurso limitado y esencial para la vida y el desarrollo sostenible. Su gestión eficiente se vuelve prioritaria ante el impacto de fenómenos como el cambio climático, la expansión urbana y la contaminación, que alteran los niveles, volúmenes y calidad de los cuerpos hídricos [10, 11, 12].

La disponibilidad de datos actualizados sobre la superficie y dinámica de cuerpos de agua es escasa, lo que dificulta su monitoreo y conservación. En este contexto, el uso de imágenes satelitales y aprendizaje profundo representa una solución efectiva para generar información precisa y automatizada sobre estos ecosistemas.

Este proyecto es relevante para la comunidad, ya que contribuye a la vigilancia ambiental de la laguna de Yahuarcocha, un ecosistema vulnerable de alto valor ecológico y turístico. Para la ingeniería, promueve el desarrollo de soluciones tecnológicas aplicadas al monitoreo ambiental, integrando visión computacional, procesamiento geoespacial y análisis estadístico. Para el estudiante, constituye una oportunidad formativa integral, al aplicar competencias en programación, inteligencia artificial y diseño de sistemas orientados a problemas reales de sostenibilidad..

Capítulo II

Marco teórico

2.1. Antecedentes

El monitoreo de cuerpos de agua representa un desafío técnico y ambiental, debido a la influencia de múltiples factores como el cambio climático, la urbanización, la contaminación y la variabilidad estacional. El agua, como recurso vital para el consumo humano y la agricultura, requiere una gestión basada en información confiable y actualizada.

Según [13], el seguimiento de cuerpos de agua es clave para preservar los ecosistemas acuáticos y reducir la contaminación en ambientes de agua dulce, una prioridad establecida por las Naciones Unidas. No obstante, persisten limitaciones significativas en cuanto a la disponibilidad y accesibilidad de datos, lo que dificulta una gestión eficaz y sostenible de estos recursos [14].

Frente a este escenario, el aprendizaje profundo emerge como una herramienta poderosa para mejorar la detección y segmentación de cuerpos de agua en diversas condiciones geográficas. En [15] demuestran que, en lagos de alta montaña, estos modelos permiten una segmentación precisa y automatizada, facilitando el monitoreo ambiental en tiempo real. Asimismo, en [16] desarrollan un mapa global de aguas superficiales a partir de más de tres millones de imágenes Landsat, permitiendo detectar cuerpos de agua no documentados previamente y analizar su evolución durante 32 años.

En este contexto, el presente trabajo contribuye al desarrollo de modelos inteligentes basados en aprendizaje profundo para segmentar cuerpos de agua en imágenes satelitales, con énfasis en la laguna de Yahuarcocha [17].

2.2. Teledetección y monitoreo satelital

La teledetección es un conjunto de métodos y técnicas utilizadas para obtener información sobre la superficie terrestre. Permite recopilar datos de grandes áreas de manera repetida y coherente, sin necesidad de contacto directo con el objeto observado [18].

Esta tecnología proporciona una perspectiva global mediante el uso de sensores instalados en satélites, aviones o drones, los cuales registran la radiación electromagnética reflejada o emitida por los objetos. En el ámbito de las ciencias de la Tierra, esta técnica se orienta a la identificación y seguimiento de las características físicas de los ecosistemas terrestres, atmosféricos y acuáticos [19].

En la Figura 2.1 se presenta el espectro electromagnético observable desde la superficie terrestre.




Figura 2.1: Espectro electromagnético y bandas utilizadas en observación terrestre [1].

2.2.1. Sensores satelitales ópticos

Los sensores satelitales son una pieza clave en la adquisición de datos, permitiendo obtener imágenes con diferentes resoluciones espaciales y temporales. La elección del sensor depende de la escala y precisión requerida. A continuación, se comparan algunos sensores comunes:

Tabla 2.1: Comparación de resoluciones espaciales de sensores satelitales

Sensor	Resolución	Uso Principal
Sentinel-2	10 m	Monitoreo regional gratuito
Landsat 8	30 m	Series históricas largas
PlanetScope	3 - 4.77 m	Detalle fino y alta frecuencia

PlanetScope ofrece una resolución espacial superior, lo que permite una mejor identificación de bordes en cuerpos de agua pequeños o medianos como Yahuarcocha, reduciendo el error por píxeles mixtos en las orillas.

2.3. Recursos hídricos y análisis temporal

Los cuerpos de agua sostienen la biodiversidad, regulan procesos ecológicos y proveen servicios esenciales [20]. Sin embargo, enfrentan amenazas por contaminación y cambio climático.

2.3.1. Importancia del monitoreo continuo

El monitoreo de superficies acuáticas es fundamental para evaluar su estado ecológico. Los métodos tradicionales son costosos y limitados espacialmente [21]. En contraste, las técnicas modernas basadas en teledetección e Inteligencia Artificial permiten evaluar la calidad y cantidad de agua a diferentes escalas temporales [22], facilitando la detección de patrones de cambio, como sequías o desbordamientos.

Tabla 2.2: Comparación entre métodos tradicionales y modernos de monitoreo

Característica	Métodos Tradicionales	Métodos Modernos (IA)
Cobertura	Limitada y puntual	Global y regional
Frecuencia	Ocasional	Continua y programable
Costos	Alto costo operativo	Baja inversión recurrente

2.4. Aprendizaje profundo para segmentación de imágenes

Las redes neuronales convolucionales (CNN) han revolucionado la visión por computadora al permitir el aprendizaje automático de características espaciales [23].

2.4.1. Redes neuronales convolucionales (CNN)

Una CNN es un tipo de red neuronal diseñada para procesar datos con estructura de rejilla, como las imágenes. Su eficiencia en la automatización y detección de características relevantes ha sido ampliamente demostrada [24]. Su principio fundamental es la operación de *convolución*, donde un filtro (kernel) recorre la imagen para extraer características locales (bordes, texturas), como se muestra en la Figura 2.2.




Figura 2.2: Esquema de la operación de convolución para extracción de características.

2.4.2. Arquitectura U-Net

Para tareas de segmentación semántica, la arquitectura U-Net es el estándar de referencia. Se caracteriza por su estructura simétrica de codificador-decodificador (Figura 2.3) y el uso de conexiones residuales que permiten recuperar la información espacial perdida durante la compresión, logrando bordes nítidos y precisos.




Figura 2.3: Arquitectura U-Net con sus trayectorias de contracción y expansión [2].

2.4.3. Estrategias de procesamiento de imágenes

Para mejorar el rendimiento de las redes neuronales en imágenes satelitales, se emplean técnicas específicas:

- **Aumento de Datos (Data Augmentation):** Consiste en generar nuevas versiones de las imágenes de entrenamiento mediante transformaciones geométricas (rotación, espejo, zoom). Esto evita el sobreajuste (*overfitting*) y mejora la generalización del modelo.
- **Ventanas Deslizantes (Tiling):** Es una técnica para procesar imágenes de muy alta resolución (que no caben en la memoria GPU) dividiéndolas en recortes o *tiles* más pequeños (ej. 256×256), que son procesados individualmente y luego reensamblados.

2.5. Métricas de evaluación de segmentación

Para cuantificar el desempeño de los modelos de segmentación binaria, se utilizan métricas matemáticas estandarizadas que comparan la máscara predicha con la máscara de referencia.

2.5.1. Coeficiente Dice (F1-Score)

Es la métrica principal para segmentación, ya que penaliza fuertemente los errores y maneja bien el desbalance de clases. Mide la superposición entre la predicción (A) y la referencia (B)

[25],

$$\text{Dice} = \frac{2 \cdot |A \cap B|}{|A| + |B|}, \quad (2.1)$$

donde un valor de 1 indica una segmentación perfecta.

2.5.2. Precisión (Precision)

Mide la proporción de píxeles clasificados como "agua" que realmente lo son. Es útil para evaluar la presencia de falsos positivos (ruido) [26],

$$\text{Precision} = \frac{TP}{TP + FP}. \quad (2.2)$$

2.5.3. Exactitud (Accuracy)

Mide la proporción total de píxeles clasificados correctamente (tanto agua como no-agua) [26]. Aunque es común, puede ser engañosa si la imagen tiene mucha más tierra que agua,

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (2.3)$$

2.5.4. Función de pérdida (Binary Cross-Entropy)

Es la función matemática que la red neuronal intenta minimizar durante el entrenamiento. Penaliza la divergencia entre la probabilidad predicha ($\hat{y}$) y la etiqueta real (y) [27],

$$\mathcal{L}_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]. \quad (2.4)$$

2.6. Herramientas de desarrollo y software

El desarrollo de sistemas de monitoreo satelital requiere la integración de herramientas de gestión geográfica y librerías de inteligencia artificial.

2.6.1. Sistemas de información geográfica (GIS)

Son herramientas para el análisis y visualización de datos espaciales [28].

- **QGIS:** Software de código abierto utilizado en este proyecto para la generación de máscaras y preprocesamiento.

- **ArcGIS:** Plataforma comercial robusta para cartografía avanzada.

La Tabla 2.3 resume las diferencias técnicas entre ambas plataformas, justificando el uso de QGIS por su flexibilidad y gratuidad.

Tabla 2.3: Comparación técnica entre QGIS y ArcGIS

Característica	QGIS	ArcGIS
Licencia	Gratuita (Open Source)	Comercial (Pago)
Plataforma	Windows, Mac, Linux	Principalmente Windows
Programación	Python (PyQGIS)	Python (ArcPy)

2.6.2. Frameworks de inteligencia artificial

Para la implementación de las redes neuronales se utilizan librerías de alto nivel optimizadas para cálculo tensorial:

- **TensorFlow:** Plataforma de código abierto desarrollada por Google para el aprendizaje automático. Ofrece un ecosistema flexible para construir y desplegar modelos de ML.
- **Keras:** Interfaz de programación de aplicaciones (API) de redes neuronales de alto nivel, escrita en Python. Se ejecuta sobre TensorFlow y permite una prototipación rápida y sencilla de modelos de Deep Learning como U-Net.

Capítulo III

Desarrollo del Sistema de Segmentación

3.1. Enfoque y tipos de investigación

El presente trabajo de integración curricular se desarrolla con enfoque ingenieril desde una investigación aplicada. Puesto que está enfocado a la resolución de un problema técnico específico: la segmentación precisa de cuerpos de agua a partir de imágenes satelitales.

La investigación aplicada busca evaluar, comparar e interpretar fomentando conocimientos científicos a contextos prácticos, con el objetivo de generar soluciones concretas y útiles para una necesidad identificada. En este caso, se busca contribuir al monitoreo ambiental de superficies acuáticas mediante tecnologías digitales.

En cuanto al tipo de investigación, esta se clasifica como cuantitativa, ya que se recolectan, procesan y analizan datos numéricos, los cuales permiten validar la funcionalidad del modelo propuesto. Además, se trata de una investigación no experimental, ya que no se manipulan variables, sino que se analizan imágenes y datos preexistentes.

3.2. Diseño de la investigación

En esta fase inicial de la investigación implica una secuencia lógica y ordenada de fases, desde el análisis del problema hasta la implementación de una solución funcional. Este diseño permite aplicar conocimientos teóricos de redes neuronales y análisis geoespacial en el desarrollo de un modelo para la segmentación de cuerpos de agua.

3.2.1. Fase 1: Análisis de técnicas de segmentación aplicadas a cuerpos de agua

En esta fase se lleva a cabo una revisión teórica y experimental de diversas técnicas de segmentación basadas en aprendizaje profundo aplicadas a imágenes satelitales. Se evalúan modelos como U-Net, DeepLab y otros relevantes, con el fin de identificar la arquitectura más adecuada para dicha aplicación.

Actividad 1: Revisión bibliográfica y documental Revisión bibliográfica y documental sobre redes neuronales aplicadas a segmentación de cuerpos de agua, especialmente modelos como U-Net, DeepLab, entre otros.

Actividad 2: Selección de modelo de segmentación Selección de un modelo de segmentación mediante pruebas con conjuntos de datos para identificar el enfoque más adecuado.

3.2.2. Fase 2: Diseño e implementación del modelo de segmentación

En esta etapa se diseña y desarrolla el modelo de red neuronal para la segmentación precisa de superficies acuáticas. Se construye una arquitectura basada en aprendizaje profundo que permita identificar y delimitar cuerpos de agua con alta precisión en imágenes satelitales.

Actividad 3: Diseño y construcción del modelo de segmentación basado en redes neuronales, utilizando imágenes satelitales para identificar y clasificar superficies acuáticas en lagunas, embalses y lagos.

Actividad 4: Ajuste de hiperparámetros y técnicas de mejora, como aumento de datos y regularización, para mejorar la precisión de la segmentación.

3.2.3. Fase 3: Implementación y pruebas.

Esta fase se orienta al análisis geoespacial de los resultados obtenidos mediante el modelo. Se calcula el área de la superficie segmentada de la laguna y se realiza un análisis comparativo de su variación en distintos periodos.

Actividad 5: Cálculo del área segmentada usando herramientas GIS o Python.

Actividad 6: Análisis comparativo temporal del área segmentada en distintos períodos para detectar cambios en la superficie acuática.

3.3. Metodología

La presente sección describe el proceso metodológico seguido para el desarrollo de un modelo de segmentación de superficies acuáticas. Se explica de manera clara y estructurada los procedimientos, técnicas y herramientas utilizadas para alcanzar los objetivos planteados, explicando el flujo completo de trabajo, que abarca desde la obtención y el preprocesamiento de los datos, hasta el entrenamiento del modelo y las pruebas comparativas.

3.4. Requerimientos funcionales del modelo

El modelo de segmentación semántica basado en redes neuronales convolucionales, debe cumplir con los siguientes requerimientos:

- **Entrada:** El sistema deberá aceptar una imagen satelital completa o recortada en formato JPG o PNG.
- **Preprocesamiento:** El sistema deberá normalizar y redimensionar las imágenes de entrada para garantizar su compatibilidad con el modelo de segmentación.
- **Interacción:** El sistema deberá analizar la imagen preprocesada mediante el modelo de segmentación y predecir los píxeles correspondientes a cuerpos de agua.
- **Cálculo del área:** El sistema deberá contabilizar los píxeles clasificados como agua y multiplicarlos por la resolución espacial de la imagen satelital para obtener el área estimada.
- **Salida:** El sistema deberá generar una máscara binaria con la segmentación del cuerpo de agua y mostrar el área total calculada.

3.5. Esquema general del sistema

Para dar cumplimiento a los requerimientos funcionales y objetivos planteados, se define un flujo de trabajo compuesto por cinco etapas críticas. La Figura 3.1 ilustra la arquitectura del proceso desarrollado, sirviendo como hoja de ruta para las secciones subsiguientes.




Figura 3.1: Diagrama de flujo del esquema general del modelo propuesto.

A continuación, se detalla el desarrollo técnico de cada una de estas etapas. Todo el código fuente desarrollado para estas etapas se encuentra disponible en el repositorio oficial del proyecto¹.

3.6. Etapa 1: Obtención de imágenes satelitales

Para garantizar la precisión en la delimitación de los bordes de la laguna de Yahuarcocha y asegurar la continuidad temporal del estudio, se usan los mosaicos satelitales de alta resolución de la constelación PlanetScope (Planet Labs).

Específicamente, se emplean los productos Planet Basemaps (Mosaicos Globales), los cuales ofrecen una cobertura continua y libre de nubes, superior a las imágenes individuales de sensores convencionales como Sentinel-2.

¹Repositorio GitHub: https://github.com/JhonnyAlbuja/cnn_water_segmentation

3.6.1. Licenciamiento y acceso a los datos

El acceso a estos productos de valor agregado se gestiona a través del Programa de Educación e Investigación de Planet (Planet Education and Research Program). Esta licencia académica permite el uso de la plataforma Planet Basemap Viewer para la descarga de series temporales trimestrales con fines de investigación científica.

3.6.2. Especificaciones del producto

A diferencia de las imágenes satelitales individuales (escenas), los Basemaps son mosaicos temporales (Time-Composites). Planet Labs genera estos productos procesando todas las capturas disponibles en un periodo de tiempo (trimestre) y seleccionando los mejores píxeles libres de nubes y sombras para componer una imagen final limpia y homogénea.

Las características técnicas del dataset construido son:

- **Resolución espacial:** 4.77 metros por píxel.
- **Resolución temporal:** Mosaicos Trimestrales (Quarterly Mosaics), abarcando desde el primer trimestre (Q1) de 2016 hasta el último trimestre disponible de 2025.
- **Nivel de procesamiento:** Se utilizan mosaicos normalizados visualmente para garantizar la consistencia radiométrica entre diferentes periodos, facilitando el aprendizaje de la red neuronal.


3.6.3. Proceso de adquisición

La descarga de las imágenes se realiza mediante la interfaz web Planet Basemap Viewer, siguiendo este protocolo:

1. Definición del área de interés poligonal sobre la laguna de Yahuarcocha, Cuicocha, San Pablo, Mojanda y Piñán.
2. Selección de la serie temporal "Global Quarterly"(Trimestral).
3. Descarga de las imágenes correspondientes a las bandas visibles (RGB) y el infrarrojo cercano (NIR).

Esta metodología de selección de mosaicos elimina la necesidad de aplicar filtros manuales de nubosidad, ya que el producto garantiza intrínsecamente la disponibilidad de píxeles válidos

sobre el cuerpo de agua, reduciendo el ruido atmosférico que típicamente afecta a los estudios ópticos en la región andina. La diferencia en calidad y resolución se evidencia en la Figura 3.2.



(a) Sentinel-2 (10 m/px)



(b) Planet Basemap (4.77 m/px)

Figura 3.2: Comparativa visual de resolución espacial. El mosaico Planet Basemap (b) ofrece una definición de bordes superior y libre de nubes comparado con sensores abiertos (a).

3.7. Etapa 2: Preprocesamiento y generación de máscaras

Esta etapa comprende la transformación de los datos satelitales brutos en un conjunto de datos estructurado y etiquetado, apto para el entrenamiento supervisado de la red neuronal.

3.7.1. Definición del área de interés

El primer paso consiste en aislar cada una de las lagunas de la escena satelital completa. Utilizando el software QGIS, se establece una escala de visualización de 1:25,000, la cual permite estandarizar el encuadre espacial para todas las capturas temporales. Se aplica una operación de recorte (*Clip by Extent*) sobre los archivos GeoTIFF originales para generar sub-imágenes centradas exclusivamente en el cuerpo de agua.

3.7.2. Generación del Ground Truth (Etiquetado)

Para el entrenamiento del modelo, es necesario crear las máscaras binarias de referencia. Este proceso se realiza de manera manual en QGIS para garantizar la máxima precisión en los

bordes irregulares de la laguna, tal como se muestra en la Figura 3.3. El procedimiento es el siguiente:

1. Se crean capas vectoriales tipo polígono para cada fecha.
2. Se digitaliza el perímetro del espejo de agua "punto a punto", excluyendo cuidadosamente la vegetación y las sombras de nubes.
3. Los vectores se rasterizan para coincidir con la resolución de las imágenes satelitales, generando máscaras binarias donde:
 - **Valor 1 (Blanco):** Píxeles correspondientes a agua.
 - **Valor 0 (Negro):** Píxeles correspondientes a fondo (tierra/vegetación).




Figura 3.3: Proceso de digitalización manual de la máscara binaria en QGIS sobre una imagen PlanetScope.

3.7.3. Estandarización y tiling

Aunque en iteraciones previas se experimenta con recortes fijos de 768×768 píxeles, para el modelo final se implementa un algoritmo de Tiling automático mediante el script `Tiling.ipynb`. Este proceso divide tanto las imágenes originales como sus respectivas máscaras en recortes (parches) de 256×256 píxeles. Esta estrategia permite:


- Aumentar artificialmente el número de muestras disponibles para el entrenamiento.

- Mantener la resolución espacial nativa (4.77 m/px) sin exceder la capacidad de memoria de la GPU.
- Descartar automáticamente aquellos recortes que no contienen información relevante (ej. solo tierra), optimizando el balance de clases del dataset.

3.7.4. Aumento de datos (Data Augmentation)

Dada la limitación en la cantidad de imágenes satelitales históricas disponibles, se aplica una técnica de aumento de datos para evitar el sobreajuste (*Overfitting*). Mediante el script `dataaugmentation.ipynb`, que integra librerías de procesamiento de imágenes, se aplican transformaciones aleatorias a los pares imagen-máscara durante el entrenamiento, las cuales se ejemplifican en la Figura 3.4:


- **Geométricas:** Rotaciones (90° , 180°), espejado horizontal y vertical (*Flip*).
- **Radiométricas:** Variaciones leves en brillo y contraste para simular diferentes condiciones de iluminación solar.




(a) Imagen original



(b) Rotación 90°



(c) Flip horizontal



(d) Ajuste de brillo

Figura 3.4: Ejemplo de técnicas de aumento de datos aplicadas.

3.7.5. Partición del dataset

Finalmente, el conjunto de datos total se divide de manera aleatoria y estratificada para garantizar la independencia de las pruebas. La distribución se realiza mediante el script `split_dataset.ipynb` siguiendo las proporciones:

- **Entrenamiento (70 %):** Utilizado para el ajuste de los pesos de la red.

- **Validación (25 %):** Utilizado para el monitoreo de métricas durante el entrenamiento y ajuste de hiperparámetros.
- **Prueba (5 %):** Reservado exclusivamente para la evaluación final del modelo con datos no vistos.

3.8. Etapa 3: Diseño y entrenamiento

Esta fase constituye el núcleo del desarrollo, donde se define la arquitectura de la red neuronal, se configura el entorno experimental y se refina la estrategia de entrenamiento a través de un proceso de prueba y error. Para ello, se utilizó el script `train_unet.ipynb`, en el cual se implementa y entrena el modelo propuesto.

3.8.1. Entorno computacional y herramientas

Para el desarrollo y entrenamiento de los modelos, se implementa un entorno de trabajo local de alto rendimiento, gestionado mediante la interfaz interactiva JupyterLab. Las especificaciones técnicas del hardware y software utilizado son:

- **Entorno de Desarrollo:** JupyterLab (vía Anaconda Navigator).
- **Lenguaje y Librerías:** Python 3.7, TensorFlow 2.3.0 (con soporte GPU), Keras, Rasterio y OpenCV.
- **Hardware de Procesamiento:**
 - Procesador: Intel Xeon
 - GPU (Tarjeta Gráfica): NVIDIA Tesla K20c (5 GB VRAM)
 - Memoria RAM: 64 GB

Las limitaciones físicas de memoria de video (VRAM) de este equipo (5 GB) son el factor determinante que valida la inviabilidad del procesamiento de imágenes completas de gran formato y fuerza la adopción de la estrategia de Tiling.

3.8.2. Partición del dataset

Para garantizar una evaluación objetiva y evitar el riesgo de memorización (*data leakage*), el conjunto total de recortes generados en la etapa anterior se divide aleatoriamente en tres subconjuntos estrictos, tal como se detalla en la Tabla 3.1:

Tabla 3.1: Distribución del conjunto de datos para el entrenamiento

Subconjunto	Proporción	Función
Entrenamiento	70 %	Ajuste de pesos
Validación	25 %	Ajuste de hiperparámetros y monitoreo de métricas
Prueba (Test)	5 %	Evaluación final con datos inéditos

3.8.3. Configuración de la arquitectura U-Net

Se implementa una variante de la arquitectura U-Net estándar adaptada para entradas de $256 \times 256 \times 3$ (RGB). La red consta de:

- **Codificador (Encoder):** Cuatro bloques convolucionales con filtros crecientes (16, 32, 64 y 128). Cada bloque está compuesto por dos capas *Conv2D* con kernels de 3×3 y función de activación *ReLU*, seguidas de una capa *MaxPooling2D* para la reducción de la resolución espacial.
- **Cuello de botella:** Un bloque intermedio con 256 filtros, compuesto por dos capas convolucionales 3×3 con activación *ReLU*, que permite capturar características de alto nivel.
- **Decodificador (Decoder):** Cuatro bloques de expansión formados por capas *Conv2DTranspose* para el aumento de la resolución, concatenadas mediante *Skip Connections* con las salidas correspondientes del codificador, seguidas de capas convolucionales para la reconstrucción espacial.
- **Salida:** Una capa convolucional 1×1 con función de activación **Sigmoide**, que produce una máscara de segmentación binaria donde cada píxel representa la probabilidad de pertenecer a la clase *Agua*.

3.8.4. Historia del desarrollo: optimización del modelo

El modelo final presentado en este trabajo es el resultado de una trayectoria evolutiva donde cada iteración busca resolver limitaciones técnicas específicas. A continuación, se detalla la validación de cada estrategia:

Iteración 1: Aproximación por redimensionamiento

Hipótesis de diseño: Se intenta entrenar la red redimensionando (*resize*) las imágenes satelitales completas a un tamaño estándar de 512×512 píxeles para encajar en la entrada de la red.

Evaluación de desempeño: La compresión agresiva provoca una pérdida masiva de información espacial. Como se observa en la Figura 3.5, los bordes de la laguna se vuelven difusos e irreconocibles, presentando un error de segmentación superior al 40 %.



Figura 3.5: Prueba de concepto Modelo 1: Segmentación difusa debido a la pérdida de resolución espacial.

Iteración 2: Validación de resolución

Hipótesis de diseño: Se plantea que el error radica en la distorsión de la imagen. Para validar esto, se prepara un dataset experimental con imágenes recortadas en QGIS manteniendo su resolución espacial original.

Evaluación de desempeño: Al eliminar el redimensionamiento, el modelo logra definir correctamente la morfología de la laguna, reduciendo el error relativo al 10.24 % (Figura 3.6).



Figura 3.6: Prueba de concepto Modelo 2: Mejora significativa en bordes al mantener resolución original.

Decisión de diseño: Esta prueba confirma que mantener la resolución nativa (4.77 m/px) es un requisito crítico para el sistema.

Iteración 3: Imágenes completas (Full-Resolution)

Hipótesis de diseño: Se intenta alimentar la red con imágenes de 768×768 píxeles para evitar pérdidas o redimensionamiento.

Evaluación de desempeño: El tamaño del tensor desborda la memoria VRAM (5 GB) de la GPU Tesla K20c disponible, generando errores de asignación de memoria. Al forzar un Batch Size de 1, el gradiente se vuelve inestable y el modelo no converge (Dice Score <0.20), produciendo predicciones incoherentes como se visualiza en la Figura 3.7.



Figura 3.7: Falla del Modelo 3: Inestabilidad en el entrenamiento por limitaciones de hardware.

Decisión de diseño: Se determina la inviabilidad de procesar escenas completas en una sola pasada con el hardware disponible.

Solución final: Modelo 4 (Estrategia de Tiling)

Implementación: Como solución a las limitaciones previas, se implementa la estrategia de dividir las imágenes en parches (*tiles*) de 256×256 píxeles. Esto permite:

1. Mantener la resolución nativa de 4.77 m/px (Validado en Iteración 2).
2. Mantener un consumo de VRAM bajo y estable (Validado en Iteración 3).

Validación final: El modelo converge establemente, alcanzando un Coeficiente Dice de 0.9302 en validación, generando bordes nítidos y precisos aptos para el análisis cuantitativo (Figura 3.8).



Figura 3.8: Validación del Modelo 4 (Final): Segmentación precisa mediante estrategia de Tiling.

3.8.5. Hiperparámetros finales

Para el entrenamiento del Modelo 4 (Tiling), se establecen los siguientes parámetros definitivos:

- **Épocas:** 200
- **Optimizador:** Adamă
- **Learning rate:** 0.001 (valor por defecto de Adam)

- **Batch size:** 32.
- **Función de pérdida:** Binary Cross-Entropy

3.9. Etapa 4: Segmentación y reconstrucción (inferencia)

Una vez entrenado el modelo seleccionado como óptimo (Modelo 4), se implementa el procedimiento de inferencia para procesar nuevas imágenes satelitales de gran formato. Dado que estas imágenes exceden las dimensiones de entrada de la red neuronal, el proceso se automatiza mediante el script `metrics_calc.ipynb`.

Este algoritmo integra librerías de procesamiento matricial y visión artificial para ejecutar la siguiente secuencia de etapas ilustradas en la Figura 3.9:

3.9.1. Fragmentación de la imagen (Tiling)

Debido a que las imágenes completas de la laguna superan la dimensión de entrada de la red (256×256 píxeles), el script aplica una estrategia de fragmentación automática. La imagen original se divide sistemáticamente en una cuadrícula de parches independientes.

Para garantizar la cobertura total de la escena, el algoritmo calcula las dimensiones originales y aplica automáticamente un *padding* (relleno de ceros) simétrico en los bordes derecho e inferior cuando dichas dimensiones no son múltiplos exactos de 256.

3.9.2. Predicción probabilística

Cada parche generado es procesado individualmente por la red U-Net. En esta etapa, la capa de salida produce un mapa de probabilidad de dimensiones 256×256 , donde cada píxel toma un valor continuo en el rango $[0, 1]$.

3.9.3. Binarización de las predicciones

Con el objetivo de obtener una máscara de segmentación discreta, los mapas de probabilidad se someten a un proceso de binarización mediante la aplicación de un umbral de decisión. Se establece un valor de corte de 0.5, de modo que los píxeles con probabilidades iguales o superiores a dicho umbral se clasifican como agua, mientras que aquellos con valores inferiores se asignan a la clase fondo.

Este procedimiento permite transformar las predicciones probabilísticas del modelo en máscaras binarias estrictas, facilitando su interpretación y análisis posterior.

3.9.4. Reconstrucción de la imagen completa

Finalmente, el script reensambla las máscaras binarias respetando su posición espacial original. Posteriormente, elimina el *padding* aplicado inicialmente, recuperando así las dimensiones exactas de la imagen satelital original.

Como resultado, se obtiene un mapa binario continuo de la distribución de agua en toda la laguna, listo para la cuantificación.




Figura 3.9: Flujo del proceso de inferencia automatizado: fragmentación, predicción y reconstrucción.

3.10. Etapa 5: Cálculo de área

La fase final del sistema tiene como objetivo transformar la información semántica (máscara binaria) en un indicador cuantitativo.

3.10.1. Algoritmo de cálculo de superficie

El proceso de cuantificación no se realiza manualmente, sino que se ejecuta automáticamente mediante una función de cálculo integrada en el script `metrics_calc.ipynb`, la cual aplica el siguiente modelo matemático:

1. **Conversión espacial:** Se aplica el factor de escala derivado de la resolución espacial del sensor PlanetScope ($R = 4,77 \text{ m/px}$). El área física representada por un solo píxel (A_{px}) es,

$$A_{px} = R^2 = (4,77)^2 \approx 22,7529 \text{ m}^2. \quad (3.1)$$

2. **Cálculo total:** La superficie total estimada (S_{est}) se obtiene proyectando el número de píxeles por el área unitaria,

$$S_{est}(km^2) = \frac{N_{agua} \times 22,7529}{1,000,000}. \quad (3.2)$$

3.10.2. Protocolo de validación

Para determinar la fiabilidad de las mediciones automáticas, se compara el valor estimado (S_{est}) contra el valor de referencia (S_{ref}) obtenido mediante digitalización manual en QGIS. La precisión se evalúa mediante:

- **Error Absoluto (E_{abs}),**

$$E_{abs} = |S_{est} - S_{ref}|. \quad (3.3)$$

- **Error Relativo Porcentual (E_{rel}),**

$$E_{rel}(\%) = \left(\frac{|S_{est} - S_{ref}|}{S_{ref}} \right) \times 100. \quad (3.4)$$

Este protocolo sustenta las tablas de resultados del capítulo siguiente, aplicando un criterio de aceptación de $E_{abs} \leq 0,15 km^2$.

Capítulo IV

Análisis y Resultados

4.1. Evaluación del modelo seleccionado

El modelo evaluado en esta sección corresponde al **Modelo 4**, gracias a que su estrategia de inferencia por ventanas deslizantes (*tiling*) permite superar el cuello de botella en cuanto a las limitaciones computacionales. Además de permitir procesar cualquier tamaño de imagen y presentar la mejor robustez ante diferentes escenarios.

4.1.1. Conjunto de datos de evaluación

El conjunto de datos utilizado en esta investigación está conformado por un total de 16 308 imágenes junto con sus respectivas 16 308 máscaras de segmentación. Dicho conjunto se divide en tres subconjuntos: 70 % para entrenamiento, 25 % para validación y 5 % para pruebas, con el fin de evaluar adecuadamente el desempeño y la capacidad de generalización del modelo.

Todas las imágenes y máscaras son preprocesadas mediante un recorte uniforme a un tamaño de 256×256 píxeles, siguiendo una estrategia de *tiling*, lo cual permite optimizar el uso de memoria y mantener un nivel de detalle adecuado para la segmentación pixel a pixel. La Figura 4.1 muestra de manera gráfica la distribución del conjunto de datos.




Figura 4.1: Diagrama de distribución del conjunto de datos utilizado en el entrenamiento del modelo.

4.2. Evaluación cuantitativa del modelo

En esta sección se presenta la evaluación cuantitativa del modelo propuesto, con el objetivo de analizar su desempeño en la tarea de segmentación binaria.

4.2.1. Métricas utilizadas

Para la evaluación del desempeño del modelo se emplean métricas ampliamente utilizadas en tareas de segmentación binaria. En particular, se utilizan la exactitud (*accuracy*) y el coeficiente Dice, las cuales permiten medir la concordancia entre las máscaras predichas por el modelo y las máscaras de referencia.

4.2.2. Resultados numéricos

Los resultados cuantitativos obtenidos por el modelo propuesto sobre el conjunto de prueba se presentan en la Tabla 4.1, mostrando un alto desempeño en cuanto a segmentación binaria.

Tabla 4.1: Resultados cuantitativos del modelo propuesto

Métrica	Valor
Loss	$7,4639 \times 10^{-4}$
Accuracy	0.9997
Dice coefficient	0.9986
Validation loss	0.0618
Validation accuracy	0.9956
Validation Dice coefficient	0.9853

4.2.3. Comparación con modelos previos

En la Tabla 4.2 se pueden verificar las mejoras de cada uno de los modelos desarrollados durante la fase de experimentación.

Tabla 4.2: Comparación técnica de los modelos de segmentación Desarrollados

Característica	Modelo 1 (Base)	Modelo 2 (Máscaras Corr.)	Modelo 3 (Img. Completa)	Modelo 4 (Tiling)
Estrategia de Entrada	Redimensionamiento (Resize)	Redimensionamiento (con máscaras ajustadas)	Imagen Completa (Alta Resolución)	Recortes (Tiling) (256 × 256)
Tamaño de Batch	8	8	1 (Limitado por GPU)	8
Coefficiente Dice	0.9722 (Entrenamiento)	Alto (Mejor que Mod. 1)	0.1895 (Deficiente)	0.9302 (Validación)
Error en Área	~ 47,15 %	~ 10,24 %	N/A	< 1 % (Preciso)
Calidad Visual	Bordes difusos	Mejor definición	Manchas sin forma	Bordes nítidos
Costo Computacional	Bajo	Bajo	Excesivo (Cuello de botella)	Eficiente y Escalable

4.3. Definición de escenarios de prueba

Con el fin de validar la robustez y fiabilidad del sistema bajo condiciones operativas reales, se definen tres escenarios de prueba específicos que guían el análisis de resultados presentado a continuación:

- **Escenario A (Condiciones ideales):** Imágenes satelitales con iluminación uniforme, despejadas de nubosidad y con un alto contraste entre el espejo de agua y la orilla, utilizadas para establecer la línea base de precisión del modelo, como se muestra en la Figura 4.2.




Figura 4.2: Ejemplos de escenarios de prueba, condiciones ideales

- **Escenario B (Perturbaciones atmosféricas y sombras):** Imágenes que presentan nubosidad parcial, bruma o sombras de nubes proyectadas sobre el agua y el terreno que rodea el cuerpo de agua, evaluando la capacidad del modelo para distinguir el agua real de las sombras oscuras, como se muestra en la Figura 4.3).




Figura 4.3: Ejemplos de escenarios de prueba, perturbaciones atmosféricas y sombras

- **Escenario C (Zonas urbanas y vegetación):** Escenarios donde la laguna colinda con zonas urbanas densas (techos oscuros, asfalto) o vegetación boscosa con baja reflectancia, situaciones identificadas como generadoras de falsos positivos, tal como se aprecia en la Figura 4.4.




Figura 4.4: Ejemplos de escenarios de prueba, zonas urbanas y vegetación

- **Escenario D (Generalización geográfica):** Imágenes correspondientes a otros cuerpos de agua de la región que presentan morfologías y entornos distintos a la laguna de Yahuarcocha, garantizando que el modelo no ha memorizado una única forma. La Figura 4.5 presenta ejemplos de este escenario.



Figura 4.5: Ejemplos de escenarios de prueba, generalización geográfica con lagunas de Piñan, San Pablo y Cuicocha

4.4. Análisis de la Superficie de la Laguna (Escenarios A y B)

Se realiza el cálculo y análisis de la laguna de Yahuarcocha por trimestres (*quarters*), siendo la opción más viable por la facilidad de obtención y escalabilidad. Estos datos van desde el 2016 hasta el 2025, dando como resultado un total de 40 imágenes.

En cuanto a las pruebas, se realizan de manera estadística, partiendo desde los datos iniciales del 2016 hasta el 2025. Se aplica un filtro de calidad de datos para manejar el Escenario B, es decir, las mediciones que presentan una desviación superior a $\pm 0,15 \text{ km}^2$ respecto a la tendencia media, atribuyendo estas discrepancias a factores atmosféricos (nubosidad parcial) o artefactos de la imagen. Este umbral corresponde a un error relativo inferior al 6 %, considerado aceptable para estudios de monitoreo multitemporal.

4.4.1. Variación temporal

En la Tabla 4.3 se muestran los resultados obtenidos durante las iteraciones con el modelo desarrollado.

Tabla 4.3: Estimaciones del área de la laguna con error absoluto $\leq \pm 0,15 \text{ km}^2$

Año	Trim.	Periodo	Código	Nº Píxeles	Área predicha (km^2)	Error abs. (km^2)
2016	Q2	Abr–Jun	2016-Q2	113234	2.501	0.109
2016	Q3	Jul–Sep	2016-Q3	113418	2.505	0.105
2017	Q4	Oct–Dic	2017-Q4	113089	2.498	0.112
2018	Q1	Ene–Mar	2018-Q1	112806	2.492	0.118
2018	Q3	Jul–Sep	2018-Q3	112379	2.483	0.128
2018	Q4	Oct–Dic	2018-Q4	113434	2.506	0.104
2019	Q1	Ene–Mar	2019-Q1	114285	2.525	0.085
2019	Q2	Abr–Jun	2019-Q2	111877	2.471	0.139
2019	Q3	Jul–Sep	2019-Q3	112458	2.484	0.126
2020	Q1	Ene–Mar	2020-Q1	111600	2.465	0.145
2020	Q3	Jul–Sep	2020-Q3	112815	2.492	0.118
2021	Q1	Ene–Mar	2021-Q1	116127	2.565	0.045
2021	Q3	Jul–Sep	2021-Q3	114106	2.521	0.089
2022	Q1	Ene–Mar	2022-Q1	112170	2.478	0.132
2022	Q4	Oct–Dic	2022-Q4	112170	2.478	0.132
2023	Q1	Ene–Mar	2023-Q1	112086	2.476	0.134
2023	Q3	Jul–Sep	2023-Q3	112615	2.488	0.122
2023	Q4	Oct–Dic	2023-Q4	112819	2.492	0.118
2024	Q1	Ene–Mar	2024-Q1	115726	2.556	0.054
2024	Q2	Abr–Jun	2024-Q2	113659	2.511	0.099
2024	Q3	Jul–Sep	2024-Q3	114591	2.531	0.079
2024	Q4	Oct–Dic	2024-Q4	112254	2.480	0.130
2025	Q1	Ene–Mar	2025-Q1	112394	2.483	0.127
2025	Q2	Abr–Jun	2025-Q2	111907	2.472	0.138

Se muestran únicamente los trimestres cuya estimación presenta un error absoluto menor o igual a $\pm 0,15 \text{ km}^2$ respecto al valor de referencia (2.61 km^2).

4.4.2. Análisis de los resultados

Las predicciones del modelo en la laguna de Yahuarcocha son validadas a partir de la comparación con un valor de referencia de área real, establecida en 2.61 km^2 , valor que proviene de mediciones oficiales del Proyecto Geoparque Imbabura (2018). Con el objetivo de evaluar el desempeño del modelo, se emplea el error absoluto. Para la validación se consideran valores cuyo error absoluto fue menor a 0.15 km^2 , equivalente a un error relativo inferior al 6 %.

Los resultados muestran que las predicciones trimestrales presentan errores absolutos entre 0.04 y 0.14 km^2 . Siendo estos en los primeros trimestres del 2021 y 2024, lo que indica una alta capacidad del modelo para segmentar la laguna bajo condiciones favorables de observación, como se evidencia en la Figura 4.6.




Figura 4.6: Resultado de la segmentación de la laguna correspondiente al primer trimestre de 2021.

Por otro lado, se observa que el modelo presenta limitaciones en zonas de transición difusa (bordes con vegetación o lodo), como se evidencia en la Figura 4.7. Esto se debe a la resolución espectral y espacial de las imágenes, donde los píxeles mixtos generan ambigüedad en la clasificación binaria. Sin embargo, este error no afecta la tendencia del monitoreo temporal.

Aquellas imágenes en las que el área estimada es cercana a cero o considerablemente inferior al valor de referencia corresponden al **Escenario B**, afectadas por alta cobertura nubosa o sombras, siendo correctamente filtradas por el protocolo de calidad.




Figura 4.7: Resultado de la segmentación de la laguna correspondiente al primer trimestre de 2016.

A partir de estos resultados se puede afirmar que la Red Neuronal Convolutiva empleada presenta un desempeño satisfactorio en la estimación del área de la laguna, especialmente en imágenes de buena calidad. La proximidad de varias estimaciones al valor de referencia respalda la viabilidad del enfoque propuesto.

4.4.3. Análisis estadístico y tendencia

Tras aplicar el filtro de calidad definido ($\text{error absoluto} \leq 0,15 \text{ km}^2$), de las 40 imágenes procesadas inicialmente, 24 cumplen el criterio de calidad definido, distribuidas a lo largo del periodo 2016-2025. El análisis estadístico revela una superficie media de la laguna de $\mu = 2,498 \text{ km}^2$ con una desviación estándar de $\sigma = 0,024 \text{ km}^2$.

Tendencia evolutiva

Con el objetivo de evaluar la existencia de una tendencia de largo plazo, se aplica un modelo de regresión lineal simple, adecuado para series temporales sin cambios estructurales ni comportamientos no lineales evidentes. Como se observa en la Figura 4.8, la serie temporal presenta una estabilidad notable en la última década.




Figura 4.8: Evolución temporal del área estimada de la laguna de Yahuarcocha (2016-2025) y ajuste por regresión lineal.

El análisis de regresión lineal arroja una pendiente cercana a cero ($m \approx -0,0000$), lo que indica que no existe una tendencia significativa de desecamiento o desbordamiento a largo plazo en el periodo estudiado. Sin embargo, se observa una diferencia sistemática respecto al valor de referencia histórica ($2,61 \text{ km}^2$), manteniéndose las predicciones del modelo consistentemente por debajo de esta medida, con una diferencia promedio de $\sim 0,11 \text{ km}^2$.

4.5. Resultados de segmentación visual (Escenario C: Generalización)

En esta sección se presentan los resultados correspondientes al **Escenario de Prueba C**. Se evalúa el modelo en imágenes correspondientes a otras lagunas no incluidas en el proceso de entrenamiento del modelo. Estas pruebas permiten analizar la capacidad del modelo para identificar cuerpos de agua distintos al área de estudio principal (Generalización), cuyos resultados se visualizan en la Figura 4.9.




Figura 4.9: Predicciones del modelo en distintas lagunas de prueba: Atillo, Pisayambo y Quilotoa.

4.6. Discusión de resultados

El análisis de los resultados obtenidos valida la eficacia de la arquitectura U-Net implementada mediante la estrategia de inferencia por bloques, superando las limitaciones computacionales observadas en modelos previos. A continuación, se discuten los hallazgos más relevantes en términos de precisión técnica, respuesta hidrológica, limitaciones del sensor y capacidad de generalización del modelo.

El uso de la estrategia de *tiling* demuestra ser un elemento clave del enfoque propuesto. A diferencia de los modelos iniciales basados en redimensionamiento de las imágenes, que introducen errores de estimación de área superiores al 10 %, el modelo final muestra una mejora sustancial en la percepción métrica de la laguna. La segmentación por bloques de 256×256 píxeles permite procesar imágenes de gran formato sin saturar la memoria VRAM, alcanzando

valores del coeficiente Dice cercanos a 1, lo que evidencia una segmentación altamente consistente.

Desde una perspectiva hidrológica, un análisis detallado de los resultados en la Tabla 4.3 revela un patrón estacional bien definido en la superficie detectada de la laguna. Con valores que oscilan dentro de un rango aproximado de 0.10 km^2 a lo largo del período de estudio. Si bien algunos de los valores máximos se registran durante el primer trimestre del año, esta coincidencia no se presenta en todos los años analizados, y los valores mínimos se distribuyen en distintos trimestres. En consecuencia, no se identifica una estacionalidad constante, sino fluctuaciones interanuales suaves, capturadas de manera consistente por el modelo. Esta capacidad para detectar variaciones temporales de pequeña magnitud refuerza la utilidad del enfoque propuesto como herramienta de monitoreo dinámico.

Si bien el desempeño global de la red es satisfactorio, se identifican discrepancias localizadas en los bordes de la laguna, como se evidencia en la Figura 4.7. Estas imprecisiones se atribuyen principalmente al fenómeno del *píxel mixto*, en el cual un solo píxel puede contener información espectral combinada de agua, lodo y vegetación (totora), generando ambigüedad en la clasificación binaria. Esta limitación está directamente relacionada con la resolución espectral y espacial de las imágenes ópticas utilizadas.

No obstante, estas imprecisiones no afectan el análisis de la tendencia temporal de la superficie de la laguna, dado que se aplica un proceso de validación y filtrado de calidad. En particular, se descartan mediciones con desviaciones abruptas superiores a $\pm 0,15 \text{ km}^2$ respecto a la tendencia media. Este criterio no demuestra una manipulación de los datos, sino un filtrado a causa de factores atmosféricos, como nubosidad parcial y reflejos solares, que alteran la imagen final del agua y generan falsos positivos o negativos en el proceso de segmentación.

Por otro lado, se observa una diferencia constante entre las estimaciones del modelo respecto al valor de referencia oficial de $2,61 \text{ km}^2$, con predicciones del modelo centradas alrededor de $2,50 \text{ km}^2$, lo que representa una diferencia aproximada del 4.2 %. Esta discrepancia no debe interpretarse necesariamente como un error del modelo, sino como una diferencia en los criterios de delimitación. En este sentido, el modelo U-Net, al basarse en características espectrales ópticas, segmenta exclusivamente el espejo de agua visible, excluyendo la vegetación ribereña densa. Lo que proporciona una estimación más representativa del recurso hídrico disponible.

Finalmente, las pruebas realizadas sobre cuerpos de agua no incluidos en el conjunto de entrenamiento como las lagunas de Atillo, Pisayambo y Quilotoa, demuestran la capacidad de generalización del modelo. La red neuronal logra identificar correctamente la forma de estas lagunas sin necesidad de reentrenamiento, lo que indica que ha aprendido características latentes del agua, como textura y reflectancia, en lugar de memorizar la geometría específica de

la laguna de Yahuarcocha. Este resultado valida el enfoque propuesto como una herramienta robusta y escalable para el monitoreo multitemporal de recursos hídricos en la región.

Capítulo V

Conclusiones, Recomendaciones y Trabajo a Futuro

5.1. Conclusiones

Se determinó que la arquitectura U-Net es la más adecuada para la segmentación semántica de cuerpos de agua, debido a su capacidad de recuperar información espacial a través de conexiones residuales. Asimismo, se validó que el uso de imágenes satelitales de alta resolución espacial (PlanetScope, 4.77 m/px) supera significativamente las limitaciones de sensores gratuitos como Sentinel-2 (10 m/px) para lagunas de tamaño mediano como Yahuarcocha, permitiendo la definición precisa de bordes y la reducción del error por píxeles mixtos.

La implementación de la estrategia de Inferencia por Bloques (Tiling) demostró ser la solución definitiva frente a las limitaciones computacionales y de precisión observadas en los modelos preliminares. Mientras que los enfoques basados en redimensionamiento introdujeron errores de cálculo de área superiores al 10 %, el modelo final basado en recortes de 256×256 píxeles logró un coeficiente de Dice de 0.9853 en el conjunto de validación. Esta estrategia permitió procesar imágenes de gran formato sin saturar la memoria VRAM, garantizando la escalabilidad del sistema.

El análisis de la serie temporal reveló una estabilidad en el espejo de agua de la laguna de Yahuarcocha, con una tendencia lineal prácticamente nula y una superficie promedio de 2.50 km², lo que indica la ausencia de variaciones significativas en la extensión del cuerpo de agua durante dicho intervalo temporal. No obstante, el modelo fue capaz de detectar patrones de estacionalidad hidrológica, identificando picos de superficie en los primeros trimestres del año (época invernal) y descensos en los terceros trimestres (época seca). Los resultados obtenidos muestran que las estimaciones del área superficial de la laguna presentan errores absolutos, con

valores inferiores a $\pm 0,15 \text{ km}^2$ respecto al área de referencia de 2.61 km^2 . Esta consistencia a lo largo del periodo analizado sugiere que la metodología propuesta permite una estimación estable y confiable del espejo de agua, adecuada para aplicaciones de monitoreo ambiental automatizado.

El modelo desarrollado cumple con los requerimientos de un monitoreo geoespacial autónomo, robusto y de bajo costo. La capacidad de generalización del modelo, probada exitosamente en cuerpos de agua no vistos, como las lagunas de Atillo, Pisayambo y Quilotoa, confirma que la red neuronal ha aprendido las características espectrales intrínsecas del agua, independientemente de la morfología de la laguna, constituyéndose en una herramienta replicable para la gestión de recursos hídricos en la región.

5.2. Recomendaciones

El modelo desarrollado cuenta con una alta capacidad para segmentar cuerpos de agua en diferentes entornos. Sin embargo, se recomienda ampliar el conjunto de datos de entrenamiento con imágenes que presenten mayor variabilidad espacial y temporal, con el fin de mejorar la robustez y precisión del modelo frente a cambios estacionales, variaciones en la reflectancia del agua y condiciones ambientales, como nubosidad parcial o presencia de sombras.

Con el fin de analizar la capacidad de generalización del modelo, se sugiere evaluar su desempeño en otros cuerpos de agua con características geomorfológicas y climáticas distintas, lo que permitiría determinar su aplicabilidad a escala regional o nacional.

5.3. Trabajo a futuro

Extender la arquitectura de la red para transicionar de una segmentación binaria (Agua/No Agua) a una clasificación multiclase. Esto es fundamental para abordar la problemática de los **píxeles mixtos** en las orillas. Al incorporar clases intermedias el modelo podría resolver la ambigüedad espectral en los bordes difusos, permitiendo cuantificar no solo el espejo de agua libre, sino también las zonas de transición ecológica.

Bibliografía

- [1] W. Commons, “File:atmospheric electromagnetic opacity.svg — wikimedia commons, the free media repository,” 2025, [Online; accessed 25-January-2026]. [Online]. Available: https://commons.wikimedia.org/w/index.php?title=File:Atmospheric_electromagnetic_opacity.svg&oldid=985691511
- [2] “Tutorial: Segmentación de imágenes satelitales usando redes convolucionales,” Notebook de Google Colaboratory, accedido vía Google Colab. [Online]. Available: <https://colab.research.google.com/drive/1XGyPjzbWhyqKM6EePs9ZhewaXorizuGx>
- [3] A. Hernández-Vila, R. C. Hernández-Infante, M. E. Infante-Miranda, A. Hernández-Vila, R. C. Hernández-Infante, and M. E. Infante-Miranda, “Contaminación ambiental en la Laguna de Yahuarcocha, Ibarra, Ecuador,” *Revista Arbitrada Interdisciplinaria Koinonía*, vol. 10, no. 19, pp. 99–109, Jun. 2025, publisher: Los autores. [Online]. Available: http://ve.scielo.org/scielo.php?script=sci_abstract&pid=S2542-30882025000100099&lng=es&nrm=iso&tlng=es
- [4] T. Distefano and S. Kelly, “Are we in deep water? Water scarcity and its limits to economic growth,” *Ecological Economics*, vol. 142, pp. 130–147, Dec. 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0921800916310795>
- [5] J. Li, Y. Meng, Y. Li, Q. Cui, X. Yang, C. Tao, Z. Wang, L. Li, and W. Zhang, “Accurate water extraction using remote sensing imagery based on normalized difference water index and unsupervised deep learning,” *Journal of Hydrology*, vol. 612, p. 128202, Sep. 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0022169422007752>
- [6] Y. Wang, K. Yang, T. Jia, and Y. Luo, “Influence of natural factors and land use change on changes in the main lake area in China over the past 30 years,” *Ecological Indicators*, vol. 155, p. 111005, Nov. 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1470160X23011470>

- [7] C. Huang, Y. Chen, S. Zhang, and J. Wu, “Detecting, Extracting, and Monitoring Surface Water From Space Using Optical Sensors: A Review,” *Reviews of Geophysics*, vol. 56, no. 2, pp. 333–360, 2018, _eprint: <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2018RG000598>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2018RG000598>
- [8] “A Novel Technique for Semantic Segmentation of Hyperspectral Images Using Multi-View Features.” [Online]. Available: <https://www.mdpi.com/2076-3417/14/11/4909>
- [9] B. Farooq and A. Manocha, “Small water body extraction in remote sensing with enhanced CNN architecture,” *Applied Soft Computing*, vol. 169, p. 112544, Jan. 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1568494624013188>
- [10] “Importance of Long-Term Cycles for Predicting Water Level Dynamics in Natural Lakes.” [Online]. Available: https://www.researchgate.net/publication/271837371_Importance_of_Long-Term_Cycles_for_Predicting_Water_Level_Dynamics_in_Natural_Lakes
- [11] R. Barzegar, M. T. Aalami, and J. Adamowski, “Coupling a hybrid CNN-LSTM deep learning model with a Boundary Corrected Maximal Overlap Discrete Wavelet Transform for multiscale Lake water level forecasting,” *Journal of Hydrology*, vol. 598, p. 126196, Jul. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0022169421002432>
- [12] T. Warsi, S. Mukherjee, G. Biswas, T. Mitran, and S. S. Rizvi, “Chapter 23 - Urban water resources and its sustainable management,” in *Current Directions in Water Scarcity Research*, ser. Urban Water Crisis and Management, A. L. Srivastav, S. Madhav, A. K. Bhardwaj, and E. Valsami-Jones, Eds. Elsevier, Jan. 2022, vol. 6, pp. 489–509. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/B9780323918381000208>
- [13] S. Giri, “Water quality prospective in Twenty First Century: Status of water quality in major river basins, contemporary strategies and impediments: A review,” *Environmental Pollution*, vol. 271, p. 116332, Feb. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0269749120370214>
- [14] A. P. Smits, E. K. Hall, B. R. Deemer, F. Scordo, C. C. Barbosa, S. M. Carlson, K. Cawley, H.-P. Grossart, P. Kelly, S. Mammola, M. R. Pintar, C. J. Robbins, A. Ruhi, and M. Saccò, “Too much and not enough data: Challenges and solutions for generating

- information in freshwater research and monitoring,” *Ecosphere*, vol. 16, no. 3, p. e70205, 2025, _eprint: <https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1002/ecs2.70205>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/ecs2.70205>
- [15] “Exploratory Analysis Using Deep Learning for Water-Body Segmentation of Perus High-Mountain Remote Sensing Images.” [Online]. Available: <https://www.mdpi.com/1424-8220/24/16/5177>
- [16] J.-F. Pekel, A. Cottam, N. Gorelick, and A. S. Belward, “High-resolution mapping of global surface water and its long-term changes,” *Nature*, vol. 540, no. 7633, pp. 418–422, Dec. 2016, publisher: Nature Publishing Group. [Online]. Available: <https://www.nature.com/articles/nature20584>
- [17] “Estimating the Water Level and Bathymetry of Lake Yahuarcocha, Ecuador Using ICESat-2/ATL13 Satellite Laser Altimetry, System Dynamics Model, and Machine Learning.” [Online]. Available: https://www.researchgate.net/publication/372355755_Estimating_the_Water_Level_and_Bathymetry_of_Lake_Yahuarcocha_Ecuador_Using_ICESat-2ATL13_Satellite_Laser_Altimetry_System_Dynamics_Model_and_Machine_Learning
- [18] J. Veneros, L. García, E. Morales, V. Gómez, M. Torres, and F. López-Morales, “Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua,” *Idesia (Arica)*, vol. 38, no. 4, pp. 99–107, Dec. 2020. [Online]. Available: http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-34292020000400099&lng=en&nrm=iso&tlng=en
- [19] C. Pérez Gutiérrez and Á. L. Muñoz Nieto, *Teledetección: nociones y aplicaciones*, 3rd ed. Ávila: Carlos Pérez Gutiérrez and Ángel Luis Muñoz Nieto, 2006, oCLC: 644739471.
- [20] D. Bnduc, V. Simi, K. Cianfaglione, S. Barinova, S. Afanasyev, A. Öktener, G. McCall, S. Simi, and A. Curtean-Bnduc, “Freshwater as a Sustainable Resource and Generator of Secondary Resources in the 21st Century: Stressors, Threats, Risks, Management and Protection Strategies, and Conservation Approaches,” *International Journal of Environmental Research and Public Health*, vol. 19, 2022. [Online]. Available: <https://consensus.app/papers/freshwater-as-a-sustainable-resource-and-generator-of-mccall-afanasyev/eb010efa29fc58d4999c68fca80be271/>

- [21] T. D. Bhaga, T. Dube, and C. Shoko, "Satellite monitoring of surface water variability in the drought prone Western Cape, South Africa," *Physics and Chemistry of the Earth, Parts A/B/C*, vol. 124, p. 102914, Dec. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1474706520303600>
- [22] T. Dube, M. Shekede, and C. Massari, "Remote Sensing for Water Resources and Environmental Management," *Remote Sens.*, vol. 15, 2022. [Online]. Available: <https://consensus.app/papers/remote-sensing-for-water-resources-and-environmental-massari-shekede/bb32454ae8b05e189b4d5ae6897c8952/>
- [23] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, "Image Segmentation Using Deep Learning: A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, pp. 3523–3542, 2020. [Online]. Available: <https://consensus.app/papers/image-segmentation-using-deep-learning-a-survey-kehtarnavaz-terzopoulos/0f60709add535d9d9dc55779519e67a8/>
- [24] L. Alzubaidi, J. Zhang, A. Humaidi, A. Al-dujaili, Y. Duan, O. Al-Shamma, J. I. Santamaría, M. Fadhel, M. Al-Amidie, and L. Farhan, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, 2021. [Online]. Available: <https://consensus.app/papers/review-of-deep-learning-concepts-cnn-architectures-al-dujaili-al-shamma/f0b5c4abd13c580c9028c0c3a96884b9/>
- [25] "Image Segmentation Evaluation Metrics (IoU, Dice)." [Online]. Available: <https://apxml.com/courses/cnns-for-computer-vision/chapter-4-image-segmentation-techniques/segmentation-evaluation-metrics>
- [26] "How to Evaluate Deep Learning Models: Key Metrics Explained | DigitalOcean." [Online]. Available: <https://www.digitalocean.com/community/tutorials/deep-learning-metrics-precision-recall-accuracy>
- [27] V. Yathish, "Loss Functions and Their Use In Neural Networks," Aug. 2022. [Online]. Available: <https://towardsdatascience.com/loss-functions-and-their-use-in-neural-networks-a470e703f1e9/>
- [28] S. Hazra, K. Bora, and P. A. Singh, "Mapping World: A Comparative Analysis of Functionality and Usability between QGIS and ArcGIS," *Recent Advances in*

Computer Science and Communications, 2024. [Online]. Available: <https://consensus.app/papers/mapping-world-a-comparative-analysis-of-functionality-and-bora-singh/c83ee85705845c2492e15414c981196c/>

Anexos

Anexo A: Registro Completo de Segmentación Multitemporal

En esta sección se detalla la totalidad de las imágenes satelitales procesadas durante el periodo de estudio (2016–2025). La tabla incluye tanto las mediciones válidas utilizadas para el análisis de tendencias como aquellas que fueron excluidas del cálculo final debido a factores atmosféricos (nubosidad densa), sombras orográficas o errores de segmentación superiores al umbral de tolerancia ($\pm 0,15 \text{ km}^2$).

Tabla 0.1: Datos Históricos y Predicción de Áreas (2016–2025)

Año	Quarter	Periodo	Codificación	Nº Píxeles	Área (m ²)	Área (km ²)
2016	Q1	Ene–Mar	Q1-2016	20789	459229.01	0.45922901
2016	Q2	Abr–Jun	Q2-2016	113234	2501339.06	2.50133906
2016	Q3	Jul–Sep	Q3-2016	113418	2505403.62	2.50540362
2016	Q4	Oct–Dic	Q4-2016	105647	2333742.23	2.33374223
2017	Q1	Ene–Mar	Q1-2017	0	0	0
2017	Q2	Abr–Jun	Q2-2017	7628	168502.52	0.16850252
2017	Q3	Jul–Sep	Q3-2017	110906	2449913.54	2.44991354
2017	Q4	Oct–Dic	Q4-2017	113089	2498136.01	2.49813601
2018	Q1	Ene–Mar	Q1-2018	112806	2491884.54	2.49188454
2018	Q2	Abr–Jun	Q2-2018	70539	1558206.51	1.55820651
2018	Q3	Jul–Sep	Q3-2018	112379	2482452.11	2.48245211
2018	Q4	Oct–Dic	Q4-2018	113434	2505757.06	2.50575706
2019	Q1	Ene–Mar	Q1-2019	114285	2524555.65	2.52455565
2019	Q2	Abr–Jun	Q2-2019	111877	2471362.93	2.47136293
2019	Q3	Jul–Sep	Q3-2019	112458	2484197.22	2.48419722
2019	Q4	Oct–Dic	Q4-2019	95942	2119358.78	2.11935878
2020	Q1	Ene–Mar	Q1-2020	111600	2465244.00	2.46524400

Continúa en la siguiente página

Año	Quarter	Periodo	Codificación	Nº Píxeles	Área (m ²)	Área (km ²)
2020	Q2	Abr–Jun	Q2-2020	37278	823471.02	0.82347102
2020	Q3	Jul–Sep	Q3-2020	112815	2492083.35	2.49208335
2020	Q4	Oct–Dic	Q4-2020	110659	2444457.31	2.44445731
2021	Q1	Ene–Mar	Q1-2021	116127	2565245.43	2.56524543
2021	Q2	Abr–Jun	Q2-2021	110236	2435113.24	2.43511324
2021	Q3	Jul–Sep	Q3-2021	114106	2520601.54	2.52060154
2021	Q4	Oct–Dic	Q4-2021	21128	466717.52	0.46671752
2022	Q1	Ene–Mar	Q1-2022	112170	2477835.30	2.47783530
2022	Q2	Abr–Jun	Q2-2022	109911	2427933.99	2.42793399
2022	Q3	Jul–Sep	Q3-2022	110592	2442977.28	2.44297728
2022	Q4	Oct–Dic	Q4-2022	112170	2477835.30	2.47783530
2023	Q1	Ene–Mar	Q1-2023	112086	2475979.74	2.47597974
2023	Q2	Abr–Jun	Q2-2023	111272	2457998.48	2.45799848
2023	Q3	Jul–Sep	Q3-2023	112615	2487665.35	2.48766535
2023	Q4	Oct–Dic	Q4-2023	112819	2492171.71	2.49217171
2024	Q1	Ene–Mar	Q1-2024	115726	2556387.34	2.55638734
2024	Q2	Abr–Jun	Q2-2024	113659	2510727.31	2.51072731
2024	Q3	Jul–Sep	Q3-2024	114591	2531315.19	2.53131519
2024	Q4	Oct–Dic	Q4-2024	112254	2479690.86	2.47969086
2025	Q1	Ene–Mar	Q1-2025	112394	2482783.46	2.48278346
2025	Q2	Abr–Jun	Q2-2025	111907	2472025.63	2.47202563
2025	Q3	Jul–Sep	Q3-2025	99348	2194597.32	2.19459732
2025	Q4	Oct–Dic	Q4-2025	73652	1626972.68	1.62697268

Nota: Se procesaron un total de 40 imágenes trimestrales (2016–2025). De ellas, 16 fueron excluidas del análisis cuantitativo por no cumplir los criterios de calidad establecidos en la metodología.